

**STRUKTUR OCH AUTOMATISERING I INKÖSPROCESSEN: EN STUDIE
OM EFFEKTIV HANTERING AV DEAD & DYING-PRODUKTER**

Högskoleingenjörsutbildning i Industriell Ekonomi
Arbetsorganisation och Ledarskap

Michelle Karlsson
Elias Wilson



HÖGSKOLAN I BORÅS

Program: Industriell Ekonomi, Arbetsorganisation och ledarskap

Svensk titel: Struktur och automatisering i inköpsprocessen: En studie om effektiv hantering av dead & dying-produkter

English title: Structure and Automation in the Purchasing Process: A Study on the Effective Management of Dead & Dying Products

Utgivningsår: 2025

Författare: Michelle Karlsson och Elias Wilson

Handledare: Sara Lorén

Examinator: <skriv för- och efternamn på examinator här>

Nyckelord: AI, automatisering, inköpsprocess, d&d-produkter

FÖRORD

Som avslutande del i vår utbildning inom Industriell Ekonomi, med inriktning Arbetsorganisation och Ledarskap, på Högskolan i Borås har detta examensarbete utförts.

Vi vill rikta ett stort tack till vår samarbetspartner Rexel som vi haft kontakt med under arbetet. Mestadels kontakt med inköpsansvarig Max Jakobsson och inköpschef Terese Tyberg. Även ett stort tack till vår handledare Sara Lorén som under arbetets gång givit ett stöd och handledning. Till sist vill vi rikta våra varmaste hälsningar och tack till nära och kära som stöttat och hjälpt till under denna examensperiod.

Borås, 2025

Michelle Karlsson och Elias Wilson

AKRONYMLISTA

Som inledning till detta arbete används en akronymlista för att förklara förkortningar som förekommer i rapporten, och gör det lättare för läsaren att förstå innehållet.

Förkortning	Förklaring
AI	Artificiell Intelligens
AK1	Lagervara
AK2	Anskaffningsvara
AWR	Automatic Warehouse Replenishment
B2B	Business to business
DC	Distribution center
D&D	Dead and Dying
ERP	Enterprise Resource Planning
E3	Inköps- och lageroptimeringssystem
KPI	Key Performance Indicator
LBP	Leveransbevakningspunkt
SEG	Sortiments- och Enhetsgrupp
SCM	Supply Chain Management
SKU	Stock Keeping Unit

Sammanfattning

Denna studie har identifierat tekniska och organisatoriska förutsättningar som krävs för att effektivisera och delvis automatisera inköpsprocessen, med fokus på att minska kapitalbindning och förbättra lageromsättning. Studien har undersökt hur företag tidigt ska kunna identifiera så kallade dead & dying-produkter och därigenom fatta beslut med hjälp av datadrivet stöd. Genom en kvalitativ fallstudie hos företaget Rexel, inklusive intervjuer och dokumentanalys, kartlades nuvarande inköpsrutiner och utmaningar.

Resultatet visar att strukturerade arbetssätt såsom artikelklassificering, säsongsplanering och avvikelserapportering är centrala för att skapa proaktiv styrning. I kombination med teknisk infrastruktur, som systemintegration, tillgång till historisk data och beslutsstödsverktyg, skapar det förutsättningar hos företag till en med datadriven automatiserad inköpsprocess. I samband med detta har också olika AI-verktyg undersökts och analyserat hur dessa skulle kunna tillämpas så artiklar inte riskerar att hamna i dead & dying. Studien påpekar att störst potential uppstår när organisatoriska rutiner och tekniska verktyg samverkar, samtidigt som det lämnar utrymme till vidare utveckling kring automatisering och ingångar till AI-verktyg.

Abstract

This study has identified the technical and organizational prerequisites required to streamline and partially automate the purchasing process, with a focus on reducing capital tied up in inventory and improving inventory turnover. The study explores how companies can identify dead & dying products at an early stage and make decisions supported by data-driven insights. Through a qualitative case study conducted at the company Rexel, including interviews and document analysis, current purchasing routines and challenges were mapped.

The results show that structured approaches such as article classification, seasonal planning, and deviation reporting are central to enabling proactive purchasing control. When combined with technical infrastructure such as system integration, access to historical data, and decision support tools, these measures provide the foundation for a more data driven and automated purchasing process. In parallel, various AI tools were examined and analyzed in terms of how they could be applied to prevent articles from developing into dead & dying products. The study concludes that the greatest potential arises when organizational routines and technical tools interact, while also highlighting opportunities for further development in automation and AI implementation.

Innehållsförteckning

1. INLEDNING	1
1.1 Bakgrund.....	1
1.2 Problemformulering.....	1
1.3 Syfte och frågeställning	2
1.4 Avgränsningar.....	2
2. TEORI	3
2.1 Inköpsprocessens grunder	3
2.2 Problematik kring <i>dead & dying-produkter</i>	4
2.3 Proaktiv analys: från reaktion till prediktion.....	4
2.3.1 Prediktiva metoder för att förebygga <i>dead & dying</i> -artiklar.....	4
2.3.2 Proaktiv och prediktiv analys som stöd för lageroptimering.....	5
2.3.3 Hur fungerar en ABC-analys	6
2.4 ERP-system och integrerade plattformar: datadrivna beslutsstöd och analysmetoder.....	7
2.5 AI och proaktivanalys	8
2.5.1 EasyStock.....	9
2.5.2 NetStock.....	10
2.5.3 Slimstock.....	11
2.5.4 ToolsGroup	11
2.6 Riskhantering i inköpsprocessen	12
3. METOD	13
3.1 Forskningsdesign.....	13
3.2 Datainsamling	13
3.2.1 Intervjuer.....	13
3.2.2 Dokumentanalys	14
3.3 Dataanalys.....	15
3.4 Etiska överväganden och dataskydd.....	16
3.5 Metodkritik och begränsningar	16
4. RESULTAT	18
4.1 Presentation av empiriskt sammanhang.....	18
4.2 Presentation av data	21

4.2.1	Leverantörsdata kopplad till d&d-artiklar.....	21
4.3	Fallbeskrivningar av identifierade risartiklar	24
4.3.1	Fall A1: Snabbt sjunkande efterfrågan.....	24
4.3.2	Fall A2: Felaktig prognos och lång ledtid.....	25
4.3.3	Fall A3: Ny produkt med låg etablering.....	26
4.4	Bearbetning av data	27
4.4.1	Strukturerad artikelhantering som grund för effektiv lagerstyrning.....	27
4.4.2	Exempel på ABC- och avvikelseanalys	28
4.4.3	Från insikt till åtgärd: hur kan AI stötta proaktiv lagerhantering	29
4.5	Sammanfattning av resultat.....	29
4.5.1	Med AI som hjälp	30
4.5.2	Guide till proaktivt arbete	30
5.	ANALYS	32
5.1	Analysering av resultat: utveckling av olika problem	32
5.1.1	Reaktiv inköpsprocess och manuell arbetsbelastning	32
5.1.2	Brist på proaktiv analys och prediktiva prognosverktyg	33
5.1.3	Integration mellan system	34
5.2	Implementering av AI.....	34
5.3	Svar på forskningsfrågorna	35
6.	DISKUSSION	37
6.1	Diskussion av lösningars potential i relation till studiens resultat och teori	37
6.2	Slutsats i ljuset av resultat och teori	38
6.3	Praktiska implikationer och problemformuleringens utveckling	38
6.4	Framtida forskning	39

REFERENSLISTA

BILAGOR

Figur 1: Likheter och skillnader mellan green, sustainable and circular procurment (Rejeb & Appolloni 2022)	3
Figur 2: Dataanalysens struktur.....	16
Figur 3: Rexels inköpsprocess (Intervju 2025-02-21).....	18
Figur 4: Årscykel av inköpsprocess (Intervju 2025-02-21)	19
Figur 5: A1 med snabbt sjunkande efterfrågan (Intervju 2025-05-11)	25
Figur 6: A2 snabbt sjunkande efterfrågan (Intervju 2025-05-11)	26
Figur 7: A3 dålig försäljning av ny produkt (Intervju 2025-05-11).....	27
Tabell 1: Egenskaper hos produkter enligt ABC-klassificering (Ravinder & Misra 2014).....	6
Tabell 2: Sammanfattning av målgrupp, för- och nackdelar.....	9
Tabell 3: Sammanfattning av insamlad data från Rexel Sverig AB.....	14
Tabell 4: Sammanfattning av dokumentanalys	14

Tabell 5: Processens manuella och automatiserade delar (Rexel 2025 a,b,c,d).....	20
Tabell 6: D&D-produkter och artiklar i överlager (utdrag från bilaga 1)	21
Tabell 7: Leverantörer med hög andel d&d-produkter (utdrag från bilaga 2)	22
Tabell 8: Exempel på artiklar med låg försäljning och lång ledtid (utdrag från bilaga 3)	22
Tabell 9: Artiklar med låg msättning och högt lagervärde (utdrag från bilaga 4)	23
Tabell 10: Sammanställning av identifierade problem och förebyggande åtgärder.....	24
Tabell 11: ABC-klassificerade artiklar från Rexels ERP-system (utdrag från bilaga 5)	28

1. INLEDNING

Denna rapport innehåller en grundlig analys av en inköpsprocess, där lagerhantering, inköpsstrategi och kapitalomsättning inkluderas för att sedan förbättra och effektivisera processen. Detta arbete fokuserar på att automatisera avvikelshantering, införa proaktiva analyser, förbättra inköpsstrategier och införa artificiell intelligens (AI)-baserade verktyg. Rapportens syfte är att kunna användas av företag och organisationer för att förenkla valet av vilken typ av automatisering och tillämpning av AI som ska göras.

1.1 Bakgrund

En välfungerande inköpsprocess är avgörande för att säkerställa ett effektivt flöde i hela försörjningskedjan, lönsamt arbete och maximal kundnöjdhet (Harrison, Skipworth, van Hoek & Aitken 2019, s.381-382). Dagens samhälle utvecklas i snabb takt till automatisering och AI mognad, därför blir det allt viktigare för företag att hänga med. Enligt Steiner (2015, s. 25–28) är det nödvändigt att utveckla strategier som är anpassade efter organisationens behov för att kunna uppnå det. Ett sådant strategiskt arbete kräver god kunskap om organisationens delar, samt tillgång till rätt information. Enligt Harrison et al. (2019, s. 381–382) bör ett särskilt fokus läggas på strategisk sourcing och på att bygga starka leverantörsrelationer, eftersom detta bidrar till ett förbättrat kundvärde och ett mer effektivt materialflöde. För att kunna välja en lämplig inköpsstrategi krävs en djup förståelse i organisationens produkter, processer, kapital och resurser. Det är även av stor vikt att känna till både efterfrågemarknaden och leverantörskedjan för att fatta välgrundade beslut. Steiner (2015, s. 25–28) betonar att en noggrann intern och extern analys är nödvändig för att kunna förbättra inköpsprocessen och säkerställa att den valda strategin är rätt för organisationen.

Produkter i slutet av sin livscykel, så kallade dead & dying-produkter (d&d-produkter), utgör ofta en utmaning för företag, eftersom de finner produkterna svårhanterade (Wilson & Goffnet 2022). Trots att det finns teoretiska lösningar kämpar många organisationer med att minska kapitalbindningen i dessa produkter, vilket kan leda till betydande ekonomiska förluster. Produkterna blir svåra att sälja och riskerar att ligga kvar i lagret utan att generera intäkter. Enligt Bajegani och Gholamian (2022) är teknisk utveckling och nya innovationer en vanlig orsak till att produkter snabbt föråldras och omvandlas till riskartiklar. Detta kan leda till minskad försäljning och överskott i lager. Ett tydligt exempel är ett internationella handelsföretag (IBM-corporate) som 1998 förlorade en miljard dollar på grund av en föråldrad produkt som inte längre gick att sälja (Bajegani & Gholamian 2022).

Enligt Cohen (2023) har AI potential att förbättra både produktivitet och kundrelationer inom distribution genom djupinlärning, men även fungera som stöd till business to business (B2B) verksamheter. Med tillgång till kunddata kan AI ge företagen värdefulla insikter om produkt efterfrågan och köpmönster. Ju mer data AI har, desto mer lär den sig och ger nyanserade förslag till företaget (Cohen 2023). Att implementera denna typ av teknologi kräver mer än bara tekniska lösningar, det kräver även organisatoriska faktorer som datakvalitet, men också vetskap och konkretisering kring vad som kan tillämpas i inköpsprocessen. Med fokus på d&d-produkter med tekniska och organisatoriska förutsättningar i beaktning kan en framgångsrik implementering genomföras.

1.2 Problemformulering

I takt med antalet produkter och mängden data som ökar blir det svårare för företag att hantera dead & dying (d&d)-produkter. Inom ramen av befintliga inköpssystem och organisatoriska

strukturer behöver företagen jobba med proaktivt. Detta för att snabbare identifiera och hantera artiklar som hamnar i risk för att bli d&d-produkter, samt minska kapitalbindning och effektivisera inköpsprocessen. Genom att identifiera olika verktyg och metoder, även ingångar för hur AI skulle kunna implementeras, ska det hjälper till att förhindra d&d-produkter. Studien kommer också behandla vilka tekniska och organisatoriska förutsättningar som krävs för en framgångsrik tillämpning i praktiken.

1.3 Syfte och frågeställning

Syftet med denna studie är att identifiera tekniska och organisatoriska förutsättningar för att effektivisera och delvis automatisera inköpsprocessen, med målet att minska kapitalbindning och förbättra lageromsättning. Studien undersöker även hur AI och automatisering kan tillämpas för att tidigare identifiera d&d-produkter samt stödja datadrivet beslutsfattande.

- Vilka tekniska och organisatoriska förutsättningar krävs för att förbättra och eventuellt automatisera en inköpsprocess, med mål att minska kapitalbindning och förbättra lageromsättning.
- Hur kan AI och automatisering integreras i inköpsprocessen för att uppmärksamma d&d-produkter snabbare, samt förbättra beslutsfattandet genom analys av produktartiklar som riskerar att utvecklas till d&d?

1.4 Avgränsningar

Rapporten fokuserar på att analysera och föreslå förbättringar inom inköpsprocessen med hjälp av AI och automatisering för att minska förekomsten av d&d-produkter. För att kunna göra en möjlig analys på en genomförbar nivå av förbättringsarbete har arbetet begränsats inom följande områden. Omfattningen av inköpsprocessens analys har begränsats till de steg inom processen som direkt påverkar lagerhanteringen, prognosarbete och avvikelsehantering. Områden som logistik, leverantörers interna påverkan och annan specifik prissättning inkluderas endast vid direkt koppling till syftet.

Rapporten utvärderar och föreslår även en mer form av tillämpning av befintlig AI-baserade verktyg och automatiseringslösningar. Därför kommer även analysen utgå från befintliga dataflöden och rapporter som används i organisationen. Implementering av nya datainsamlingsmetoder eller större förändring kommer inte beaktas i denna studie. Dessutom ligger större delen av fokuset på långsiktig strategisk påverkan, men en mer detaljerad plan ligger utanför rapportens omfattning. Rapporten är även avgränsad till de marknader och lager som organisationen hanterar, eventuella skillnader inom regionala leverantörskedjor eller specifika lokala krav nämns bara vid relevans för inköpsprocessen som helhet.

Slutligen behandlas inte interaktionen med leverantörer och annan extern analys, utan fokuserar mer på inköpsprocessen internt. Det innebär även att utvärdering och analys av leverantörernas prestation eller externa struktur inte ligger innanför rapportens område.

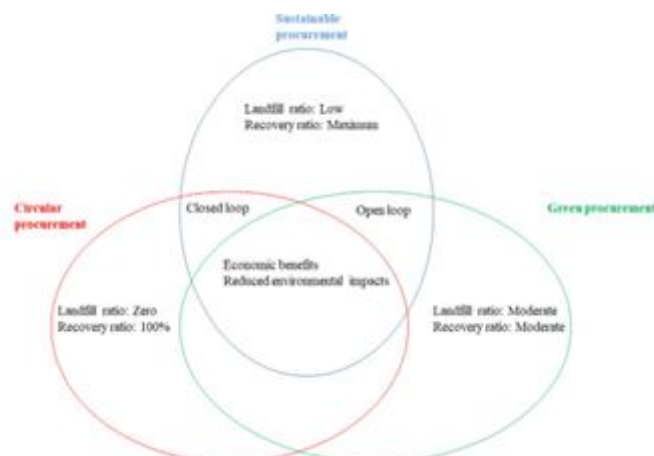
2. TEORI

För att förstå utmaningar med d&d-produkter krävs en djupare insikt i inköpsprocessens struktur och dess roll inom organisationen. Inköp är en nyckelkomponent av ett företag och påverkar allt mellan lönsamhet och resursanvändning. Användning av olika typer av modeller, strategier och metoder kan generera ett framgångsrikt tillvägagångssätt och en mer gynnsam process inom företaget. Hantering av d&d-produkter är en viktig aspekt att ha i beaktning för att minska kapitalbindning och effektivisering av lagerhantering. Med hjälp av prognosmodeller och efterfrågeanalyser kan riskerna för dessa produkter minska och bidra till en mer hållbar och flexibel inköpsstrategi. Moderna verktyg och teknologier kan också ha en avgörande roll i optimering av inköpsprocessen och riskhantering. Syftet med detta teoriavsnitt är att belysa dessa områden och ge en grundläggande kunskap för att identifiera och förstå förbättringsmöjligheter i inköpsprocessen.

2.1 Inköpsprocessens grunder

Rejeb & Appolloni (2022) skriver att på de senaste årtionden har begreppet cirkulär ekonomi tagits upp. Cirkulär ekonomi går ut på att försöka hitta en stängd iteration för att utveckla både lönsamheten och hållbarheten inom organisationer. Med utvecklingen av cirkulär ekonomi myntades begreppet cirkulär upphandling, och är den strategi som organisationer använder sig av för att skapa en cirkularitet i deras inköp. Det används för att utveckla cirkulär ekonomi och med hjälp av cirkulär upphandling kan organisationer både skapa nya och återvinna material. Cirkulär upphandling bidrar till att organisationer blir mer hållbara (Rejeb & Appolloni 2022).

Inom den offentliga sektorn används cirkulär upphandling för att minska påverkan på klimatet. Cirkulär upphandling kan utvecklas genom olika strategier för inköp, men huvudsakligen för grönt och hållbart inköp. De här typerna av inköp predikterar att inköpet ska fokusera på hållbarheten för klimatet när inköpen sker. I figur 1 illustreras likheter och skillnader mellan de här tre olika strategierna för inköp.



Figur 1: Likheter och skillnader mellan green, sustainable and circular procurement (Rejeb & Appolloni 2022)

I figur 1 illustreras grönt inköp där organisationer fokuserar på klimatet istället för andra aspekter. Cirkulär upphandling fokuserar främst på att implementera grönt tänkande i organisationers inköspolicyer och aktiviteter, medan hållbart inköp även inkluderar sociala aspekter och samhällsfrågor i beaktandet av den cirkulära ekonomin (Rejeb & Appolloni 2022).

2.2 Problematik kring *dead & dying-produkter*

Inköpsprocesser har en djup betydelse för organisationer (Steiner 2015, s.92-93). Vissa organisationer påverkas av den ökade globaliseringen inom inköp, vilket har lett till att fokuset kan ligga på effektiviteten och kostnaden av produkterna. Annat som organisationer blir påverkade av är utbud och efterfrågan. ”Även i det mest avreglerande samhällen finns det produkter som är monopoliserade” skriver Steiner (2015), det menas att det inte alltid kommer vara enkelt för en organisation att få tag på produkter. På grund av bristande tillgång kan det i sin tur leda till stora problem hos underleverantörer. Överflöd av produkter med låg efterfrågan kallas för döende, “dying”, produkter (Steiner 2015, s.92-93). Produkter som ligger i lager och inte sålts på över ett år kallas för döda, “dead”, artiklar (Steiner 2015, s.92-93). Artiklar med minskad efterfrågan eller helt och hållet utan, kallas för riskartiklar, är viktig vid lagerhantering. Inom området teknik är många artiklar där svåra att hantera, då det ständigt introduceras nyare tekniker (Bajegani och Gholamian 2022). Det brukar ske genom att efterfrågan på dessa produkter börja sjunka relativt snabbt och andra gånger långsamt. Vilket gör att produkten förvinner helt ur kundens spektrum. Att inte använda sig av rätt lagerhantering när det gäller dessa produkter kan leda till en stor ekonomisk förlust för organisationer. Däremot om organisationen hanterar riskartiklarna rätt, jobbar proaktivt med efterfrågeanalyser och använder sig av rätt resurser kan det i stället öka lönsamheten. Bajegani och Gholamian (2022) visar att om man tar hänsyn till aspekter såsom beställningsmängden, prissättningen och variation kan företag hantera föråldrade produkter mer effektivt.

Prognoser är en viktig del av inköpsprocesser, vid manuell hantering och beräkning baserad på historisk data finns en ökad risk för fel. Dessa så kallade prognosfel kan leda till över- eller underlager (Kerkkänen, Korpela & Huiskonen 2009). En studie på ett stort internationellt processföretag visade att 20 % av produkterna, som står för 86 % av försäljningen, har betydligt lägre prognosfel jämfört med de resterande 80 % av produkterna som endast står för 14 % av försäljningen. Detta tyder på att det är särskilt viktigt att fokusera prognosarbetet på högvolymprodukter (Kerkkänen, Korpela & Huiskonen 2009).

Zhou, Shen och Yu (2023) menar att en organisations lönsamhet och lagerhållning påverkas av prognosfel i hög grad. I artikeln identifieras olika typer av prognosfel såsom systematiska, slumpmässiga, absoluta och kvadratiska fel. Det betonar vikten av att förstå deras fördelning och konsekvenser vid lagerstyrning. Bland dessa har medelfel störst påverkan på både lönsamheten och lagerhållningen. Zhou, Shen och Yu (2023) visar att om organisationer implementerar modeller för att minska sina prognosfel kan lönsamheten öka med upp till 7 % jämfört med nuläget.

2.3 Proaktiv analys: från reaktion till prediktion

Inköpsoptimering är ett relativt nytt fenomen inom Supply Chain Management (SCM) och används för att minska kostnader, förbättra processer och öka lageromsättningen (Jonsson 2021). Med rätt verktyg kan en anpassad affärssystemlösning vara till stor nytta för företag. Teknologiska verktyg spelar även en viktig roll vid hantering av komplexa produktkategorier såsom d&d-produkter. I detta avsnitt presenteras olika metoder och verktyg tillsammans med en grundläggande förklaring av hur de kan tillämpas.

2.3.1 Prediktiva metoder för att förebygga *dead & dying-artiklar*

Enligt Baierle, Haupt, Furtado, Pinheiro och Sellitto (2024) innebär proaktiv analys att till exempel företag använder sig av historiska data för att kunna förutspå framtida händelser.

Proaktiv analys är en bra metod att använda vid hantering av d&d-produkter innan de utgör problem i lagerhållningen (Baierle et al. 2024). Till skillnad från reaktivt beslutsfattande, möjliggör det att arbeta förutseende och agera innan negativa konsekvenser uppstår (Vlahakis, Kopanaki & Apostolou 2020). Det ger organisationer möjlighet att agera innan problematik uppstår. För att kunna implementera det här i ett företag krävs det insamling av historiska data och rätt form av maskininlärningsmodeller. Genom att använda historisk data kan denna metod användas för att minska risken för överlager, kapitalbindning och inkurans, samt för att förbättra planeringen i inköpsprocessen.

För att ett prediktivt arbetssätt ska bli effektivt krävs organisatoriska förutsättningar. Det är också viktigt att organisationer testar och utvärderar olika typer av analysmodeller för att identifiera den som är bäst anpassad till deras specifika behov och struktur. Företag bör därför fundera på att införa artikelklassificering för att prioritera vilka produkter som kräver särskild styrning, utveckla rutiner för livscykelhantering och skapa fasta kontrollpunkter för kampanjer och säsongsvariationer (Baierle et al. 2024). Att kontinuerligt följa upp resultat och justera strategier när tidiga indikatorer visar att målen inte kommer att uppnås kan organisationen agera proaktivt snarare än reaktivt (Vlahakis, Kopanaki & Apostolou 2020). Ett proaktivt arbetssätt bidrar till att minska slöseri, sänka kostnader och öka resurseffektiviteten inom inköps- och lagerprocesserna. Prediktiva modeller fungerar inte som ersättare för mänskligt beslutsfattande utan är ett beslutsstöd som ger organisationen bättre underlag att fatta datadrivna beslut. Genom att förutse efterfrågeförändringar, identifiera riskartiklar i tid och optimera lagerstrukturen blir det möjligt att anpassa verksamheten dynamiskt. Det i sin tur stärker motståndskraften i försörjningskedjan och förbättrar långsiktig effektivitet (Baierle et al. 2024).

2.3.2 Proaktiv och prediktiv analys som stöd för lageroptimering

Systemintegration mellan ERP-system, inköpsprocesser, lager och försäljningssystem möjliggör realtidsbaserad beslutsfattning, vilket förbättrar intern synkronisering (Baierle et al. 2024). Tillsammans med det spelar beslutsstödsystem och visualiseringsverktyg en stor roll genom att erbjuda inköpare översikt över nyckeltal och avvikelser. Det i sin tur kan stärka beslutsfattandet (Baierle et al. 2024). Scenarioplanering och simuleringsmodeller i beaktning är centrala aspekter för att testa effekter av förändrade antaganden och skapa förberedelse för osäkerhet. Effektiv implementering med tydliga roller, samverkan mellan system och tolkning av data kan möjliggöra lyckade justeringar vid efterfrågeförändringar.

För att effektivt hantera lager och undvika kapitalbindning i svårsålda produkter krävs ett proaktivt arbetssätt. Artikelförvaltning genom klassificering som exempelvis försäljningsvolym, frekvens och variabilitet möjliggör prioritering av åtgärder där de gör mest nytta (Silva et al. 2023). Artiklar med osäkerhet eller låg efterfrågan kan identifieras i ett tidigare stadium, för att kunna fånga upp och åtgärda i form av kampanj eller avveckling. En viktig metod är att strukturera detta arbete med hjälp av livscykelrutiner. Dessa rutiner hjälper till att definiera tydliga steg för när, hur och vart en artikel bör introduceras, följas upp och slutligen avvecklas. Så kallade kontrollpunkter. Genom att ha tydliga kontrollpunkter och framförhålla effektiva livscykelrutiner behövs även processer för avvikelshantering, efterfrågemönster och ökade returer eller stillastående lager inkluderas och analyseras (Simões et al. 2020). Det stärker den systematiska kopplingen mellan marknadsinformation och operativa lagerbeslut.

Proaktiv lageranalys kompletteras ofta med prediktiva modeller. Det innebär att historisk data används och analyseras för att förutspå framtida efterfrågemönster på marknaden. Med tillämpning av statistiska metoder eller maskininläring kan företag identifiera mönster som

inte är synliga i traditionella rapporter. Verktyg som använd rätt kan hjälpa till att förbättra precisionen i prognoser, stödja beslut om avveckling i tid och reducera risken för överlager och d&d (Vlahakis, Kopanaki och Apostolou 2020). Tillsammans ger verktygen och metoderna ett kraftfullt stöd till att optimera lagerstrukturen och minska kapitalbindning i lågomsatta artiklar.

Organisationer behöver vara villiga till att förändras och skapa rätt förutsättningar för att möjliggöra proaktiv analys i inköpsprocessen. Det innebär att beslut grundas i analys snarare än bara erfarenhet och att det finns en kultur där datadrivna insikter värderas högt (Baierle et al. 2024). Företagen behöver ge verktygen tillförlitlig data, men också skapa en kultur där beslut fattas baserat på analys och erfarenhet. Dessutom är det avgörande att medarbetare har kompetens att tolka och agera på insikter som genereras med hjälp av den proaktiva analysen. Det är även viktigt att medarbetare på företaget är rätt utbildade till att tolka och agera på de insikter som ges av använda modeller. Om kompetens inte finns är det viktigt att lägga resurser på att göra det. Vilket i sin tur understryker behovet av kontinuerlig utbildning och kompetensutveckling (Vlahakis, Kopanaki & Apostolou 2020).

2.3.3 Hur fungerar en ABC-analys

I en ABC-analys kategoriseras artiklar efter deras betydelse för att möjliggöra prioriterad styrning av produkter med hög risk, låg omsättning eller stort kapitalvärde (Ravinder & Misra 2014). De artiklar som omsätter mest och har högst efterfrågan klassificeras som A-artiklar. Artiklar med lägst omsättning och lägst efterfrågan klassificeras som C-artiklar medan B-artiklarna är en nivå mellan A- och C-artiklar. Verksamhetens fokus bör ligga A-artiklar, eftersom de genererar störst lönsamhet men också är svårast att ersätta, vilket illustreras i tabell 1.

Tabell 1: Egenskaper hos produkter enligt ABC-klassificering (Ravinder & Misra 2014)

Klassificering	Hög nivå	Måttlig nivå	Låg nivå
A	Efterfrågan, pris, inurans-risk, föråldring, svinn, på fyllnings-kostnad, ledtid och validitet (i efterfrågan, pris och ledtid)		Användbarhet, antal leverantörer och ersättbarhet
B		Efterfrågan, pris, inkurans-risk, föråldring, svinn, på-fyllningskostnad, ledtid, variabilitet (i efterfrågan, pris och ledtid), användbarhet, antal leverantörer och ersättbarhet	

C

Användbarhet, antal leverantörer och ersättbarhet

Efterfrågan, pris, inkurans-risk, föråldring, svinn, påfyllningskostnad, ledtid och variabilitet (i efterfrågan, pris och ledtid)

Tabell 1 sammanfattar de viktigaste egenskaperna hos artiklar som är indelade i klasserna A, B och C. Tabellen visar hur viktigt det är att bevaka A-artiklar eftersom de är kritiska för verksamheten. C-artiklar är dock mindre lönsamma och behöver därför inte övervakas lika mycket som A-artiklar. Ravinder och Misra (2014) påpekar att sorteringen bara är värdefull om man därefter styr hur mycket och när man beställer artiklar i respektive klass.

Att utföra en ABC-analys kräver en trestegsprocess enligt Ravinder och Misra (2014). Först väljs de kriterier som ska gälla för artiklarna. Kriterierna väljs av analytikern och fler kriterier ökar tillförlitligheten. Därefter fastställer analytikern hur stor vikt varje kriterium ska tilldelas. Kriterierna är flexibla och bör omprövas regelbundet för att analysen ska bibehålla sin relevans. Varje artikel tilldelas därefter ett värde för varje kriterium, Ravinder och Misra (2014) skriver att resultaten kan omvandlas till en 0–100-skala. Därefter rangordnas artiklarna i en fallande lista, högpoängsartiklarna blir A-artiklar, sedan blir de måttliga artiklarna B-artiklar och resten blir C-artiklar. Andelen artiklar i varje klass bestäms av analytikern. Hela processen kan genomföras i ett kalkylblad (Ravinder & Misra 2014).

2.4 ERP-system och integrerade plattformar: datadrivna beslutsstöd och analysmetoder

Enterprise Resource Planning (ERP)-system är en effektiv lösning för företag som strävar efter att uppnå sina verksamhetsmål (Microsoft u.å.b). Dessa system möjliggör kommunikation mellan olika affärssystem och avdelningar inom organisationen. Inom SCM bidrar ERP-system till ökad transparens samtidigt som de möjliggör realtidsspårning av lagernivåer, lagerstatus och leveransinformation. ERP-system används även för prognostisering och efterfrågeplanering där historisk data analyseras för att förutse framtida behov (Munyua 2023). “ERP-system är grunden för den moderna driften av datadrivet beslut” (Krishna & Sharma 2025), citatet speglar hur ERP-system förbättrar precisionen och proaktiviteten i inköpsbeslut. För att ytterligare utveckla och förbättra dessa aspekter kan mer avancerade plattformar som AI-verktyg användas vid intresse. Genom att integrera detta på ERP-system kan det bistå att hantera stora datamängder av historiska data och identifiera trender, avvikelser och säsongsmönster i kundefterfråga (Graham & Jordan 2025). Med denna typ av integration kan företag enklare hantera större datamängder, förbättra realdata och reagera snabbare på riskartiklar, vilket i sin tur leder till minskad kapitalbindning och förhindrar inkurans. För att AI-verktygen ska kunna fungera optimalt behöver det vara kompatibelt med företagets aktuella tillstånd, tekniskt och organisatoriskt. Det kräver också att arbetsprocesser anpassas och medarbetare också har rätt kompetens för att hantera systemen (Graham & Jordan 2025).

Datadrivna beslutsstöd är bra att använda i företag för att kunna stödja de beslut som tas. Datadrivna stöd och analys förhindrar inkurans och felberäkningar, ökar tillförlitligheten och

gör att analyser kan hantera större datamängder. Verktyg som Power-BI används för att analysera prognosavvikelser genom att identifiera produkters fallande efterfrågan och vidta åtgärder därefter (Microsoft u.å.a). Det används också till att analysera stora datamängder och snabbt identifiera olika åtgärder som behöver göras. Genom att förstå och räkna ut trender och prognosavvikelser kan det hjälpa företag att visualisera skillnader mellan faktiska och förväntade värden (Microsoft n.d.a).

2.5 AI och proaktivanalys

Enligt Liu och Vakharia (2024) kan efterfrågebaserade prognoser förbättra organisationers lagerhållning avsevärt. Traditionella prognosmetoder är användbara men har sina begränsningar. Genom att använda maskininlärning (machine learning) kan dessa begränsningar övervinnas, vilket möjliggör en mer djupgående och nyanserade prognos av efterfrågan. AI spelar en avgörande roll i arbetet med att utveckla hållbara försörjningskedjor eftersom den kan förbättra både beslutsfattande och operationell effektivitet. Möjligheten att förutse efterfrågemönster innebär inte bara förbättrad lageroptimering och planering, utan också minskad miljöpåverkan genom minimerat svinn och effektivare resursutnyttjande. Rao, Nilakantan, Iyengar och Lee (2018) framhåller att digitaliseringens roll i omställningen från traditionella till mer datadrivna försörjningskedjor är central.

Som tidigare nämnts är AI och automatisering också verktyg som kan användas för att hantera utmaningar som uppstår i inköpsprocesser (Graham & Jordan 2025). Vid hantering av d&dprodukter är maskininlärning och dataanalys från AI-baserade verktyg särskilt värdefulla, dessa illustreras i tabell 2. AI-system kan utföra samma funktioner som traditionella inköpssystem, men med avsevärt högre kapacitet att bearbeta och analysera stora datamängder. Denna typ av automatisering bidrar till att förenkla inköpshanteringen, minska det manuella arbetet och möjliggöra snabbare samt mer träffsäkra beslut. Detta leder i sin tur till minskad inkurans och bättre resursanvändning (Spreitzenbarth, Bode & Stuckenschmidt 2024). EasyStock, Slim4, Toolsgroup och NetStock är fyra exempel av AI-verktyg som har blivit vanliga inom B2B-sektorn, och presenteras i tabell 2 nedan. Informationen i tabell 2 baseras på litteraturgenomgången i kapitel 2.5. Där funktionalitet, målgrupp och implementeringskrav för systemen analyserats utifrån Mouritzis et al. (2017), SlimStock (u.å.), Samuels (2025) och Xia et al. (2012). Dessa lösningar är i huvudsak molnbaserade och utformade för att integreras med befintliga ERP-system. Genom sådan integration kan det stärka redan existerande automatiserade lösningar och ge ett mer proaktivt stöd i inköpsprocessen.

Tabell 2: Sammanfattning av målgrupp, för- och nackdelar

AI-verktyg	Målgrupp	Kostnad (per månad i kr)	Fördelar	Nackdelar
EasyStock	Små till medelstora företag	ca. 6 700 – 20 800kr	Lätt att integrera med befintliga ERP-system	Kräver god datakvalitet och struktur i ERP-system
			Automatiserar efterfrågeanalys och skapar konkreta inköpsförslag	Bygger på att organisationen är redo att arbeta mer datadrivet
NetStock	Små till medelstora företag	Från ca. 4 200kr	Passar bra för B2B-företag med grossistverksamhet och e-handel	Begränsat anpassningsbar för komplexa sortiment med speciella krav.
			Fokuserar på kapitalbindning, servicegrad och riskminimering. Integreras med ERP och ger tydliga prioriteringsförslag.	Inte lika avancerad som ex, Slim4 för simulering och långsiktig planering. Kräver manuell tolkning av vissa analyser.
Slim4 (SlimStock)	Medelstora företag till stora företag	Offertbaserat ofta >20 000kr	Avancerad analyskapacitet, särskilt för stora sortiment.	Viss risk att användare förlitar sig för mycket på automatiska rekommendationer. Kräver mer implementationstid och teknisk anpassning.
			Simulerar scenarier och visualiserar beslutseffekter.	Passar främst större organisationer med hög datamognad.
Toolsgroup (SO99+)	Större företag	Från ca. 52 500kr	Ger operativa och strategiska beslutsunderlag. Specialiserad på hantering av långsamt rörliga produkter.	Högre kostnadsnivå och större förändringsbehov internt. Stark på hantering av oregelbunden efterfrågan.
			Använder självanpassade AI-algoritmer för prognoser och riskanalys. Tar hänsyn till osäkerhet och livscykkelkostnader.	Förbättrar servicenivå utan att öka överlager. Självlärande system som anpassas över tid.

2.5.1 EasyStock

För att AI och automatisering ska kunna integreras i inköpsprocesser krävs en teknisk infrastruktur där lösningen kan kopplas till företagets affärssystem (ERP). EasyStock är en app som kan integreras och är baserad på molnbaserad lageroptimering (Mourtzis, Doukas & Vandera 2017). Appen går ut på att optimera lagerhanteringen på en organisationsskala för distributionen, den hjälper också att minska lagerkostnaderna, samt öka servicenivåerna (Mourtzis, Doukas & Vandera 2017). Med EasyStock kan det tillsammans med befintligt ERP-system analysera inköpsdata, lagernivå och försäljningsdata i realtid. Automatiserad efterfrågeanalys, som identifierar artiklar med avvikande försäljningsmönster, tillsammans med proaktiv flaggning av produkter med sjunkande efterfrågan eller överlager, utgör centrala funktioner i AI-baserade lageroptimeringsverktyg. Dessa funktioner kompletteras av beslutsstöd, där systemet genererar rekommendationer om vilka artiklar som bör beställas, justeras i kvantitet eller avvecklas. Tillsammans möjliggör dessa verktyg en datadriven och förebyggande hantering av sortimentet, där artiklar som riskerar att bli d&d-produkter identifieras i ett tidigt skede, innan de hinner binda upp onödigt kapital i lagret. Det skapar förutsättningar för effektivare inköpsbeslut, förbättrad lageromsättning och ökad lönsamhet (Mourtzis, Doukas & Vandera 2017).

Som tidigare nämnt kräver implementationen både tekniska och organisatoriska förändringar. I den tekniska aspekten är det viktigt att företagets ERP-system är kompatibelt med externa AI-lösningar, samt tillförlitlig och innehåller strukturerade data över en längre tid. Ur den organisatoriska planet kräver det istället att inköpskulturen är villig till att förändras och ändra beslutsfattning till mer databaserad, än baserad på erfarenhet (Mourtzis, Doukas & Vandera 2017). Det krävs också viss intern utbildning för att kunna tolka och agera på AI genererade insikter, även tydliga processer hur flaggade riskartiklar hanteras. Resultatet av en genomförd implementering blir då minskad kapitalbindning, förbättrad lageromsättning och ökad servicegrad (EasyStock u.å.). Det här innebär att riskartiklar avvecklas eller minimeras i god tid, inköp styrs av efterfrågeprognoser snarare än historiska mönster och automatiseringen säkerställer att artiklar som kommer efterfrågas är tillgängliga utan överlager. Denna typ av automatisering passar bra till B2B-företag som är grossister och har e-handel (EasyStock u.å.). EasyStock hjälper företagen att automatiskt beräkna säkerhetslager och beställningspunkter. Även att optimera beställningskvantiteter utifrån parametrar som leveranstid, efterfrågevariation och säsongsvariation, och till sist identifiera produkter som binder oproportionerligt mycket kapital. Alltså skapar systemet ett beslutsstöd som förbättrar styrningen av inköp och lager till en mer proaktiv och datadriven verksamhet.

2.5.2 NetStock

Som EasyStock är denna typ av automatisering en molnbaserad AI som behöver leva i symbios med ERP-system, målet med denna AI är också att stödja lageroptimering och automatisera inköpsprocesser. Tillskillnad från EasyStock är NetStock anpassat till små och medelstora företag inom distribution, grossistverksamheter och tillverkning (Netstock u.å.). Med hjälp av prognoser och analyser kan den automatisera inköp, identifiera överskottslager och flagga framtida risker. Detta gör den särskilt relevant för B2B-aktörer med komplexa, men resurs begränsade lagerstrukturer (Netstock u.å.). NetStock fungerar som ett proaktivt beslutsstöd i där användaren får rekommendationer utifrån riskbaserad analys av lager och efterfrågedata.

Systemet hjälper, liknande EasyStock, att flagga riskartiklar, identifiera överskottslager och optimera inköpsbeslut. Citatet "a risk-based inventory and demand forecasting solution is used by customers in distribution, manufacturing, retail, and warehousing to minimize stock-outs, reduce excess inventory, and improve time to order." (PR Newswire 2021b) understryker hur denna typ av teknik hjälper företag att förebygga problem snarare än att reagera i efterhand. Verktöget ger ett starkt stöd för att identifiera och agera på potentiella d&d-produkter innan de blir ett kostsamt problem. NetStock erbjuder ett system som integrerar med ERP och ger företaget insikter i vad som bör hanteras (PR Newswire 2024a). De parametrar och aktiviteter NetStock hanterar är efterfrågeprognoser, beräkning av säkerhetslager, kapitalbindningsanalys, prioritering av inköpsorder och servicegradsmätning. Baserat på säsongsvariationer, historisk försäljning och trender är det ett perfekt stöd vid beslutsfattning.

NetStock erbjuder ett konkret exempel på hur AI kan integrera med befintliga ERP-system och effektivisera inköpsprocesser och förbättra lagerstyrningen. Verktögen genererar att företaget agerar mer prediktivt och handlingsinriktat utefter realtidsdata, ger stöd som minskar risken för kapitalbindning och förbättrar företagets förmåga att agera i tid (NetStock u.å.). Precis som EasyStock krävs det likadana organisatoriska och tekniska förutsättningar för att integrationen av AI ska fylla sitt syfte. Vanliga utmaningar vid integrationen är naturligtvis motstånd mot förändring, bristande datakvalitet och överdriven tilltro till tekniken (Osmonbekov, Johnston & Donthu 2024). Alltså att företagen räknar med att AI ska lösa allt automatiskt, när det egentligen kräver viss mänsklig tolkning och styrning. Vikten i förståelse att AI är ett verktyg

som ska stödja, och inte själva ersättningen för strategiska beslut, är av stor vikt för att det ska fungera.

Men också fel fokus i implementationen, att man inte knyter i den till konkreta affärs mål (Osmonbekov, Johnston & Donthu 2024). Att implementationen görs för brett och snabbt, och skapar förvirring. Det är också viktigt att ha tålmod kring investeringen då avkastningen på investeringen ofta syns efter några månader (Culot, Podrecca & Nassimbeni 2024).

2.5.3 Slimstock

Denna typ av automatisering passar bäst till medelstora eller större bolag som behöver en helhetslösning för proaktiva analyser (Slimstock u.å.). Slim4 är ett verktyg baserad AI som används till lagerhantering med fokus på lageroptimering, minskat överlager och allmänt svinn. Denna avancerade AI-baserade plattform är utvecklad av SlimStock. Appen kan användas inom parthandel eller tillverkning med stora sortiment. SCM-plattformen kan också hjälpa till med prognoser, jobbar proaktivt och uppmärksammar artiklar innan de hamnar i d&d (Slimstock u.å.). I takt med traditionella prognosmetoder kan det här avancerade analysverktyget hjälpa till att göra mer pålitliga och snabba beslut. Genom att använda sig av den här typ av AI kan det förstärka försörjningskedjor och förhindra motståndskrafter enligt (Slimstock u.å.). Implementering av Slim4 görs genom integration med företagets affärssystem, plattformen kommer kontinuerligt hämta och analysera data om försäljning, inköp, lagerstatus och efterfrågemönster. SlimStock erbjuder ett projektbaserat införande där de definierar mål, processer och nyckeltal för optimering. Implementeringen omfattar dataintegration via AI eller andra kopplingar till ERP-systemet. Konfiguration av parametrar utifrån företagets sortimentstruktur, ledtider och säsongsvariationer. Den här AI:n inkluderar också utbildning av personal i hur systemet används och tolkas, och till sist kontinuerlig uppföljning och support efter driftsättning (Slimstock u.å.).

Slim4 erbjuder både operativa och strategiska beslut i inköps och lagerhanteringsprocesserna. Såsom efterfrågeprognoser baserad på historisk data, säsongsvariationer och trender över tid inkluderas, samt automatisk flaggning av riskartiklar, beställningsförslag i realtid, simuleringsverktyg och dashboard övervakning (Samuels 2025). Det erbjuder en helhetslösning för företag som vill jobba proaktivt med lageroptimering och förutsägbar inköpsstyrning. Till skillnad från NetStock och EasyStock ger detta program också konkreta åtgärdsförslag för att undvika dem (Samuels 2025). Liknande de andra systemen är förändringsmotstånd hos personal, behov av utbildning och kompetensutveckling, datamognad, anpassning och konfiguration, de stora utmaningarna vid implementering. Däremot det som skiljer Slim4 är deras avancerade efterfrågeprognos och användarvänliga gränssnitt (Bartels 2025). Enligt Bartels (2025) fallstudie förbättrar Slim4 planeringsprocesser och ökar transparensen i försörjningskedjan genom att erbjuda exakta efterfrågeprognoser och automatiserade lagerrekommendationer. Det viktiga att tänka på vid implementering av denna AI är detsamma som resterande, vikten i tillgång av rätt och aktuell data är avgörande för att algoritmerna ska kunna generera tillförlitliga prognoser. Att personalen är anpassningsbar, ledningsstöd med starkt engagemang och även en stabil teknisk infrastruktur som stödjer integrationen mellan AI och befintliga affärssystem (Unal, Erkayman & Usanmaz 2023).

2.5.4 ToolsGroup

Det här är en industriell AI-applikation som används för efterfrågeanalyser för leverantörskedjor (Xia et al. 2021). ToolsGroup erbjuder en produkt som kallas SO99+, det är en plattform för lageroptimering och prognostisering (Toolsgroup u.å.). Med hjälp av självanpassade modeller

kan den hantera komplexa efterfrågnings modeller. Den är specialiserad på att kunna hantera långsamrörande efterfrågan, flaggar riskartiklar i förväg. SO99+ kan då justera om prognoserna eller rekommenderar utträngning på valda artiklar. Plattformen använder självlärande algoritmer och probabilistiska modeller för att förutse efterfrågan, identifiera riskartiklar och optimera inköpsbeslut.

Den här typen fungerar bäst till större distributörer eller tillverkare med komplexa lager och många SKU:er. Passar utmärkt till organisationer som kräver en högre servicegrad, men minimal inkurans (Toolsgroup u.å). Som de andra AI-systemen appliceras även denna på befintliga ERP-system för att hämta realtidsdata kring försäljning, inköp, ledtider, lagernivåer och produktlivscyklar. Ju mer AI-modellen används, desto bättre tränad och anpassad blir den utefter företagets historik, efterfrågemönster och affärsmål. Det leder till att prognoser och lagerrekommendationer blir självanpassande över tid (Toolsgroup u.å). Självklart krävs också tillgång till strukturerad och konsekvent historisk data, vilket innebär att företaget behöver genomföra en datarensning och mappning (Xia et al. 2021). ToolGroup erbjuder likt Slim4 en support och utbildning för att hjälpa personal att öka kompetens och förståelse kring hur prognoser ska tolkas, hur de bör agera på flaggade artiklar och användarnivå av beslutsstödet.

Precis som de tre andra alternativen ovan styrs SO99+ av parametrar som efterfråga, produktlivscykelstadier, ledtid och orderkostnad (Xia et al. 2021). Dock inkluderar denna AI även osäkerhet och kostnadseffekter genom att analysera risknivåer för varje SKU (Optilon 2018). Utmaningarna med införing av SO99+ är även här kompetens hos personal, förändringsmotstånd, initiala kostnader och höga krav på datakvalitet. Det är även här viktigt att ha datadrivna arbetsprocesser och ledningens stöd, ett affärssystem som har konsekvent och komplett data, ett tvärfunktionellt arbetssätt där inköp, logistik och försäljning samarbetar. Användning av det här verktyg kommer generera förbättrade prognoser, ökad servicenivå för produkter med oregelbunden eller långsam efterfrågan, och minskning i överlager (Optilon 2018).

2.6 Riskhantering i inköpsprocessen

Begreppet risk definieras ofta som en händelse som inte är förutsedd eller utgör ett hot mot organisationens verksamhet (Nyamah, Feng, Yeboah Nyamah, Opoku & Ewusi 2023). Risker är en ständig närvaro i organisatoriska aktiviteter och påverkar i hög grad både produktivitet och affärskontinuitet. Inom inköpsprocesser är organisationer särskilt utsatta för flera typer av risker, exempelvis leverantörsberoende, logistiska störningar eller brister i planering. Av denna anledning är det avgörande att företag utvecklar en effektiv riskplaneringsprocess som kan identifiera och hantera potentiella hot (Nyamah et al. 2023).

Enligt Sörqvist och Bergendahl (2021, s.154-155) kan en riskanalys genomföras på olika sätt beroende på ambitionsnivån. Det kan förekomma många olika risker i en process. Eftersom det kan förekomma många olika risker i en process är det viktigt att välja en lämplig analysmetod. En enklare riskanalysmetod som kan användas är ett what-if-seminarium. Det innebär att man samlar personer som är kunniga inom området och låter dem diskutera eventuella risker. Det kan också göras en omröstning om riskerna för att bedöma deras storlek (Sörqvist & Bergendahl 2021, s. 154-155).

Att förebygga risker är en viktig del av varje organisation arbete. Harrison et al. (2019, s. 167) skriver om hur organisationer dedikerar olika typer av grupper för att förebygga risker som kan uppstå. Dessa grupper arbetar främst med att planera och föra protokoll över risker som skulle kunna uppstå i organisationen. De tränar också personal i hur de ska agera när något oväntat händer och rapporterar potentiella risker till ledningen (Harrison et al 2019, s. 167)

3. METOD

För att svara på rapportens ställda frågeställningar och uppnå syftet har studien utfört en kvalitativ metodansats med fokus på datainsamling, analys och praktiska rekommendationer. Syftet med detta kapitel är att läsaren ska få en bättre förståelse av forskarens antaganden om metoder, samt en översiktlig beskrivning av forskningsprocessen. Begripligheten i detta kapitel är viktigt för att kunna förstå hur forskningen genomfördes och anledningar till det valda tillvägagångssättet. Först presenteras forskningsdesignen och efterföljande steg presenteras i kronologisk ordning, samt forskningsansatsen. Därefter förklaras de metoder som använts för att analysera data. Avslutande presenteras dataanalys och metodologiska begränsningar.

3.1 Forskningsdesign

Studien är en kvalitativ fallstudie (Säfsten & Gustavsson 2020, s.106) av ett företags inköpsprocess med syfte att analysera hur AI och automatisering kan användas i processen. Denna forskningsdesign har valts eftersom den ger möjlighet till en djupare undersökning av organisatoriska processer i dess verkliga kontext (Säfsten & Gustavsson 2020, s.106). Från att studera nuläget av inköpsprocessen till att analysera olika systemdata, ges möjlighet att identifiera konkreta förbättringsmöjligheter och ingångar till AI eller annan automatisering som skulle kunna appliceras. Problemet är nära till en specifik organisation och process, där frågeställningarna innehåller nyckelord som hur, var, vad eller varför. För en möjlig studie har tillgång till både interna systemdata och nyckelpersoner använts för en mer detaljerad information. Den explorativa karaktären av studien har givit ett fokus till att undersöka nya möjligheter av att använda AI i inköpsprocesser. Men också till de analytiska delar där nuvarande processer jämförts med teoretiska ramverk. Med en abduktiv ansats har studien genomförts, dvs. en blandning av teori och empiri där insikter från verkligheten successivt refererats till olika teoretiska ramverk (Säfsten & Gustavsson 2020, s.49). Denna ansats har möjliggjort att AI och automatisering blivit möjligt att tillämpa i inköpsprocessen lite i taget under hela arbetets gång, i samband med det konkreta fallet och litteratur.

3.2 Datainsamling

Datainsamling i denna studie är baserad på primär och sekundär data som har samlats in, se tabell 3. Primärdata i studien representerar den empiriska data som samlats in efter intervjuer och observationer forskarna själva har gjort. Sekundärdata avser den data som samlats in dokument från Rexel genom Excel-filer och andra utdrag från deras affärssystem. Den data har sammanställts och analyserats för att ge en fördjupad bild av nuläget. De två kategoriserade datainsamlingarna används för att skapa en helhetsbild och tydligt sammanhang av informationen. Jämförelse av analys och insamlad data kommer bidra till ett mer tillförlitligt resultat enligt Säfsten och Gustavsson (2020).

3.2.1 Intervjuer

För att kunna svara på rapportens syfte, vilket är att undersöka hur man kan effektivisera en inköpsprocess med applicering av automatisering och AI program, har primärdata samlats in från företaget Rexel enligt tabell 3. Nyckelpersonerna för detta arbete är Max Jakobsson som är inköpare och Terese Thyberg som är inköpschef.

Tabell 3: Sammanfattning av insamlad data från Rexel Sverig AB

<i>Informant</i>	<i>Tidsperiod</i>	<i>Insamlad data</i>
<i>Inköpschef och inköpare</i>	November 2024 - Maj 2025	Semi- och ostrukturerade intervjuer, inköpsprocess och uppföljning via e-post.
<i>Inköpare</i>	Februari 2025	Grundläggande genomgång av inköpsprocessen.
<i>Inköpschef och inköpare</i>	December 2024 – Maj 2025	Frekventa interaktioner med intervjuer, datainsamling och epostuppföljning.
<i>Inköpare</i>	Januari 2025 – Maj 2025	Sporadisk kontakt med ostrukturerade frågor och uppföljningar.
<i>Inköpare</i>	Februari 2025 – Mars 2025	Förtydligande och mer detaljerad genomgång av inköpsprocess och kartläggning via e-post
<i>Inköpschef och inköpare</i>	April 2025 – Maj 2025	E-post kontakt kring detaljerad information om process och specifika artiklar.
<i>Inköpare</i>	Maj 2025	Insamling av konkreta fall av artiklar som representerar problemet.

För att kunna samla in primärdata sker kontakt med nyckelpersonerna på företaget där de succesivt går igenom inköpsprocessen. Syftet med den här genomgången från företaget är att få en grundläggande förståelse hur inköpsprocessen fungerar och vilka delar som potentiellt kan effektiviseras. Vid insamling av kvalitativ empiri genomfördes en semistrukturerad intervju för att möjliggöra en fördjupad förståelse av företagets perspektiv, men också ge möjlighet till flexibilitet. Syftet är att undersöka vilka produktartiklar som är i riskzon för att senare kunna använda sig av forskning och AI för att effektivisera.

3.2.2 Dokumentanalys

Sekundärdata i denna studie är i stor vikt, då det bidrar till insikten i företagets nuläge. Sekundärdata har samlats in, enligt tabell 4, och ger en tydlig överblick av dess utmaningar, historiska mönster i efterfrågan, avvikelser och lagerstatus. Interna dokument, befintliga system och tidigare rapporter inom företaget har analyserats för en djupare förståelse.

Tabell 4: Sammanfattning av dokumentanalys

<i>Källa (bilaga/system)</i>	<i>Datotyp/Nyckelvariabel</i>	<i>Användningsområde</i>
<i>ERP-E3 och AWR-artikelorderhistorik</i>	Artikel-ID, försäljning/månad, ledtid och avvikelshantering	Identifiera d&d, SKU:er och beräkna prognosfel. Samt bedöma nuvarande prognosmetoder och jämföra mot AI-verktyg.

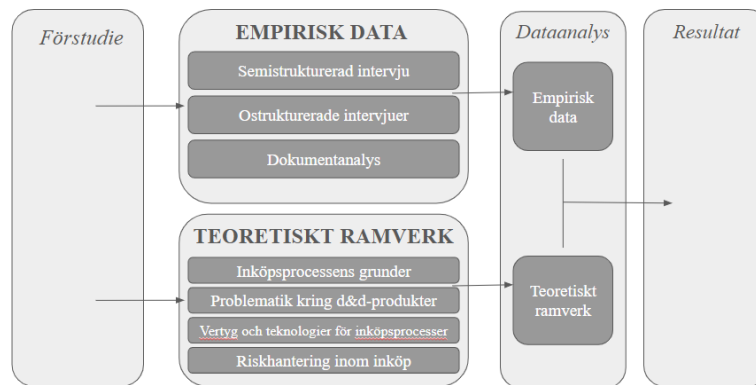
<i>Power-BI rapport tillgänglighet</i>	Saldoförändringar och prognosavvikelser	För att mäta nuläge, visualisera mönster och validera intervjuerna.
<i>Interna processbeskrivningar</i>	Flödesschema och roller	Processkartläggning
<i>Kvartal- och månadsrapporter</i>	Kategoristyrning och leverantörrelationer	Triangulär intervjudata
<i>Bilaga 1: D&D& överlager leverantörer</i>	Lagervärde, andel dead/dying/överlager	Rangordna riskleverantörer
<i>Bilaga 2: Dead & Dying leverantörer</i>	Leverantörer, andel d&d	Bekräfta problemets omfattning
<i>Bilaga 3: Lagerartiklar</i>	Artikel-ID, saldo, ledtid och försäljning	Förståelse för individuella artiklar
<i>Bilaga 4: L2a Inventory Provision</i>	Förstalagerdatum, omsättning och frekvensklass	Spåra kapitalbindning

Källor använts av störst del är från ERP-systemet, Power-BI rapporter och interna processbeskrivningar och dokumentation från kvartals och månadsrapporter. ERP-systemen (E3 och AWR) har tillgång till bland annat artikeldata, orderhistorik, lagersaldon, ledtider och avvikelshantering. Power-BI innehåller analyser över tillgänglighet, saldiförändringar och prognosavvikelser. Interna processbeskrivningar har använts för att förstå hur inköpsarbetet är organiserat och vilka riktlinjer som styr det dagliga, veckovisa och månatliga arbetet. Dokumentationen från kvartals och månadsrapporter gav en bättre översikt i hur kategoristyrning, klassificering av artiklar och leverantörsrelationer hanteras över tid. Med det som grund kunde en nulägesanalys göras, och sedan en utvärdering av hur AI och automatisering kan integreras för att förbättra processerna.

3.3 Dataanalys

Analys av den insamlade data gjordes i flertal steg, för en tydligare bild av tillvägagångssättet illustreras det med en bild i figur 2. En processkartläggning gjordes för att kunna analysera nuvarande inköpsprocesser och identifiera var i processen AI skulle kunna appliceras. Den här processkartläggningen gjordes med hjälp av primärdata från Rexel och nyckelpersonerna. Det

analyserades även parallellt med det teoretiska ramverk som framtagits av den vetenskapliga studie som gjordes



Figur 2: Dataanalysens struktur

3.4 Etiska överväganden och dataskydd

Att följa god forskningssed är för att undvika onödig skada på kollegor och avdelningar på företaget. Anonymisering av studien minskar även risken för personlig stigmatisering och underlättar en mer saklig diskussion för en generaliserad analys. Därav att utdrag av företagsdata som använts i rapporten kommer att tillhandahålla anonyma artikel-ID och benämns med neutrala nummer (t.ex. 1,2,3 etc.). Informanterna har fått muntlig och skriftlig information om studiens syfte, samtliga respondenter har muntligt gett samtycke till att dessa uppgifter ska användas i arbetet. I enighet med principer om öppen vetenskap kommer det empiriska materialet vara tillgänglig via högskolans databas efter slutförd examination. Material som innehåller känslig information kommer anonymiseras för att respektera deltagares integritet och Rexels affärsintressen, samtidigt som lagkrav och etiska riktlinjer följs.

3.5 Metodkritik och begränsningar

Studien är baserad på intervjuer med två nyckelpersoner; inköpare och inköpschefen, från Rexel, det begränsade urvalet kan leda till organisationsspecifik bias och minskar generaliserbarheten. Med djup empiriskt underlag resulterar i att besluten därför kan vara färgade av organisationens specifika kultur. Mönster och prognosfel är sannolikt relevanta för andra B2B-grossister, men slutsatserna bör betraktas som mer analytiska än statistiskt generaliserbara. För en bredare studie och förmåga till en möjlig bredare statistisk slutsats krävs fler fallstudier i olika branscher och storlekar. Kontakt med respondenterna i över ett halvår och successivt under studiens gång har givit djupare information kring företaget, men kan samtidigt påverka objektiviteten i tolkningarna. Det innebär att studiens medvetenhet om anpassningar och tolkningar från organisationens problemformulering är av stor vikt vid förståelse av resultatet, dess tillförlitlighet och generalisering. För att motverka det jämförs informationen kontinuerligt med det teoretiska ramverk som efterforskat.

I detta fall är det viktigt att endast begränsa till datainsamlingen, eftersom denna studie analyserar potentiell tillämpning i endast inköpsprocessen. Det innebär att studien återigen inte kommer utforska vad som händer vid förändring och applicering av andra verktyg än de som redan finns, därav att slutsatserna inte är faktiska utan mer hypotetiska. För att helt och hållet veta hur utfallet blir krävs det testning i praktiken innan det kan valideras fullt ut. Det påverkar också möjligheten att följa upp vissa processförändringar över tid eller mer långsiktig analys av potentiella AI-lösningar. Även tillgången till vissa typer av systemdata som varit

fragmentarisk eller krävt tolkning för att förstå. Det påverkar precisionen i analysen och särskilt i samband med att identifiera mönster i lager och avvikelldata. Studien är av kvalitativ metod och innebär också att tolkning och analyser formats av forskarens förståelse och perspektiv, vilket medför en typ av subjektiv bedömning. För att minska den påverkan har flera datakällor använts och resultatet har kontinuerligt jämförts mot teoretiska ramverk.

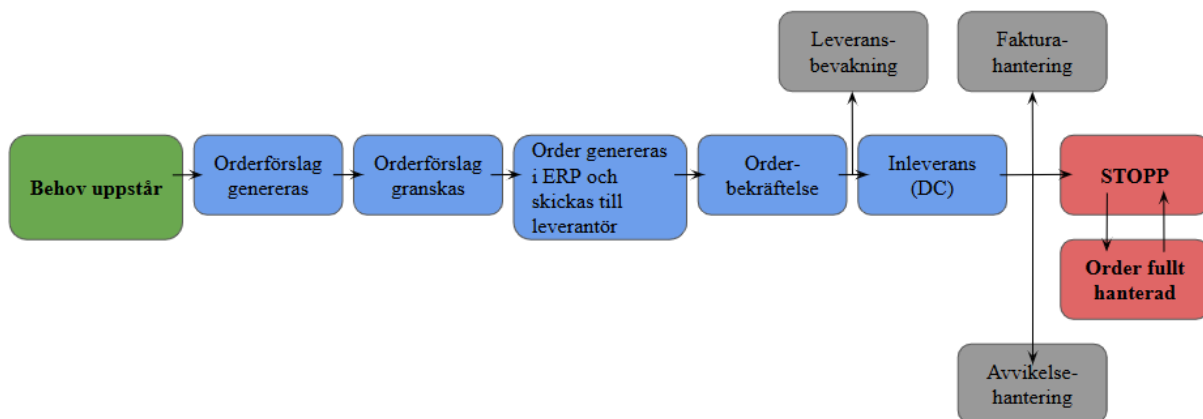
4. RESULTAT

I detta avsnitt presenteras resultatet från undersökningen av hur företag kan byta ut sitt nuvarande reaktiva arbetssätt till ett mer proaktivt. Här presenteras även vilka tekniska och organisatoriska förutsättningar som krävs för att ge denna implementation bäst möjlighet till att minska kapitalbindning och förbättring av lageromsättningen. I resultatet presenteras även befintliga AI-baserade verktyg som är särskilt utvecklade för att stödja B2B-företag. Verktygen hjälper till att tidigt identifiera riskartiklar och därmed minska risken att artiklar hamnar i kategorin d&d. Det i sin tur hjälper också företag att minska kapitalbindning och förbättra lageromsättningen.

4.1 Presentation av empiriskt sammanhang

Rexels inköpsprocess omfattar både dagliga operativa aktiviteter och strategisk halvårsplanering. Figur 3 illustrerar hur Rexel i stora drag hanterar sin inköpsprocess. Syftet är att säkerställa att rätt artiklar finns på rätt plats vid rätt tid, genom att kombinera säsongsdata, försäljningsprognoser och lagernivåer. Inköpssystemet, E3, och stödsystemet AWR, genererar automatiserade orderförslag utifrån parametrar som historisk efterfrågan, ledtider, säkerhetslager och orderfrekvens. Dessa förslag granskas därefter manuellt av inköpare, vilket innebär att processen är delvis automatiserad men till stor del beroende av mänsklig bedömning.

Artiklarna som hanteras delas in i två huvudkategorier: AK1 (lagervaror) och AK2 (anskaffningsvaror). AK1 omfattar ca 25 000 artiklar som är regelbundet förekommande och lagerhållna, medan AK2 består av varor som endast tas in vid behov. Det är främst inom AK1 som problem med d&d-produkter uppstår. Enligt intervjuerna har dessa varor ofta korta ledtider, vilket gör dem känsliga för plötsliga efterfrågeförändringar. För AK2-artiklar används i högre grad säkerhetslager som buffert, men även här förekommer inkurans.

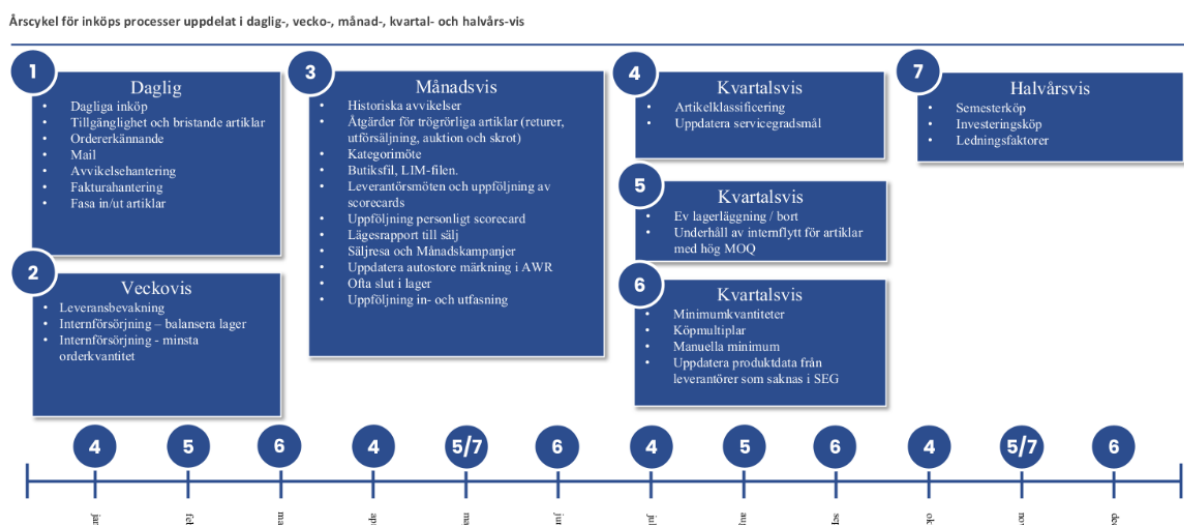


Figur 3: Rexels inköpsprocess (Intervju 2025-02-21)

Den operativa inköpsprocessen innebär att inköpare dagligen granskar E3:s systemförslag, hanterar restnoteringar, och analyserar artiklar med tomt saldo. Vid förseningar kontaktas leverantörer manuellt, och ERP-systemet påminner om sena order. Bekräftelse av order ska ske inom 24 timmar. För leveransavvikelser används stödsystem som Tyringe och Abbyy, och samarbetet med lager är centralt. Inköpare initierar också interna flyttar av artiklar vid behov, särskilt när efterfrågan plötsligt förändras. Power BI används som ett verktyg för uppföljning och analys, t.ex. för att visualisera lagersaldo, identifiera försäljningsavvikelser och behov av kampanjer. Även om systemet tillhandahåller relevant data, måste inköpare själva tolka och

agera på informationen. Säsongsvariationer identifieras och beaktas manuellt, exempelvis för sommarmånader där efterfrågan historiskt minskar. Systemen som används hos företaget arbetar parallellt med varandra och är inte sammanfogade.

Månadsvis sker uppföljning av nyckeltal (KPI:er) såsom lagervärde, omsättningshastighet och servicegrad. Analysen sker främst i Power-BI där inköpare kan granska trögryrliga artiklar och fatta beslut om lämpliga åtgärder. Inköparna deltar även i möten med leverantörer och produktägare för att diskutera lagerstatus och förbättringsåtgärder. Olika lösningar som retur till leverantör, utförsäljning, auktion eller skrotning är åtgärder som ofta väljs. Det finns tydliga instruktioner för varje steg i inköpsprocessen, inklusive att bevaka leveranser, hantera avvikelser och skicka påminnelser vid förseningar som visas översiktligt i figur 3. Ordern levereras därefter till distributionslagret inom avtalad tid. I figur 4 illustreras årscykel för inköpsprocesser som uppdelas i dagliga-, vecko-, månad-, kvartal- och halvårs-vis.



Figur 4: Årscykel av inköpsprocess (Intervju 2025-02-21)

Vid nyintroduktion av artiklar visar intervjudata att prognoser är särskilt osäkra på grund av bristen på försäljningshistorik. Inköpare förlitar sig då på produktchefers bedömning snarare än systemets rekommendationer. Det framgår att nya artiklar som inte etablerar sig snabbt ofta returneras eller fasa ut inom ett år.

På strategisk nivå sker halvårsvis planering för att anpassa inköp till perioder med stängda leverantörer, samt inför prisjusteringar. Lagerkapacitet, kapitalkostnader och systemparametrar ses då över för att justera inköpsstrategier och undvika överlager. Detta skiljer sig från de mer operativa dagliga aktiviteterna och kräver en mer långsiktig analys av trender och behov. Sammanfattningsvis visar det empiriska materialet att inköpsprocessen är välstrukturerad men till stor del manuell och reaktiv, vilket gör det svårt att agera i tid vid förändrad efterfrågan. Det finns ett visst stöd från affärssystem och analysverktyg, men processerna är fortfarande beroende av inköparens egna tolkningar och beslut. Det skapar utrymme för att utveckla mer prediktiva och automatiserade stöd, något som behandlas vidare i resultatkapitlet.

För att ytterligare skapa förståelse till hur processen fungerar har tabell 5 gjorts efter överenskommelse med respondenten (Intervju 2025-05-16). Den visualiserar vad som sker manuellt och automatiskt, men också en mer ingående förklaring på delarna av inköpen i processen. Det finns ett visst automatiseringsstöd, men kritiska beslut och uppföljningar sker fortfarande manuellt, särskilt vid avvikelsehantering och prognoser.

Tabell 5: Processens manuella och automatiserade delar (Rexel 2025 a,b,c,d)

<i>Aktivitet</i>	<i>Manuell eller Automatisk</i>	<i>Beskrivning</i>
<i>Orderläggning</i>	Automatisk	Inköpsförslaget skapas upp automatiskt med hjälp av AWR. En kortare manuell analys krävs i samband med förslaget.
<i>Orderbekräftelse</i>	Automatisk och Manuell	Orderbekräftelser via systemen är till 95% automatiserat, står för ca 65% av flödet. Resterande görs manuellt.
<i>Orderbekräftelse</i>	Automatisk och Manuell	Uppföljning av leveransstatus görs genom ett automatiskt utskick till leverantör som sedan behöver ageras på manuellt.
<i>Avvikelsehantering</i>	Manuell	Leverans- och fakturaavvikelser följs upp manuellt i ärenden som skapas av lager och reskontra.
<i>Analys av bristande artiklar</i>	Manuell	Power-BI rapport bidrar med underlag över bristande artiklar som inköpare behöver följa upp manuellt
<i>Analys av dead & dying</i>	Manuell	Power-BI rapporter finns som stöd för att identifiera artiklar som är d&d men uppföljning och förebyggande görs manuellt.

Intervjudata visar att nya artiklar är särskilt svåra att prognostisera korrekt på grund av bristen på historisk försäljning. Enligt inköpspersonalen är prognossäkerheten generellt god för etablerade artiklar men sämre för nya, vilket gör att manuell granskning av produktansvarig blir avgörande.

Sammantaget visar intervjudata att processens reaktiva karaktär och brist på proaktiv automatisering bidrar till att d&d-produkter inte identifieras förrän de redan bundit kapital i lagret. Även om företaget använder avancerade verktyg som Power-BI, krävs manuell bearbetning av data, vilket fördröjer beslut och åtgärder. Detta stödjer behovet av integrerade AI-lösningar som automatiskt kan flagga riskartiklar, analysera efterfrågemönster och ge

inköpsrekommendationer utan att belasta personalen med tunga manuella analyser. Kampanjer som hanteras tillsammans med leverantörer och är oftast prisbaserade. Strategisk inköpsplanering sker i begränsad utsträckning och Rexel saknar helt ett etablerat ramverk, vilket försvårar en långsiktig styrning baserat på proaktiva analyser.

4.2 Presentation av data

I detta avsnitt presenteras det insamlade empiriska materialet som utgör grunden för analysen. Det medför också grunden till analys av inköpsprocessens effektivitet och hantering av d&dprodukter. Genom att kombinera information från affärssystem, visualiseringsverktyg och interna rapporter har olika nyckelområden identifierats. Med utdrag på riskartiklar, överlager och trögrörliga produkter har det tillsammans gett en överblick av datakällorna och resas funktioner. Tillsammans med visualisering av leverantör och artikelspecifikation, avslutande har konkreta fallbeskrivningar illustrerats och representerar typiska riskmönster.

4.2.1 Leverantörsdata kopplad till d&d-artiklar

För en bättre helhetsbild av företagets inköpsprocess och lagerhantering har flera olika datakällor analyserats. Primära data har hämtats från ERP-systemet och stödsystemet AWR. I dessa system finns information om artikelhistorik, ledtider, lagersaldon och produkter som av vikt. Utöver det har Power-BI använts för att visualisera trender, prognosavvikelser och omsättningshastighet. Interna bilagor som innehåller artiklar och leverantörer som klassificeras efter andel d&d-produkter och överlager har även hämtats för att komplettera informationen. Syftet med att analysera datakällorna har varit att identifiera trögrörliga artiklar och kartlägga riskmönster för att skapa bättre förutsättningar för proaktiv styrning och minskad kapitalbindning. Tabell 6-9 är utdrag från Rexel. De presenterar utdrag från artikelnivå som visar detaljer om lagerstatus, omsättningsfrekvens, orderhistorik och prognosavvikelse. Detta används som stöd hos företaget vid beslut om exempelvis skrotning eller säljkampanjer.

Tabell 6 innehåller ett utdrag från bilaga 1, D&D & överlager leverantörer. I denna bilaga visas en sammanställning av leverantörer och hur stor andel av deras artiklar som klassificeras som dead, dying eller överlager. Bilaga 1 är en sammanställning av artiklar kopplade till d&dprodukter och överlager med fokus på leverantörstillhörighet. Informationen kan också användas för att identifiera vilka leverantörer som bidrar till mest kapitalbindning i form av trögrörliga produkter. Det bidrar också till att ge insikt i vilka leverantörer som har störst andel osålda eller överskottsartiklar, vilket kan påverka effektiviteten negativt. Tabell 6 visar hur mycket av varje produkt som finns i lager, hur mycket kapital i kronor det binder upp och procenten av det.

Tabell 6 innehåller inte bara hur mycket av varje produkt som finns i lager. Utan också vilket ekonomiskt värde det motsvarar i procent av leverantörens totala värde. Ett exempel är leverantör 28127 BCCT då 48,9% av lagret är överlager, av vad som köptes in. 7,2% av lagret (ca. 2Mkr) består av produkter som säljer väldigt dåligt och 0% av produkter som klassas som osäljbara. Det innebär att 56,1% av lagret från denna leverantör är överlager eller svårsålt, detta visar att leverantören står för en andel av det problematiska lagret.

Tabell 6: D&D-produkter och artiklar i överlager (utdrag från bilaga 1)

Leverantör	On hand amount	Overstock amount	Over Stock%	Dying amount	Dying %	Dead amount	Dead %
------------	----------------	------------------	-------------	--------------	---------	-------------	--------

28127 BCCT	27 660 767	123534298,14	0,489	1982095,44	0,071	-	-
18736 WEST.	36 733 519	7837641,50	0,213	2495595,00	0,067	49	1,32032E06
10352 DRAKA.	71 701 443	5706789,34	0,079	1816188,23	0,025	984 036	0,01372408

I tabell 7 presenteras ett utdrag från bilaga 5, Dead & dying leverantörer. Bilagan visar hur stor del av lagervärdet hos olika leverantörer som består av produkter med låg eller ingen efterfrågan. För varje leverantör visas ett totalt lagervärde, följt av hur mycket av det som klassas som dead eller dying. I sista kolumnen visas den totala andelen d&d som procent av det totala lagervärdet. Den visar vilka aktörer som har störst andel lågomsatta produkter. Detta kan tolkas som en indikator på att artiklar från dessa leverantörer ofta utvecklas till d&d-produkter.

Ett exempel är rad ett, leverantör Draka, med ett lagervärde på cirka 72,3 miljoner kronor (Mkr). Cirka 2,8 Mkr är artiklar med låg eller ingen försäljning. Detta visar en tydlig bild av vilka leverantörer som står för störst finansiell risk i bundet kapital av osäljbara eller långsamt omsatta produkter.

Tabell 7: Leverantörer med hög andel d&d-produkter (utdrag från bilaga 2)

Leverantör	Lagervärde (kr)	Dead (kr)	Dying (kr)	%
1035 DRAKA.	72 307 502	984 036	1 801 526	3,9
10103 NKT SWE.	44 204 310	49 414	2 442 106	5,6
18736 WEST CO.	38 586 567	49	1 734 921	4,5
12212 ELEKTRO.	33 782 953	32 571	350 391	1,1

Tabell 8 är ett utdrag från Lagerartiklar-filen, bilaga 3, och ger insikt på artikelnivå. Denna typ av information ger uppgifter om bland annat artikelnummer, tillgänglighet, restorde, senaste orderdatum och datum artikeln var slut i lager. Det möjliggjorde en förståelse för individuella artiklars omsättning. Bilaga 3 innehåller artiklar som utgör en särskild risk ur lagerstyrningsperspektiv. Artiklarna är svåra att justera i inköpsvolym i takt med förändringar i efterfrågan.

Artiklarna riskerar därför att snabbt övergå till d&d-status. Artiklar i tabell 8 är exempel då försäljningen på nya produkter som är svåra att förutspå efterfrågan på. Försäljningen är låg första dagarna och vissa artiklar har lång ledtid. Vissa artiklar fortsätter sälja och andra inte. Detta skapar sårbarhet där inköp baseras på äldre prognoser och kan leda till överskott och bundet kapital.

Tabell 8: Exempel på artiklar med låg försäljning och lång ledtid (utdrag från bilaga 3)

Artikelnr	Artikel	I lager	Tillgänglig	Rest order	Beräknad ledtid (dgr)	Senast lager lagd	Senast slut på lager
ButikNytt	ButikNytt	0	0	0	1	-	-

1	EBR.	0	0	0	8	20140303	20221012
2	ÄNDFÖRSL.	0	0	0	50	20230224	20250212
3	ÄNDFÖRSL.	0	-30	30	2	20201011	20220516
4	ÄNDFÖRSL.	0	0	0	50	20230224	20250212
5	ÄNDFÖRSL.	0	0	0	50	20230224	20250319
6	ÄNDFÖRSL.	600	600	0	50	20220708	20240923
7	ÄNDFÖRSL.	5 196	5 916	0	2	20221129	20220110
8	ÄNDFÖRSL.	3 500	3 500	0	2	20221129	20220110

Den mest detaljerade informationen finns i L2a Inventory Provision i bilaga 4. Om en artikel har markerats som gammal hittas den i bilaga 4, i följd av omsättning- och frekvensklass. För att enklare förstå återfinns ett utdrag från de fyra första raderna och fem kolumnerna i tabell 9. Varje artikel är kopplad till en frekvensklass (F1–F5, där F1 innebär hög försäljningsfrekvens och F5 låg) samt en omsättningsklass (A–D, där A är hög och D låg omsättning). Artiklar utan klassning innebär att systemet saknar analys för artikeln och visas därmed blankt.

Bilaga 4 innehåller data över lageravsättningar kopplade till osäljbara eller osäkra artiklar, anonymiserat. Denna används för att analysera finansiell påverkan av d&d-produkter och överlager. Ett exempel är artikel 7, i tabell 9, som har ett lagervärde på 440 099 kr, se bilaga 4. Men mycket låg efterfrågefrekvens. Artikeln har inte omsatts på flera månader och står därmed för ett betydande kapitalbundet värde utan avkastning.

Tabell 9: Artiklar med låg msättning och högt lagervärde (utdrag från bilaga 4)

Artikel	Första lager datum	Lagersaldo (st)	Lagervärde (kr)	Omsättnings klass	Frekvensklass
1	20190130	839	25 027	B	F2
2	20190614	2 000	59660	C	F5
3	20190104	2 987	107 771	B	F1
4	20190802	320	19 437	C	F4
5	20190111	1 269	89 642	A	F1
6	20190619	832	90 097	B	F2
7	20190104	10 465	440 099	A	F1
8	20190503	1 020	71 930	B	F3
9	20190102	7 197	598 588	A	F1

4.3 Fallbeskrivningar av identifierade risartiklar

För att illustrera hur produkter över tid utvecklats till d&d-produkter har tre slumpmässiga artiklar valts ut. I samråd med företaget, baserat på uppgifter från ERP-systemet och Power BI. Artiklarna valde med grund av en kombination av historiska försäljningsdata, aktuellt lagersaldo, inköphistorik samt vilka åtgärder som vidtagits för att minska lagernivån. Enligt respondenten (Intervju 2025-05-16) uppvisar dessa artiklar tydliga karaktärsdrag för d&d problematik. Mönstren som identifierats i dessa fall är återkommande bland andra artiklar i sortimentet, vilket gör dem representativa för typiska orsaker till att produkter utvecklas till d&d-artiklar.

De tre artiklarna är fallstudier som representerar olika typer av problem med d&d-produkter. En sammanfattning av dessa illustreras i tabell 10. Tillsammans visar ett brett spektrum av orsaker till att produkter blir svårsålda och binder kapital i onödan. Exempelen konkretiserar behovet av mer proaktiva och datadrivna verktyg vid inköpsarbetet. Fallstudierna visar trots tillgång till stödjande system krävs ytterligare analyskapacitet, prediktiva modeller och lösningar för att identifiera riskartiklar i ett tidigare skede och därmed undvika onödig inkurans. Tillsammans med en tydlig problembild presenteras också åtgärder som kan förhindra att liknande problem förekommer i framtiden, kopplat till teoretiskt ramverk i studien. Lösningar som ABC-analys, livscykelrutiner och AI-verktyg kan vara framgångsrika verktyg.

Tabell 10: Sammanställning av identifierade problem och förebyggande åtgärder

<i>Fall/Artikel</i>	<i>Problembild</i>	<i>Förebyggande åtgärd</i>
A1	Snabbt fallande efterfrågan	Tydliga livscykelrutiner, regelbundna kontrollpunkter för uppföljning.
A2	Felprognos och lång ledtid	Prognosuppföljning och ABC-klassificering för att minska inköpsvolym.
A3	Ny produkt med låg etablering	Säsongsplanering och utvärderingsrutiner för nyintroduktioner.

4.3.1 Fall A1: Snabbt sjunkande efterfrågan

I figur 5 visas ett exempel på en artikel som sålt stora mängder under 2022 och därefter köpts in. Figur 5 illustrerar en produkt som tidigare varit en produkt som sålts mycket, men nästintill all efterfrågan har försvunnit. I (a) beskrivs försäljningen över fyra år där artikeln sålt som mest 2022, följt av en kraftig nedgång de följande åren. Det är ett exempel på problemet vid inköp baserat av tidigare toppar, utan att väga in förändrad marknad.

Efter en hög efterfrågan har stora mängder av artikel 1 (A1) beställts och i samband med detta har stora leveransproblem uppstått. Det i sin tur har lett till att en stor mängd ordrar har lagts men inte kunnat levereras i tid, därav att många beställningar låg och väntade. När efterfrågan

sedan sjönk hade ett lager fullt av en produkt som inte längre efterfrågades, vilket ledde till överlager och klassas som dying. Status av artikeln 2025, kan ses i figur 5 (b), där lagervärdet är på 381 657 kr och 96% av det är dying. Åtgärder på detta har varit två prissänkningar med 50% per gång och utförsäljning har försökts att göras utan större lycka. De 640st som såldes är via auktion och inte för ordinarie pris. Det här påvisar tydligt att nästan allt som är kvar på lagret är problematiskt. Figur 5 illustrerar att kostnaden är hög, men varorna rör sig inte. Prissänkningar och utförsäljning har inte fungerat och är ett typiskt fall av felbedömning i efterfrågeprognosen.

	29/12	26/01	23/02	23/03	20/04	18/05	15/06	13/07	10/08	07/09	05/10	02/11	30/11	Sum
2022	286	930	1 331	1 975	375	1 116	1 589	3 118	1 532	2 565	2 863	4 704	830	23 214
2023	605	1 661	2 215	1 399	2 358	543	726	586	782	241	386	185	276	11 963
2024	295	198	361	123	152	100	62	6	10	0	80	57	100	1 544
2025	1	50	36	0	640									727
Sammansatt	1	50	36	0	640	100	62	6	10	0	80	57	100	1 142
Profil	1,43	1,40	1,25	1,36	0,99	0,89	0,41	0,31	0,31	0,82	0,99	1,36	1,49	0,93

(a)



(b)

(c)


Figur 5: A1 med snabbt sjunkande efterfrågan (Intervju 2025-05-11)

Teoretisk lösning på denna typ av problem är tydliga kontrollpunkter (se avsnitt 4.5.2). Det innebär att företag inför en etablerad rutin för att identifiera när en artikel går in i sen mognadsfas eller börjar tappa efterfrågan (Simões et al. 2020). Vid tidigare identifiering av fallande efterfrågan kan åtgärd som kampanj, utfasning eller kvantitetsreduktion förhindra att artikeln hamnar i d&d. Genom att ha fasta tidpunkter för efterfrågeuppföljning exempelvis varje månad, kan det möjliggöra att agera tidigare på avvikelserna (Silva et al. 2023). I detta fall kan även vara till hjälp här.

4.3.2 Fall A2: Felaktig prognos och lång ledtid

Ett annat exempel som illustreras, i figur 6, nedan är en artikel 2 (A2) som sålde mycket under 2024. Figur 6 (a) visar ett exempel på en artikels försäljning över tid, med fokus på vad som hände efter att den största kunden försvann. I figur 6 (a) illustreras en tydligt hög försäljning 2024, följt av ett kraftigt fall 2025 då det nästan inte var någon försäljning alls. Anledning till sjunkande efterfrågan hos A2 var på grund av konkurs hos den huvudsakliga kunden. Åtgärder för att förhindra artikelns förflyttning till d&d var utförsäljning och prissänkning med 50%, 25 försökte utförsäljning i flera månader men stannade ändå i totalt lagervärde på 65 000 kr med 91% som dying. Diagram (b) och (c) visar att lagret består nästan helt av produkter som inte längre går att sälja, trots prissänkning och utförsäljning. Det är ett exempel på inkurans som inte fångats i tid.

	29/12	26/01	23/02	23/03	20/04	18/05	15/06	13/07	10/08	07/09	05/10	02/11	30/11	Sum
2022	36	16	16	16	98	16	22	5	14	12	18	49	24	342
2023	24	85	88	19	21	30	8	13	20	1	1	2	1	313
2024	1	14	1	3	0	1	0	0	5	0	4	0	7	36
2025	3	2	0	0	0	0	0	0	0	0	0	0	0	5
Sammansatt	3	2	0	0	0	1	0	0	5	0	4	0	7	22
Profil	0,84	1,12	1,28	1,33	1,22	0,98	0,70	0,76	1,03	1,22	1,16	0,91	0,46	0,93



Figur 6: A2 snabbt sjunkande efterfrågan (Intervju 2025-05-11)

Problemet kan hanteras genom avvikelseanalys och ABC-klassificering. Att systematiskt arbeta för att möta och följa prognosfel kan göra att felet upptäcks tidigare och ledtid hanteras mer strategiskt (Kerckänen et al. 2009). Om artikeln klassificeras som lågvolyms (C-artikel) hade den kanske inte beställts i samma omfattning, eller med kortare bevakningsintervall (Ravinder & Misra 2014). En artikel som klassas som högvolyms kan istället fortsätta beställas i samma omfattning. AI-verktyg kan också hjälpa till vid svårigheter av prognosräkning på efterfråga. Avvikelseanalys görs genom att prognostisera försäljningen och jämföra den med faktisk försäljning. Artiklar med stora skillnader kan då identifieras, vilket tyder på risk för överlager eller brist. Artiklar med hög respektive låg försäljningsvolyms bör prioriteras (Zhou et al. 2023). Dessa artiklar har störst påverkan på lönsamheten och lagerhållningen (Kerckänen et al. 2009).

4.3.3 Fall A3: Ny produkt med låg etablering

I sista exemplet som finns i figur 7 är en artikel (A3) som köptes in som en lagervara i slutet av 2023. Figur 7 (a) visar inte en artikels försäljning över flera år, utan snarare ett enstaka händelseförlopp. November 2023 lades artikeln upp på lager och under 2023–2024 var det nästan ingen försäljning alls. November 2024 gjordes sedan en retur på 90% av lagersaldot. Artikeln togs alltså in i förhoppning om försäljning, men såldes aldrig. Ett år senare insåg man problemet och skickade tillbaka majoriteten av lagret till leverantören. Denna artikel började aldrig sälja och gjordes därför en retur på av 90% av saldot för att undvika d&d. Denna typ av exempel är vanlig bland nya artiklar. Diagram (b) och (c) i figur 7 illustrerar ett stapeldiagram där man denna gång hann agera i tid och minskade risken för att produkten skulle bli osäljbar, dock förblir resterande 10% dying.

	29/12	26/01	23/02	23/03	20/04	18/05	15/06	13/07	10/08	07/09	05/10	02/11	30/11	Sum
2022	0	0	0	0	0	0	0	0	0	0	0	0	0	0
2023	0	0	0	0	0	0	0	0	0	0	0	0	9	9
2024	0	0	0	0	0	0	0	0	0	0	0	0	0	0
2025	2	0	0	0	0	0	0	0	0	0	0	0	0	2
Sammansatt	2	0	0	0	0	0	0	0	0	0	0	0	0	2

(a)



(b)

(c)

Figur 7: A3 dålig försäljning av ny produkt (Intervju 2025-05-11)

I detta fall var problemet att produkten var ny och inte hade någon historisk data och baserades istället på uppskattning. Den sålde inte, men låg kvar i lager i väntan på att ta fart. Teoretiskt sätt skulle denna typ av problem kunna lösas med hjälp av en förbättrad livscykel, säsongs och kampanjplanering. Vid ny introduktion borde produkter följas tätare och ha en tydlig plan för utvärdering efter bestämt antal månader, om produkterna inte når volymmål bör de snabbt fasas ut (Simões et al. 2020). Enligt ABC-klassificering skulle denna artikel placeras i kategori C, vilket innebär att den bör ha låg prioritet och tätare uppföljning. Genom att matcha produktanseringar med säsongsvariationer och marknadsföringsfönster kan etableringen förbättras (Silva et al. 2023). AI-verktyg kan också hjälpa till med bättre livscykelplanering och hantera större mängde historisk data som sedan kan förutspå efterfrågemönster.

4.4 Bearbetning av data

Från den genomförda nulägesanalysen och de tre artikelfallen framträder återkommande mönster. Försäljning som snabbt avviker på grund av enstaka kunder, men också brist på efterfrågeanalys av nya artiklar. Tillsammans påpekar det att en inköpsprocess som i dagsläget är reaktiv och delvis manuell, försvårar tidig identifiering av riskartiklar och ökar kapitalbindningen.

4.4.1 Strukturerad artikelhantering som grund för effektiv lagerstyrning

För att förebygga liknande problem i framtiden rekommenderas en lösning där det generellt är viktigt att jobba proaktivt istället för reaktivt. Det finns flera sätt att arbeta mer proaktivt i inköpsprocessen, speciellt med utgångspunkt från A1, A2 och A3 som presenterades. Inköpsavdelningar borde införa artikelklassificering för att prioritera styrning och säsongsplanering med fasta kontrollpunkter för kampanjer och utförsäljning. Enligt Ravinder och Misra (2014) möjliggör artikelklassificering, exempelvis ABC-analys, att organisationer kan prioritera styrning av artiklar med högt värde, låg omsättning eller ökad risk. Det skapar bättre förutsättningar för styrning av kritiska artiklar och minskar risken för kapitalbindning.

Vikten av säsongsplanering betonas, vilket enligt Silva et al. (2023) bidrar till att enklare kunna förutse förändringar i efterfrågemönster kopplade till kampanjer och säsongsvariationer. Det minskar risken för överlager efter temporära efterfrågetoppar. Simões et al. (2020) lyfter också vikten i att ha tydliga livscykelrutiner för att kunna avveckla artiklar i rätt tid, innan de utvecklas till d&d-produkter. Det i sin tur hjälper till att minska kapitalbindning och inkurans.

Livscykelrutiner anger när artiklar bör avvecklas samt en tydlig process för avvikelserapportering kopplad till efterfrågeförändring, retur och stillastående lager. Det möjliggör en förbättrad analys av datamängder hos företag och snabbare identifiering av riskartiklar, förbättrad prognostisering, kapitalbindning och lagerhantering (Vlahakis, Kopanaki & Apostolou 2020). Metoderna som är nämnda kräver inte avancerade systemlösningar men skapar grund för bättre framförhållning, minskad kapitalbindning och tydligare beslutsunderlag. Vidare till en annan viktig organisatorisk förutsättning är etablering av tydliga processer för avvikelshantering och rapportering. Vid förändring av efterfrågemönster, retur och stillastående lager är det viktigt att processerna är utvecklade. Detta för att snabbt kunna identifiera riskartiklar, agera i tid och undvika onödiga lagerkostnader (Vlahakis, Kopanaki & Apostolou 2020).

4.4.2 Exempel på ABC- och avvikelleanalys

Detta avsnitt bygger på analyser av artikeldata, från bilaga 1-4, som samlats in från Rexels ERP-system (E3), automatiska beställningssystem (AWR) och visualiserings verktyg (Power BI). Datan har använts för att identifiera signaler som föregår att artiklar blir d&d. Det görs genom en ABC-analys. Tillsammans med analysen kan datan även kopplas till åtgärdsförslag.

En ABC-analys kan genom att dela in artiklarna i tre kategorier. A-klassen representerar 80% av de mest värdefulla artiklarna, B-klassen de nästkommande 15% och C-klassen de minst värdefulla 5%. Detta visas i tabell 11, utdrag från bilaga 5. Bilaga 5 innehåller en strukturerad sammanställning av artiklar från lager där varje rad representerar en anonymiserad artikel. Lagerstrukturen har analyserats och artiklarna har tidigare klassificerats utifrån kapitalbindning och försäljningsfrekvens. En ABC-analys genomfördes baserat på lagervärde. Tillsammans har varje artikel också medföljts av en frekvensklass från tidigare gjord systemklassificering, se bilaga 4. Artiklarna hade tidigare grupperats in i frekvensklass F1-F5.

Genom att kombinera dessa har dimensionerna möjliggjort en identifikation av artiklar som både säljer sällan och binder lite kapital dvs. C-klass och tillhör F5. Artiklar identifierade som C-klass och F5 är lämpliga kandidater för sortimentrationisering, som i sin tur är konkret beslutsunderlag för att minska kapitalbindning och effektivisera lagret. Artiklar med kombination A-klass och F1 är artiklar som bör bevakas mest kritiskt. De säljer ofta och plockas frekvent, därav att de är bra att ha tillgänglig i lager. Artikel som istället tillhör A-klass med F5 är en artikel som fortfarande är hög i försäljningsvärde totalt sätt men säljs sällan. Detta är en artikel som ger hör intäkt vid enstaka tillfällen, denna är också viktig att ha i bevakning. Därav bör artiklarna hanteras olika beroende på vilken kombination av ABC-klass de tillhör i kombination med frekvensklass, eftersom produkterna är av olika vikt beroende på efterfrågan och hur mycket kapital produkten binder upp.

Tabell 11: ABC-klassificerade artiklar från Rexels ERP-system (utdrag från bilaga 5)

Artikel	Värde Normal lager	ABC-klass	Frekvensklass
1	5 111 664,00	A	F2
2	3 663 019,57	A	F1
3	4 681 842,11	A	F5
4	3 801 389,40	A	F1

Dessa metoder kräver inte avancerade tekniska lösningar utan kan implementeras med befintliga systemstöd och processer. Det skapar en grund till en förbättrad framförhållning hos företaget, som i sin tur förbättrar lageromsättning och bidrar till lägre kapitalbindning. Samtidigt kan detta också fungera som en bra ingång till framtida automatisering. Metoderna kan fungera i samråd med framtida AI-implementeringar och bidra till en gradvis övergång till en mer datadriven och förutseende inköpsfunktion. Där analys av historisk data och artikelbeteende kan integreras med prediktiva verktyg som är automatiserade beslutsstöd.

4.4.3 Från insikt till åtgärd: hur kan AI stötta proaktiv lagerhantering

Det finns olika typer av AI-verktyg för att undvika d&d inom företag där fokuset hos dess AI-programmen inom lageroptimering. EasyStock, Slim4, Netstock och ToolsGroup är fyra program som presenteras i rapporten.

EasyStock och NetStock riktar sig mot mindre företag som vill komma igång med avancerad lagerstyrning (Mourtzis, Doukas & Vandera 2017). Även om företagen söker en snabb översikt av lagerhälsa och frigöring av bundet kapital (PR Newswire 2024a). EasyStock är ett molnbaserat AI-verktyg som appliceras på befintliga ERP-system och jobbar proaktivt. Genom att tidigt identifiera produkter med minskad efterfrågan och utstickande lagernivåer hjälper detta verktyg att minska kapitalbindning och inkurans (Mourtzis, Doukas & Vandera 2017). NetStock är också ett molnbaserat prognos- och lagerhanteringsverktyg. Liknande EasyStock passar det till mindre företag, men kan också hantera något större företag. Dessa verktyg fungerar till verksamheter som vill bibehålla en viss del av inköpsprocessen manuell. AI-verktygen fungerar istället som ett ytterligare stöd i beslutsfattningen (Mourtzis, Doukas & Vandera 2017). Denna typ av AI används som stöd vid beslut av inköp och överskottslager. Den hjälper också till att minimera risk för att artiklar ska hamna i d&d (PR Newswire 2024a).

Slim4 och Toolsgroup är mer avancerade och passar bättre till större företag och aktörer med ett mer komplext sortiment. De är mer anpassade till att ge helhetslösningar till företag inom lageroptimering, prognoser och proaktiv hantering. Slim4 är en AI-baserad plattform från SlimStock och riktar sig till större företag (Slimstock u.å.). Toolsgroup är väldigt liknande men ger sina lösningar genom en plattform kallad SO99+. Med hjälp av egenanpassade modeller är denna AI specialiserad på att hantera riskartiklar i tid och uppmärksamma trögörliga efterfrågningsmönster (Xia et al. 2021). Dessa verktyg rekommenderas till företag som vill att AI-verktygen ska ersätta alla delar i inköpsprocessen och inte vara i lika stort behov av den mänskliga faktorn (Xia et al. 2021).

4.5 Sammanfattning av resultat

Resultatet visar att företag ofta hamnar i en situation med många artiklar i d&d på grund av sitt reaktiva arbetssätt och komplexa lagerhantering. Det leder till att produkter med fallande efterfrågan och försämrade försäljning upptäcks försent och hamnar i d&d. Detta exemplifierar studien i de tre representativa artikelfallen, se figur 5-7. Trots att företagets befintliga ERP- och BI-system erbjuder ett visst stöd, mycket av arbetet är fortfarande manuellt och har brister i prediktiv kapacitet. Detta leder till en förhöjd kapitalbindning, förseningar i utfasning och ineffektiva kampanjer och resursstrategier.

Rexel använder sig av ett system, E3, som kräver små manuella justeringar. Den största delen av d&d-produkter förekommer bland artiklar med låg ledtid och saknar helt prediktiva

modeller. Deras prognossäkerhet anses vara bra för etablerade produkter men mycket sämre för nya med mindre historiska data. Andra system som Power-BI används i inköpsprocessen för att stödja inköparnas beslutsfattning. AWR-systemet hjälper till att förutse säsongsprofiler som bygger på genomsnittlig efterfrågan över fyra år. Systemen som stödjer inköpsprocessen gör att Rexel arbetar mer reaktivt än proaktivt, speciellt med artiklar som är sjunkande i efterfrågan.’

4.5.1 Med AI som hjälp

För att åtgärda dessa typer av problem föreslås en konkret lösning där AI integreras i inköpsprocessen, som hjälper till att skapa ett prediktivt arbete, datadriven och automatiserad styrning. Fyra relevanta AI-verktyg har identifierats, se tabell 2. EasyStock, Netstock, Slim4 och Toolsgroup är verktyg som potentiellt kan minska kapitalbindningen och förbättra organisationers prognosering. För att företag ska lyckas krävs en djupdykning i de olika mjukvarorna för att identifiera vilken som fungerar bäst för organisationen och matchning av företagsstorleken. Djupdykningen bör göras genom att företaget själva kommer fram till vilka typer av utmaningar de har, samt storlek och omsättning som AI-verktyget ska hantera. Det kräver också en genomgång av de verktyg som redan används såsom ERP-systemet E3, AWR och Power-BI. Det tillsammans med en behovsanalys bör innehålla frågor som dessa:

- Vilka funktioner för lagerstyrning, prognoser, artikelklassificering och rapportering finns redan i systemet?
- Kan systemen ge realtidsdata, hanterar de säsongsvariationer eller saknas stöd för livscykelspanning?
- Vilka delar i inköpsprocessen kräver mest manuell handpåläggning idag? Vilka moment vill inköpare ha bättre stöd i?
- Kan systemen integreras och växa tillsammans med organisationen eller behövs externa stödverktyg?

Gemensamt med dessa verktyg är att de bygger på integration med företagets ERP-system och använder historisk data för att skapa automatiska prognoser, riskflaggor och åtgärdsförslag. Lösningen möjliggör ett skifte från erfarenhetsbaserade och reaktiva beslut till ett mer strategiskt och prediktivt arbetssätt

4.5.2 Guide till proaktivt arbete

Utöver AI lyfter resultatet även fram kompletterande förbättringsåtgärder som inte kräver teknisk implementation. Såsom strukturerad artikelklassificering, tydlig livscykelstyrning och säsongsplanering är olika verktyg företag kan använda sig av. Detta för att minska kapitalbindning och förbättra lageromsättning, från att arbeta reaktivt till att utveckla ett mer proaktivt arbetssätt. Artikelklassificering som ABC-analys och säsongsplanering med fasta kontrollpunkter kan bidra till minskat överlager (Ravinder & Misra 2014). Dessa metoder hjälper till att strukturera en tydlig avvikelserrapportering som tidigt kan åtgärda förändring i efterfrågan eller stillastående lager. Åtgärderna kräver inte avancerade system men skapar en stabil grund för datadriven utveckling och framtida automatisering.

I avsnitt 4.4.2 är ett enkelt exempel på hur en artikelklassificering kan användas. För att ta fram fasta kontrollpunkter i en inköpsprocess krävs ett systematiskt tillvägagångssätt där historisk produktdata analyseras. Genom att analysera gammal data kan mönster och avvikelser identifieras som föregår med information till att förhindra produkter i d&d. Detta är centralt i ett proaktivt arbetssätt där målet är att upptäcka riskartiklar i ett tidigt skede och vidta åtgärder

innan de skapar överskottslager och kapitalbindning. Baierle et al. (2024) understryker vikten i att använda den historiska data som finns i kombination med prediktiva modeller.

För att kunna förutse förändringar i efterfrågan är även kontrollpunkter viktigt att använda (Ravinder & Misra 2014). Kontrollpunkter kan baseras på exempelvis snabba försäljningsnedgångar, ovanligt låg lageromsättning, lång ledtid eller att artikeln saknar kundorder. Denna typ av indikation bör utlösa automatiska varningar i beslutsstödsystem och stödja den proaktiva styrningen. Kontrollpunkter kan enkelt kopplas till artikelklassificering, ABC-analys, där C-artiklar som har låg efterfrågan och högt kapitalvärde läggs i fokus. Det genererar att artiklar som kräver särskild övervakning fångas upp och prioriteras framför artiklar som inte behöver samma uppmärksamhet.

En annan viktig dimension i kontrollpunkterna är säsongspanering. Som rapporten nämner i kapitel 2.3.2 och 4.4.1 kan efterfrågan kraftigt variera beroende på årstid eller kampanjcykel. Genom att jämföra aktuell försäljning mot säsongshistorik kan avvikelser som tyder på felbeställningar eller överskattad efterfrågan snabbt upptäckas. Fasta kontrollpunkter jobbar istället tillsammans med säsongsvariationerna och blir en avgörande faktor för en anpassad lagerstyrning dynamiskt och strategiskt. Detta kan hjälpa till med minskning av kapitalbindning och onödig inkurans.

Tillsammans bidrar lösningarna till att företag stegvis kan förbättras och implementera den grad automation som önskas. Från processförbättringar till avancerade AI-verktyg kan de hjälpa inköpsprocessen beroende på företagets digitala mognad och affärsbehov. EasyStock och NetStock är mer lämpliga till företag som vill börja automatisera och optimera utan att riskera för mycket, mer som instegsverktyg (Mourtzis, Doukas & Vandera 2017). Slim4 och ToolsGroup är bättre lämpade till företag med komplexa lagerstrukturer, stora sortiment och hög digitalmognad (Xia et al. 2021). Men alternativ helt utan AI presenteras också i form av metoder som kräver att organisationer agerar mer proaktivt istället för reaktivt.

5. ANALYS

I kapitel fem utvecklas den empiriska studiens resultat med hjälp av befintlig teori. Syftet är att analysen lyfter hur de olika lösningarna kan appliceras på en inköpsprocess för att effektivisera, som i sin tur kan leda till en minskad mängd d&d-produkter. Med hjälp av befintlig teori kommer återkommande problem identifieras. Målet är att ge en förbättrad insikt i lösningsförslag som hjälper företag med d&d-produkter.

5.1 Analysering av resultat: utveckling av olika problem

Avsnittet är uppbyggt på att först förklara problemtyper inom organisationer. Sedan kommer ett avsnitt om hur företag kan implementera problemtyperna i praktiken, samt kommer en kort sammanfattningen i slutet av avsnittet. Avsnittet är uppdelat utifrån problem som kan finnas i organisationer. Brist på proaktiv analys och prognosverktyg och till sist icke integrerade system.

5.1.1 Reaktiv inköpsprocess och manuell arbetsbelastning

Den empiriska data som samlades in visade att den manuella arbetsbelastningen var stor och baserades helt och hållet på ett reaktivt arbetssätt. Ett problem som uppstår med det manuella arbetssättet är att inköpare själva måste identifiera avvikande artiklar som antingen är döende eller säsongsbaserade. Eftersom inköpare själva måste identifiera dessa artiklar blir arbetet reaktivt. En inköpare kommer att reagera på avvikande artiklar när de redan har börjat. Tidigare studier illustrerar att organisationer ofta arbetar reaktivt och ordet inköpsoptimering är ett relativt nytt fenomen (Jonsson 2021). Eftersom det är nytt inom SCM finns det fortfarande organisationer som är fast i det manuella reaktiva arbetssättet. Nackdelar med reaktivt arbete är att det ger en ökad risk för fel och är tidskrävande. Arbetssättet ökar också risken för att artiklar inte hinner upptäckas innan de blir d&d-produkter. Som Kerkkänen, Korpela och Huiskonen (2009) skriver finns det en ökad risk för prognosfel med manuell hantering. Prognosfelen kan leda till överlager och utan ett effektivt system som plockar upp d&d-produkter kan de förbli lagervaror och därmed öka kapitalbindningen.

AI och automatisering kan vara värdefulla när det kommer till hanteringen av d&d-produkter (Graham & Jordan 2025). AI kan hantera samma funktioner som traditionella inköpssystem, fast göra det med en högre kapacitet. Genom att använda sig av automatisering kommer felet vid manuellt arbete försvinna och beslutet kring artiklarna kommer att bli mer säkra. Enligt Spreitzenbarth, Bode & Stuckenschmidt (2024) kommer detta leda till lägre inkurans och bättre resursanvändning.

Fyra molnbaserade AI verktyg som ofta förklaras i litteraturen; EasyStock, NetStock, Slim4 och Toolsgroup, används huvudsakligen för att minska d&d-produkter genom lageroptimering. Gemensamt mellan dessa fyra är att de hanterar stora mängder data som rör sig kring efterfrågehistorik, säsongsmönster och lageromsättning. De hjälper till att hantera artiklar med hög risk för överlager och inkurans. Genom att beräkna prognoser och visualisera varningssystem bidrar det till en bättre proaktiv och datadriven inköpsstyrning och beslutsfattning. Skillnaden på dessa fyra ligger främst i storleken på företag, resurser och komplexitet.

På det tekniska planet behöver dessa system vara i symbios med andra typer av affärssystem som ERP, de behöver även tillgång till historiska data. Även fast verktygen automatiserar processen krävs fortfarande en viss kompetens till att manuellt tolka och agera på data som tas fram. Det kräver också att företaget har en villighet till att förändras, att gå från reaktiv till

proaktiv lagerstyrning som förutsätter anpassade rutiner och roller. AI kan integreras i inköpsprocessen på ett sätt som hjälper till med d&d-produkter, men också stödjer långsiktig planering och strategiska beslut. Genom att välja rätt verktyg kan det skapa utmärkta tekniska och organisatoriska förutsättningar, som i sin tur minskar kapitalbindning och ökar effektiviteten i inköpsprocessen.

5.1.2 Brist på proaktiv analys och prediktiva prognosverktyg

En viktig del av inköpsprocessen är prognoser, som bidrar till att kunna estimerade framtida efterfrågan och jobba mer proaktivt. Fältdata illustrerar att nyintroducerade artiklar som har låg träffsäkerhet, till skillnad från väletablerade artiklar. En problematik som kan uppkomma inom organisationer är brister på proaktiva analyser försvårar prognostisering av nya artiklar. Ett till problem som många organisationer har är att det ofta uppkommer prognosfel i högvolums produkter (Kerckhove, Korpela & Huisman 2009). Det kan leda till överlager och högkapitalbindning. Lagerhållningen och lönsamheten påverkas i hög grad av prognosfel inom organisationer (Zhou, Shen & Yu 2023). Automatisering av prognosarbetet kan motverka dessa typer av fel. Lönsamheten ökar med 7% inom organisationer som implementerar prediktiva modeller (Zhou, Shen & Yu 2023).

Ett bra ERP-system är viktigt för att kunna hantera stora mängder data (Microsoft u.å.b). ERP-system kan ha svårt att hantera stora datamängder hos väl etablerade företag, därför kan en bra lösning vara att komplettera med andra verktyg. För att skapa bra prognoser i krävs tillgång till historisk data. Med hjälp av flera organisatoriska metoder såsom artikelklassificering, säsongsplanering och livscykelrutiner, kan proaktiv inköpsplanering vara möjligt. Dessa metoder stödjer tidigare forskning från Ravinder och Misra (2014) som betonar värdet av ABC-analys. Fokus på artiklar med hög affärskritisk betydelse är mer gynnsamt att lägga resurser på. Att dessa metoder redan i viss mån används i verksamheter indikerar på teknisk automatisering, men inte nödvändigtvis en förbättrad styrning. I linje med det Silva et al. (2023) nämner hon att manuell säsongsplanering kan skapa bättre framförhållning och minska lagerhanterade risker. Studien visar att tydliga strukturer och rutiner kan förhindra inkurans och skapa bättre framförhållning, dock lutar sig studien hellre mot automatiserade processer för att minska den mänskliga faktorns risker för fel. Livscykelrutiner och avvikelshantering framstår i analysen som särskilt viktig eftersom det tidigt kan hantera artiklar som riskerar att utvecklas till d&d. Det stöds av Vlahakis, Kopanaki och Apostolou (2020) som lyfter vikten i att agera tidigt på signaler, snarare än att vänta tills effekten märks i försäljningsstatistiken. Dessa insikter tillsammans visar att ett proaktivt arbetssätt är fullt möjligt att införa med befintliga resurser, men kräver organisatorisk mognad och engagemang tillsammans med tydliga processer.

AI-verktyg kan hjälpa till med problemen. En konsekvens av att inte jobba proaktivt är inkurans i lagerhanteringen. Att börja arbeta proaktivt är åter igen viktigt för att minska slöseriet, sänka kostnader och öka resurseffektiviteten (Vlahakis, Kopanaki & Apostolou 2020). Baierle et al. (2024) skriver om hur AI och prediktiva modeller inte är en ersättare för mänskligt beslutstagande utan det ger organisationer bättre underlag för att fatta beslut kring efterfrågan. Med hjälp av proaktiva analyser kan framtida problematik förhindras innan det startar. Som tidigare tagits upp kan dessa fyra AI-verktyg användas för att förutse prognoser och arbeta proaktivt. Det kan också lösa problem om hur man ska hantera nya produkter med prognoser. Där det förutser att liknande produkter finns att jämföra med för att förutspå efterfrågan.

5.1.3 Integration mellan system

Utifrån den insamlade empiriska data var ett annat problem som identifierades att företagets system inte var integrerade med varandra. Många företag använder sig redan av proaktiv analys och verktyg som hjälper företaget att jobba prediktivt. Ett problem som uppstår hos exempelvis Rexel, trots användning av prediktiva verktyg, är att verktygen inte är integrerade med varandra. Det innebär att systemen arbetar parallellt och kan leda till glapp eller dubbelarbete. Att systemen inte är integrerade kan vara en anledning till att de inte fångar upp artiklar i tid, som i sin tur leder till uppkomst av d&d-produkter. Icke integrerade systemen kan även leda till försämrad datakvalité hos organisationer, vilket i sin tur skapar mer problematik i inköpsprocessen.

Som Graham och Jordan (2025) skriver är det viktigt att det finns ett befintligt ERP-system som vill förändra inköpsprocessen till mer proaktiv. AI och automatisering kan lösa problem med icke integrerade system, men fungerar också som ett verktyg inom organisationer för att hantera komplexa efterfrågan variation i inköp (Graham & Jordan 2025). Opton (2018) skriver också om potentiella lösningar hos AI-verktyg och även förmåga att analysera risknivåerna för varje SKU. Det skulle kunna vara fördelaktigt hos organisationen på många plan. Det finns även andra möjligheter som inte fokuserar på AI, utan istället lägger störst vikt i att försöka sammankoppla systemen. Som slutsats kan AI integreras med befintligt ERP system som skulle kunna lösa problemet och förhindra dubbelarbetet som systemen gör idag. Men är heller inte ett måste, utan kan göras utan AI-verktyg.

5.2 Implementering av AI

Implementering i en organisation kräver att identifiering av risker har gjorts innan. Nyamah et al. (2023) visar att prognos-, lagerinventering- och kundberoenderisker är viktiga att ta hänsyn till i inköpsprocessen. Genom att tydliggöra de här riskerna kan organisationer sätta upp gemensamma mål. Vid implementeringen av olika tillvägagångssätt för att minska d&dprodukter, är det viktigt att gemensamt jobba mot det mål som bestämts.

När målen är uppsatta krävs det att organisationen säkerställer att datagrunden och datakvaliteten är på plats innan arbetssätt förändras, eller eventuell AI-verktyg implementeras. ERP-system har ofta redan transaktionsdata som AI kräver för att kunna göra en lyckad implementering (Munyua 2023). Att den tekniska infrastrukturen är på plats när man implementerar den nya approachen i ERP-systemen är extremt viktigt och avgörande för att målen ska uppnås (Unal, Erkeyman & Usanmaz 2023). Om en organisation ska använda sig av AI är utvärderingen av olika verktyg och analys ett krav för lyckad implementering (Baierle et al. 2024).

Implementation av proaktivt arbete, istället för reaktivt, kan med hjälp av data som redan finns i organisationen vara starten för att flagga riskartiklar innan de blir d&d-artiklar. Med rätt prognosarbete kan prognosfel i högvolymprodukter kan hanteras (Kerckänen, Korpela & Huiskonen 2009). AI-verktygen kan också flagga riskartiklar i ERP-systemen. Det är därför viktigt att ha tydliga mål i god tid före implementeringen nya verktyg och arbetssätt. Det är också viktigt att förtydliga hur tolkning av rapporter från det nya arbetssättet ska utföras. Som Harrison et al. (2019, s.167) skriver är det viktigt att dedikera olika grupper i en organisation för att hantera olika risker som kan uppkomma.

5.3 Svar på forskningsfrågorna

I det här avsnittet besvaras forskningsfrågorna ytterligare. För att besvara forskningsfrågorna används befintlig teori från litteraturen. Syftet med detta arbete var att förbättra företags tekniska och organisatoriska förutsättningar, för att i sin tur minska kapitalbindning och förhindra d&d-produkter.

Vilka tekniska och organisatoriska förutsättningar krävs för att förbättra och eventuellt automatisera en inköpsprocess, med mål att minska kapitalbindning och förbättra lageromsättning?

För att förbättra och delvis automatisera en inköpsprocess i syfte till att minska kapitalbindning och förbättra lageromsättning krävs en kombination av organisatoriska och tekniska förutsättningar. Tydliga livscykelrutiner kan bidra till att identifiera artiklar som riskerar att hamna i d&d tidigare, så man kan avveckla dessa innan de hinner utvecklas. Det minskar kapital bindning och inkurans enligt Simões et al. (2020). Därmed är det viktigt att etablera processer för avvikelshantering vid förändring i efterfrågan, returer och stillastående lager. Det i sin tur leder till att man tidigare får chans att göra åtgärder innan artiklar hunnit utvecklas till att antingen vara i risk eller d&d (Vlahakis, Kopanaki & Apostolou, 2020).

På organisatorisk nivå är det av stor vikt att införa strukturerade arbetssätt som artikelklassificering, exempelvis ABC-analys, vilket gör det enklare att prioritera styrning av produkter med högt och låg omsättning (Ravinder & Misra 2014). Vidare krävs en tydligare manuell säsongsplanerad process. Tydliga fasta kontrollpunkter gör att företag tydligare kan förutse efterfrågemönster kopplade till kampanjer och variationer, som i sin tur minskar risken för överlager (Silva et al. 2023). Detta är olika exempel på åtgärder som kan göras på organisatorisk nivå utan att kräva avancerad teknik, men ändå skapar en stabil grund för mer datadriven styrning.

Tillförlitlig data och god kvalitet är ett krav för att den tekniska sidan ska få tillgång till att göra analys och automatisera. Integration mellan inköp, försäljning och lagersystem är återigen en viktig förutsättning för att kunna arbeta med realtidsinformation. Tillsammans skapar de tekniska förutsättningarna underlag för framtida automatisering och användning av prediktiva verktyg. Därmed utgör organisatoriska strukturer och datadrivet arbetssätt med en fungerande metod, men lämnar också utrymme för vidare utveckling.

Hur kan AI och automatisering integreras i inköpsprocessen för att uppmärksamma d&dprodukter snabbare, samt förbättra beslutsfattandet genom analys av produktartiklar som riskerar att utvecklas till d&d?

AI och automatisering kan genom predaktiv analys identifiera riskartiklar tidigt och förhindra förekomsten av d&d-produkter. Som Rao et al. (2018) skriver är AI och automatisering en central del av försörjningskedjor. Med hjälp av AI och automatiserings verktygen som tagits upp i litteraturen kan företag gå ifrån reaktivt prognosarbete till ett prediktivt arbete. Programmen som Easystock och Netstock integreras inom företag men är bättre designade för mindre till medelstora företag. Slim4 och ToolsGroup är kräver större koncentration att integrera, eftersom de är mer avancerade och fungerar som ett nät över hela organisationen. Vid en implementering vid något av de här AI verktygen kan företag förvänta sig att deras riskartiklar flaggas tidigare innan de börjar bli d&d-produkter. Den manuella belastningen kommer att minska också med automatiseringen, prognossäkerheten förväntas att bli bättre och för nya artiklar där programmen jämför dessa artiklar med liknande kommer en prognos kunna skapas (Kerkkänen, Korpela & Huiskonen 2009). Besluts-kulturen inom organisationer kommer också bli mer datadriven med hjälp av AI och automatisering.

För att lyckas implementera AI och automatisering i sin inköpsprocess krävs det en teknikinvestering samt organisatorisk mognad. Det krävs även en del tekniska förutsättningar. En viktig del är systemintegrationen där alla AI-verktygen integreras med en organisations befintliga ERP-system. AI-verktygen kräver också att det finns bra data och bra datakvalité i organisationen. Som Graham och Jordan (2025) skriver är stödet från data väldigt viktigt för att förhindra inkurans och felberäkningar i prognoser. Det krävs då en hel del tekniskt stöd för att kunna implementera AI och automatisering i en organisation men minst lika viktigt är också det organisatoriska stödet. Att arbetarna har rätt kompetens för att kunna hantera AI system är viktigt för en lyckad implementering (Graham & Jordan 2025). Innan man implementerar någon form av AI krävs det en viss form av intern utbildning på hur man ska tyda den samt att det krävs en villighet genom organisationen att göra förändringar (Mourtiz, Doukas & Vandera 2017).

6. DISKUSSION

I det här kapitlet tolkas resultatet förankrat med tidigare forskning samt den metodologiska ansats som använts. Avsnittet handlar om svar på forskningsfrågorna och fördjupad diskussion av resultatet. Till sist kommer även den valda metoden att diskuteras, samt möjligheter till framtida forskning.

6.1 Diskussion av lösningars potential i relation till studiens resultat och teori

Detta avsnitt syftar till att diskutera studiens resultat i relation till forskningsfrågorna, analysen och tidigare teori. Resultatet av studien visar att flera organisatoriska och tekniska faktorer är avgörande för att möjliggöra en effektiv och automatiserad inköpsprocess, med mål att minska kapitalbindning och förbättra lageromsättningen. Studien visar att organisatoriska åtgärder har stor roll vid möjliggörandet av ett mer förutseende inköpsarbete. De åtgärder som benämns i resultatet kan prioriteras till artikelklassificering, säsongspanering och etablerade livscykelrutiner. Dessa är mest betydelsefulla vid åtgärder för avveckling av d&d-produkter (Simões et al., 2020). Tolkningen blir då att företag som saknar avancerad teknik kan göra stora förbättringar genom att skapa strukturer för datainsamling, analys och beslutsfattande. Organisatoriska rutiner som avvikelserapportering, ansvarsfördelning och gemensamma styrmodeller kan fungera som både stöd för effektivt arbete. Men också som förutsättning till framtida automatisering. På den tekniska nivån visar studien att systemintegration av befintliga affärssystem underlättar arbetet med realtidsinformation. Visualiseringsverktyg, som exempelvis Power-BI, och tillgång till historisk data framstår som teknisk grund och stärker det dagliga beslutsfattandet. Den tidigare forskningen påpekar att tillförlitlig data och integration är viktiga faktorer i alla typer av prediktiva system (Rezai & Ortt 2024).

Studien visar också att AI och automatisering har en tydlig potential i att effektivisera inköpsprocesser och kan vara en central lösning vid hantering av d&d-produkter och riskhantering. Den andra forskningsfrågan behandlade hur AI kan användas för att minska förekomsten av d&d-produkter. Här visar resultatet ett molnbaserat AI-verktyg som kan möjliggöra ett mer proaktivt och datadrivet arbetssätt. Dock är det förutsatt att det är kompatibelt med befintliga ERP-system, som även betonas av Graham och Jordan (2025).

Flera verktyg med olika kapacitet identifierades, samtidigt som studies begränsningar är i beaktning. Detta är en kvalitativ fallstudie och riskerar därför att resultaten är väldigt kontextbundet. AI-verktygen har heller inte praktiskt testats i organisationen, vilket innebär att slutsatserna bygger på teoretisk potential snarare än observerad effekt. Det är också möjligt att feltolkningar från respondenterna eller forskarna själva har påverkat analysen.

Trots begränsningarna harmonierar resultatet med tidigare forskning. Studien visar att datakvalitet, systemkompatibilitet och intern kompetens är av stor vikt för att lyckas med implementationen. Det stöds av Mourtzis, Doukas och Vandera (2017) som belyser vikten av utbildning hos personal och förändringsberedskap innan automatisering. Studien visar också att teknik i sig inte är tillräckligt, utan organisatorisk mognad och tydliga roller i förändringsarbete är minst lika viktigt. Liu och Vakharia (2024) visar exempel hur AI-verktyg kan hjälpa till att förbättra efterfrågeprognoser och lagerhållning. Studien kompletterar tidigare litteratur med interna utmaningar som ofta förbises, exempelvis utbildningsbehov och förändringsmotstånd i inköpsarbetet. Sammanfattningsvis bekräftar resultaten förväntningar och stärker antagandet att AI-lösningar kan skapa nytta i hanteringen av d&d-produkter. En komplettering med förändringsledning och ytterligare förståelse i implementeringshinder skulle kunna generera en

positiv förändring. Studien visar att AI-verktygen inte bara erbjuder tekniska förbättringar, utan också ställer krav på organisatorisk utveckling för att rimligt kunna ge verktygen bästa möjlighet att nå full potential.

6.2 Slutsats i ljuset av resultat och teori

Som tidigare nämnt var syftet med denna studie att undersöka hur tekniska och organisatoriska faktorer kan möjliggöra en mer effektiv och datadriven inköpsprocess med lägre kapitalbindning och bättre lageromsättning. Med hjälp av analys, diskussion och metodreflektion kan studien formulera en tydlig slutsats utifrån syftet.

Med den genomförda kvalitativa fallstudien och empiriska data som samlats in i samverkan med företaget, kan studien fastslå att en effektiv och datadriven inköpsprocess är möjligt. Med en kombination av grundläggande tekniskt stöd och organisatoriska strukturer besvarar det studiens syfte. Resultatet visar att enkla metoder kan ge stor effekt, särskilt när de stöds av tillförlitlig data och integrerade system. Det är också möjligt att implementera AI-lösningar i inköpsprocessen för att identifiera riskartiklar i ett tidigare skede (Mourtzis, Doukas & Vandera 2017). Det i sin tur kommer också hjälpa till med att minska kapitalbindning och skapa ett mer proaktivt arbetssätt (Xia et al. 2021).

Slutsatsen är baserad på befintliga affärssystem, tillsammans med AI-verktyg som bygger på realtidsanalys och prediktiv modellering. Att integrera det i processen kan bidra till en förbättrad prognosprecision och lagerstyrning. Studien visar också att teknisk infrastruktur och organisatorisk mognad är av stor vikt för att framgångsrikt implementera AI. Metodvalet har gett en fördjupad förståelse men begränsar generaliserbarheten, som påverkar tolkningen av resultatet. Sammanfattningsvis bevisar studien att förändring från reaktivt till proaktivt arbete inte bara kan förbättra inköpsprocessen. Utan det skapar också möjlighet till mer datadrivna och långsiktigt hållbara inköpsbeslut inom B2B-verksamheter. Det i sin tur kan också skapa ingångar för ytterligare automatisering och potentiellt integrera AI-verktyg vid önskan.

6.3 Praktiska implikationer och problemformuleringens utveckling

För att konkretisera vad resultatet innebär för praktiken och för de aktörer studien riktar sig mot i problemformuleringen har följande implikationer formulerats. Slutsatsen kan delas in i olika implikationer som resultaten har för olika aktörer och intressenter. I detta skede kommer även undersökningens omfattning och relevans i relation till det ursprungliga problemet också diskuteras och undersökas.

Företag med stora sortiment och komplex lagerstruktur såsom Rexel (Bilaga 5) påvisas av studien att det finns en konkret lösning till hantering av riskartiklar (Mourtzis, Doukas & Vandera 2017). Denna lösning kan hjälpa till att minska d&d-produkter och därefter frigöra kapital. Med hjälp av denna studie kan beslutsfattande förlita sig mer på prediktiva verktyg och distansera sig från manuella rutiner om de vill. Det i sin tur effektiviserar arbetet och minskar risk för felbeslut (Mourtzis, Doukas & Vandera 2017).

AI kan också bidra till mer tillförlitliga beslutsunderlag och minska belastningen i den dagliga orderhanteringen hos inköpspersonal. Genom att istället jobba reaktivt på avvikelser och överskottslager kan inköparen agera proaktivt med stöd av AI-system som flaggar artiklar i risk i ett tidigare skede (Xia et al. 2021). Nackdelen med detta är dock att utbildning och ett förändrat arbetssätt påtvingas för att dataanalys ska kunna integreras i det operativa flödet.

Systemägare och IT-ansvariga behöver öppna upp ERP-system för integration med externa verktyg (Rao, Nilakantan, Iyengar & Lee 2018). Stabila datakällor som har tydlig struktur och historisk väsentlig information är ett krav för att systemen ska kunna fungera optimalt.

Resultatet i studien bevisar att teknisk förberedelse och datakvalitet är lika avgörande för en lyckad implementering som företagsmognad. Studiens avgränsningar till ett företag och interna inköpsprocesser gav en djupare analys av praktiska utmaningar och tekniska lösningar. Givet problemets komplexitet var detta en rimlig avgränsning. Men samtidigt var externa faktorer inte inkluderade och problemet som identifierades är riktat mot företag som har svårt att hantera produkter som hamnar i d&d. Studien är därför belyst ur ett konkret verksamhetsperspektiv och gör att studien bidrar med praktiska insikter.

6.4 Framtida forskning

Med hjälp av studiens resultat, metodupplägg och identifierade begränsningar finns flera intressanta riktningar för framtida forskning. Studien har bidragit med att belysa möjligheter med AI inom inköp, men också visat fler aspekter som är outforskade och kan kräva vidare undersökning.

En naturlig fortsättning skulle vara att genomföra flerfallsstudie där olika B2B-verksamheter jämförs. Det ger nästa studie ett mer breddat perspektiv och inkluderar faktorer som organisatoriska skillnader, teknisk infrastruktur och datamognad, som är en stor aspekt för en lyckad implementering. Genom att utföra en flerfallsstudie förstärker det resultatets överförbarhet, vilket i denna studie hade som begränsning. Det vore också bra att kombinera kvalitativ och kvantitativ datainsamling, genom att analysera större mängder systemdata eller genomföra en enkätstudie bland inköpare. Det i sin tur stärker resultatets generaliserbarhet och ger en statistisk aspekt på de insikter som genererats av studien.

Vidare till ytterligare potential vore att studera praktisk implementering av AI-system. Att undersöka hur de påverkar nyckeltal som kapitalbindning, servicegrad och lageromsättning över tid. Denna studie baserades på potentialen och förutsättningarna, men saknar ett faktum av effekter vid praktisk tillämpning. Men att utöka studien till det skulle innebära en mer longitudinell studie med före och eftermätningar, som passar till ett vidare projekt. Aspekten av den faktiska implementeringen av AI i inköp skulle ge studiens resultat ett perspektiv ur både ekonomi och organisatoriska möjligheter.

En annan möjlighet för en mer fördjupad forskning skulle kunna vara leverantörernas roll i d&d-problematiken. Att inkludera externa aktörer i leverantörskedjan kan bidra till ett mer holistiskt perspektiv och förståelse för orsaker till överlager och inkurans. Ett bredare perspektiv som omfattar hela värdekedjan snarare än endast interna inköpsprocessen.

Till sist kan ett sista behov att utveckla och undersöka användaranpassade AI-lösningar. Företag har ofta begränsade resurser och teknisk kompetens, forskning inom detta område skulle kunna bidra till en med skräddarsydd lösning för inköpsoptimering med hjälp av AI.

Sammanfattningsvis bevisar studien att AI har stor potential vid förbättring av inköpsprocesser, men fler empiriska och praktiska studier krävs för att förstå hur den potentialen bäst utnyttjas för olika organisatorers kontext. Behovet av framtida forskning som sammanfogar teknik, organisation och strategi är av stor nöd för att ge så bra möjligheter, för implementering av AI, som möjligt.

REFERENSER

Baierle, I. C., Haupt, L., Furtado, J. C., Pinheiro, E. T. & Sellitto, M. A. (2024). Forecasting raw material yield in the tanning industry: A machine learning approach. *Forecasting*, 6(4), s. 1078–1097. doi:10.3390/forecast6040054

Bajegani, H. Z. & Gholamian, M. R. (2022). Optimal Inventory Model with Time and Price Dependent Demand Under the Risk of Product Obsolescence. *International Journal of Applied and Computational Mathematics*, 8(1), Artikel 12. doi:10.1007/s40819-021-01230-z

Bartels, N. (2025). Miles & More GmbH selects Slimstock's Slim4 solution to optimize supply chain and inventory processes. <https://itsubwaymap.com/2025/03/11/miles-more-gmbh-selects-slimstocks-slim4-solution-to-optimise-supply-chain-and-inventory-processes/> [2025-05-09]

Cohen, B. (2023). AI in distribution: How artificial intelligence can drive growth. *Supply House Times*, 66(6), s. 13. Troy: BNP Media. Hämtad från ProQuest Central.

Culot, G., Podrecca, M. & Nassimbeni, G. (2024). Artificial intelligence in supply chain management: A systematic literature review of empirical studies and research directions. *Computers in Industry*, 162, Artikel 104132. doi:10.1016/j.compind.2024.104132

EasyStock (u.å.). EasyStock appen. <https://www.eazystock.com/sv/> [2025-05-06]

Graham, O. & Jordan, N. (2025). AI and Supply Chain Optimization: Reducing Errors in ERP Systems. Preprints.org. <https://www.preprints.org/manuscript/202504.0384/v1> [2025-05-06]

Harrison, A., Skipworth, H., van Hoek, R. & Aitken, J. (2019). *Logistics management and strategy*. 6 uppl., Studentlitteratur.

Jonsson, P. (2021). *Logistik – läran om effektiva materialflöden*. 4 uppl., Studentlitteratur.

Kerkkänen, A., Korpela, J. & Huiskonen, J. (2009). Demand forecasting errors in industrial context: Measurement and impacts. *International Journal of Production Economics*, 118(1), s. 43–48. doi:10.1016/j.ijpe.2008.08.008

Krishna, P. V. & Sharma, R. (2025). Advances in machine learning for data analytics. *International Journal of Computer Engineering and Research*, 7(2), s. 85–95. doi:10.22362/2349-7084

Liu, R. & Vakharia, V. (2024). Optimizing Supply Chain Management Through BO-CNN-LSTM for Demand Forecasting and Inventory Management. *Journal of Organizational and End User Computing*, 36(1), s. 1–25. doi:10.4018/JOEUC.335591

Microsoft (u.å.a). Power BI-översikt. <https://learn.microsoft.com/sv-se/power-bi/fundamentals/power-bioverview> [2025-05-07]

Microsoft (u.å.b). Vad är ERP? <https://www.microsoft.com/sv-se/dynamics-365/resources/what-is-erp> [2025-05-07]

Mourtzis, D., Doukas, M. & Vandera, C. (2017). Smart mobile apps for supporting product design and decision-making in the era of mass customisation. *International Journal of Computer Integrated Manufacturing*, 30(7), s. 690–707. doi:10.1080/0951192X.2016.1187295

Munyua, R. (2023). ERP Systems and Their Impact on Supply Chain Management. [förhandspublicerad online]. doi:10.93140/AE.2.2.12538.09926

Netstock (u.å.). Netstock. <https://www.getapp.com/operations-management-software/a/netstock/> [2025-05-06]

Nyamah, E. Y., Feng, Y., Yeboah Nyamah, E., Opoku, R. K. & Ewusi, M. (2023). Procurement process risk and performance: Empirical evidence from manufacturing firms. *Benchmarking: An International Journal*, 30(1), s. 75–101. doi:10.1108/BIJ-06-2021-0306

Opton (2018). Case report: Thule Group improves supply chain planning. <https://optilon.com/wpcontent/uploads/2018/06/Case-report-Thule.pdf> [2025-05-09]

Osmonbekov, T., Johnston, J. W. & Donthu, N. (2024). Artificial intelligence advancements in procurement: Transforming organizational buying behavior. *Journal of Business & Industrial Marketing*, 39(12), s. 2745–2758. doi:10.1108/JBIM-01-2024-0026

PR Newswire (2024a). Netstock Earns Spot on G2's 2024 Best Software Awards for Highest Satisfaction. ProQuest. <https://www.proquest.com/docview/3106350375?pq-origsite=primo&accountid=9670> [2025-05-06]

PR Newswire (2021b). Netstock Named a Leader in G2's Winter 2022 Grid Report for Demand Planning Software. ProQuest. <https://www.proquest.com/docview/2550599814?accountid=9670> [2025-05-06]

Rao, S., Nilakantan, R., Iyengar, D. & Lee, K. B. (2018). On the viability of fixing leaky supply chains for the poor through benefit transfers: A call for joint distribution. *Journal of Business Logistics*. doi:10.1111/jbl.12189

Ravinder, H. och Misra, R.B. (2014) 'ABC Analysis for Inventory Management: Bridging the Gap Between Research and Classroom', *American Journal of Business Education*, 7(3), ss. 257–264.

Rejeb, A. & Appolloni, A. (2022). The nexus of Industry 4.0 and circular procurement. *Sustainability*, 14(23), Artikel 15633. doi:10.3390/su142315633

Rexel. (2025a). Dead & dying leverantörer. Intern rapport, tillhandahållen av [Inköpsavdelning], [2025-04-02]. Ej publicerat material.

Rexel. (2025b). D&D & överlager leverantör. Intern rapport, tillhandahållen av [Inköpsavdelning], [2025-04-02]. Ej publicerat material.

Rexel. (2025c). Lagerartiklar. Intern rapport, tillhandahållen av [Inköpsavdelning], [2025-04-02]. Ej publicerat material.

Rexel. (2025d). L2a_inventory_provision_Bolag_Rexel. Intern rapport, tillhandahållen av [Inköpsavdelning], [2025-04-02]. Ej publicerat material.

Samuels, A. (2024). Examining the integration of artificial intelligence in supply chain management from Industry 4.0 to 6.0: A systematic literature review. *Frontiers in Artificial Intelligence*, 7, Artikel 1477044. doi:10.3389/frai.2024.1477044

Silva, R., Kumar, R., Khan, M. & Hussain, M. (2023). *Optimizing inventory management with seasonal demand forecasting in a fuzzy environment*. *International Journal of Supply Chain Management*, 12(1), s. 45–56.

Simões, J., Martins, J., Silva, F. J. G. & Campilho, R. D. S. G. (2023). *Challenges and opportunities in product life cycle management in the context of Industry 4.0*. *Procedia CIRP*, 104, s. 123–128.

Slimstock (u.å.). Slim4-plattformen. <https://www.slimstock.com/se/topic/slim4-platform-se/> [2025-05-06]

Spreitzenbarth, J. M., Bode, C. & Stuckenschmidt, H. (2024). Artificial intelligence and machine learning in purchasing and supply management: A mixed-methods review of the state-of-the-art in literature and practice. *Purchasing and Supply Management*, 30(1), s. 1–21. doi:10.1016/j.pursup.2024.100896

Steiner, T. (2022). *Modernt inköp*. 1:3 uppl., Studentlitteratur.

Säfsten, K. & Gustavsson, M. (2020). *Forskningsmetodik för ingenjörer och andra problemlösare*. 1:2 uppl., Studentlitteratur.

Sörqvist, L. & Bergendahl, M. (2021). Lean: Processutveckling med fokus på kundvärde och effektiva flöden. 2:1 uppl., Studentlitteratur.

Toolsgroup (u.å.). SO99+ platformen. <https://www.toolsgroup.com/solutions/inventory-optimizationsoftware/> [2025-05-06]

Unal, Ö. A., ErKayman, B. & Usanmaz, B. (2023). Application of artificial intelligence in inventory management: A systematic review of the literature. *Applied Mechanics Reviews*, 30(1). doi:10.1007/s11831-022-09879-5

Vlahakis, G., Kopanaki, E. & Apostolou, D. (2020). Proactive decision making in supply chain procurement. *Journal of Internet Commerce*, 30(1), s. 28–50. doi:10.1080/10919392.2019.1671739

Wilson, M. & Goffnett, S. (2022). Reverse logistics: Understanding end-of-life product management. *Business Horizons*, 65(5), s. 643–655. doi:10.1016/j.bushor.2021.10.005

Xia, K., Saily, C., Kirkpatrick, M., Anumbe, N., Sheth, A. & Harik, R. (2021). Towards semantic integration of machine vision systems to aid manufacturing event understanding. *Sensors (Basel, Switzerland)*, 21(13), Artikel 4276. doi:10.3390/s21134276

Zhou, Y., Shen, X. & Yu, Y. (2023). Inventory control strategy: Based on demand forecast error. *Modern Supply Chain Research and Applications*, 5(2), s. 74–101. doi:10.1108/MS CRA-02-2023-00

BILAGOR

Bilaga 1 – D&D & överlager leverantörer

[D&D & överlager leverantörer.xlsx](#)

Bilaga 2 – Dead & dying leverantörer

[Dead & dying leverantörer.xlsx](#)

Bilaga 3 – Lagerartiklar

[Lagerartiklar anonym.xlsx](#)

Bilaga 4 – L2a Inventory Provision

[L2a Inventory Provision Bolag Rexel anonym.xlsx](#)

Bilaga 5 – Artiklar i ABC-analys

[Alla artiklar anonymiserade ABC Frekvens](#)



HÖGSKOLAN
I BORÅS