

AALBORG UNIVERSITET

AALBORG BUSINESS SCHOOL

10. SEMESTER

GRUPPE 13

**Eksponering for kunstig intelligens i arbejdslivet:
Effekter på jobmobilitet og opkvalificering**

03/06/2025





**Det Samfunds-
videnskabelige Fakultet**
Aalborg Business School
Fibigerstræde 2
9220 Aalborg

Titel:

Eksponering for kunstig intelligens i arbejdslivet:
Effekter på jobmobilitet og opkvalificering

Projekt:

10. Semester

Projektperiode:

02/2025 - 06/2025

Deltagere:

Christian Bernth: 20184649

Emma Skipper: 20206684

Vejleder:

Jacob Rubæk Holm

Antal tegn med mellemrum: 175.612

Rapport sidetal: 69

Bilag sidetal: 7

Total sidetal: 90

Afsluttet d. 03-06-2025

Abstract

This project examines how occupational exposure to artificial intelligence (AI) influences job mobility and upskilling within the Danish labour market. Using the AI Occupational Exposure (AIOE) index developed by Felten et al. (2021), AI exposure scores are then linked to Danish labour data from 2010 to 2021 to explore shifts in labour market dynamics across ISCO-defined skill groups.

The analysis focuses on ISCO groups 1–4, including managers, academics, technicians, and clerical support workers' occupations with relatively high AI exposure. Patterns of job changes and course participation are analyzed using survival models with repeated events, applying the Prentice, Williams, and Peterson gap time (PWP-GT) approach. AI exposure is operationalized both continuously and categorically to allow for differentiated analysis.

Findings indicate a positive correlation between higher AI exposure and decreased likelihood of both job transitions and participation in training activities. This relationship is particularly evident among high- and mid-skill groups, suggesting that AI exposure may drive proactive adjustment, thereby stabilizing workers in their existing positions. Conversely, leader occupations tend to show higher engagement in upskilling, along with basic office occupations.

Rather than supporting a narrative of large-scale displacement, the results suggest that AI exposure is associated with increased individual mobility and learning. Upskilling appears to function as a key mechanism for adapting to technological change.

This study contributes to the empirical literature by offering a context-specific analysis of AI's impact on workforce dynamics, highlighting the importance of continuous learning and targeted policy responses in navigating labor market transitions.

Denne rapport er udarbejdet af studerende på 10. semester ved AAU Business School, Aalborg Universitet, i foråret 2025. Arbejdet er udført som led i den afsluttende del af kandidatuddannelsen og er baseret på en problembaseret læringstilgang, som karakteriserer Aalborg-modellen.

Rapporten benytter Harvard-metoden til kildehenvisning for at sikre korrekt og konsekvent akademisk referencepraksis. Arbejdet er udarbejdet under vejledning af Jacob Rubæk Holm, som vi gerne vil takke for faglig sparring og konstruktiv feedback gennem projektforløbet.

Christian Bernth

Christian Bernth

Emma Skipper

Emma Skipper

Nomenclature

Forkortelser

AG Andersen Gill model

AIC Akaike's Information Criterion

AIOE Artificial Intelligence Occupational Exposure

GT Gap time - Tid siden sidste hændelse

$h_k(t)$ Hazard ratio ved hændelse k

HR Hazard Ratio

PH Proportional Hazard

PWP Prentice, Williams, and Peterson model

PH-test Test af proportional hazards antagelsen

Symbol forklaring

β Koefficient

$\mathbf{z}$ Vektor af forklarende variabler

$\exp(\beta)$ Hazard ratio

$h_0(t)$ Baseline hazardrate

Figurer

1.1	Densiteten af AIOE-score for danske jobstillinger i hhv. høj, midt- og lav-skill .	6
1.2	Fordeling af danske arbejdstagere, opdelt i Høj-, Midt- og lav skill gruppe i 2019.	7
1.3	Fordeling af danske arbejdstagere baseret på deres AIOE-score	8
2.1	Eksempel på gennemsnitsudregning af ISCO-koder.	16
2.2	Struktur i PWP-GT modellen: Gap time måles mellem hændelser, og stratificering sker på eventnummer.	24
4.1	Træning i AI Chatbots (Humlum og Vestergaard, 2025)	37
5.1	Heatmap for stillinger med AI-potentiale, kolonnen udgør summen af alle andele til 100.	40
A.1	Schoenfeld residuale plot med ± 1 konfidensinterval for kursus model 1	75
A.2	Schoenfeld residuale plot med ± 1 konfidensinterval for kursus model 2	75
A.3	Schoenfeld residuale plot med ± 1 konfidensinterval for kursus model 3	76
A.4	Schoenfeld residuale plot med ± 1 konfidensinterval for jobskifte model 1	78
A.5	Schoenfeld residuale plot med ± 1 konfidensinterval for jobskifte model 2	78
A.6	Schoenfeld residuale plot med ± 1 konfidensinterval for jobskifte model 3	79
A.7	Schoenfeld residuale plot med ± 1 konfidensinterval for jobskifte model 3b	79
A.8	AIOE-score kontinuerlig effekt på risiko for kursusdeltagelse	80
A.9	AIOE-score kontinuerlig effekt på risiko for jobskifte	80

Tabeller

1.1	Oversigt over de mest og mindst AI-eksponerede jobstillinger.	4
5.1	Udvikling og mobilitet på ISCO-niveau 1-4 fra 2010 til 2021	38
5.2	AIC-sammenligning af modeller for kursusdeltagelse	43
5.3	Model 1 - Kursusdeltagelse med AIOE som kontinuerlig variabel	43
5.4	Model 2 - Kursusdeltagelse: AIOE som gruppeopdelt	45
5.5	Model 3 - Kursusdeltagelse: AIOE-grupper og interaktioner	46
5.6	AIC-sammenligning af modeller for jobskifte	49
5.7	Model 1 - Jobskifte: Med AIOE-score som kontinuerlig variabel	49
5.8	Model 2 - Jobskifte: Med AIOE-gruppering	50
5.9	Model 3 - Jobskifte: AIOE-grupper med interaktioner	52

5.10	Model 3b - Jobskifte: AIOE-score med interaktioner	53
5.11	HR-effekter - Kursusdeltagelse med og uden jobskifte kumulativ	55
5.12	HR-effekter - Jobskifte med og uden kursus kumulativ	55
A.1	Test af proportional hazards-antagelsen (Schoenfeld residualer)	74
A.2	Test af proportional hazards-antagelsen (Schoenfeld residualer)	77

Indholdsfortegnelse

Nomenclature	v
Kapitel 1 Introduktion	1
1.1 AI's indflydelse på arbejdsmarkedet og jobpolarisering	1
1.1.1 Skill-niveauer og AI's arbejdsmarkedseffekter	2
1.2 Jobpolarisering og teknologisk påvirkning af mobilitet	4
1.2.1 Jobmobilitet i dansk kontekst	5
1.3 Arbejdsmarkeds eksponering	6
1.4 Problemformulering	10
1.4.1 Hovedspørgsmål	10
1.5 Afgræsning af fokusområde	10
1.5.1 Underspørgsmål	11
1.6 Litteraturreview	11
Kapitel 2 Metode	15
2.1 AI Occupational Exposure (AIOE)	15
2.2 Anvendte variable og datadefinitioner	16
2.2.1 Population og ISCO-baseret afgrænsning	16
2.2.2 Eventvariable og tidsstruktur	17
2.2.3 AIOE-score og jobrelaterede variable	17
2.2.4 Kursusvariabel og opkvalificering	17
2.2.5 Andre kontrolvariable og baggrund	18
2.2.6 Outliers	19
2.3 Metodisk tilgang til gentagne hændelser	19
2.3.1 Cox regression model	19
2.3.2 Andersen Gill (AG) model:	21
2.3.3 Prentice, Williams, and Peterson gap time (PWP-GT) model:	22
2.4 Begrundelse for at inkludere både job- og kursusmodeller	24
2.4.1 Potentielle bias og håndtering i analysen	25
Kapitel 3 Redegørelse	26
3.1 Jobmobilitet på det danske arbejdsmarkedet	26
3.2 Megatrends på arbejdsmarkedet	28
3.2.1 Klimaforandringer og arbejdsmarkedet	28
3.2.2 Teknologisk udvikling og digitalisering	29
3.2.3 Demografisk udvikling	29
3.2.4 Fremtidens arbejdsliv	29

3.2.5	Økonomisk udvikling	29
3.2.6	Megatrends og arbejdsmarkedets fremtid	30
3.3	Kursusdeltagelse og bagvedliggende mekanismer	32
Kapitel 4	Teori	33
4.1	Jobmobilitet på arbejdsmarkedet	33
4.2	Tilegnelse af viden	34
4.2.1	Efter- og videreuddannelse	34
4.2.2	Initiativ og incitament i efter- og videreuddannelse	36
Kapitel 5	Analyse	38
5.1	Deskriptive analyser og visualiseringer	38
5.1.1	Bevægelse på arbejdsmarkedet	38
5.1.2	Heatmap for jobmobiliteten fra 2010 til 2021	39
5.2	Modelstruktur og analytisk tilgang	41
5.3	Prentice-Williams-Peterson Gap-Time analyse af kursusdeltagelse events	42
5.3.1	Modelvurdering	42
5.3.2	PWP-GT kursus model AIOE-score	43
5.3.3	PWP-GT kursus model AIOE-gruppe	45
5.3.4	PWP-GT kursus model AIOE-interaktioner	46
5.4	Prentice-Williams-Peterson analyse af jobskifte events	47
5.4.1	Modelvurdering	48
5.4.2	PWP-GT jobskift model AIOE-score	49
5.4.3	PWP-GT jobskift model AIOE-gruppe	50
5.4.4	PWP-GT jobskift model AIOE-interaktioner	52
5.4.5	PWP-GT jobskift model 3b - AIOE-score + interaktioner	53
5.4.6	Vurdering af model og tilgang	54
5.5	Robusthedstest af modelvalg	54
5.5.1	Kursus model sammenligning	55
5.5.2	Jobskifte model sammenligning	55
Kapitel 6	Diskussion	56
6.1	Analytisk refleksion	56
6.1.1	Diskussion af Heatmap og Bevægelse på Arbejdsmarkedet	56
6.1.2	Model 1 AIOE som kontinuerlig variabel (Kursusdeltagelse)	57
6.1.3	Model 2 AIOE som grupperet variabel (Kursusdeltagelse)	58
6.1.4	Model 3 Interaktioner (Kursusdeltagelse)	58
6.1.5	Model 1 AIOE som kontinuerlig variabel (Jobskifte)	59
6.1.6	Model 2 AIOE som grupperet variabel (Jobskifte)	60
6.1.7	Model 3 Interaktioner (Jobskifte)	60
6.2	Model 3b - alternativ model til model 3 (jobskifte)	61
6.2.1	Efter- og videreuddannelse som mekanisme for jobmobilitet	62
6.2.2	Jobskifte som tilpasningsstrategi	62

6.3	Fejlkilder og usikkerheder	63
6.3.1	Kursusvariablen er delvis proxy	63
6.3.2	Jobskiftevariabel	63
6.3.3	Afgrænsning til ISCO 1-4	64
6.3.4	COVID-19	64
6.3.5	Modelusikkerhed Jobmodel 2 og 3	64
6.3.6	Alternative modeller	64
6.3.7	Generelle udfordringer ved modelstruktur	65
Kapitel 7	Konklusion	66
Kapitel 8	Perspektivering	68
Litteratur		70
Appendiks A	Supplering til analyserne	74
A.1	Validerings test kursus	74
A.2	Validerings test jobskifte	77
A.3	AIOE kontinuerlig effekt for kursusdeltagelses model 1	80
A.4	AIOE kontinuerlig effekt for jobskifte model 1	80

1.1 AI's indflydelse på arbejdsmarkedet og jobpolarisering

Digital automatisering og kunstig intelligens (AI) er i fuld gang med at forandre arbejdsmarkedet og redefinere, hvordan vi arbejder. Teknologier, der tidligere blev betragtet som fremtidige løsninger, er nu integreret i dagligdagen og påvirker alt fra rutineopgaver til komplekse beslutningsprocesser. Denne udvikling skaber nye muligheder, men medfører også betydelige omstruktureringer på tværs af sektorer.

Kunstig intelligens (AI) er en central del af denne teknologiske revolution. AI dækker over en bred vifte af teknologier til at efterligne menneskelig intelligens og automatisere opgaver. Det inkluderer alt fra simple automatiserede processer til avancerede maskinlæringsmodeller. AI er defineret som teknologier, der anvender avancerede algoritmer og dataanalyse til at træffe beslutninger eller understøtte menneskelig beslutningsprocesser. AI er ikke blot en fremtidsvision, men en teknologi, der allerede har sat sit præg på arbejdsmarkedet og vores daglige liv (Dahl et al., 2024). Mange mennesker interagerer dagligt med AI-teknologier, ofte uden at være bevidste om det. Eksempelvis anvendes AI i søgemaskiner, maskinoversættelse, for eksempel Google Translate, samt ansigts- og stemmegenkendelse. AI er også en integreret del af smarte enheder som stemmestyrede assistenter, chatbots og anbefalingssystemer på streamingtjenester (Leander, 2023).

På arbejdspladsen kan AI bidrage til at effektivisere processer, automatisere opgaver og understøtte beslutningstagning på tværs af brancher. Ved at analysere store datamængder kan AI identificere mønstre og trends, som mennesker måske overser, hvilket gør det muligt for virksomheder at træffe mere informerede beslutninger. AI anvendes til at optimere produktionsprocesser, forbedre kundeservice gennem chatbots og virtuelle assistenter, samt forudsige vedligeholdelsesbehov i industrien, hvilket reducerer driftsomkostninger og minimerer fejl. Yderligere kan AI tilpasses branchers behov. Eksempelvis kan AI i sundhedssektoren anvendes til at diagnosticere sygdomme ud fra medicinske billeder, som vist i studier (Leander, 2023), der fremhæver AI's præcision i radiologi. I finanssektoren anvendes AI til risikovurdering, opdagelse af svindel samt automatiseret handel. AI's indflydelse er uundgåelig, og den vokser i takt med teknologiens fremskridt og udbredelse. Denne vækst drives især af forbedringer i datatilgængelighed, algoritmisk effektivitet og øget computerkraft (Dahl et al., 2024).

I takt med at AI bliver mere avanceret og udbredt, ændres arbejdsmarkedets dynamik

markant. Virksomheder implementerer i en stigende grad AI-baserede løsninger for at optimere arbejdsgange, øge produktiviteten og reducere omkostninger. Automatisering af rutineprægede opgaver betyder, at medarbejdere i visse brancher skal omstille sig til nye roller, der kræver mere analytisk og kreativ tænkning. Derudover er der en voksende efterspørgsel på teknologiske færdigheder, hvor AI-relaterede kvalifikationer inden for dataanalyse, maskinlæring og programmering bliver mere værdifulde. Derved opstår en dynamik, hvor visse højt specialiserede erhverv udnytter adgangen til AI som et værktøj til optimering, mens simple jobstillinger, der har automatiserbare opgaver, oplever risiko for at blive overflødige eller at skulle søge opkvalificering (Teutloff et al., 2025).

1.1.1 Skill-niveauer og AI's arbejdsmarkedseffekter

Samtidig peger anden forskning også på, at denne teknologiske udvikling ikke påvirker alle jobtyper ens. Ifølge Goos et al. (2014) er arbejdsmarkedet i stigende grad præget af jobpolarisering, hvor "high-skill" og "low-skill" job vokser, mens "mid-skill" job gradvist forsvinder. Dette skyldes blandt andet, at mellemlønnede rutineprægede opgaver ofte er lettere at automatisere. Goos et al. (2014) anvender International Standard Classification of Occupations (ISCO) til at definere disse kategorier. Høj-skill omfatter ISCO-koder, der starter med 1, 2 og 3, som dækker ledere, teknikere og højtuddannede fagfolk. Midt-skill dækkes af ISCO-koder, der starter med 4, 6, 7 og 8, herunder kontorarbejdere og håndværkere. Hvor lav-skill omfatter ISCO-koder, der starter med 5 og 9, hvilket inkluderer servicearbejdere og ufaglærte.

Kobler man denne klassificering sammen med, hvordan AI integreres på arbejdspladserne, tegner der sig et fælles billede af en skæv udvikling på arbejdsmarkedet, præget af øget polarisering. Anvendelsen af AI interagerer tæt med disse skillgrupper, idet teknologien ofte skaber nye muligheder i høj-skill stillinger, mens den samtidig øger presset på rutineprægede midt- og lav-skill jobs, som i højere grad kan automatiseres.

De lavtlønnede jobs, betegnet som lav-skill, udføres primært af personer med begrænset formel uddannelse og færre tekniske færdigheder. Mellemlønnede jobs, midt-skill, kræver en vis grad af specialiseret viden og erfaring, men ikke nødvendigvis en lang formel uddannelse. Højt betalte jobs, høj-skill, involverer avancerede færdigheder og højere uddannelsesniveauer (Goos et al., 2014).

Midt-skill gruppen befinder sig i en bred mellemposition, eftersom AI kan lette arbejdsbyrden samt skabe nye krav om teknologiske færdigheder. Administrative medarbejdere og teknisk personale kan drage fordel af AI-værktøjer, da de kan automatisere opgaver og øge effektiviteten. De skal dog samtidig tilpasse sig de nye arbejdsmetoder samt opkvalificeres for at følge med den teknologiske udvikling. Udfordringen for midt-skill gruppen er, at de ligger i en balance mellem at kunne udnytte teknologiens fordele, samtidig med at de skal undgå, at visse funktioner bliver overflødige, hvilket øger behovet for kontinuerlig kompetenceudvikling (Dahl et al., 2024).

Høj-skill jobstillinger drager ofte en stor fordel af AI, eftersom teknologien kan anvendes

til at udføre avancerede dataanalyser, optimere komplekse processer samt understøtte en strategisk beslutningstagning. Eksempelvis kan finansanalytikere og ingeniører anvende AI til at forudsige tendenser og automatisere modeller, dermed øges effektiviteten og innovationen. For lav-skill jobstillinger, som typisk har rutineprægede og manuelle opgaver, er mulighederne for AI-integration mere begrænsede. Flere jobstillinger herunder er udsat for automatisering, dermed øges risikoen for, at visse jobstillinger bliver overflødige (Dahl et al., 2024). Dertil kunne det være lagerstyring eller rengøring, hvor automatiserede værktøjer øger produktiviteten betydeligt. Der er dog brancher som byggeri, hvor automatisering er mere udfordrende, eftersom det kræver en fysisk tilstedeværelse og håndværksmæssige færdigheder (Damm et al., 2021).

AI ændrer ikke kun selve arbejdsopgaverne, men også arbejdsstrukturen. Flere virksomheder bevæger sig mod hybride arbejdsmiljøer, hvor AI understøtter fjernarbejde, intelligente mødeplanlægningssystemer og automatiseret kommunikation. Samtidig skaber teknologien et øget behov for både tekniske specialister og menneskelige kompetencer. Soft skills som problemløsning, kritisk tænkning og samarbejde bliver stadig vigtigere, efterhånden som AI overtager rutineprægede opgaver. Når medarbejderne frigøres fra tidskrævende og gentagne opgaver, kan de fokusere mere på komplekse og værdiskabende opgaver, dermed øges effektiviteten. På den måde får man en mere dynamisk arbejdsplads, hvor de menneskelige kompetencer bliver udnyttet optimalt. Derudover er der en stigende efterspørgsel efter dataeksperter, der kan udvikle og optimere AI-modeller, Big Data-analytikere, der omsætter store datamængder til indsigt, samt AI-etikereksperter, der sikrer ansvarlig brug af teknologien (Hau, 2024). Denne udvikling understreger vigtigheden af løbende opkvalificering og tilpasning af arbejdsstyrkens kompetencer for at imødekomme de skiftende krav på arbejdsmarkedet som følge af AI's fremmarch. I denne sammenhæng bliver deltagelse i relevante kurser og efteruddannelsesforløb en væsentlig mekanisme til at ruste arbejdstagere til nye krav og understøtte mobilitet på tværs af jobstillinger og sektorer.

En nyere metode til at undersøge, hvordan AI kan påvirke arbejdsmarkedet, kan være AI Occupational Exposure (AIOE), der blev udviklet af Felten et al. (2021). Denne måling af eksponering angiver, hvilke jobstillinger der kan benytte AI til opgaver på arbejdspladsen. En høj AIOE-score vil betyde en stor eksponering over for AI, imens en negativ AIOE-score vil betyde, at AI kun kan blive udnyttet i et meget begrænset omfang eller kun i meget specifikke tilfælde, der ikke er en primær opgave i arbejdsgangen. Denne måling tillader at kunne bedømme potentialet for AI-implementering for jobstillinger og kortlægge, hvilke stillinger der kan være potentielt sårbare over for fremskridt i AI, og hvor der kan opstå efterspørgsel efter færdigheder relateret til AI.

Den måde, hvorpå AI påvirker forskellige typer job, hænger dermed ikke alene sammen med mulighederne, men også med bredere forskydninger på arbejdsmarkedet. Dette kommer i form af jobpolariseringen og dens sammenhæng med teknologisk udvikling og mobilitet.

1.2 Jobpolarisering og teknologisk påvirkning af mobilitet

Jobpolarisering refererer til den strukturelle tendens i arbejdsmarkedet, hvor der observeres en stigning i antallet af lavtlønnede og højtbetalte jobs, men antallet af mellemlønnede jobs falder. Denne udvikling kan i høj grad kobles til jobmobilitet, idet bevægelser på arbejdsmarkedet kan accelerere eller forstærke polariseringen (Goos et al., 2014).

Jobmobilitet spiller en central rolle i denne polarisering. Teknologiske fremskridt og globalisering har skabt en dynamik, hvor midt-skill jobs i stigende grad automatiseres eller outsources. Der er fortsat jobs i midt-skill, men antallet er faldende, hvilket skaber et pres på arbejdstagerne. En del tvinges til at skifte til lavtlønnede servicejobs, mens andre opkvalificerer sig til højt betalte stillinger. Denne bevægelse kan ses som en effekt af arbejdsmarkedets tilpasning, hvor arbejdstagere enten bevæger sig nedad i løn- og færdighedsniveau eller opad gennem videreuddannelse og specialisering (Goos et al., 2014).

Denne proces kan forklares ved, at teknologisk udvikling og øget offshoring reducerer efterspørgslen efter midt-skill jobs, mens efterspørgslen efter høj-skill øges pga. behovet for at udvikle, administrere og vedligeholde avancerede teknologier. Samtidig stiger efterspørgslen efter lav-skill servicejobs, eftersom de ofte er svære at automatisere og kræver menneskelig interaktion (Goos et al., 2014).

Derudover kan regionale forskelle i jobmobilitet og polarisering observeres. I storbyområder, hvor der er større adgang til uddannelsesinstitutioner og teknologiske arbejdspladser, ser man ofte en højere grad af opadgående mobilitet mod høj-skill jobs. I modsætning hertil kan landsdistrikter og områder med få uddannelsesmuligheder opleve en koncentration af lav-skill jobs, hvilket yderligere forstærker den geografiske ulighed i jobpolariseringen (Kristiansen et al., 2022).

Derfor kan jobpolarisering ses som en direkte konsekvens af jobmobilitet, hvor arbejdstagernes bevægelse på tværs af sektorer og færdighedsniveauer bidrager til den ændrede beskæftigelsesstruktur. I denne proces kan opkvalificering og deltagelse i efteruddannelseskurser fungere som en strategisk mulighed for arbejdstagere, der søger at bevæge sig mod mere stabile eller AI-egnede jobstillinger.

Gruppe	Højeste AIOE score	Laveste AIOE score
Højskill	Økonomidirektør (1211) AIOE: 1.446	Dans og koreografi (2653) AIOE: -2,123
Midt-skill	Konsulent (4416) AIOE: 1.353	Tagdækker (7121) AIOE: -1,753
Lav-skill	Telefonsælger (5244) AIOE: 1.118	Manuelt vask af tøj (9121) AIOE: -1,950

Tabel 1.1. Oversigt over de mest og mindst AI-eksponerede jobstillinger.

Tabel 1.1 giver eksempler på højeste og laveste AIOE-score indenfor hver skill-gruppe. Dermed opsættes den ramme, hvorved stillinger i hver gruppe kan befinde sig imellem.

For høj-skill er rammen primært i den positive ende af AIOE-scores. Betydningen af dette er, at disse stillinger med en positiv AIOE-score har et potentiale til at udnytte AI i en vis grad. Her angives økonomidirektør som en stilling, der især kan benytte AI til sine arbejdsopgaver, hvor en stilling som dans og koreografi i samme gruppe er den laveste og har en negativ score. Dette vil betyde, at implementering af AI i de primære arbejdsopgaver er udfordrende eller ikke muligt. Ser man på midt-skill gruppen, vil rammen indeholde stillinger fra meget eksponeret til meget lavt eksponeret jobstillinger. Dette dækker for eksempel konsulenter, der kan udnytte AI til deres arbejdsopgaver, og tagdækkere, som ikke kan benytte AI til at udføre deres daglige arbejdsopgaver. Lav-skill gruppen består hovedsageligt af stillinger, der har udfordringer eller ikke har interaktion med AI i deres opgaver. Dette viser, at i lav- og midt-skill stillingerne, hvor AI ikke kan bruges, vil der fra et risikoperspektiv ikke være i fare for substituering af AI foreløbigt. Fordelingen af alle danske stillinger og deres AIOE-score vises grafisk i figur 1.1.

1.2.1 Jobmobilitet i dansk kontekst

Jobmobilitet betegner arbejdstageres bevægelser mellem stillinger, brancher og sektorer. Mobilitet udgør en central mekanisme i arbejdsmarkedets tilpasningsevne og fleksibilitet, særligt i en tid præget af digitalisering og automatisering. Der skelnes ofte mellem horisontal mobilitet, hvor individer skifter job inden for samme færdigheds- og lønniveau, og vertikal mobilitet, som indebærer bevægelser op og ned i kvalifikations- eller lønniveau (Bolvig et al., 2017).

I dansk kontekst understøttes høj mobilitet af den såkaldte "flexicurity-model", der kombinerer fleksible ansættelsesformer med et stærkt socialt sikkerhedsnet. Ifølge Danmarks Statistik (2025) var jobomsætningen i fjerde kvartal 2023 på 22,7% svarende til cirka 689.000 personer, der havde påbegyndt deres nuværende job inden for det seneste år. Dette niveau er 1,6% højere end før COVID-19-pandemien i 2019, hvilket afspejler et dynamisk arbejdsmarked i forandring (Mathiesen, 2023).

Mobilitet varierer dog betydeligt med alder og uddannelsesniveau. Yngre arbejdstagere har generelt højere mobilitet, hvorimod ældre udviser større jobstabilitet. Ligeledes er personer uden en kompetencegivende uddannelse ofte ansat i sektorer med høj mobilitet, såsom detail og service. Hvorimod højtuddannede har en tendens til lavere, men mere målrettet, mobilitet til stillinger med højere løn og ansvar (Bess et al., 2022); (Mathiesen, 2023).

I relation til digital automatisering og kunstig intelligens fungerer jobmobilitet både som en tilpasningsmekanisme og som en potentiel kilde til ulighed. Når jobstillinger ændres, vil nogle arbejdstagere kunne opkvalificere sig og drage fordel af nye muligheder, hvorimod andre risikerer at blive skubbet ned i lavere kvalificerede stillinger. Dermed bliver mobilitet ikke blot et udtryk for fleksibilitet, men også en mulig forstærker af jobpolarisering og strukturel ulighed på arbejdsmarkedet (Bolvig et al., 2017); (Bess et al., 2022); (Mathiesen, 2023).

1.3 Arbejdsmarkeds eksponering

Med udgangspunkt i afsnit 1.1's opdeling af skill-grupperne, vil en dybere undersøgelse blive gennemført for at finde deres fordeling og mønstre på det danske arbejdsmarked. Her vil AIOE blive påført til de danske jobstillinger for at skabe forståelse for, hvordan de forskellige skill-grupper er placeret ift. hinanden.

Figur 1.1 viser densiteten af alle danske firecifrede ISCO-koder baseret på deres tilhørende AIOE-score. Figuren tager ikke højde for antallet af arbejdstagere, men viser udelukkende fordelingen blandt jobstillingskategorierne. Her er jobstillingerne opdelt i høj, midt- og lav-skill for at sammenligne placeringen af grupperne, samt have en oversigt for de hyppigste "grupperinger" af stillingers eksponering. Til at skabe denne fordeling benyttedes data fra Danmarks Statistik til at placere AIOE-scoren på de danske jobstillinger, for præcist at kortlægge AI-eksponeringen af det danske arbejdsmarked. Figuren viser fordelingen af de tre færdighedsniveauer i relation til graden af eksponering for AI i arbejdsopgaver.




Figur 1.1. Densiteten af AIOE-score for danske jobstillinger i hhv. høj, midt- og lav-skill

Y-aksen repræsenterer koncentrationen af fordelingen for de tre færdighedsniveauer (lav, midt og høj) på tværs af AIOE-scoren, fra positiv til negativ. Fordelingen spænder fra -2,123 til 1,446, hvilket viser, at det danske arbejdsmarked har et bredt spænd mellem de mest og mindst eksponerede. Denne skala afspejler AI's eksponering på arbejdsopgaver, uden i sig selv at tage stilling til, om denne eksponering har en negativ eller positiv konsekvens. Lav-skill gruppen har tre tydelige klynger, hvilket indikerer, at denne gruppe er fordelt på at være meget negativt eksponeret, negativt eksponeret og neutralt. Dette betyder, at mulighederne for at integrere AI i deres opgaver er begrænsede. Grupperingen omkring neutral eksponering skyldes, at mange af deres opgaver kan delvist påvirkes af AI. Midt-skill gruppen viser en markant polarisering, hvor en del af gruppen befinder sig i negativ eksponering, blandt andet bestående af håndværkere, der har en begrænset anvendelse af AI i deres fysiske opgaver. Derimod har den anden andel en meget høj

AIOE-score, hvilket giver større muligheder for at anvende AI til deres daglige opgaver. Denne andel er hovedsageligt kontorstillinger, hvor de primære opgaver udføres på en computer. Høj-skill er primært koncentreret i positiv eksponering, da AI ofte anvendes til at forbedre produktivitet og beslutningstagning. Disse tre grupper afspejler overordnet, hvordan det danske arbejdsmarked er eksponeret over for AI. Høj-skill og en del af midt-skill gruppen udgør den primære sektor for AI-integration i større omfang. Dog kan AI stadig implementeres i negativt eksponerede erhverv, men typisk i en mere begrænset kapacitet og kun til specifikke delopgaver.

Hvis man derfra ser på, hvordan den danske arbejdsstyrke er fordelt, ser man en lignende fordeling af stillinger eksponeret overfor AI. Figur 1.2 viser den procentvise fordeling af høj-, midt- og lav-skill grupperne på det danske arbejdsmarked.




Figur 1.2. Fordeling af danske arbejdstagere, opdelt i Høj-, Midt- og lav skill gruppe i 2019.

Høj-skill er den største af de tre grupper, og den repræsenterer en betydelig andel af arbejdsstyrken. Det indikerer, at der er relativt flere personer med avancerede færdigheder, ofte relateret til specialiseret viden og højtuddannede positioner. Personer i høj-skill gruppen har ofte lettere adgang til AI-teknologi og avancerede værktøjer, der understøtter deres arbejdsopgaver produktivt. I modsætning hertil er midt-skill gruppen den mindste af de tre, hvilket indikerer, at denne gruppe har en mindre repræsentation på arbejdsmarkedet. Midt-skill jobstillinger inkluderer både håndværkere og administrative jobstillinger, hvilket primært er fysisk arbejde eller kontoropgaver. For kontorarbejderne er de ofte mere modtagelige for automatisering og opkvalificering, som kan være en årsag til en mindre arbejdsmarkedsandel. Lav-skill gruppen ligger mellem de to andre grupper. Dermed er der et betydeligt antal personer i denne gruppe, men stadig færre end i høj-færdighedsgruppen. Gruppen består ofte af personer i job, der kræver færre tekniske færdigheder og generelt omfatter mere rutineprægede eller manuelle opgaver.

Samlet viser figur 1.2, hvordan det danske arbejdsmarked er opdelt med flere personer i høj-

skill gruppen og færrest i midt-skill gruppen. Det afspejler de ændrede krav og muligheder, som teknologisk udvikling og automatisering medfører, samt at der er flere stillinger i lav- og midt-skill gruppen, som består af midlertidige- eller deltidsstillinger. Derfra vil der nu ses på AIOE-score fordelingen for jobstillingerne.



Figur 1.3. Fordeling af danske arbejdstagere baseret på deres AIOE-score

Figur 1.3 viser et stablet søjlediagram over høj-, midt- og lav-skill-grupper på det danske arbejdsmarked, baseret på antallet af arbejdstagere og deres tilhørende AIOE-score. Intervallet for søjlerne for AIOE-scoren er 0,2.

Høj-skill individer er primært koncentreret i den positive ende af AIOE-skalaen. Det betyder, at de fleste i denne gruppe er stærkt eksponerede for AI. Det vil sige, at høj-skill jobstillinger ofte drager fordel af AI, der kan understøtte deres arbejde gennem for eksempel automatisering af komplekse processer. Derfor viser figur 1.3 en stor koncentration af specialiseret jobstillinger mod den højeste positive AIOE-score.

Midt-skill individer har en mere delt fordeling. En del af gruppen er placeret omkring den negative AIOE-score, det betyder, at disse jobstillinger er relativt lavt eksponerede for AI. Det omfatter jobs med manuelle eller praktiske opgaver, der ikke kan automatiseres så let med AI. Der er dog en andel af midt-skill i den positive side af AIOE-scoren. Det indikerer, at disse jobstillinger kan drage fordel af AI til at øge effektiviteten. Det kan være inden for administrative og teknisk orienterede opgaver, hvor AI kan anvendes til automatisering af for eksempel rutineprægede opgaver. Dermed er den højt AI-eksponeret andel også sårbar, eftersom en del af den står over for risikoen for automatisering af deres opgaver.

Lav-skill individer har den største koncentration omkring den neutrale og negative AIOE-score. Det betyder, at lavt kvalificerede jobstillinger har en begrænset eller neutral eksponering for AI. En del jobstillingerne i denne gruppe involverer manuelle, rutineprægede opgaver, der ikke nødvendigvis kan automatiseres effektivt med AI. Det kan også være jobstillinger, som ikke er tilpasset AI-drevne løsninger. Dermed ses en stor

koncentration for lav-skill i de negative områder af AIOE-skalaen, hvilket afspejler en lavere grad af teknologisk integration.

Samlet set viser figur 1.3, hvordan de tre skill-grupper på arbejdsmarkedet forskelligt er eksponeret for AI. Høj-skill er primært orienteret mod positiv AI-eksponering. Midt-skill har en mere blandet fordeling, samt lav-skill er domineret af en lavere eller neutral AI-eksponering. Det understøtter, hvordan AI og teknologisk udvikling påvirker arbejdsmarkedets dynamik. Hertil kan høj-skill i højere grad udnytte AI, hvor lav-skill i højere grad ikke er eksponeret for at anvende AI og automatisering. Midt-skill gruppen er bredt fordelt og generelt relativt lavt eksponeret for AI-implementering. Derimod står midt-skill overfor en potentiel marginalisering, eftersom flere af deres jobstillinger med høj AIOE-score kan automatiseres.

1.4 Problemformulering

Introduktionen har lagt an til AI's indflydelse på arbejdsmarkedet og belyser de dynamikker, der følger med introduktionen af AI. AI ligger ikke længere fjært i fremtiden, men er blevet integreret og breder sig for hvert år. Denne udvikling leder til ændringer i arbejdsmarkedet og i de krav, der bliver stillet til den enkelte medarbejder. Dermed er det et interessant perspektiv i, hvordan AIOE kan benyttes til at undersøge, hvordan skill-grupperne påvirkes af AI, og hvilke jobstillinger der vil undergå omstruktureringer. AIOE giver et konkret værktøj til at undersøge strukturen og mobiliteten på arbejdsmarkedet, som ændrer sig i takt med AI's indtræden, og identificerer, hvilke kategorier der undergår skift baseret på deres AIOE-score. Dette kan lede til øget eller en sænket jobmobilitet, når krav og færdigheder inden for AI bliver mere eftersøgt, som giver problemformuleringen:

1.4.1 Hovedspørgsmål

“Hvordan påvirker kunstig intelligens jobmobiliteten på arbejdsmarkedet, og hvilke jobstillingskategorier oplever den største omstrukturering som følge af kunstig intelligens?”

1.5 Afgræsning af fokusområde

Problemformuleringen opstiller et bredt spørgsmål om tendenser på det danske arbejdsmarked. For at kunne besvare dette spørgsmål på en meningsfuld måde er det nødvendigt at foretage en række afgrænsninger. Disse afgrænsninger sikrer, at undersøgelsen kan fokusere på de dele af arbejdsmarkedet, hvor AI-eksponering forventes at have den største betydning, og hvor effekterne mest tydeligt kan observeres og måles. Derfor afgrænses undersøgelsen til jobstillinger med en højere sandsynlighed for AI-eksponering. Konkret omfatter analysen alle jobstillinger med ISCO-koderne 1 til 4, hvilket inkluderer ledere, akademikere, teknikere og kontoransatte. Disse kategorier er udvalgt på baggrund af afsnit 1.3 og figur 1.1, som angiver, at disse grupper udviser en generelt positiv til højt positiv eksponering over for AI. Det gør dem relevante i forhold til at forstå, hvordan AI kan påvirke jobskifte, samt hvordan AI påvirker forskellige sektorer af arbejdsmarkedet. Det betyder også, at rapporten ikke har til formål at give en udtømmende analyse af alle sektorer eller jobtyper, men for en fokusgruppe.

Formålet er ikke kun at analysere, hvordan AI påvirker jobmobilitet, men også at undersøge, hvordan AI hænger sammen med deltagelse i opkvalificerende kurser. Rapporten undersøger således både, hvordan AI-eksponering påvirker sandsynligheden for jobskifte og kursusdeltagelse, og hvordan disse to dynamikker påvirker hinanden. Det inkluderer også analyse af, om kursusdeltagelse kan føre til senere jobskifte, og omvendt; om mobilitet kan udløse lærings- og opkvalificeringsforløb. Der lægges desuden vægt på, hvordan samspillet mellem AI-eksponering og disse to variable: kursusdeltagelse og mobilitet, former hinandens udvikling, og hvordan det varierer på tværs af jobkategorier.

AI-definitionen af AIOE forstås som smal kunstig intelligens anvendt i arbejdsrelaterede funktioner og teknologier, der understøtter eller overtager specifikke opgaver uden at besidde generelle kognitive evner. AIOE-scoren dækker blandt andet automatisering, maskinlæring og datadrevet analyse og anvendes i sin oprindelige form kombineret med danske registerdata Felten et al. (2021).

1.5.1 Underspørgsmål

Denne afgrænsning danner et grundlag for at undersøge mere specifikke aspekter af, hvordan kunstig intelligens påvirker jobmobiliteten inden for de udvalgte arbejdsområder. For at besvare hovedspørgsmålet undersøger rapporten en række mere fokuserede underspørgsmål og følgende problemformulering:

“Hvordan påvirker kunstig intelligens jobmobiliteten for stillinger med AI-potentiale, og hvilken effekt har kursusdeltagelse på mobiliteten?”

- “Har høj AIOE-score en indvirkning på jobskiftefrekvensen?”
- “Er der tegn på, at AI påvirker tendensen til jobskifte, og i så fald gør den det mere sandsynligt, at folk skifter job, eller styrker den motivationen for at blive i deres nuværende stilling?”
- “Kan AIOE forudsige job tab eller jobskabelse inden for bestemte skill-grupper?”
- “Hvordan påvirker AIOE tendens til opkvalificering og leder det til jobskifte eller øget jobsikkerhed?”

Disse underspørgsmål er udvalgt til at undersøge, hvordan jobskiftetendenser påvirkes af AI-eksponering, samt om opkvalificerende kurser kan lede til jobskifte eller har en fastholdende effekt.

1.6 Litteraturreview

Dette afsnit har til formål at gennemgå eksisterende litteratur om digital automatisering og jobmobilitet. Formålet er at identificere tidligere fund og metodiske tilgange, som analysen kan bygge videre på.

Gennem de seneste år har digital automatisering og AI transformeret arbejdsmarkedet på tværs af brancher og sektorer. Teknologierne har potentiale til at ændre efterspørgslen efter arbejdskraft, hvilket resulterer i både jobskabelse og jobtab samt en øget nødvendighed for opkvalificering og efteruddannelse for at imødekomme de nye krav.

En artikel der undersøger dette, er Cazzaniga et al. (2024), som fokuserer på jobmobilitet på tværs af lande. Denne undersøgelse går i dybden med de strukturelle transformationer, der kan skabes af AI, samt konsekvenserne for de næste generationer. Her "highlightes" de forhold, der er imellem eksponering til AI og skift i arbejdssektorerne. Artiklen opsætter potentialet af jobskabelse via AI imod den substituerende af eksisterende industrier, som

derived bliver udsat. Studiet giver indsigt i, hvordan denne adoptering er varierende mellem lande baseret på deres teknologiske parathed overfor AI. En vigtig pointe der bliver opsat, er nødvendigheden for "reskilling" og overgangsværktøjer, hvilket understøtter behovet for målrettede efteruddannelsesinitiativer.

Der er flere studier, der fremhæver, at automatisering i høj grad påvirker jobstillingerne, der involverer rutineprægede opgaver. I rapporten Arntz et al. (2016) ses det, at op mod 9% af jobstillinger i OECD-landene er i høj risiko for at blive automatiseret. Dette indikerer et behov for efteruddannelse og opkvalificering, særligt for arbejdstagere i rutineprægede sektorer.

Det er dog en lavere andel ift. Frey og Osborne (2017), hvor de estimerer, at 47% af de amerikanske jobstillinger har en høj sandsynlighed for at blive automatiseret. Forskellen på disse to estimeringer i rapporterne Frey og Osborne (2017) og Arntz et al. (2016) skyldes forskellen i deres metodologi. Frey og Osbornes analyse er baseret på ekspertvurderinger af, hvorvidt hele jobstillinger kan automatiseres. Dermed bliver der ikke taget hensyn til variationen i opgaver indenfor de enkelte jobstillinger. De har anvendt en binær tilgang, hvor en jobstilling blev vurderet ud fra, om den enten kunne automatiseres fuldt ud eller ikke kunne automatiseres (Frey og Osborne, 2017). Derimod anvendte Arntz et al. (2016) en mere nuanceret metode, eftersom de vurderede automatiseringspotentialet ud fra opgaveniveau fremfor jobniveau. De argumenterer for, at mange jobstillinger indeholder en kombination af opgaver, der kan og ikke kan automatiseres, hvilket gør, at hele jobstillinger ikke nødvendigvis forsvinder, men snarere omstruktureres. Dette åbner op for behovet for efteruddannelse og opkvalificering, da arbejdstagere skal tilegne sig nye kompetencer for at kunne udføre de tilbageværende opgaver, der ikke kan automatiseres. Selv i jobstillinger med et højt automatiseringspotentialt vil der stadig være behov for menneskelig indgriben i nogle aspekter af arbejdet (Arntz et al., 2016).

Til trods for, at automatisering kan medføre jobtab, peger rapporten Bessen (2018) på, at der opstår nye jobmuligheder i takt med teknologiens udvikling. Ifølge rapporten argumenteres der for, at AI skaber efterspørgsel efter nye kompetencer og roller, særligt inden for dataanalyse, teknologi og IT-support. Hertil fremhæves der, at de nye jobs ofte kræver højt specialiserede færdigheder, hvilket kan skabe en ulighed for arbejdstagere uden adgang til relevant efteruddannelse. Denne forskel kunne resultere i en ujævn fordeling af arbejdsmarkedets fordele, hvor nogle grupper har bedre adgang til jobmuligheder, hvorimod andre kan blive fanget i mere usikre jobstillinger i takt med AI's udvikling (Bessen, 2018). Dette understreger vigtigheden af effektive efteruddannelsesprogrammer, der kan sikre, at alle arbejdstagere får mulighed for at drage fordel af de nye jobmuligheder.

I henhold til den danske kontekst belyses det i Københavns Universitets Forskningscenter for Arbejdsmarkeds- og Organisationsstudiers (FAOS) rapport, at automatiseringens indvirkning varierer mellem brancher i Danmark. Sektorer som produktion og transport oplever markante omstruktureringer, hvorimod service- og sundhedssektorerne er mindre berørt. I automatiserede sektorer er der et stigende behov for opkvalificering hos arbejdsta-

gerne, hvilket understreger vigtigheden af uddannelsesinitiativer for at lette omstrukturen. Yderligere fremhæver FAOS, at der er behov for en aktiv arbejdsmarkedspolitik, der kan understøtte de mest sårbare grupper i overgangen til et mere digitaliseret arbejdsmarked. Det er typisk arbejdstagere, der er lavt uddannede, ældre samt dem med begrænset adgang til efter/videreuddannelse og digitale kompetencer (Institut et al., 2017).

Dertil bidrager McKinsey Global Institute til forståelsen af automatiseringens indvirkning med rapporten Manyika (2018). I rapporten identificeres ti centrale udfordringer, herunder behovet for omfattende omskoling og opkvalificering af arbejdstagere. Der fremhæves, at til trods for at automatisering kan eliminere visse jobstillinger, vil der samtidig blive skabt nye jobstillinger, og dermed øges efterspørgslen efter specifikke kompetencer inden for eksempel digitale færdigheder og kritisk tænkning. En af de vigtigste udfordringer, der fremhæves, er at sikre, at omskoling er tilgængelig og effektiv, således at arbejdstagerne kan tilegne sig de nødvendige kompetencer til omstruktureringen (Manyika, 2018).

Samlet set peger litteraturen på, at selvom automatisering og AI medfører betydelige udfordringer for arbejdsmarkedet, er der også muligheder for at skabe et mere dynamisk og tilpasset arbejdsmarked gennem målrettede efteruddannelses- og opkvalificeringsinitiativer. Dette gør det afgørende at have en klar strategi for livslang læring og fleksible uddannelsesprogrammer, der kan ruste arbejdstagere til fremtidens arbejdsmarked.

En anden relevant analyse i konteksten af kunstig intelligens og arbejdsmarkedet er *"Large Language Models and the Danish Labour Market"* af Teutloff et al. (2024). Denne undersøgelse har fokus på, hvordan store sprogmodeller (LLM'er) kan påvirke det danske arbejdsmarked ved at anvende AIOE-scores, der oprindeligt er udviklet til det amerikanske arbejdsmarked. Det er vigtigt at understrege, at den oprindelige AIOE-score fra (Felten et al., 2021) ikke er målrettet LLM'er, men bred AI-eksponering. (Teutloff et al., 2024) udvider AIOE-konceptet til LLM'er, hvilket adskiller sig fra denne rapports anvendelse, som er forankret i AIOE's oprindelige anvendelsesområde. Ved at kombinere disse eksponeringsmål med danske registerdata vurderer analysen, hvilke erhverv og sektorer der har størst potentiale for at blive påvirket af LLM'er, samt hvordan den påvirkning varierer på tværs af indkomstniveau, køn og geografisk placering. Analysen viser, at job med kognitive rutineopgaver har de højeste LLM-scores, hvilket indikerer et større potentiale for understøttelse eller erstatning af LLM'er. Juridiske fagfolk har den højeste score, mens malere og bygningsrengøringsarbejdere har de laveste. Vidensbaserede erhverv, især videregående uddannelsesinstitutioner, har højere eksponering end sektorer præget af fysiske opgaver som bygge- og anlægsbranchen. Derudover påviser undersøgelsen også kønsforskelle i eksponeringen for LLM'er. Kvinder i beskæftigelse har generelt en højere LLM-score end mænd. Det skyldes, at kvinder oftere arbejder i erhverv med kognitive opgaver såsom administration, undervisning og sundhed. Mænd har dog en lidt højere LLM-score i sundheds- og socialektoren, hvilket kan skyldes en overrepræsentation af mænd i ledelses- og analytiske stillinger inden for sektoren. Analysen finder en positiv sammenhæng mellem personlig indkomst og LLM-eksponering, idet højtlonnede jobs har større potentiale for at drage fordel af AI-teknologi. Geografisk er eksponeringen højest

i storbyer som København, Aarhus, Aalborg og Odense, hvor vidensintensive erhverv er mest koncentrerede.

Analysen er metodisk stærk, da den kombinerer detaljerede danske registerdata med en etableret international metode til vurdering af AI-eksponering. Selve tilpasningen af AIOE-score til det danske forhold har dog begrænsninger, eftersom den oprindeligt er udviklet af det amerikanske arbejdsmarked. Dermed kan jobbeskrivelser, arbejdsopgaver og teknologisk adoption mellem Danmark og USA påvirke præcisionen af estimaterne.

Samlet set viser undersøgelsen en detaljeret indsigt i, hvordan LLM'er kan påvirke det danske arbejdsmarked. Studiet understreger, at effekten af LLM'er er ulige fordelt og afhænger af faktorer såsom erhvervstype, indkomst, uddannelsesniveau og geografi (Teutloff et al., 2024).

Metode 2

Dette kapitel vil beskrive de variabler og data, der vil blive benyttet til at undersøge gentagende deltagelser i kurser og gentagende jobskifte. Herunder vil AIOE-målingen formidles, som angiver AI-eksponeringen for fokusgruppen i analysen. Det giver dermed indsigt i, hvordan AI potentielt kan skabe opkvalificering eller jobskifte. Derudover vil de modeller og processer, der ligger bag, blive forklaret for at angive, hvordan resultaterne skal fortolkes.


2.1 AI Occupational Exposure (AIOE)

AI Occupational Exposure (AIOE) er skabt af Felten et al. (2021) som en måleenhed til at undersøge og kortlægge, hvordan forskellige erhvervsopgaver interagerer med kunstig intelligens. Denne konstruerede måling af eksponering over for AI til opgaver er baseret på forskellige faktorer. Målingen er sammensat af forskellige typer af opgaver/aktiviteter på arbejdspladser, som AI kan påvirke, fra Occupational Information Network databasen (O*NET). Det er en database for krav, færdigheder og opgaver for amerikanske erhverv. Hertil er der koblet arbejdsmarkedsmålinger om AI-udvikling fra Electronic Frontier Foundation (EFF) som indikatorer. Derfra bliver der skabt en matrix til at udpege, hvor relevant AI kan være til forskellige opgaver og færdigheder. AIOE-scoren afspejler, hvor høj en grad arbejdsopgaver og tilknyttede færdigheder potentielt kan understøttes af AI. AIOE-scoren anvendes dermed som et kvantitativt mål for AI-eksponering i analyser af arbejdsmarkedets tilpasning til teknologisk udvikling.

SOC til ISCO konvertering

AIOE er skabt baseret på den amerikanske arbejdsmarkedsklassifikation Standard Occupational Classification (SOC). For at anvende AIOE på det danske arbejdsmarked, er det nødvendigt at lave en konvertering fra SOC-kodning til ISCO-kodning, som er kompatibel med jobstillinger i Danmark. Her benyttes der "SOC-ISCO Crosswalk", som tillader at lave denne konvertering til en firecifret ISCO-kodning, der benyttes til at klassificere arbejdsstillinger i Danmark (Bureau of Labor Statistics, 2012). Ved denne konvertering vil der opstå et overlap af visse SOC-stillinger, som bliver tildelt den samme ISCO-kode ved brugen af "SOC-ISCO Crosswalk"; derfor vil der laves en gennemsnitsberegning af AIOE-scoren for disse stillinger. Dermed kan AIOE-målingen blive benyttet til at undersøge de danske jobstillinger via ISCO-formatet.

Ved denne konvertering er der en vigtig forskel imellem SOC og ISCO, der opstår, da visse SOC-koder ikke har en direkte ISCO-modpart. Dette kommer i form af "First-line supervisors" er en unik stilling i SOC-kodning, som ikke har en direkte tilsvarende ISCO-ækvivalent. Denne stilling er sat til at have samme ISCO-kode, men til trods for at de er hævet over den typiske arbejder i stillingen, er de klassificeret som en lederrolle, men ikke tilstrækkelig for at være kodet som en mellemlider i ISCO-kodning. Dermed vil denne stilling ikke blive medtaget i gennemsnitsberegningen af AIOE-scoren, da den ikke repræsenterer stillingens karakter korrekt ved konvertering til ISCO-format.



Figur 2.1. Eksempel på gennemsnitsudregning af ISCO-koder.

Kortlægning af de jobstillinger der ikke har en tildelt AIOE-score fra konverteringen, bliver tildelt en ved at aggregere ISCO til en tre cifret kodning ved at tage en gennemsnitsberegning af de fire cifret ISCO-koder, som deler de tre første cifre med den pågældende jobstilling.

2.2 Anvendte variable og datadefinitioner

Til at undersøge, hvordan jobmobiliteten bliver påvirket, bliver der brugt individers arbejdsmarkedsdata. Dataet baserer sig på registerdata fra Danmarks Statistik, som indeholder detaljeret information om individers tilknytning til arbejdsmarkedet i perioden 2010 til 2021. Data dækker blandt andet beskæftigelse, branche, sektor, arbejdskommune, stillingskode (ISCO) samt demografiske oplysninger som alder og køn. Derudover indgår oplysninger om kursusedtagelse samt en målestok for AI-eksponering (AIOE), der er koblet til stillingskoderne. For at belyse jobmobilitet anvendes variable, der afspejler både strukturelle forhold (for eksempel arbejdsstedets sektor og branche), individuelle karakteristika (alder, køn og kompetenceniveau) samt efteruddannelsesaktivitet. AI-eksponering anvendes både som en kontinuert indeksvariabel og i kategoriseret form.

2.2.1 Population og ISCO-baseret afgrænsning

Analysen baseres på årlige observationer i perioden 2010-2021 for individer over 18 år, der i mindst én periode har været i fuldtidsbeskæftigelse i job klassificeret med ISCO-koder, der starter med cifrene 1 til 4. Disse koder dækker ledere, højere og mellemlange

vidensarbejdere samt kontorarbejdere og udgør det segment af arbejdsstyrken, der er relevant for vurdering af AI-eksponering og opkvalificeringsaktivitet.

Kun observationer med ISCO-koder i dette interval (ISCO 1-4) samt arbejdsløsheds-koden 9999 er inkluderet i data. Observationer med øvrige ISCO-koder (ISCO 0 og 5-9) udelades, da disse ikke indgår i målingen af AIOE-score, Skill-gruppering og ligger uden for det teoretiske fokus. Skift til eller fra arbejdsløshed (ISCO 9999) indgår som periode i datastrukturen til visualiseringer, men kun observationer fra den udsatte gruppe (ISCO 1-4) medtages i Prentice, Williams, and Peterson gap time (PWP-GT) modellering.

Datasættet er konstrueret ud fra et Personnummer (PNR), som muliggør tilkobling af baggrundsinformation og aggregering af variable over tid. Populationen er beskåret, så kun observationer med relevante hændelser og komplette oplysninger indgår i de estimerede modeller.

2.2.2 Eventvariable og tidsstruktur

Til modellering af henholdsvis kursusdeltagelse og jobskifte anvendes Prentice-Williams-Peterson Gap-Time modeller, som kræver eventopdelt data. Data er derfor struktureret i start-stop-format med årlige intervaller, hvor hver observation repræsenterer en risikoperiode mellem hændelser. Observationer censureres ved udgang fra arbejdsmarkedet eller ved datasluttidspunktet. Til hver hændelsestype konstrueres en binær eventvariabel, om der sker et jobskifte eller en kursusdeltagelse, en kumulativ eventtæller og et eventnummer til stratificeringen.

Et jobskifte defineres som en ændring i individets firecifrede ISCO-kode fra ét år til det næste. Denne tilgang gør det muligt at identificere både horisontale og vertikale mobilitetsforløb. Da registerdata ikke indeholder information om motivation eller kontekst for skiftet, skal variabelen forstås som et mål for faktisk mobilitet snarere end individers valg. Analysen kan derfor ikke skelne mellem frivillige og ufrivillige skift, men fokuserer på den strukturelle sammenhæng mellem eksponering for AI og observeret bevægelse på arbejdsmarkedet.

2.2.3 AIOE-score og jobrelaterede variable

AIOE-scoren måler graden af AI-eksponering på baggrund af de relevante ISCO-koder og anvendes både som kontinuerlig variabel, og som grupperet variabel delt i tre dele: lav, mellem, høj. Jobskifte defineres som overgange mellem ISCO-koder inden for 1-4 eller som ændringer i branche, sektor eller arbejdskommune inden for samme ISCO-kode. Denne tilgang tillader opfangelse af jobskifte, hvor der ikke er ændring i jobstilling.

2.2.4 Kursusvariabel og opkvalificering

Kursusdeltagelse konstrueres på baggrund af en liste over AI- og IT-relaterede kurser, der også omfatter databehandling og robotteknologi. Grundet manglende information

om kursusomfang fungerer listen som proxy for AI-relevant opkvalificering. Kurser krydsmatches med individernes kursusaktiviteter for hvert år, og der dannes en variabel for, om personen har deltaget i relevante kurser.

Dataet fra Danmarks Statistik er kursusdeltagelse kodet som en hændelse. Kursusvariablen anvendes som en proxy for formel opkvalificering og indgår som afhængig variabel i analyserne med gentagne hændelser (PWP-GT). Til dette er der benyttet et filter til at udvælge relevante kurser til proxy og reelle AI-kurser. Her er der benyttet bredere søgeord, som begrænser antallet baseret på matches i kursusbeskrivelserne, hvilket er den eneste uddybende information tilgængelig til at vurdere, om et kursus er relevant. Disse mange søgeord er det indledende filter til at finde kurser, der potentielt kan benyttes, dette inkluderer ord som: *program*, *IT*, *AI*, *kunstig intelligens*, *data*, *machine learning* m.fl.

Derefter er der vurderet, hvorvidt de forskellige kurser er relevante nok til at medtages. Her er simple urelevante kurser såsom: "*Introduktion til Microsoft Office programmer*", ikke medtaget, da den kommer frem grundet søgeordet *program*, men har sandsynligvis kun et minimalt overlap med AI-kurser.

Der er data på, om en person har deltaget i et kursus, samt sluttidspunktet for deltagelsen, hvilket gør det muligt at analysere hændelser over tid. Datasættet gør det muligt at registrere flere kursusdeltagelser pr. individ. Dermed omfatter analysen udelukkende fuldførte kurser, eftersom forløb, der er afbrudt eller ikke bestået, ikke indgår.

Der eksisterer tilknyttede kursusbeskrivelser, men disse er kun delvist udfyldt i registreret. Derfor er det kun de kurser med en angivet beskrivelse og relevans for AI-eksponering eller medtagne proxier, der er inkluderet i analysen. Yderligere er der en uddannelseskode til stede, men den anvendes ikke, eftersom den kun angiver institution eller udbyder og ikke direkte kursusindholdet. Selve personstatistikken fra Danmarks Statistik er en årlig måling af deltagelse i kurser og enkeltfag. Herunder angives alle påbegyndte kurser, om de er gennemført, undervejs eller afbrudt. Dataet indsamles fra uddannelsesinstitutioner, Undervisningsministeriet, samt AMU-udbydere (Sørensen, 2024).

Det er i analysen ikke muligt at skelne eksplicit mellem selvvalgt og arbejdsgiverbetalt efter- og videreuddannelse (EVU), da dette ikke fremgår direkte af de tilgængelige registerdata. Kursusvariablen benyttes således som en binær indikator for, om individet har deltaget i et opkvalificerende kursus, uden information om initiativ. Forskellen mellem selvvalgt og arbejdsgiverinitieret EVU er ikke direkte medarbejdet i modellerne, men anvendes som et refleksionspunkt i analysen af motivation og incitament.

2.2.5 Andre kontrolvariable og baggrund

Alder, køn og arbejdsregion er tilkoblet via PNR. Regioner konstrueres som aggregater af kommuner af hensyn til modellering, men kommuner anvendes særskilt til at bedre identificere jobskifte. Skillgrupper inddeles baseret på ISCO-startcifre: ledere (1), høj viden (2), mellem viden (3) og kontorarbejde (4). Opdelingen benyttes til at analysere lærings-

og mobilitetsmønstre på tværs af kvalifikationsniveauer.

2.2.6 Outliers

For at hjælpe modellen i dens estimering er det kun de første fem events for jobskifte og kursus, der bliver undersøgt. Effekten af denne begrænsning vil betyde, at estimaterne i stratificeringen bliver mere stabile, da der kun er et meget lille antal individer, som oplever mere end 5 events. Ydermere grundlag for dette er, at mere end 5 jobskift for en observationsperiode på 11 vil betyde, at individer ikke har fast arbejde i mere end halvdelen af perioden. Dette kan være et andet område, som vil være mere egnet til en anden form for analyse, der kan fokusere på dette.

2.3 Metodisk tilgang til gentagne hændelser

Formålet med analysen er at undersøge, hvordan jobmobilitet bliver påvirket af forskellige faktorer, herunder AI-eksponering. Til dette anvendes en metode inden for overlevelsesanalyser, som estimerer sandsynligheden for, at en hændelse indtræffer over tid. I denne analyse er det ikke død eller sygdom, som i klassisk overlevelsesanalyse, men her vil det være tid til næste jobskifte eller deltagelse i kurser.

Derfor vil overlevelsestid være perioden, hvor en person ikke har oplevet en hændelse. Hændelsen angiver, om et jobskifte eller en kursusdeltagelse er sket, hvor overlevelsestiden vil afslutte. Estimeringen i modellen er risikoen for, at hændelsen indtræffer, givet at hændelsen ikke er sket endnu. Dette udtrykkes som hazardrate, som er sandsynligheden for hændelsen i et lille tidsinterval for udsatte individer. Overlevelsesmodeller benytter kovariater (uafhængige variabler), der antages at påvirke risikoen for hændelsen. Kovariater kan inddeles i eksempelvis demografiske variabler såsom alder og køn eller karakteristika som AIOE-score eller tidligere hændelser. Hertil benyttes en udvidelse af den traditionelle Cox-overlevelsesanalyseform, som kan se på "recurrent events", der tillader, at events kan ske i en rækkefølge.

2.3.1 Cox regression model

Udgangspunktet er Cox proportional hazard modellen, som estimerer risiko (hazard raten) for en event indtræffer, forudsat den ikke er sket endnu. Cox-modellen er designet til at analysere sammenhænge mellem overlevelsestid og en eller flere forklarende variable uden at specificere en præcis form for baseline hazard-raten. Dermed kan effekten af for eksempel forskel i AI-eksponeringen spille en rolle i, hvordan risikoen for jobskifte kan ske over tid.

Cox-modellen udgangspunkt i følgende specifikation af den øjeblikkelige hazardrate:

$$(2.1) \quad \lambda_i(t) = \lambda_0(t) \exp(X_i(t)^\top \beta)$$

Her betegner:

- $\lambda_i(t)$: Hazardraten for et individ i ved tiden t
- $\lambda_0(t)$: Baseline hazardrate når alle kovariater er nul
- $X_i(t)$: Vektor af (eventuelt tidsafhængige) kovariater for individ i
- β : Koefficientvektor, som estimeres ud fra data

$\exp(X_i(t)^\top \beta)$ er den relative risiko for et individ sammenlignet med en person i baselinegruppen $\lambda_0(t)$. De estimerede koefficienter β fra Cox-modellen repræsenterer log-hazard-ratioer. Ved at tage eksponentialen af koefficienterne får man hazard-ratioer, der beskriver den relative ændring i hazardraten for hver enhedsændring i den pågældende kovariat.

Et eksempel er hazardratioen mellem individers hazardrater givet: $h(t; \mathbf{z})$ ved tiden t :

$$(2.2) \quad h(t; \mathbf{z}) = h_0(t) \exp(\mathbf{z} \cdot \beta)$$

$$(2.3) \quad \frac{h(t; z_i = 1)}{h(t; z_j = 0)} = \exp(0.25) \approx 1.28$$

Her er $h_0(t)$ baseline-hazardraten, og β er en vektor af koefficienter, der estimerer effekten af kovariaterne for et event.

En central antagelse i Cox-modellen er, at hazardraterne for individer med forskellige kovariater er proportionale over tid. Dermed vil forholdet mellem deres hazardrater være konstant over tid og afhænger af forskellene i kovariaterne.

Eksempelvis, hvis en binær kovariat såsom køn, hvor $z = 1$ er mænd og $z = 0$ er kvinder. Den estimerede koefficient for mænd er $\beta = 0,25$, hvilket betyder hazardraten for mænd i forhold til kvinder vil være:

$$(2.4) \quad \frac{h(t; \mathbf{z}_i = \text{mand})}{h(t; \mathbf{z}_j = \text{kvinde})} = \exp(0.25) \approx 1.28$$

Dermed vil man aflæse hazardratio mellem køn som: Mænd har 28% højere risiko for jobskifte end kvinder. Overstående ligning bygger på antagelsen om, at forholdet mellem hazardraterne er konstant over tid.

Ved en kontinuerlig kovariat såsom AIOE-score, fortolkes effekten som ændringen i hazardraten for hver enheds stigning i værdien. Er $\beta = 0.40$ vil en stigning på 1 point i AIOE-score medføre en forøgelse af hazardraten på:

$$(2.5) \quad \exp(0.40) \approx 1.49$$

Det vil betyde, at en højere AIOE-score er forbundet med 49% højere risiko for jobskifte. Dette giver en måde at fortolke på risikoeffekten af hver kovariat på eventen, hvor kontinuerte variabler angives som ændring i risiko per enhed, og kategoriske variabler i forhold til en reference. Derfor aflæser man hazard-ratioen som en procent ændring af

risiko i forhold til referencen. På den måde får man indsigt i, hvordan kovariaterne påvirker overlevelsestiden i den undersøgte population (Therneau og Grambsch, 2000).

Forskellen mellem risiko og sandsynlighed er vigtig at skelne mellem, hvor hazardraten ikke er en sandsynlighed i sig selv, men snarere et mål for den øjeblikkelige risiko for, at en hændelse indtræffer på tidspunktet t . Mens en sandsynlighed altid ligger mellem 0 og 1, kan en hazardrate være højere end 1, da den refererer til risiko per tidsenhed og ikke en total andel.

Den traditionelle Cox-model er begrænset til analyser af tid til første hændelse. Denne begrænsning tillader, at hvert individ kun kan bidrage med en hændelse i perioden. Dette gør den også utilstrækkelig til at undersøge jobskift eller kursusdeltagelse for arbejdstyrken, som kan opleve disse hændelser flere gange i løbet af en periode.

Begrænsningerne kan imødekommes ved at udvide modellen, således den kan håndtere flere hændelser per person i perioden. Dertil kan Andersen Gill (AG) modellen og Prentice, Williams, and Peterson gap time (PWP-GT) modellen benyttes til at indføre udvidelser til Cox-modellen Therneau og Grambsch (2000).

2.3.2 Andersen Gill (AG) model:

Andersen-Gill-modellen (AG) udvider den klassiske Cox proportional hazards-model til at individer kan opleve flere hændelser over forløbet. AG-modellen anvender en "start-stop" struktur, hvor hver observationsrække angiver et risikointerval for en potentiel hændelse. Igennem dette kan tidsafhængig stratificering, tidsopdaterende variabler og flere hændelser tillades. Eksempelvis vil to jobskifte for et individ skabe tre intervaller, som tillader en ny status i form af værdier afhængige af jobstillingen såsom AIOE-score (Therneau og Grambsch, 2000).

For at tage højde for afhængighed mellem hændelser inden for samme individ, kan observationerne behandles ved cluster(ID). Dette indebærer ikke en ændring af modelstrukturen, men en justering hvor der anvendes en robust variansestimering, en "sandwich-estimator". Ved at angive hvilke observationer der tilhører samme individ, tillader og korrigerer modellen for, at observationerne kan være afhængige af hinanden for samme individ (Therneau og Grambsch, 2000).

Centralt for AG-modellen er, at risikoen for en hændelse beskrives ved en *tælleproces*-tilgang, hvor for hvert individ i defineres:

- $N_i(t)$: en tælleproces, der angiver antallet af hændelser for individ i frem til tid t .
- $Y_i(t)$: en *at-risk proces* og indikator for, om individet er i risiko ved tid t .
- $X_i(t)$: Vektor af kovariater, som kan være tidsafhængige.

Hazardfunktionen for individ i , frem til tiden t er givet ved:

$$(2.6) \quad \lambda(t) = Y_i(t)\lambda_0(t) \exp(X_i(t)^\top \beta)$$

Her er $\lambda_0(t)$ baseline hazard, β en vektor af koefficienter og $Y_i(t)$ sikrer, at et individ kun kan bidrage til risiko, hvis individet kan udsættes for risikoen.

Uden cluster data er et centralt aspekt ved AG-modellen dens antagelse om, at risikoen "nulstilles" efter hver observeret hændelse. Derfor vil hver hændelse behandles uafhængigt af tidligere hændelser. Estimationen af β i AG-modellen sker ved at maksimere partial likelihood funktionen, hvor hver hændelse, uanset om den stammer fra samme individ, behandles som en separat observation (Andersen og Gill, 1982). Sandsynligheden for en hændelse ved et givet tidspunkt estimeres betinget af, at individet var i risikosættet umiddelbart før hændelsen.

Selvom AG-modellen ikke eksplicit modellerer afhængighed mellem hændelser, kan en vis afhængighed indføres ved at inkludere antallet af tidligere hændelser (Therneau og Grambsch, 2000). Samlet giver AG-modellen en fleksibel tilgang til analyse af data med gentagne hændelser. Kursusdeltagelse kunne potentielt være afhængig af individets nuværende status end af de forrige deltagelser. Derimod vil jobskifte oftest være afhængigt af forrige jobstillinger. Derfor vil man indrage en rækkefølge, og dermed afhængighed til forrige jobskifte, som håndteres i Prentice-Williams-Peterson (PWP)-modellen. Hertil vil begge hændelsestyper undersøges med PWP-modellen.

2.3.3 Prentice, Williams, and Peterson gap time (PWP-GT) model:

Prentice-Williams-Peterson (PWP)-modellen anvendes til at håndtere gentagne hændelser for samme individ, hvor et individ ikke kan være udsat for hændelse 2, før hændelse 1 sker. Dette gør modellen særligt velegnet til analyse af flere jobskift eller flere kursusdeltagelser, hvor hændelsernes rækkefølge og timing er meningsfuld. Afhængigheden mellem hændelserne er indført i gennem stratificering af hændelsesnummeret, som tvinger modellen til at estimere separate baseline hazardfunktioner for hver hændelse (Therneau og Grambsch, 2000). Dette skaber en ny separat baseline hazard λ_{0k} for hver gang en hændelse sker, som er modsat AG-modellen, som antager en fælles baseline hazard for alle hændelser. PWP tillader, at risikoen kan variere fra hændelse til hændelse, derfor vil risikoniveauet ikke antages ens for alle hændelser.

PWP-strukturen kan opstilles i to varianter, afhængigt af formålet med fortolkningen af analysen. Man kan undersøge "total time" (TT), hvor tiden måles fra begyndelsen, og betyder, at risiko akkumulerer med tiden. Hvis analysen fokuserer på effekten af livsforløb, eller direkte på observationstiden, er denne variant oplagt. I modsætning er tiden i "Gap time" (GT) målt siden sidste hændelse. PWP-GT antager, at risikoen for en ny hændelse "nulstilles" efter en hændelse og afhænger af for næste jobskifte. Gap-time varianten vil være oplagt til at undersøge risikoen for hændelser såsom jobskifte.

Denne tilgang sikrer, at rækkefølgen af hændelser respekteres, og at afhængigheden mellem hændelser inden for samme individ håndteres korrekt. Dermed adskiller PWP-GT sig fra for eksempel Andersen-Gill-modellen, som tillader gentagne hændelser, men ikke nødvendigvis tager højde for hændelsers rækkefølge eller forskellighed (Therneau og

Grambsch, 2000).

I PWP-GT-modellen er hazardfunktionen for et individ i ved den k 'te hændelse:

$$(2.7) \quad \lambda_{ik}(t) = Y_{ik}(t)\lambda_{0k}(t) \exp(X_{ik}(t)^\top \beta)$$

Her er:

- $\lambda_{ik}(t)$: Hazardrate ved tid t for individ i 's k 'te hændelse
- $Y_{ik}(t)$: *At-risk indikator* = 1 hvis individet er i risiko for hændelse k ved tid t
- $\lambda_{0k}(t)$: Stratificeringsspecifik baseline hazardfunktion for hændelse k
- $X_{ik}(t)$: Kovariater (evt. tidsafhængige) for individ i
- β : Fælles koefficientvektor


Denne struktur tillader, at både risiko og effekten af kovariater kan variere på tværs af hændelser. PWP-GT er derfor særligt velegnet til hændelser med sekventiel afhængighed, såsom jobskifte, hvor tidligere hændelser kan ændre adfærden ved fremtidige hændelser.

I PWP-GT modellen er der nogle antagelser, der skelner fra AG og Cox modellen:

- Senere hændelser afhænger af tidligere hændelser (indført rækkefølge).
- Hazardraten kan variere med antallet af tidligere hændelser.
- Hazardraten tillades at variere mellem forskellige hændelser.

En metodisk udfordring ved PWT-GP-modellen er, at datamængden reduceres ved høje hændelsesnumre, hvilket kan medføre til øget estimeringsusikkerhed (Therneau og Grambsch, 2000).

Nedenfor viser figur 2.2 strukturen i PWP-GT modellen. Risikoen stratificeres efter hændelsesnummer, hvor tiden måles som gap time fra forrige hændelse. Kun individer, der har oplevet event k , kan komme i risiko for event $k + 1$.



Figur 2.2. Struktur i PWP-GT modellen: Gap time måles mellem hændelser, og stratificering sker på eventnummer.

2.4 Begrundelse for at inkludere både job- og kursusmodeller

I denne undersøgelse er det et metodisk valg at analysere både jobmobilitet og kursusdeltagelse som separate, men forbundne reaktionsmønstre på AI-eksponering. Baggrunden for valget er, at de to fænomener ikke bør betragtes isoleret, men som forbundne.

Når en arbejdstager bliver mødt med et øget brug af kunstig intelligens i deres jobstillinger, kan det medføre forskellige former for respons. Der vil være nogen, der vælger at skifte job, hvorimod andre vælger at opkvalificere sig gennem kursusdeltagelse. For mange kan disse to handlinger dog hænge sammen. Opkvalificering kan være en forudsætning for at skifte job, mens jobskifte i sig selv kan skabe behov for nye kompetencer eller andre personlige forhold.

Dermed undersøges begge veje samtidig for at få et billede af, hvordan AI påvirker arbejdsmarkedet på et observeret niveau. Ser man udelukkende på enten mobilitet eller læring, kan man risikere at overse vigtige sammenhænge. Eksempelvis hvordan deltagelse i efter- og videreuddannelse kan reducere risikoen for jobtab, eller hvordan høj mobilitet kan være et tegn på, hvordan arbejdstagere aktivt tilpasser sig en ny teknologi.

De to modeller anvender samme metode (PWP-GT), bygger på samme datagrundlag samt er strukturelt ens. Dermed får man muligheden for at sammenligne resultaterne og undersøge, om AI påvirker mobilitet og opkvalificering på samme måde eller giver modsigende effekter. Dertil kan man se, om bestemte grupper reagerer forskelligt afhængigt

af deres position i arbejdsmarkedet.

2.4.1 Potentielle bias og håndtering i analysen

Potentielle udfordringer for dette er, at effekterne fra de kumulative variabler, jobskifte og kursusdeltagelse, kan være biased, samt over- eller underestimere effekten. Ydermere skal det tolkes som et korreleret mønster og ikke, at det ene leder direkte til en event. Da man ikke kan skelne om folk reagerer eller er proaktive med registerdata i forvejen, vil der være uobserverede årsager, som ikke nødvendigvis kan fanges i modellen. De biases, der kan optræde i modellen, er omitted variable bias, såsom motivation for hændelse. Derudover er motivation også en selektionsbias, da der er effekter, der ikke kan kontrolleres for uden at medtage information om, hvorfor individer har taget et kursus eller skiftet deres job.

Redegørelse 3

Dette kapitel giver en redegørelse for jobmobilitet i Danmark og sætter det i relation til større samfundstendenser. Der præsenteres seks megatrends, herunder teknologisk udvikling og demografi, som påvirker arbejdsmarkedets fremtid. Formålet er at skabe en kontekst for analysen og forstå AI's rolle i omstruktureringen af arbejdsmarkedet. Teksten bringer indsigt i den nuværende og fremtidige ramme, som arbejdsmarkedet er påvirket af, dermed vil disse effekter være en bagliggende struktur, som analysen indirekte er påvirket af over tid.

3.1 Jobmobilitet på det danske arbejdsmarkedet

Som gennemgået i afsnit 1.2.1 udgør jobmobilitet en væsentlig mekanisme i arbejdsmarkedets tilpasning til teknologiske forandringer, samtidig med en potentiel forstærkning af strukturel ulighed. I dette afsnit uddybes de empiriske mønstre i mobiliteten på det danske arbejdsmarked, med fokus på demografiske forskelle, brancher, geografisk mobilitet og effekterne af COVID-19.

Under pandemien oplevede det danske arbejdsmarked en stor økonomisk nedgang i Danmark på grund af restriktioner og nedlukningerne, som også betød nedgang i beskæftigelsen. Dog sprang beskæftigelsen op over de næste to år med næsten 115.000 personer og bragte arbejdsløsheden ned på et niveau, der var lignende det niveau, der var før finanskrisen. Dette har bragt andre dynamikker til det danske arbejdsmarked, hvor der har været stigende tilpasningsevner til de udsatte stillinger samt stigninger i andre sektorer såsom byggeri. Under de to år med fremgang i beskæftigelsen har der også været øget mobilitet for ledige, hvor der har været opgang i brancher med forhøjet efterspørgsel (Bess et al., 2022).

Ifølge Danmarks Statistik var jobomsætningen i fjerde kvartal 2024 på 227%, hvilket svarer til 689.000 personer, der havde påbegyndt deres nuværende job inden for det seneste år. Det er et fald ift. 2022, hvor jobomsætningen toppede med 24%, men niveauet lå stadig 1,6% over før-pandeminiveauet i 2019. Den høje mobilitet skyldes blandt andet, at en del brancher oplevede arbejdskraftmangel efter COVID-19, hvilket førte til øget jobrotation (Danmarks Statistik, 2025b).

COVID-19 pandemien har haft en betydelig indvirkning på jobmobiliteten. I de første måneder af pandemien faldt beskæftigelsen kraftigt, men arbejdsmarkedet tilpassede sig

hurtigt. Ledige arbejdskraftressourcer blev omplaceret til brancher med høj efterspørgsel, eksempelvis sundhed, logistik og IT. Derudover medførte pandemien en acceleration af digitaliseringen, hvilket skabte flere muligheder for fjernarbejde og dermed reducerede behovet for fysisk mobilitet. Det har haft en længerevarende effekt på arbejdsmarkedet, eftersom flere virksomheder er blevet mere åbne over for fjernarbejde, hvilket kan reducere nødvendigheden for geografisk mobilitet i nogle erhverv (Bess et al., 2022).

Jobmobiliteten varierer med alder. Yngre arbejdstagere har en højere mobilitet end ældre. I aldersgruppen 15-24 år havde 51,8% været i deres nuværende job i mindre end ét år, mens andelen var 34,4% for 25-34-årige. Til sammenligning havde 7,9% af de 65-74-årige startet i et nyt job inden for det seneste år, og 63,6% af denne gruppe havde været i det samme job i mere end ni år. Det kan betyde, at unge ofte har en løsere tilknytning til arbejdsmarkedet, er under uddannelse eller søger erfaring i forskellige brancher. Hvorimod ældre arbejdstagere har en større jobstabilitet og højere anciennitet (Danmarks Statistik, 2025b).

Uddannelsesniveauet har en betydelig rolle i jobmobiliteten. Personer uden erhvervskompetencegivende uddannelse har ofte en høj jobmobilitet, eftersom de typisk arbejder i brancher med flere kortvarige ansættelser, såsom detailhandel og service. Faglærte har en mere stabil mobilitet alt efter branchens konjunkturer, hvorimod videregående uddannelse generelt skifter job sjældnere, men ofte til stillinger med højere løn og bedre karrierespektiver. Jobmobiliteten blandt højtuddannede steg under COVID-19, særligt inden for sundhedssektoren og IT-branchen, hvor efterspørgslen steg markant (Danmarks Statistik, 2025b; Bess et al., 2022). Derudover varierer jobmobiliteten også betydeligt på tværs af brancher. De højeste niveauer ses i hotel- og restaurationsbranchen samt detailhandlen, hvor ansættelser ofte er midlertidige eller sæsonbetonede. Modsat i industri og byggebranchen er der en mere moderat mobilitet, hvor jobskifte er hyppigere under højkonjunkturer. Derimod har man i den offentlige sektor, særligt i undervisnings- og sundhedssektoren, en relativt lav jobmobilitet, eftersom mange ansættelser er langsigtede og ofte kræver nogle specifikke kvalifikationer (Danmarks Statistik, 2025b).

Geografisk jobmobilitet er en anden vigtig dimension af jobmobiliteten, det vil sige hvorvidt arbejdstagere er villige til at flytte for at tage et nyt job. Selvom danske lønmodtagere generelt har en høj tendens til at skifte job, er de mindre tilbøjelige til at flytte geografisk end i mange andre lande. En væsentlig årsag til dette er det danske velfærdssystem og dagpengemodellen. Nationalbanken har påpeget, at personer, der er ledighedsforsikrede, er mindre tilbøjelige til at flytte for et nyt job sammenlignet med ikke-forsikrede. Det gælder særligt for de yngre arbejdstagere, der ofte har en stærk social tilknytning til deres nuværende bopæl, samtidig med at dagpengene giver en økonomisk sikkerhed, hvilket gør det muligt at søge arbejde lokalt uden at føle et pres for at flytte. Til trods for dette har arbejdsmarkedsreformer de seneste 25 år haft en vis effekt på den geografiske mobilitet. Reformerne har blandt andet øget kravene til, at ledige skal søge job bredere geografisk, særligt hvis der ikke er tilstrækkeligt med jobmuligheder i deres nærområder. Dette har haft betydning for langtidsledige, der i højere grad presses til at acceptere job uden for deres

bopæl. Til trods for at dette har medført en øget geografisk mobilitet blandt forsikrede ledige, er niveauet fortsat lavt sammenlignet med andre lande (Bess et al., 2022).

3.2 Megatrends på arbejdsmarkedet

Mens kapitel 3.1 viste, hvordan jobmobilitet konkret udfolder sig i en dansk kontekst, udgør megatrends de strukturelle kræfter, der former fremtidens muligheder og begrænsninger for denne mobilitet. Dette afsnit giver en specifik forståelse for fremtidig planlægning og mønstre bl.a. AI har på arbejdsmarkedet, der giver kontekst til hvilken retning arbejdsmarkedet bevæger sig imod.

Megatrends refererer til de store, langsigtede kræfter, der har en omfattende indvirkning på samfundet, økonomien, teknologien og miljøet. Disse trends er hverken kortvarige eller midlertidige, men fundamentale forandringer, der strækker sig henover årtier. De kan omforme vores liv og arbejdsmarkedet globalt. Megatrends kan omfatte udviklinger som teknologiske fremskridt, klimaforandringer, ændringer i demografiske mønstre, økonomiske tendenser og samfundsmæssige ændringer. De påvirker både virksomheder, regeringer og arbejdstagere, og kan skabe nye muligheder samt udfordringer.

Man anvender megatrends til strategisk planlægning og beslutningstagning, eftersom de giver et klart billede af, hvordan de er med til at forme fremtiden. Megatrends hjælper både virksomheder samt offentlige institutioner til at forudsige fremtidige ændringer, samt sikre, at der tages hensyn til langvarige udviklinger i beslutningsprocesser. Derudover anvendes de af investorer for at identificere fremtidens vækstområder og risikofaktorer. Megatrends er generelt vigtige for at forstå de overordnede ændringer i samfundet og økonomien, for at man kan tilpasse sig disse ændringer.

For at forstå megatrends og deres påvirkning på arbejdsmarkedet, er rapporterne HBS Economics og Shapiro Futures (2023) og IRISGROUP (2023) anvendt. HBS Economics og Shapiro Futures (2023) undersøger de faktorer, der former arbejdsmarkedet i takt med de forandrede økonomiske og teknologiske forhold. Hvor IRISGROUP (2023) har fokus på de små og mellemstore virksomheders (SMV'er) tilpasning til megatrends, samt de udfordringer, virksomhederne står over for i forbindelse med teknologisk udvikling og grøn omstilling. Rapporterne giver indsigt i, hvordan de centrale megatrends påvirker arbejdsmarkedet på forskellige niveauer.

3.2.1 Klimaforandringer og arbejdsmarkedet

Klimaforandringer påvirker arbejdsmarkedet ved at ændre økonomiske strukturer og skabe nye jobsektorer. Globale temperaturstigninger og ekstreme vejrfænomener øger behovet for grøn teknologi, bæredygtig energi og infrastrukturtilpasninger, hvilket skaber jobmuligheder for ingeniører og eksperter inden for grøn teknologi. Politiske og økonomiske incitament driver investeringer væk fra fossile brændstoffer, mens reguleringer som CO_2 -afgifter fremmer bæredygtige forretningsmodeller. Virksomheder integrerer bæredygtighed

i strategierne og søger medarbejdere med kompetencer inden for cirkulær økonomi og energieffektivitet. SMV'er står over for udfordringer med begrænsede ressourcer og vælger ofte samarbejder eller opkvalificering af medarbejdere for at tilpasse sig grønne krav.

3.2.2 Teknologisk udvikling og digitalisering

Teknologisk udvikling og digitalisering transformerer arbejdsmarkedet ved at ændre arbejdsprocesser og kompetencekrav. Kunstig intelligens og automatisering øger produktiviteten, men skaber også behov for omskoling og nye færdigheder. Investeringer i teknologiske løsninger øger efterspørgslen på specialiserede medarbejdere inden for AI, dataanalyse og teknisk integration. Konkurrencen om talent intensiveres, især blandt SMV'er, der benytter freelancere eller outsourcing for at få adgang til specialistkompetencer. Automatisering ændrer arbejdsprocesser, hvor lavt kvalificerede stillinger erstattes af teknisk krævende roller, mens fleksible arbejdsmodeller og fjernarbejde har fremgang.

3.2.3 Demografisk udvikling

En aldrende befolkning reducerer den erhvervsaktive del af arbejdsstyrken og skaber mangel på arbejdskraft. Urbanisering og stigende boligpriser driver behovet for fleksibilitet og fjernarbejde, mens migration og hybride arbejdsmodeller bliver nødvendige for at afbøde arbejdsstyrkens fragmentering. Kompetenceudvikling og livslang læring er afgørende, da ældre arbejdstagere må genuddannes for at forblive relevante, mens yngre generationer drager fordel af øgede læringsmuligheder. Digitalisering understøtter mobilitet og fleksibilitet, hvilket skaber en arbejdsstyrke, der er bedre rustet til fremtidige demografiske udfordringer.

3.2.4 Fremtidens arbejdsliv

Fremtidens arbejdsliv vil være præget af fleksible arbejdsrammer og en øget balance mellem arbejde og privatliv. Urbanisering og den teknologiske udvikling, herunder digitale platforme og apps, skaber nye arbejdsformer som platformsarbejde og gig-økonomi. Livslang læring bliver centralt, da arbejdspladser udvikler efteruddannelsesprogrammer for at sikre tilpasning til skiftende krav. Virtuelle samarbejdsværktøjer som Teams og Zoom muliggør hybride arbejdsformer, der giver arbejdstagere større frihed, men også udfordringer i forhold til jobstabilitet og arbejdsforhold. Virksomheder må derfor tilpasse sig ved at udvikle bæredygtige løsninger og fleksible arbejdsmodeller.

3.2.5 Økonomisk udvikling

Økonomisk udvikling påvirkes af geopolitiske spændinger, international konkurrence og krav om bæredygtighed. Virksomheder står over for at skulle balancere mellem produktivitet og grøn omstilling, hvilket skaber behov for strategisk planlægning og tekniske specialister. Kriser og handelskonflikter har afsløret sårbarheder i globale forsyningskæder, hvilket fremmer reshoring og investering i lokal produktion. Teknologiske fremskridt øger mobiliteten blandt højtuddannede arbejdstagere, der oplever flere

jobmuligheder, mens lavtuddannede arbejdstagere kan blive udfordret af skiftende arbejdsmarkedsbehov. Virksomheder fokuserer derfor på grøn innovation og effektivitet for at bevare konkurrenceevnen.

3.2.6 Megatrends og arbejdsmarkedets fremtid

Den globale arbejdsmarkedsstruktur er under hastig forandring. Arbejdsmarkedet påvirkes på tværs af makro-, meso- og mikroniveauer og har betydning for både virksomheder og arbejdstagere. For at forstå, hvordan det grønne arbejdsmarked formes af disse udviklinger, er det nødvendigt at analysere de bagvedliggende drivkræfter og konsekvenser for arbejdsstyrken.

En væsentlig problemstilling er, hvorvidt den grønne omstilling kan bremse digital automatisering, eftersom kunstig intelligens og digitale teknologier er ekstremt energikrævende. Især træningen af avancerede AI-modeller har vist sig at være ressourceintensiv, hvor enkelte modeller kan forbruge en strømkapacitet svarende til hundredvis af husholdningers årlige energiforbrug. I takt med at flere sektorer integrerer AI-løsninger, vil det samlede energiforbrug til digital automatisering stige markant. Hvis denne udvikling overstiger kapaciteten af bæredygtige energikilder, vil det kunne medføre regulatoriske indgreb såsom skatter eller restriktioner for energiforbrugende teknologier. Samtidig kan stigende energipriser gøre det mindre økonomisk fordelagtigt for virksomheder at implementere automatiserede løsninger, hvilket kan resultere i, at digitaliseringens tempo og omfang begrænses. Omvendt kan AI-teknologi fremme den grønne omstilling gennem forbedrede energisystemer, ressourceoptimering og intelligent dataanalyse, hvilket muliggør mere bæredygtig forvaltning af energiforbrug. AI anvendes i energisektoren til at balancere elnettet, optimere distribution af vedvarende energi samt forbedre energieffektiviteten i industrielle processer. Derudover kan AI understøtte udviklingen af bæredygtige teknologier ved at accelerere forskning og produktudvikling inden for grøn innovation. Dermed kan AI både udgøre en udfordring for den grønne omstilling samt være en nødvendighed for dens succes. Jobmobiliteten påvirkes i denne sammenhæng ved, at efterspørgslen på arbejdskraft inden for grøn teknologi, energioptimering og bæredygtig infrastruktur vil stige, hvorimod nogle traditionelle erhverv kan blive reduceret eller omlagt (HBS Economics og Shapiro Futures, 2023).

En anden central problemstilling er, hvordan AI kan afhjælpe udfordringer forårsaget af den demografiske udvikling. Flere vestlige lande oplever en aldrende befolkning, hvilket skaber strukturelle udfordringer på arbejdsmarkedet. Særligt sundheds- og omsorgssektoren oplever et stigende pres, eftersom behovet for pleje- og serviceydelser stiger, samtidig med at antallet af erhvervsaktive borgere falder. Dette skaber en ubalance mellem udbud og efterspørgsel på arbejdskraft, hvor man risikerer en stor mangel på kvalificerede medarbejdere. AI og automatisering spiller en rolle i at afhjælpe denne udfordring ved at effektivisere administrative arbejdsgange, forbedre ressourceplanlægning og understøtte sundhedspersonalet i plejeopgaver. AI-baserede systemer kan eksempelvis anvendes til at automatisere journalføring eller forudsige patientbehov gennem avanceret dataanalyse. Derudover kan robotteknologi og intelligente assistenter aflaste sundhedspersonalet ved

at håndtere fysiske opgaver såsom medicindosering, mobilitetshjælp og overvågning af patienters vitale data. På længere sigt kan jobmobiliteten ændres betydeligt som følge af denne udvikling. Automatisering kan mindske behovet for administrative medarbejdere i sundhedssektoren, mens efterspørgslen på tekniske specialister, der kan udvikle, vedligeholde og implementere AI-løsninger, vil stige. Samtidig kan arbejdstagere fra brancher, hvor automatisering reducerer behovet for arbejdskraft, omskoles til sundhedssektoren, hvor efterspørgslen på visse servicefunktioner fortsat vil være høj. AI kan dog ikke erstatte alle funktioner, særligt ikke i servicefag, hvor menneskelig kontakt, empati og social interaktion er essentielle komponenter i ydelsen (IRISGROUP, 2023).

Samtidig spiller geopolitiske spændinger en stigende rolle i AI-udviklingen, eftersom teknologisk innovation i stigende grad betragtes som et strategisk konkurrenceparameter blandt nationer. Ifølge rapporterne (HBS Economics og Shapiro Futures, 2023); (IRISGROUP, 2023) betragtes investering i AI og digitale teknologier ikke kun som et økonomisk tiltag, men også som strategiske værktøjer, der kan styrke nationers konkurrenceevne og sikkerhedspolitiske position. Rapporterne peger på, at stormagter som USA, Kina og EU aktivt implementerer politiske strategier med henblik på at opnå teknologisk selvstændighed og kontrol over kritiske teknologier, hvilket intensiverer konkurrencen globalt. Danmark påvirkes ligeledes af denne udvikling. Den stigende strategiske betydning af AI har medført øgede investeringer i teknologisk innovation, hvilket særligt påvirker efterspørgslen på specialiseret arbejdskraft som IT-specialister, ingeniører og AI-udviklere. Dette kan bidrage positivt til jobmobiliteten i Danmark, eftersom højtuddannede medarbejdere oplever nye jobmuligheder inden for teknologiske sektorer (IRISGROUP, 2023). På den anden side fører geopolitiske spændinger og handelsrestriktioner til udfordringer for danske virksomheder. Det kan eksempelvis være grundet begrænset adgang til udenlandsk teknologi eller vanskeligheder ved at rekruttere international arbejdskraft. Disse forhold kan tvinge virksomheder til at reorganisere deres forsyningskæder og fokusere mere på lokal innovation og produktion. Dette kan øge efterspørgslen på lokal arbejdskraft inden for teknologiske og industrielle sektorer, hvilket potentielt skaber nye jobstillinger lokalt. Omvendt kan denne reorganisering også føre til øgede omkostninger og nedsat konkurrenceevne for virksomheder, der er afhængige af global specialisering og international ekspertise. Det kan begrænse væksten og reducere jobmulighederne på længere sigt (HBS Economics og Shapiro Futures, 2023).

Samlet ser peger rapporterne på, at digital automatisering og AI-udvikling ikke foregår isoleret, men er stærkt påvirket af bredere samfundsmæssige og økonomiske megatrends som grøn omstilling, demografisk udvikling og geopolitik. Disse trends kan både fremme og begrænse digital automatisering og jobmobilitet, afhængigt af hvordan nationale og internationale strategier udvikler sig, samt hvordan virksomheder og arbejdsstyrken tilpasser sig disse udfordringer (HBS Economics og Shapiro Futures, 2023); (IRISGROUP, 2023).

3.3 Kursusdeltagelse og bagvedliggende mekanismer

Tidligere har der været fokus på de strukturelle faktorer, der påvirker jobmobilitet. Det er ligeledes relevant at overveje, hvad der former sandsynligheden for kursusdeltagelse. Efter- og videreuddannelse er en vigtig mekanisme i arbejdsmarkedets tilpasning, men kursusdeltagelse sker ikke isoleret fra øvrige forhold. Den påvirkes af både økonomiske betingelser, organisatoriske strategier og individuelle incitamenter.

Kursusdeltagelse hænger ofte sammen med konjunkturerne. Når virksomheder oplever lavere efterspørgsel eller perioder med mindre travlhed, vælger nogle at sende medarbejdere på kursus i stedet for at fyre folk eller sætte dem ned i tid. Det kan være en måde at bruge pausen konstruktivt på og samtidig ruste medarbejderne til fremtidens opgaver. Ifølge Larsen et al. (2024) er det en tilgang, der bliver stadig mere udbredt, især i brancher, hvor teknologiske forandringer og usikkerhed fylder meget. I Danmark understøttes denne form for tilpasning af den såkaldte flexicurity-model, som kombinerer fleksible ansættelsesvilkår med et aktivt arbejdsmarkedssystem, der blandt andet giver mulighed for efteruddannelse (Bolvig et al., 2017).

På individniveau kan kursusdeltagelse være motiveret af ønsket om at styrke sin markedsværdi, sikre beskæftigelse eller forberede et jobskifte. For arbejdsgivere handler det ofte om at tilpasse medarbejdernes kompetencer til nye teknologiske rammer, herunder implementering af AI-systemer i arbejdsopgaver Dahl et al. (2024). Arntz et al. (2016) understreger, at automatisering sjældent eliminerer hele jobstillinger, men i stedet ændrer opgavefordelingen, hvilket øger behovet for målrettet opkvalificering i eksisterende stillinger.

Der er flere undersøgelser, der peger på, at der er tydelige forskelle i, hvem der deltager i efter- og videreuddannelse. Ifølge Bess et al. (2022) og Mathiesen (2023) er det oftere højtuddannede og yngre arbejdstagere, der deltager i kurser, hvorimod lavtuddannede og ældre har en lavere deltagelsesrate. Dette skaber en risiko for, at dem med størst behov for opkvalificering har mindst adgang, hvilket kan forstærke eksisterende uligheder på arbejdsmarkedet.

Kapitlet præsenterer teori om jobmobilitet og efter- og videreuddannelse, som anvendes til at belyse, hvordan arbejdstagere bevæger sig mellem stillinger på arbejdsmarkedet, og hvordan opkvalificering kan modvirke konsekvenserne af automatisering og AI. Teorierne danner den forståelsesramme, der bruges til at analysere arbejdsmarkedets tilpasning til teknologiske forandringer.

4.1 Jobmobilitet på arbejdsmarkedet

Jobmobilitet er mekanismen i arbejdsmarkedet, der tillader fordeling af arbejdere på arbejdsmarkedet. Jobmobilitet på arbejdsmarkedet er en vigtig mekanisme for, at arbejdsmarkedet kan opnå økonomisk effektivitet, igennem reduktion af mismatch imellem arbejdere og virksomheder. Jobmobilitet kan deles op i bevægelsen af arbejdere imellem internt, som er ved forfremmelser eller stillingsskift i virksomhederne, eller ekstern mobilitet, som er anskaffelse af et nyt job, lokation og/eller skift af industri. Herunder kan personer skifte arbejde for at kunne få bedre løn, forhold eller for at have bedre fremtidige muligheder. Den anden side af jobmobilitet er et tvunget scenarie, hvor man bliver fyret eller virksomheden lukker ned (Borjas, 2016).

En del af jobmobiliteten opstår igennem human kapital, som giver større mulighed for at besidde flere kvalifikationer på arbejdsmarkedet. Kvalifikationer kan opdeles i to dele, hvor den første er færdigheder, der kan benyttes i flere stillinger og kan føre til bredere muligheder på arbejdsmarkedet. Derudover kan man have meget specifikke kompetencer, som er eftertragtede i sin egen virksomhed samt direkte konkurrenter, og det kan skabe incitament til at skifte job.

En anden del, som især kan påvirke jobmobilitet, er omkostningerne ved at skifte arbejde. Der er familieaspektet for mange, hvor muligheden for nyt job ikke altid ligger geografisk optimalt for ens hjem. Derved skabes der omkostninger ved potentiel flytning, som påvirker partner og deres job, eller at pendle, hvis lokationen er inden for en acceptabel afstand. Hvis partneren ikke kan få et job, eller hvis begge deres job ikke forbedres over den nuværende situation, vil der være større omkostninger ved flytning end ved at forblive. Andre omkostninger kan opstå i form af jobsøgningen, hvor en længere søgning kan bringe bedre forhold og/eller løn, imens der også er en omkostning ved evt. arbejdsløshed eller mistet tilbud (Borjas, 2016).

De faktorer, der også spiller ind i skift af job og jobmobilitet, er blandt andet færdigheder, alder, uddannelse, reservationsløn og arbejdsforhold. Jo flere færdigheder og højere uddannelse man besidder, jo højere mobilitet, da der vil være adgang til flere muligheder. Løn og arbejdsforhold kan både sænke mobiliteten eller forøge den. Forøgelse sker ved, at arbejdstagere skifter job for at opnå højere løn, at der er dårlige arbejdsforhold eller lave fremtidige muligheder, som skaber jobskifte hos arbejdstagerne. De faktorer, der sænker mobiliteten, øger også effektiviteten og forlænger ansættelserne. Dette sker ved incitament til at forblive ved virksomheden, hvor der er fordele, som overgår de alternativer, der er på arbejdsmarkedet (Borjas, 2016).

4.2 Tilegnelse af viden

Jobmobilitet afhænger ikke kun af eksterne faktorer som makroøkonomiske forhold og teknologisk udvikling. Det afhænger i høj grad af arbejdstagernes evne til at opkvalificere sig samt tilegne sig nye færdigheder i takt med arbejdsmarkedets transformation. Efter- og videreuddannelse spiller en stor rolle i at gøre overgangen lettere for arbejdstagere, der er påvirket af automatisering og digitalisering. Ifølge Human Capital Theory betragtes uddannelse og kompetenceudvikling som en investering i arbejdstagernes produktivitet, hvormed arbejdsstyrkens samlede output kan stige og dermed fremme økonomisk vækst. Human kapital er de færdigheder, erfaringer og viden, som arbejdstagere akkumulerer gennem formel uddannelse, arbejdsmarkedserfaring og videreuddannelse. Teorien antager, at man træffer rationelle valg om investering i uddannelse baseret på de forventede økonomiske afkast i form af højere løn og bedre beskæftigelsesmuligheder. Dermed kan investering i human kapital forbedre jobmobiliteten, hvilket reducerer risikoen for strukturel arbejdsløshed samt øger arbejdstagernes evne til at tilpasse sig teknologiske og økonomiske forandringer (Becker, 1964).

4.2.1 Efter- og videreuddannelse

I en økonomi, hvor teknologiske fremskridt løbende transformerer efterspørgslen på kompetencer, er kontinuerlig læring ikke længere en valgmulighed, men en uundgåelig forudsætning for at forblive konkurrencedygtig på arbejdsmarkedet. Efter- og videreuddannelse kan udvide en arbejdstagers jobmuligheder ved både at styrke generelle og specifikke færdigheder. Ved at styrke generelle faktorer er det muligt at skifte branche eller sektor, hvorved styrkelse af specifikke færdigheder kan forbedre ens karriereudsigter inden for en konkret virksomhed eller industri. Automatisering og AI overtager i stigende grad rutineprægede opgaver, dermed ændres kompetencekravene på tværs af sektorer (Heckman, 2000).

Ifølge (Becker, 1964) udgør investeringer i human kapital, eksempelvis gennem uddannelse og træning, en central mekanisme til at øge produktiviteten og fremtidig indkomst. Derfor er det væsentligt, at man skelner mellem generel, brancherelateret og virksomhedsspecifik human kapital. Generel human kapital er bredt anvendelig og transportabel mellem sektorer og funktioner. Brancherelateret (industry-specific) human kapital er kompetencer,

der har værdi inden for én sektor, men er sjældent anvendelige på tværs af sektorer. Virksomhedsspecifik (firm-specific) human kapital refererer til færdigheder og viden, der kun har værdi inden for én bestemt organisation; det kan være kendskab til interne systemer og arbejdsprocesser. Denne type kapital er givende for arbejdsgiverne, eftersom det øger effektiviteten samt reducerer behovet for oplæring. Derimod kan denne form for kapital dog hæmme medarbejdernes mobilitet på arbejdsmarkedet.

I et nutidigt arbejdsmarked, der er præget af stigende AI-udsathed, bliver arbejdstagere med færre anvendelige og kontekstafhængige kompetencer i en stigende grad udsatte. Eftersom teknologiske omstillinger ændrer eller fjerner bestemte jobstillinger, vil nogle arbejdstagere miste relevans, hvilket øger sårbarheden for disse grupper. Dermed er der et stigende behov for både opkvalificering og re-skilling. På den måde kan arbejdstagere tilpasse sig nye teknologiske krav og dermed bevæge sig mellem brancher eller jobstillinger (Arntz et al., 2016); (Bessen, 2018).

Derudover skaber denne udvikling en polarisering af arbejdsmarkedet, hvor midt-skill stillinger forsvinder, mens lav-skill stillinger i serviceindustrien samt høj-skill stillinger inden for teknologi og dataanalyse vokser. Derefter handler efter- og videreuddannelse ikke blot om at forbedre sine eksisterende færdigheder, men i mange tilfælde om re-skilling, dvs. få en fuldstændig omskoling til nye færdigheder (Goos et al., 2010).

I forlængelse af dette kan investering i efter- og videreuddannelse ses som en strategisk beslutning, både på individ- og samfundsniveau. Tidligere afsnit har vist, at AI-eksponering kan skabe behov for nye kompetencer, og i den forbindelse spiller økonomiske forhold en central rolle. Der eksisterer økonomiske barrierer, som kan begrænse omfanget af deltagelse i efter- og videreuddannelse. Derfor er økonomiske incitamenter såsom skattefradrag, direkte subsidier og arbejdsgiverstøtte afgørende for at fremme deltagelsen. Mange arbejdstagere vil fravælge efter- og videreuddannelse, hvis disse støttemekanismer ikke er til stede, da de kortsigtede økonomiske omkostninger, herunder indkomsttab under uddannelsesperioden, kan virke afskrækkende (Leuven et al., 2002).

Samtidig fremhæver OECD, at der eksisterer et *free-rider problem*, eftersom virksomheder ofte afholder sig fra at investere i en generel kompetenceudvikling af deres medarbejdere, da de har en frygt for, at disse medarbejdere efterfølgende forlader virksomheden. En markedsfejl som denne kan føre til en underinvestering i human kapital, hvilket inviterer statslige indgreb såsom skatteordninger og offentlige tilskud til efter- og videreuddannelse (OECD, 2017).

Der er en væsentlig udfordring i at tilpasse arbejdsstyrken til de teknologiske forandringer, hvilket er udviklingen af fleksible læringsmodeller, der muliggør opkvalificering af arbejdstagere, samtidig med at de forbliver på arbejdsmarkedet. OECD fremhæver, at digitale læringsplatforme, mikrocertificeringer og modulopbyggede uddannelsesforløb kan reducere de praktiske barrierer ved efter- og videreuddannelse. Dermed bliver det lettere for arbejdstagere at kombinere efter- og videreuddannelse med et fuldtidsarbejde og familieliv. Dertil er det også afgørende, at samarbejdet mellem private virksomheder og uddannelsesinstitu-

tioner sikrer, at efter- og videreuddannelsestilbud matcher arbejdsmarkedets behov. En del virksomheder udvikler i dag interne træningsprogrammer eller partnerskaber med universiteter for at skræddersy efter- og videreuddannelsesforløb, der passer til deres specifikke kompetencekrav (Zahidi et al., 2020).


Det centrale formål med efter- og videreuddannelse er at styrke både horisontal og vertikal jobmobilitet. Horisontal jobmobilitet er ved et brancheskift, for eksempel fra detailhandel til e-commerce, hvorimod vertikal mobilitet er en karriereavancement, såsom overgang fra specialist til leder. Der er en stigende tendens til, at virksomheder søger medarbejdere med tværfaglige færdigheder. Dermed er det muligt for arbejdstagere at bevæge sig mellem forskellige funktioner og brancher. Derudover er efter- og videreuddannelse en væsentlig mekanisme til at afhjælpe teknologisk arbejdsløshed, hvor automatisering og AI fjerner visse jobstillinger (Zahidi et al., 2020). Yderligere er opkvalificering og re-skilling de mest effektive redskaber til at reducere risikoen for strukturel arbejdsløshed, eftersom de gør det muligt for arbejdstagere at skifte job med højere vækstpotentiale. Særligt digitalisering af økonomien har et stigende behov for kompetencer inden for programmering, dataanalyse, projektledelse og digital kommunikation, der ofte kan erhverves gennem efter- og videreuddannelsesforløb (OECD, 2021).

4.2.2 Initiativ og incitament i efter- og videreuddannelse

Med afsæt i den teoretiske gennemgang af efter- og videreuddannelsens betydning for udviklingen af human kapital, er det centralt at undersøge, hvem der tager initiativ til opkvalificeringen, og hvilken form for værdi dette skaber. Det har afgørende betydning for, om der er tale om en investering i generel, virksomhedsspecifik eller brancherelateret human kapital. Dermed har det også en betydning for arbejdstagernes mobilitet og værdi på arbejdsmarkedet. Efter- og videreuddannelse kan igangsættes af arbejdsgiveren eller arbejdstageren selv (Becker, 1964). Når efter- og videreuddannelse er betalt af arbejdsgiveren, vil der typisk være tale om en målrettet kompetenceudvikling, der tjener virksomhedens specifikke behov. Denne form for opkvalificering vil derfor oftest tilføre medarbejderen virksomhedsspecifik human kapital. På den måde bliver medarbejderen mere værdifuld i den eksisterende stilling, men man kan risikere at begrænse muligheden for at anvende disse færdigheder i andre virksomheder. Derimod kan efter- og videreuddannelse, som arbejdstageren selv har finansieret, være rettet mod generelle eller brancherelaterede kompetencer. Dette udvider ikke alene mulighederne for mobilitet på tværs af virksomheder og sektorer, men kan også øge arbejdstagerens attraktivitet for andre arbejdsgivere, herunder konkurrenter, da de opnåede kompetencer i højere grad er anvendelige (Humlum og Vestergaard, 2025).

En analyse baseret på (Humlum og Vestergaard, 2025) viser, at der på tværs af 11 udvalgte ISCO-grupper er variation i, om efter- og videreuddannelse primært er igangsat af arbejdstageren selv eller af arbejdsgiveren. Flere analyser viser, at faggrupper som softwareudviklere og marketingmedarbejdere udviser en relativt høj andel af selvvalgt kursusdeltagelse. Dette peger på en tendens, hvor arbejdstagere i disse funktioner aktivt

opsøger AI-relateret opkvalificering for at styrke deres mobilitet og relevans i en digitaliseret økonomi. Derudover ses i faggrupper som HR-professionelle og journalister også en overvægt af selvvalgt kursusdeltagelse, mens grupper som kundeservicemedarbejdere, kontorassistenter og regnskabsmedarbejdere i højere grad deltager i kursusdeltagelse, der er arrangeret af arbejdsgiveren. Dette mønster kan forklares med variationer i jobstillingernes grad af specialisering samt arbejdsgiverens incitament til at beskytte egne investeringer gennem virksomhedsspecifik opkvalificering.



Figur 4.1. Træning i AI Chatbots (Humlum og Vestergaard, 2025)

Figur 4.1 fra (Humlum og Vestergaard, 2025) viser fordelingen af AI-relateret efter- og videreuddannelse fordelt på, om den er igangsat af virksomheden (Firm-Arranged) eller igangsat af arbejdstageren selv (Worker-Arranged), på tværs af 11 jobkategorier.

I et arbejdsmarked, hvor teknologiske forandringer og udbredelsen af AI forandrer jobindhold og krav til færdigheder, bliver det mere og mere vigtigt at forstå, hvordan efter- og videreuddannelse virker i praksis. Det handler ikke blot om, hvorvidt efter- og videreuddannelse har en positiv effekt, men også om hvem der tager initiativet til den, hvilken type af kompetencer samt værdien den bidrager med, både for den enkelte og for arbejdsmarkedet som helhed.

Analyse 5

Dette kapitel præsenterer analyser af kursusedtagelse og jobskifte baseret på PWP-GT-modeller samt visualiseringer af jobmobilitet.

5.1 Deskriptive analyser og visualiseringer

5.1.1 Bevægelse på arbejdsmarkedet

Til at opstille en analyse af mobilitet på arbejdsmarkedet startes analysen med at se på, hvordan individer bevæger sig over tid. Her vil man kunne få indsigt i bevægelser for personer, der stadig er på arbejdsmarkedet både i 2010 og 2021. Dette kan opdeles i, hvilke tilvækst hovedgrupperne (ISCO 1-4) har oplevet, hvilke bevægelser der sker mellem jobkategorier samt hvorvidt individer forbliver, skifter eller udtræder. Tabel 5.1 viser udviklingen for ISCO-hovedgrupperne 1 til 4, der dækker henholdsvis ledelse, højere videnaarbejde, mellemlangt videnaarbejde og kontorarbejde. Tabellen belyser både ændringer i disse dele af arbejdsmarkedet samt mønstre inden for og mellem grupperne.

Kategori	Ledere	Høj viden	Mid viden	Kontorarbejde
Antal i 2010	107.908	684.571	307.117	218.486
Antal i 2021	121.521	863.114	323.254	269.036
Ændring i antal	13.613	178.543	16.137	50.550
Vækst i procent	+12.6%	+26.1%	+5.3%	+23.1%
Korrigeret for stigning	+0.5%	+14%	-6.8%	+11%
Forbliver i sin stilling	24.827	273.022	85.274	41.654
Andel der forbliver	23%	39,9%	27,8%	19,1%
Skifter hovedgruppe	355	11.897	7681	712
Andel skifter hovedgruppe	0,3%	1,8%	2,5%	0,4%
Til beslægtet stilling	91	422	171	0
Andel til beslægtet stilling	0,1%	0,1%	0,1%	0%
Udtrådt fra arbejdsmarkedet	82.763	406.272	218.183	176.465
Andel udtrådt	76,7%	59,3%	71,0%	80,8%

Tabel 5.1. Udvikling og mobilitet på ISCO-niveau 1-4 fra 2010 til 2021

Korrektionen for den generelle beskæftigelsesstigning sker ifølge RAS311, hvor der sker en stigning fra november 2010 på 2.704.542 til 3.031.215 ultimo november 2021. Dette skaber 12,08% højere beskæftigelse på det danske arbejdsmarked (Danmarks Statistik, 2025a).

Tabel 5.1 viser, at især **Høj viden** oplever den største vækst i antal beskæftigede fra 2010 til 2021 med en stigning på 14%. Samtidigt er det også den gruppe, som har oplevet den største andel, der forbliver i stillingen med 39,9%, samt færrest, der udtræder fra arbejdsmarkedet på 59,3%. Dette indikerer både høj stabilitet samt tilstrømning til denne gruppe. Dette kan være skabt af øget efterspørgsel på akademikere og specialiserede kompetencer på arbejdsmarkedet.

Kontorarbejde udviser et anderledes mønster. Selvom gruppen vokser med 11% fra 2010 til 2021, har den den laveste andel, der forbliver i stillingen på 19,1% og den højeste andel, der udtræder af arbejdsmarkedet med 80,8%. Dette peger på et område i omstilling, hvor jobfunktionerne forandres, forsvinder eller flyttes. En stor del af denne udskiftning kan være skabt af digitalisering, som rammer administrative job hårdt. Tilvæksten kan i højere grad være drevet af flere faktorer, såsom at kontorarbejde kan være præget af entry jobs, hvor individer over et længere forløb vil blive forfremmet eller finde nye stillinger. Derudover er der også stor udskiftning, hvilket tegner på usikre eller midlertidige forhold i denne del af arbejdsmarkedet.

For **Ledere** sker der en meget lille tilstrømning på 0,3%, mens **Mid viden** oplever et fald i beskæftigelse på -6,8%. Begge har større mængder af personer, der udgår fra arbejdsmarkedet på 76,7% og 71%. Mens der er en større andel af **Mid viden** der forbliver på 27,8%, mens **Ledere** er det kun 23%. Dette kan tyde på, at mellemlange videnstillinger er en smule mere stabile over længere jobforløb end lederstillinger.


På tværs af alle grupper ses det, at meget få personer skifter mellem hovedgrupper ved 0,3% og 2,5%, og endnu færre skifter til en beslægtet stilling (0,0 – 0,1%). Det peger på, at horisontal mobilitet mellem hovedgrupperne er begrænset over lange karrierer, og at arbejdsmarkedet i høj grad er segmenteret. Jobskift sker primært inden for samme funktionelle område, mens strukturel mobilitet mellem hovedgrupper er meget sjælden. Derudover er en stor andel, som forbliver i deres langvarige karriere, som forklaret i afsnit 3.1. Disse individer kan have tilknytning til deres arbejdsplads eller have specialiseret sig til at forblive i samme stillingstype.

For at bidrage til denne overordnede observation og identificere, hvordan mobiliteten konkret udfolder sig mellem jobfunktioner, suppleres analysen med et heatmap over overgange mellem to cifrede ISCO-koder. Dette giver mulighed for at undersøge, i hvilke specifikke stillingskategorier der sker bevægelse, og hvilke der er præget af stabilitet. Herigennem kan mønstre i arbejdsmarkedets indre dynamik og graden af specialisering tydeliggøres.

5.1.2 Heatmap for jobmobiliteten fra 2010 til 2021

Figur 5.1 viser et heatmap, som kun visualiserer mobiliteten mellem jobstillinger i perioden 2010 til 2021 for stillinger med et identificeret AI-potentiale. Figuren er baseret på to cifrede ISCO-koder fra Danmarks Statistik, hvor både X- og Y-aksen viser de aggregerede jobkoder fra 10 til 49. Heatmappet viser antallet af individer, der har skiftet fra én

jobstilling til en anden, hvor farverne angiver frekvensen. Farveskalaen går fra mørklilla (lav frekvens) over orange til gul (høj frekvens). I modsætning til den overordnede analyse på hovedgruppeniveau giver dette billede et mere detaljeret indblik i, hvordan individer bevæger sig mellem konkrete funktioner. Farveskalaen repræsenterer andelen af personer, der har bevæget sig mellem to stillinger eller de som forbliver i sin stilling, angivet via diagonalen.



Figur 5.1. Heatmap for stillinger med AI-potentiale, kolonnen udgør summen af alle andele til 100.

Figur 5.1 viser tydeligt, at mange individer forbliver i samme jobstilling over perioden, hvilket ses i den diagonale linje, som domineres af gule og orange farver. Dette mønster indikerer en relativt høj grad af jobstabilitet. Hver kolonne summeres til 100% af gruppens individer, hvor andele på mere end 4% er anoteret med tekst. Felter uden tekst repræsenterer mindre end 4% af udgangsgruppens bevægelse og er derfor nedtonet i visningen for at øge det visuelle.

Det dominerende mønster i heatmappet er stadig den markante diagonale linje med gule og orange felter, som viser, at en stor andel af individerne forbliver i samme jobfunktion over tid. Dette gælder især grupper som Sundhed 89,3%, Undervisning 82,1% og Økonomi & administration 51,6%, som alle har en høj andel af fastholdelse for længere karriere. Det afspejler høj specialisering og lavere mobilitet, hvor kvalifikationer og krav kan begrænse bevægeligheden på tværs af stillinger.

Lederfunktioner viser en mere nuanceret vinkel. Øverste ledere har 57,5% der forbliver, mens Leder: Produktion ligger på 45,8%. Der ses flere mindre, men synlige andele, der

bevæger sig til andre ledelsesfunktioner, hvilket kan være udtryk for karriereskift til lignende stillinger i andre virksomheder.

Andre grupper udviser større variation. Eksempelvis ses Forretning og administration og Tekniker: Sundhed med en fastholdelsesprocentdel på henholdsvis 53% og 60,9%, men også med større andele af individer, der bevæger sig til beslægtede funktioner. Det indikerer en vis grad af horisontal mobilitet inden for relaterede sektorer. Derudover forbliver 64% af IT, hvor små andele skifter til andre brancher. De laveste diagonale værdier og største tegn på spredt mobilitet ses blandt Kontor & sekretær, Kundeservice og Kontor: Andet. Kontor: Andet på 33,9%, mens Kundeservice og Regnskab også har flere små overgange ud til andre funktioner. Det tyder på højere omskiftelighed og mulig strukturel udsathed, eksempelvis i takt med digitalisering.

Samlet viser heatmappet, at de fleste bevægelser sker inden for den samme ISCO hovedgruppe, hvor kun få celler uden for diagonalen overstiger 4% og dermed opnår visning i figuren. Det viser et billede af et arbejdsmarked med høj intern stabilitet og lav horisontal mobilitet på tværs af jobtyper for længere karrierer. Mobilitet er mere koncentreret til fagligt beslægtede områder, hvilket peger på en specialisering og funktionel afgrænsning.

5.2 Modelstruktur og analytisk tilgang

I det følgende analyseres risiko for henholdsvis kursusdeltagelse og jobskifte ved hjælp af PWP-GT-modeller. PWP-GT-modellen er en udvidelse af Cox-regressionen, som muliggør analyse af gentagne events (recurrent events), modellen stratificerer efter hændelsesrækkefølge og dermed tager højde for tidsafhængighed og forrige events. Dette gør det muligt at undersøge, hvordan individer er påvirket af flere kurser og jobskift over tid.

Dataet er struktureret i et start-stop format, hvor hver observation repræsenterer en risikoperiode mellem events. Begge modeller operationaliserer tiden som år. Stratificering anvendes på region, hvilket kontrollerer for de geografiske forskelle og dynamikker. Dette er desuden motiveret af resultaterne fra Schoenfeld-residualplottet, der indledningsvis for region viser et tydeligt brud på den Proportional Hazard-antagelse, hvilket tilføjer systematiske afvigelser i estimeringen af de øvrige effekter. Stratificering på region anvendes således for at kontrollere for tidsafhængige regionale forskelle i baseline hazard uden at introducere tidsvarierende interaktioner, hvilket ville øge modellernes kompleksitet markant.

For begge modeller estimeres tre versioner: (1) med AIOE-score som en kontinuerlig variabel, (2) med AIOE-score inddelt i eksponeringsgrupper (høj, mellem og lav) og (3) med gruppebaseret AIOE samt interaktioner med henholdsvis kumulativ kursusdeltagelse og jobskifte.

5.3 Prentice-Williams-Peterson Gap-Time analyse af kursusdeltagelse events

Dette afsnit undersøger kursusdeltagelse som en tilpasningsmekanisme til stigende AI-eksponering. Med udgangspunkt i tidligere forskning og den metodiske tilgang i afsnit 2.2.4 operationaliseres kursusdeltagelse som en indikator for arbejdstageres opkvalificeringsadfærd. Analysen anvender en PWP-GT-model i dette afsnit til at måle risikoen for gentagen deltagelse i AI-relaterede kurser over tid, afhængigt af individets AIOE-score, færdighedsgruppe, alder og jobmobilitet. Målet er at belyse, om kursusdeltagelse er systematisk relateret til AI-eksponering, og i hvilken grad tidligere erfaringer, såsom tidligere kursusdeltagelse eller jobskift, påvirker denne adfærd.

5.3.1 Modelvurdering

Inden resultaterne af PWP-GT-modellerne for kursusdeltagelse præsenteres, vurderes antagelserne bag modelleringen. De tre modeller har forskellige analytiske formål: **Model 1** vurderer den lineære effekt af AI-eksponering, **Model 2** muliggør identifikation af ikke-lineære ændringer i risiko mellem eksponeringsgrupper, og **Model 3** undersøger, hvordan hændeshistorik påvirker grupperne forskelligt gennem interaktioner.

Modellerne vurderes gennem Proportional Hazard-test (PH-test), visuel inspektion af Schoenfeld-residualer samt AIC-sammenligninger. PH-testen kontrollerer, om kovariaternes effekt ændrer sig systematisk over tid, hvilket ville udgøre et brud på Cox-modellens grundantagelse. Schoenfeld-residualer anvendes til grafisk vurdering af tidsafhængighed og fortolkes med henblik på systematiske afvigelser og graden af afvigelse fra nul over tid. AIC anvendes til at sammenligne modellerne med henblik på, hvilken model der bedst balancerer forklaringskraft og kompleksitet. Resultaterne er dokumenteret i appendiks A.1.

Test af Proportional Hazard-antagelsen

PH-testen er udført for hver model og er angivet i tabel A.1 i appendiks A.1. På grund af det meget store observationssæt vil selv minimale afvigelser kunne give statistisk signifikante resultater. Derfor er en visuel vurdering af Schoenfeld-residuale-plottet nødvendig. Et eksempel herpå er variabelen **Alder** i kursus model 1, udviser et helt stabilt forløb over tid, men alligevel har et signifikant testresultat. Dette indikerer, at testresultaterne ikke nødvendigvis afspejler et reelt brud på PH-antagelsen (Therneau og Grambsch, 2000). For model 1 blev der observeret mindre afvigelser fra proportionalitet, men residualkurverne lå overvejende inden for ± 1 og viste hverken retningsskift eller markant drift over tid. PH-antagelsen vurderes derfor som acceptabel for disse modeller til analysens formål.

For kursus model 2 og 3 observeres visse små systematiske mønstre i Schoenfeld-kurverne for **Kumulative kursusdeltagelse** og **Skill-grupper**, men uden retningsskift eller markant drift over tid. Residualerne ligger fortsat primært inden for ± 1 . For kursus model 3 ses let stigende tendenser i enkelte interaktionseffekter, men der er ikke tegn på

alvorlige afvigelser fra proportionalitetsantagelsen.

Det vurderes derfor, at PH-antagelsen generelt er opfyldt, og med forsigtighed kan resultaterne fortolkes. Her kan der være mindre afvigelser ved specifikke tidspunkter, og dermed have mindre bias i estimeringen.

AIC: Udvælgelse af goodness of fit

Akaike's Information Criterion (AIC) er en måling, der vurderer modellers kompleksitet og evne til at forklare data. AIC bruges til modeludvælgelse, hvor en lavere værdi er ønskværdig, da det er den bedste kombination af goodness of fit og forklaringsevne. Værdien er udelukkende til at sammenligne modeller og forskellen mellem deres værdier.

Model 3, interaktionsmodellen, opnår den laveste AIC og udviser dermed, at den giver den bedste samlede goodness of fit. Sammenligningen vises i følgende tabel 5.2:

Modelnavn	Frihedsgrader brugt	AIC-værdi
Model 1: AIOE som kontinuierlig	8	60,648
Model 2: AIOE som grupperet	9	60,616
Model 3: AIOE grupperet + interaktion	13	60,551

Tabel 5.2. AIC-sammenligning af modeller for kursusdeltagelse

5.3.2 PWP-GT kursus model AIOE-score

Variabel	Koefficient	Ændring i risiko	Robust 95% CI
Kumulative jobskift	-0.0954***	-9.1%	[0.888, 0.926]
Kumulative kursusdeltagelse	0.3753***	+45.5%	[1.276, 1.659]
AIOE-score	-0.2112***	-19.0%	[0.752, 0.871]
Høj viden Skill-gruppe	-0.2200**	-19.8%	[0.695, 0.927]
Mellem viden Skill-gruppe	-0.2471**	-21.4%	[0.679, 0.910]
Kontorarbejde Skill-gruppe	-0.0232	-2.3%	[0.853, 1.119]
Alder	-0.0208***	-2.1%	[0.976, 0.983]
Mænd	0.0691*	+7.1%	[1.013, 1.134]

Tabel 5.3. Model 1 - Kursusdeltagelse med AIOE som kontinuierlig variabel

Tabel 5.3 viser resultaterne for PWP-GT-modellen, hvis formål er at undersøge, hvordan variation i **AIOE-score** hænger sammen med sandsynligheden for at deltage i kurser. **AIOE-score** indgår som en kontinuierlig forklarende variabel i denne model til at undersøge dette. Her vil der ses på hazard ratioen, som er konverteret til ændring i risiko relativt til baseline eller referencegruppe.

For modellen vil denne ligning beskrive sandsynligheden for, at en person i oplever et jobskifte ved tidspunkt t i forhold til en reference. Til dette udregnes hazard ratioen for alle kovariaterne, som vist i følgende ligning:

$$(5.1) \lambda_{ik}(t) = Y_{ik}(t) \cdot \lambda_{0k}(t) \cdot \exp \left(\beta_1 \cdot \text{Jobskifte}_{ik}(t) + \beta_2 \cdot \text{Kursus}_{ik}(t) + \dots + \beta_8 \cdot \text{Mænd}_{ik}(t) \right)$$

Dermed hvis man sammenligner en referenceperson (A) som: har 0 tidligere kurser og jobskift, neutral AIOE-score = 0, er i ledergruppen, 40 år gammel og kvinde. Denne baseline sammenlignes med alternativet (B): 1 tidligere kursus og jobskift, højere AIOE-score = 1, er i Høj videngruppen, 40 år gammel og mand. Hvor beregningen af baseline personen (A) bliver:

$$X_A = -0.09534 \cdot 0 \text{ (Jobskifte)} + 0.3753 \cdot 0 \text{ (Kursus)} + \dots + 0.0691 \cdot 0 \text{ (Mand)} = -0.8325$$

Og alternativpersonen (B):

$$X_B = -0.0954 \cdot 2 \text{ (Jobskifte)} + 0.3753 \cdot 1 \text{ (Kursus)} + \dots + 0.0691 \cdot 1 \text{ (Mand)} = -1.010$$

Dermed vil den relative hazard ratio forskel mellem person B og A være:

$$\text{HR}_{B/A} = \exp(X_B - X_A) = \exp(-1.0100 + 0.8325) = \exp(-0.1775) \approx 0.8375$$

Dermed har man en sammenligning mellem to individer ud fra hazard ratioerne fra modellen og viser, at person (B) har cirka 16.3% lavere risiko for kursusdeltagelse end referenceperson (A). I modellen er det de individuelle kovariater, som påvirker hazard ratioen, der er fokuspunktet i modellens resultater og bliver præsenteret under:

AIOE-score måler, hvordan risikoen for kursusdeltagelse ændrer sig ved én enhedsstigning i eksponering, hvor scoren varierer i intervallet fra $-2,123$ til $1,446$. For hver stigning på 1 point i **AIOE-score** reduceres risikoen for kursusdeltagelse med 19%, den samlede effekt over hele intervallet er illustreret i appendiks A.3. Individer med den laveste score på $-2,123$ har 56,6% højere risiko for kursusdeltagelse end referencen af **AIOE-score** = 0, mens de med den højeste score på $1,446$ har en 26,3% lavere risiko for kursusdeltagelse. Resultaterne indikerer således, at en højere AIOE-score reducerer sandsynligheden for at påbegynde nye kurser i forhold til en neutral AIOE-score. Højt AI-eksponerede individer er ikke dem, der oftest deltager i kurser; tværtimod er det de mindre AI-udsatte, der tager AI-relaterede kurser. Dette kan skyldes forskelle i kursusudbud eller gennem intern oplæring på arbejdspladserne, der ikke fanges af modellen.

Derudover observeres en mindre negativ effekt af **Kumulative jobskift** på 9,1%, mens **Kumulativ kursusdeltagelse** har en markant risikoøgende effekt på 45,5%. Tidligere deltagelse i kurser øger således sandsynligheden for yderligere deltagelse, hvilket kan indikere, at læring stimulerer yderligere læring. Omvendt mindsker hyppige jobskift delvist risikoen for individer til at deltage i kurser. Dette kan være en tendens for individer, der skifter job hyppigt, allerede besidder de nødvendige kvalifikationer til nye jobstillinger, eller grundet usikkerhed mellem individ og arbejdsgiver.

Færdighedsniveauerne under **Skill-grupper** udviser også signifikante effekter. Højt- og mellemhøjtuddannede individer har en lavere risiko for kursusdeltagelse sammenlignet med referencegruppen **Leder**, med henholdsvis 19,8% og 21,4% lavere risiko. For **Kontorarbejdere** observeres der ingen signifikant forskel i forhold til ledergruppen. Disse

mønstre kan skyldes, at ledere har et behov for opkvalificering for at følge med i den digitale omstilling. Hvorimod højt- og mellemhøjtuddannede individer muligvis allerede besidder de relevante specialiseringer i forhold til lederne.

Alder har en lille, men signifikant negativ effekt på 2,1% per år, hvilket indikerer, at sandsynligheden for kursusdeltagelse falder med stigende alder. Over en periode på 10 år svarer det til cirka 21% lavere risiko. Dette kan indikere, at ældre medarbejdere har et lavere incitament til yderligere opkvalificering, eller omvendt, at yngre medarbejdere i højere grad søger ny viden og udvikling. **Køn** har en moderat effekt, idet **Mænd** har 7,1% højere risiko for kursusdeltagelse end kvinder.

Samlet viser resultaterne, at højere AI-eksponering signifikant reducerer sandsynligheden for at deltage i AI/IT-kurser. Tidligere kursusdeltagelse har en markant positiv effekt og øger risikoen for yderligere deltagelse. Ledergruppen deltager i højere grad end de øvrige skill-grupper, mens hyppige jobskift og samtidig stigende alder er forbundet med lavere sandsynlighed for kursusdeltagelse.

5.3.3 PWP-GT kursus model AIOE-gruppe

Denne model er AIOE-score opdelt i Højt-, Mellem- og Lavt-udsatte grupper. Den kontinuerlige model giver de marginale effekter af AIOE-scoren, hvor denne model vil muliggøre at fange de ikke-lineære effekter af variablen.

Variabel	Koefficient	Ændring i risiko	Robust 95% CI
Kumulative jobskift	-0.0993***	−9.5%	[0.883, 0.928]
Kumulative kursusdeltagelse	0.3867***	+47.2%	[1.287, 1.683]
Højt AI-udsatte	-0.3133***	−26.9%	[0.671, 0.796]
Mellem AI-udsatte	-0.2031***	−18.4%	[0.762, 0.874]
Høj viden Skill-gruppe	-0.1907*	−17.4%	[0.707, 0.966]
Mellem viden Skill-gruppe	-0.1999*	−18.1%	[0.725, 0.925]
Kontorarbejde Skill-gruppe	-0.0125	−1.2%	[0.853, 1.144]
Alder	-0.0185***	−1.9%	[0.978, 0.985]
Mænd	0.0957***	+10.0%	[1.041, 1.163]

Tabel 5.4. Model 2 - Kursusdeltagelse: AIOE som gruppeopdelt
*Ændring i risiko = $\exp(\text{Hazard ratio} - 1) * 100$*

Tabel 5.4 viser resultaterne fra PWP-GT-modellen, hvor **AIOE-score** er operationaliseret som en kategorisk variabel opdelt i tre intervaller: lav, mellem, høj. Referencegruppen udgøres af lavt AI-udsatte. Her bliver der set på hazard ratioen om størrelsen af risiko relativt til referencen, enten en specifik gruppe, såsom **Lavt AI-udsat** eller en neutral værdi som ved de kumulative variabler, hvor det er individer uden tidligere kurser eller jobskift.

Resultaterne viser, at både mellem- og højt AI-udsatte har en signifikant lavere risiko for kursusdeltagelse. **Højt AI-udsatte** har en 26,9% lavere risiko, mens **Mellem AI-udsatte** har en 18,1% lavere risiko sammenlignet med referencegruppen. Disse

resultater understøtter den tendens, der ses i den kontinuerlige model; at en højere AIOE-score er forbundet med lavere sandsynlighed for kursusdeltagelse. Dette underbygger mønsteret fra model 1, at individer med høj AI-eksponering i mindre grad benytter sig af kursustilbud.

I lighed med den tidligere model har **Kumulativ kursusdeltagelse** en positiv effekt, idet den er forbundet med en 47,2% højere risiko for ny deltagelse. Omvendt reducerer **Kumulative jobskift** risikoen for kursusdeltagelse med 9,5%.

Færdighedsgrupperne viser, at både **Høj viden** og **Mellem viden** er forbundet med en lavere sandsynlighed for kursusdeltagelse, med henholdsvis 17,4% og 18,1% lavere risiko sammenlignet med referencegruppen **Leder**. For **Kontorarbejdere** omfatter konfidensintervallet en hazard ratio på 1, hvilket betyder, at effekten ikke er statistisk signifikant. Dette indikerer, at det primært er ledergruppen, der deltager i opkvalificeringstiltag.

Alder har igen en negativ effekt på 1,9%, hvilket antyder en aldersbetinget nedgang i sandsynligheden for kursusdeltagelse over tid. Derudover har **Mænd** i denne model en 10% højere risiko for deltagelse sammenlignet med kvinder, hvilket er i overensstemmelse med tidligere resultater.

Sammenlignet med model 1, hvor AIOE-score indgår som en kontinuerlig variabel, viser gruppemodellen den samme overordnede tendens: Højere AI-eksponering er forbundet med lavere risiko for kursusdeltagelse.

5.3.4 PWP-GT kursus model AIOE-interaktioner

Variabel	Koefficient	Ændring i risiko	Robust 95% CI
Kumulative jobskift	-0.2316***	−20.7%	[0.749, 0.839]
Kumulative kursusdeltagelse	0.2132	+23.7%	[0.993, 1.545]
Højt AI-udsatte	-0.9110***	−59.9%	[0.308, 0.524]
Mellem AI-udsatte	-0.4570**	−36.7%	[0.488, 0.821]
Høj viden Skill-gruppe	-0.1989*	−17.5%	[0.705, 0.965]
Mellem viden Skill-gruppe	-0.1826*	−16.9%	[0.703, 0.984]
Kontorarbejde Skill-gruppe	-0.0126	−1.2%	[0.853, 1.144]
Alder	-0.0181***	−1.8%	[0.978, 0.985]
Mænd	0.0928***	+9.7%	[1.038, 1.173]
Kumulative jobskift × Høj AI-udsatte	0.2148***	+24.0%	[1.158, 1.346]
Kumulative jobskift × Mellem AI-udsatte	0.1733***	+18.9%	[1.115, 1.283]
Kumulative kursusdeltagelse × Høj AI-udsatte	0.3333**	+39.6%	[1.102, 1.766]
Kumulative kursusdeltagelse × Mellem AI-udsatte	0.0903	+9.4%	[0.840, 1.273]

Tabel 5.5. Model 3 - Kursusdeltagelse: AIOE-grupper og interaktioner

$$\text{Ændring i risiko} = \exp(\text{Hazard ratio} - 1) * 100)$$

Tabel 5.5 udvider den tidligere analyse ved at inkludere interaktionsled mellem AIOE-grupper og både **Kumulative jobskift** og **Kumulative kursusdeltagelse**. Dette muliggør en undersøgelse af, om effekten af tidligere adfærd varierer afhængigt af graden af AI-eksponering.

Generelt viser resultaterne, at både *Højt AI-udsatte* og *Mellem AI-udsatte* fortsat har en markant lavere sandsynlighed for kursusdeltagelse sammenlignet med lavt AI-udsatte. Effekten for *Højt AI-udsatte* øges fra 26,9% lavere risiko end i model 2 op til 59,9%, mens *Mellem AI-udsatte* går fra 18,4% til 36,7% lavere risiko end de lavt AI-udsatte.

Interaktionen mellem *Kumulative jobskift* med *Højt AI-udsatte* og *Mellem AI-udsatte* modvirker den generelle negative effekt og resulterer i en øget sandsynlighed for kursusdeltagelse. For *Højt AI-udsatte* og *Mellem AI-udsatte*, som samtidig har haft skiftet minimum ét job, ses en forøget risiko på henholdsvis 24% og 18,9% sammenlignet med *Lavt AI-udsatte*. Selvom AI-udsatte generelt deltager mindre i kurser i sig selv, tyder resultaterne på, at et jobskifte markant øger deres sandsynlighed for deltagelse, når der sker et jobskifte. Dette kan indikere, at jobskift fungerer som en udløsende faktor for kursusdeltagelse blandt grupper, der ellers er mindre tilbøjelige til at opkvalificere sig. Det kan skyldes *onboarding* eller krav om efteruddannelse i forbindelse med nye jobstillinger.

Interaktionen med de AI-udsatte grupper og *Kumulative kursusdeltagelse* viser, at tidligere kursusdeltagelse i særlig grad øger sandsynligheden for fremtidig deltagelse blandt *Højt AI-udsatte*, hvor risikoen stiger til 39,6%. For *Mellem AI-udsatte* er effekten derimod usignifikant med en effekt på 9,4%. Dette kan indikere, at når *Højt AI-udsatte* først har påbegyndt kursusdeltagelse, er der en tendens til, at yderligere kurser følger.

Kumulativ kursusdeltagelse har en positiv effekt, men på et lavere niveau end i den forrige model fra 47,2% ned til 23,7% øget risiko. For *Kumulativ jobskifte* ses en forstærket negativ effekt med en 20,7% lavere risiko for kursusdeltagelse. Dog ændrer dette sig markant, når interaktionen med AI-udsatte grupper inddrages; der ses en modsat effekt, hvor risikoen for kursusdeltagelse stiger blandt de AI-udsatte, der har skiftet job.

Skill-grupper viser et risikomønster, der ligner det i de forrige modeller, hvilket igen bekræfter, at ledere har den højeste risiko for kursusdeltagelse. *Alder* og *Mænd* følger samme mønster som i tidligere analyser: Ældre har lavere sandsynlighed for kursusdeltagelse, mens *Mænd* i gennemsnit har en højere sandsynlighed end kvinder.

Samlet viser modellen, at AI-eksponering i sig selv reducerer sandsynligheden for kursusdeltagelse. Dog engagerer individer med høj AI-eksponering sig i højere grad i kurser, hvis de har skiftet job hyppigt eller allerede har erfaring med relevant kursusdeltagelse. Interaktionseffekterne peger således på et differentieret læringsmønster, hvor tidligere erfaringer spiller en vigtig rolle i, hvordan AI-eksponerede grupper responderer på muligheder for opkvalificering.

5.4 Prentice-Williams-Peterson analyse af jobskifte events

Resultaterne peger på, at kursusdeltagelse i nogen grad hænger sammen med AI-eksponering, især for bestemte grupper. Dette rejser spørgsmålet, om opkvalificering også fører til øget mobilitet på arbejdsmarkedet. I det følgende afsnit undersøges derfor, hvordan jobskiftefrekvensen påvirkes af AIOE-score, og om der kan identificeres mønstre i mobilitet

på tværs af skill-niveauer.

5.4.1 Modelvurdering

For jobskifte modellerne vurderes igen antagelserne bag modelleringen. De tre modeller har, som ved analysen af kursusdeltagelse, til formål at belyse, hvordan AI-eksponering påvirker risikoen for jobskifte. Dette bliver igen gjort med proportional hazard-testen (PH-testen), visuel vurdering af Schoenfeld-residualer samt AIC-sammenligninger. Resultaterne af disse vurderinger er dokumenteret i appendiks A.2.

Test af Proportional Hazard-antagelsen

Tabel A.2 i appendiks A.2, viser resultaterne af PH-testen for de tre modeller. For alle modeller er **Kumulative kursusdeltagelse** ikke signifikant og bryder dermed ikke PH-antagelsen. Variablen **Køn** bryder antagelsen i model 1, men ikke i modellerne 2 og 3. De øvrige variabler viser høj statistisk signifikans på tværs af alle tre modeller. Derfor suppleres den statistiske test med en visuel undersøgelse af Schoenfeld-residual plots for at identificere eventuelle følsomheder, der kan have indflydelse på signifikansniveauet uden at afspejle et reelt brud på proportionalitetsantagelsen.

Generelt viser Schoenfeld-residualerne for alle modellerne, at **Alder** og **Køn** har flade forløb over tid, til trods for at PH-testen indikerer signifikante afvigelser. Dette tyder på, at testresultaterne ikke nødvendigvis afspejler substantielle brud på proportionalitetsantagelsen. I model 1 observeres desuden et mindre brud for **Skill grupper**, hvor der angives et mindre brud uden for konfidensintervallet.

I model 2 ses, at **AIOE-grupper** bevæger sig uden for konfidensintervallet, hvilket indikerer en systematisk trend og et tydeligere brud på PH-antagelsen. **Skill grupper** udviser en lignende tendens som i model 1 med mindre, men stabile afvigelser. For øvrige variabler observeres kun mindre udsving, som ligger inden for acceptable grænser og vurderes ikke at udgøre væsentlige brud på antagelsen.

Model 3 viser overordnet samme resultater i kovariaterne som de foregående modeller. De største brud på PH-antagelserne sker ved interaktionerne med **AIOE-grupper**. Her er et klart eksempel på, at der skal laves et indgreb til at modellere anderledes.

Model 3b er lavet baseret på AIOE-score som kontinuerlig variabel og med interaktioner. Dette er for at undersøge en mere robust model, med bedre overholdelse af PH-antagelserne og til sammenligning af resultater.

AIC: Udvælgelse af bedste goodness of fit

Ved vurderingen af modelkriterierne sammenlignes modellerne med særlig opmærksomhed på, at model 2 og 3 udviser væsentlige brud på PH-antagelsen, hvilket har betydning for modellernes validitet.

Modelnavn	Frihedsgrader brugt	AIC-værdi
Model 1: AIOE som kontinuerlig	8	8.798.761
Model 2: AIOE som grupperet	9	8.783.929
Model 3: AIOE grupperet + interaktion	13	8.783.277
Model 3b: AIOE kontinuerlig + interaktion	10	8.798.743

Tabel 5.6. AIC-sammenligning af modeller for jobskifte

I tabel 5.6 sammenlignes AIC-værdierne for de tre modeller. På trods af brud på PH-antagelsen i både model 2 og 3 vurderes model 3b som den mest egnet til fortolkning, da den har den lavere AIC end model 1, samt ikke bryder den visuelle inspektion af Schoenfeld-residualerne.

5.4.2 PWP-GT jobskift model AIOE-score

Variabel	Koefficient	Ændring i risiko	Robust 95% CI
Kumulative jobskift	0.5498***	+73.3%	[1.639, 1.833]
Kumulative kursusdeltagelse	-0.1383***	-12.9%	[0.841, 0.901]
AIOE-score	-0.0825***	-7.9%	[0.912, 0.929]
Høj viden Skill-gruppe	-0.1850***	-16.9%	[0.816, 0.847]
Mellem viden Skill-gruppe	-0.1629***	-15.0%	[0.824, 0.874]
Kontorarbejde Skill-gruppe	0.0598***	+6.2%	[1.045, 1.079]
Alder	-0.0213***	-2.1%	[0.976, 0.981]
Mænd	0.0361***	+3.7%	[1.031, 1.043]

Tabel 5.7. Model 1 - Jobskifte: Med AIOE-score som kontinuerlig variabel
 $\text{Ændring i risiko} = \exp(\text{Hazard ratio} - 1) * 100$

Tabel 5.7 viser resultaterne fra PWP-GT-modellen, som analyserer sandsynligheden for jobskifte ved hjælp af **AIOE-score** som en kontinuerlig forklarende variabel. Modellen belyser således, hvordan AI-eksponering samt øvrige kontrolvariable påvirker jobmobilitet over tid.

Resultaterne viser, at en stigning på 1 point i **AIOE-score** reducerer risikoen for jobskifte med 7,9%. Ved laveste AI-eksponering ses en stigning i risikoen på op til 19,1%, men efterhånden som AI-scoren stiger, aftager denne effekt og bliver negativ. Blandt de mest AI-udsatte reduceres risikoen for jobskifte med op til 11,2%. Effekten over hele intervallet er illustreret i appendiks A.4. Det betyder, at individer med lav AI-eksponering oftere skifter job end dem med høj AI-eksponering. En mulig forklaring er, at stillinger med høj AI-eksponering generelt er mere specialiserede eller stabile, hvilket reducerer mobiliteten.

Kumulative jobskift har en markant positiv effekt på sandsynligheden for yderligere jobskift med 73,3% øget risiko for at skifte arbejde igen. Da der er tale om en kumulativ variabel, vil risikoen for jobskifte følge en eksponentiel udvikling: $HR(n) = 1.73^n$. Ved to tidligere jobskift vil risikoen således være: $1.73^2 = 2.99$ svarende til cirka $\approx 199\%$ højere risiko for endnu et jobskifte. Dette indikerer en substantiel effekt, hvor visse individer har en markant højere tilbøjelighed til at skifte jobstilling igen. Det kan også tyde på, at

nogle individer har vanskeligt ved at tilpasse sig til deres nye stilling og påbegynder et nyt jobskifte.

Modsat ses en negativ effekt af **Kumulativ kursusdeltagelse**, idet tidligere deltagelse i kurser reducerer risikoen for jobskifte med 12,9%. Dette kan indikere, at deltagelse i efter- og videreuddannelse stabiliserer ansættelsesforhold og dermed mindsker sandsynligheden for at skifte job.

Blandt færdighedsgrupperne er det kun **Kontorarbejde Skill**, der udviser en positiv effekt med 6,2% højere risiko sammenlignet med ledergruppen. Dette antyder, at individer med kontorfærdigheder i højere grad skifter job, muligvis som følge af lavere adgangsbarrierer eller større udbud af relevante stillinger. Derimod ses en lavere risiko for jobskifte blandt grupperne **Høj viden** og **Mellem viden**, med henholdsvis 16,9% og 15% lavere risiko, hvilket peger på en større jobstabilitet i mere specialiserede funktioner.

Alder har en negativ effekt på 2,1%, hvilket stemmer overens med tidligere resultater, der viser, at ældre individer generelt er mindre mobile på arbejdsmarkedet. Desuden har **Mænd** en 3,7% højere risiko for jobskifte sammenlignet med kvinder.

Samlet set viser modellen, at høj AI-eksponering er forbundet med lavere jobmobilitet, mens kursusdeltagelse har en beskæftigelsesstabiliserende effekt og ikke fremmer jobskifte. Resultaterne tyder på, at AI-udsatte grupper ikke reagerer på teknologisk pres ved at søge nye stillinger. Derimod indikerer den kumulative effekt af tidligere jobskifte, at visse grupper har en mobilitetsprofil præget af gentagne jobskift.

5.4.3 PWP-GT jobskift model AIOE-gruppe

Variabel	Koefficient	Ændring i risiko	Robust 95% CI
Kumulative jobskift	0.6037***	+82.9%	[1.715, 1.949]
Kumulative kursusdeltagelse	-0.1503***	-13.9%	[0.832, 0.889]
Høj AI-udsatte	-0.4430***	-35.8%	[0.605, 0.681]
Mellem AI-udsatte	-0.3617***	-30.3%	[0.659, 0.736]
Høj viden Skill-gruppe	-0.1543***	-14.3%	[0.825, 0.889]
Mellem viden Skill-gruppe	-0.1563***	-14.4%	[0.831, 0.880]
Kontorarbejde Skill-gruppe	0.0912***	+9.5%	[1.077, 1.114]
Alder	-0.0194***	-1.9%	[0.978, 0.983]
Mænd	0.0395***	+4.0%	[1.033, 1.057]

Tabel 5.8. Model 2 - Jobskifte: Med AIOE-gruppering
 $\text{Ændring i risiko} = \exp(\text{Hazard ratio} - 1) * 100$

Tabel 5.8 præsenterer jobskiftmodellen, hvor AIOE-score er inddelt i tre intervaller: lav, mellem og høj. Referencegruppen for AI-eksponering er lavt AI-udsatte. For færdighedsgrupperne anvendes ledere som reference, mens kvinder er referencegruppen for køn.

Resultaterne viser, at **Mellem AI-udsatte** individer har en signifikant lavere risiko

for jobskifte sammenlignet med de lavt AI-udsatte. De har 30,3% lavere risiko end referencegruppen. For de Højt AI-udsatte ses en endnu lavere risiko på 35,8%, hvilket tyder på, at AI-eksponering kan have en stabiliserende effekt i jobstillinger, der ellers kunne betragtes som udsatte. I modsætning hertil oplever lavt AI-eksponerede grupper muligvis større organisatoriske omstruktureringer. Dette antyder samtidig, at AI-eksponering har en omvendt effekt for visse kontorjob, som ellers antages at være i risiko for automatisering gennem AI.

Kumulative jobskift har en markant positiv effekt på 82,9%, hvilket indikerer en stærk selvforstærkende tendens: tidligere jobskift øger sandsynligheden for yderligere mobilitet. Omvendt reducerer Kumulativ kursusdeltagelse risikoen for jobskifte med 13,9%, hvilket antyder, at efter- og videreuddannelse har en fastholdende effekt og bidrager til øget stabilitet i ansættelsen.

Blandt færdighedsvariablerne er det kun Kontorarbejde Skill-gruppe, der udviser en øget risiko for jobskifte, med en stigning på 9,5%. Dette indikerer en højere mobilitet blandt kontorarbejdere. De øvrige færdighedsniveauer høj- og mellem viden, har lavere risiko på henholdsvis 14,3% og 14,4%, hvilket tyder på, at mere specialiserede eller tekniske jobstillinger er forbundet med større jobstabilitet.

Alder udviser igen en negativ effekt over tid, hvilket styrker forrige resultater, at ældre individer generelt har lavere jobmobilitet. Derudover har Mænd en 4% højere risiko for jobskifte sammenlignet med kvinder.

Disse tendenser indikerer, at individer i jobstillinger med høj AI-eksponering generelt har en lavere risiko for jobskifte, hvilket kan virke modstridende i forhold til antagelsen om, at teknologisk pres fører til øget mobilitet. Det kan dog tolkes som, at disse individer besidder kompetencer, og derfor i højere grad fastholdes i deres stillinger. I lavt AI-eksponerede jobstillinger, hvor AI-eksponering er begrænset, ses til gengæld en højere mobilitet, hvilket kan skyldes organisatoriske ændringer eller manglende tilpasning. Resultaterne peger dermed på en asymmetrisk reaktion om, hvordan arbejdstagere reagerer på teknologisk udvikling via mobilitet.

5.4.4 PWP-GT jobskift model AIOE-interaktioner

Variabel	Koefficient	Ændring i risiko	Robust 95% CI
Kumulative kursUSDeltagelse	-0.0925***	−8.8%	[0.867, 0.958]
Kumulative jobskifte	0.5879***	+80.1%	[1.721, 1.882]
Høj AI-udsatte	-0.6175***	−46.1%	[0.514, 0.566]
Mellem AI-udsatte	-0.4050***	−33.4%	[0.617, 0.722]
Høj viden Skill-gruppe	-0.1586***	−14.7%	[0.802, 0.868]
Mellem viden Skill-gruppe	-0.1563***	−14.4%	[0.814, 0.874]
Kontorarbejde Skill-gruppe	0.0887***	+9.3%	[1.075, 1.118]
Alder	-0.0193***	−1.9%	[0.978, 0.983]
Mænd	0.0441***	+4.5%	[1.038, 1.063]
Kumulative jobskifte × Høj AI-udsatte	0.0909***	+9.5%	[1.072, 1.117]
Kumulative jobskifte × Mellem AI-udsatte	0.0258***	+2.6%	[1.018, 1.030]
Kumulative kursUSDeltagelse × Høj AI-udsatte	-0.0251	−2.5%	[0.910, 1.045]
Kumulative kursUSDeltagelse × Mellem AI-udsatte	-0.1417***	−13.2%	[0.833, 0.902]

Tabel 5.9. Model 3 - Jobskifte: AIOE-grupper med interaktioner
 $\text{Ændring i risiko} = \exp(\text{Hazard ratio} - 1) * 100$

Tabel 5.9 præsenterer modellen med interaktioner mellem AIOE-grupper og henholdsvis kumulative jobskifte og kursUSDeltagelse. Denne model muliggør en undersøgelse af, hvordan sammenhængen mellem tidligere adfærd og jobskifte varierer afhængigt af graden af AI-eksponering.

Resultaterne viser, at både mellem- og højt AI-udsatte individer har en signifikant lavere risiko for jobskifte sammenlignet med referencegruppen (lavt AI-udsatte), med henholdsvis 33,4% og 46,1% lavere risiko. Dette indikerer, at højere AI-eksponering ikke er forbundet med øget mobilitet på arbejdsmarkedet, men snarere har en jobstabiliserende effekt.

Kumulative jobskifte har en markant øget risiko på 80,1%, mens **Kumulative kursUSDeltagelse** reducerer risikoen med 8,8%. Dette understøtter, at gentagne jobskifte har en selvforstærkende effekt på jobmobilitet, mens deltagelse i kurser virker fastholdende og bidrager til større stabilitet i den nuværende jobstilling.

Derudover viser resultaterne, at interaktionen mellem **Kumulative jobskifte** og henholdsvis mellem- og højt AI-udsatte individer øger risikoen for yderligere jobskifte med 2,6% og 9,5%. Dette indikerer, at tidligere jobskifte udgør en forstærkende faktor for mobilitet, også blandt individer med høj AI-eksponering, hvilket tyder på en vedvarende tendens til jobskifte i disse grupper.

Interaktionerne med **Kumulative kursUSDeltagelse** viser en reduceret risiko for jobskifte på 13,2% blandt mellem AI-udsatte individer, mens der ikke ses nogen tydelig effekt blandt de højt AI-udsatte. Dette tyder på, at kursUSDeltagelse har en fastholdende effekt for mellem AI-udsatte, mens denne effekt ikke gør sig gældende i samme grad for højt AI-udsatte grupper.

Herudover bekræftes igen en negativ effekt af **Alder**, hvilket indikerer lavere mobilitet

blandt ældre individer. Mænd har en let forhøjet risiko for jobskifte sammenlignet med kvinder. Individer i **Kontorarbejde** udviser signifikant højere mobilitet, mens individer med henholdsvis høj- og mellemvidensbaserede færdigheder har en signifikant reduceret risiko for jobskifte på 14,7% og 14,4%, hvilket peger på større jobstabilitet i specialiserede funktioner.

Samlet set indikerer modellen, at tidligere mobilitet og graden af AI-eksponering har betydning for sandsynligheden for jobskifte, mens kursusdeltagelse har en stabiliserende effekt. Der tegner sig en differentieret dynamik, hvor især mellem AI-udsatte individer reagerer anderledes på tidligere jobskifte og efter- og videreuddannelse, hvilket peger på, at effekten af tidligere adfærd afhænger af eksponeringsniveauet.

5.4.5 PWP-GT jobskift model 3b - AIOE-score + interaktioner

Model 3b er et alternativ af den tidligere analyse i model 3, hvor vi undersøger, om effekten af AIOE-score afhænger af tidligere hændelser som kumulative kursusdeltagelser og jobskift, uden at bryde PH-antagelsen. I appendiks 5.10 ses det, at interaktionen mellem AIOE-score og de kumulative variabler ikke bryder PH-antagelsen, som ved **Model 3**, hvor der er tydelige brud. Derfor kan modellen inkludere både interaktioner og baseline AIOE-score, uden at der opstår alvorlige metodiske problemer.

Variabel	Koefficient	Ændring i risiko	Robust 95% CI
Kumulative jobskift	0.5583***	+74.8%	[1.677, 1.822]
Kumulative kursusdeltagelse	-0.0769	-7.4%	[0.892, 1.000]
AIOE-score	-0.0617***	-6.0%	[0.930, 0.950]
Høj viden Skill-gruppe	-0.1849***	-16.9%	[0.814, 0.848]
Mellem viden Skill-gruppe	-0.1634***	-15.0%	[0.828, 0.873]
Kontorarbejde Skill-gruppe	0.0604***	+6.2%	[1.046, 1.079]
Alder	-0.0213***	-2.1%	[0.976, 0.981]
Mænd	0.0365***	+3.7%	[1.032, 1.049]
Kumulative jobskift × AIOE-score	-0.0126***	-1.3%	[0.971, 0.988]
Kumulative kursusdeltagelse × AIOE-score	-0.0598	-5.8%	[0.880, 1.000]

Tabel 5.10. Model 3b - Jobskifte: AIOE-score med interaktioner
 $\text{Ændring i risiko} = \exp(\text{Hazard ratio} - 1) * 100$

Resultaterne for model 3b vises i tabel 5.10. Ved at undersøge hazard ratioen ses der, at **Kumulative jobskift** har en markant effekt: for hver tidligere jobskift stiger risikoen for endnu et skift med 74,8% i forhold til individer uden tidligere jobskifte. Modsat reducerer **Kumulativ kursusdeltagelse** risikoen for jobskifte med 7,4%, hvilket indikerer, at opkvalificering har en stabiliserende effekt på ens arbejdssituation.

AIOE-score viser 6% lavere risiko per stigning i enhed, som antyder, at højere AI-eksponerede job skifter mindre, muligvis grundet, at de har en specialisering eller mere stabile arbejdsforhold. For den maksimale AIOE-score er der 8,5% lavere risiko for et jobskifte, mens mindste AIOE-score vil betyde, at der er 14% stigning i risiko for jobskifte i forhold til at have en neutral AIOE-score.

For skillgrupperne har **Høj viden** 16,9% lavere risiko, samt **Mellem viden** har 15,0% lavere risiko. Igen er det referencegruppen **ledere**, som er mest sandsynlig for skifte arbejde, mens kontorarbejde har lidt højere udskiftning på 6,2% højere risiko. For *Alder* har man 2,1% lavere risiko per år man ældres, mens **Mænd** 3,7% højere risiko for jobskifte sammenlignet med kvinder.

Kumulative jobskift $\times$ **AIOE** har 1,3% lavere effekt af tidligere jobskift, jo højere AIOE-score ens jobstilling har. Dermed peger det på, at AI-eksponering dæmper tendensen til gentagne jobskift for højt AI-udsatte jobstillinger. **Kursus** $\times$ **AIOE** har 5,8% lavere risiko, men ikke signifikant, hvis usikkerhed forhindrer klar konklusion.

Samlet set viser modellen, at AIOE ikke blot har en direkte indflydelse på jobmobilitet, men også ændrer betydningen af tidligere adfærd. Gentagne jobskift er meget selvforstærkende, men den effekt dæmpes ved høj AI-eksponering. Højere skill-niveauer er klart forbundet med lavere mobilitet, hvilket viser et arbejdsmarked præget af segmentering og specialisering.

5.4.6 Vurdering af model og tilgang

I løbet af analyserne er det blevet klart, at modellerne ikke i alle tilfælde lever op til de krav, som PWP-GT opsætter for præcis tidsmæssig fortolkning. Resultaterne kan derfor ikke nødvendigvis anvendes til en præcis forudsigelse, men de giver stadig mulighed for at undersøge overordnede tendenser og forskelle mellem variabler.

En vigtig del er, hvor meget man kan stole på modellens resultater, når proportional hazards-antagelsen ikke altid holder helt. I nogle af modellerne er denne antagelse blevet brudt i mindre grad, især når det gælder interaktioner. Det sætter grænser for, hvor præcist man kan sige noget om udviklingen over tid.

Det betyder dog ikke, at resultaterne er ubrugelige, men det er dog vigtigt at tage højde for modellernes begrænsninger. Derfor skal resultaterne først og fremmest ses som en måde at identificere mønstre og forskelle på. Eksempelvis om individer med høj AI-eksponering generelt har større risiko for jobskifte, eller om tidligere hændelser har en vedvarende betydning.

5.5 Robusthedstest af modelvalg

For at undersøge disse problematikker er der lavet en test med og uden de respektive kumulative variabler og en sammenligning. Dette vises i tabel 5.11 og 5.12. I tabellerne kan man se, at resultaterne viser, at de øvrige kovariater er forholdsvis stabile. Kursusmodellens største forskel er 2,5%, og jobskitemodellen viser 0,2% forskel. Indikationen af dette er, at følsomheden for at medtage variablerne ikke er stor, men fortolkningen skal stadig tilpasses, grundet de korrelerede mønstre.

5.5.1 Kursus model sammenligning

Variabel	HR (med)	Forskel	HR (uden)
Kursus kumulativ	+45.5%	+1.8	+43.7%
AIOE-score	-19.0%	+2.3	-21.3%
Høj Viden	-19.8%	+2.5	-22.3%
Mellem viden	-22.3%	-0.3	-22.0%
Kontorarbejde	-2.3%	+0.6	-2.9%
Alder	-2.1%	=	-2.1%
Mænd	+7.1%	-1.7	+8.8%

Tabel 5.11. HR-effekter - Kursusdeltagelse med og uden jobskifte kumulativ

Kursusdeltagelsesmodellen i tabel 5.11 viser forskellen mellem en model med og uden kumulativ jobskifte medtaget. Her ses der forskelle, der varierer mellem +2,5% til -1,7%, disse forskelle ses ikke som meget store og kan være forudsaget af det lave antal af events, der bliver frigivet af udelukkelsen af kovariaten. Dette kan også være fra effekter, som har korrelation i modellen.

5.5.2 Jobskifte model sammenligning

Variabel	HR (med)	Forskel	HR (uden)
Jobskifte kumulativ	+73.3%	=	+73.3%
AIOE-score	-7.9%	+0.1	-8.0%
Høj Viden	-16.9%	=	-16.9%
Mellem Viden	-15.0%	+0.2	-15.2%
Kontorarbejde	+6.2%	+0.1	+6.1%
Alder	-2.1%	=	-2.1%
Mænd	+3.7%	=	+3.7%

Tabel 5.12. HR-effekter - Jobskifte med og uden kursus kumulativ

Jobskiftemodellen i tabel 5.12 viser næsten ingen forskel i variablerne ved udelukkelse af kursusdeltagelse. Dette kan ses, at der er mange antal events, hvilket betyder, at udelukkelsen af kovariaten ikke har stor betydning for forklaringsgraden som i kursusdeltagelsesmodellen.

Samlet er begge modeller robuste i deres estimering, men tyder på, at de to hændelser er korrelerede, men ikke i en grad der skaber alvorlig endogenitet i modellerne. Der er derfor lav risiko for bias ved at modellere hændelserne separat.

Diskussion 6

Dette kapitel diskuterer hovedresultaterne fra analysen og sætter dem i relation til specialets problemformulering. Her reflekteres over betydningen af AI-eksponering for kursUSDeltagelse og jobskifte, samt de valg og usikkerheder, der har påvirket analysen.

6.1 Analytisk refleksion

6.1.1 Diskussion af Heatmap og Bevægelse på Arbejdsmarkedet

Heatmappet for jobskifte for jobstillinger med højt AI-potentiale i figur 5.1 udviser en markant diagonal struktur, der indikerer lav horisontal mobilitet og en høj grad af jobstillingsstabilitet. Dette mønster understreger, at arbejdstagere typisk forbliver inden for deres fagområde. Dermed er det i et begrænset omfang, at arbejdstagerne bevæger sig på tværs af jobstillinger. Den diagonale intensitet er særlig tydelig i grupper med højt specialiserede funktioner, hvor jobmatch mellem kompetencer og opgaver synes at dominere mobilitetsmønstret. Henhold til teorien om horisontal og vertikal mobilitet i afsnit 4.1 understøtter dette et billede af et arbejdsmarked, hvor bevægelser primært sker inden for samme kvalifikationsniveau. Det indebærer dermed ikke nødvendigvis et opadgående karriereforløb over tid.

Som det fremgår i tabel 5.1, der viser udviklingen i mobilitet på ISCO-niveau 1-4 over perioden 2010-2021, at der generel tendens til intern mobilitet frem for skift mellem sektorer eller arbejdsområder. Det tyder på et arbejdsmarked, hvor specialisering er med til at fastholde medarbejdere i stabile jobstillinger, men hvor det samtidig kan være en barriere for fleksibilitet og omstilling. Eksempelvis er Sundhed og økonomi & administration karakteriseret ved lav mobilitet på tværs af jobstillinger. Årsagen til dette kan være, at deres kompetencer er snævert definerede, og at deres arbejdsopgaver er afgrænsede i forhold til andre funktioner. Ifølge afsnit 3.1 om jobmobilitet i dansk kontekst kan dette hænge sammen med forskelle i adgang til efter- og videreuddannelse, eller at de har for specialiserede kompetencer i deres felt.

Hermed opstår spørgsmålet, om arbejdsmarkedet i en tilstrækkelig grad understøtter mobilitet gennem opkvalificering eller efter- og videreuddannelse, eller om der eksisterer strukturelle barrierer, der fastholder arbejdstagere i specialiserede roller. Som beskrevet i afsnit 4.2 og 4.2.1 fungerer efter- og videreuddannelse som en nøglemekanisme til at imødegå teknologisk pres og understøtte jobmobilitet. Resultaterne fra analysen antyder,

at denne mekanisme ikke nødvendigvis aktiveres i de faggrupper, hvor potentialet for AI-understøttelse er størst, hvilket rejser spørgsmål om motivation og incitamentsstruktur.

Ledelsesfunktioner adskiller sig ved at udvise lavere diagonal intensitet og en højere grad af mobilitet internt mellem ledelsesroller. Dette fremgår i figur 5.1, hvor særligt jobstillinger som øverste ledelse, hvor 57,5% forbliver og produktionsledelse (48,5%) viser spredning til beslægtede ledelsesstillinger. Dette kan afspejle karriereudvikling snarere end funktionelt skift og tyder på, at ledelseskompeterer lettere kan anvendes i forskellige organisatoriske sammenhænge. Samtidig understøtter den danske flexicurity-model fra afsnit 3.1, med et vist niveau af mobilitet blandt højtuddannede, hvilket kan bidrage til denne dynamik. Strategiske ændringer og lederskifte kan også være medvirkende faktorer bag turnover i denne gruppe.

Sammenspillet mellem AI og jobmobilitet er komplekst. Til trods for en hypotese om, at høj AI-eksponering vil føre til øget jobskifte, viser analyserne (jf. figur A.9) kun en begrænset sammenhæng mellem høj AIOE-score og øget sandsynlighed for mobilitet. Det tyder på, at AI i mange tilfælde anvendes til at effektivisere og stabilisere nuværende roller frem for at transformere dem. Dette kan bidrage til lav mobilitet, særligt blandt højt specialiserede medarbejdere. Det bekræfter afsnit 3.2 pointe om, at teknologi ikke altid medfører ændringer i jobstillinger, men i nogle tilfælde i stedet bidrager til at fastholde og styrke de eksisterende arbejdsstrukturer.

Samlet set indikerer heatmappet og bevægelsesmønstret på arbejdsmarkedet, at der er tale om en høj grad af funktionsspecialisering og lav tværgående mobilitet. Det vil sige en struktur, der både kan sikre mobilitet og effektivitet, men samtidig begrænse arbejdsmarkedets tilpasningsevne i mødet med teknologisk forandring. Dette tydeliggør behovet for både politisk og organisatorisk fokus på mobilitet og opkvalificering, ikke kun blandt lavtuddannede, men også hos de højest kvalificerede, der i stigende grad spiller en central rolle i den AI-drevne omstilling.

6.1.2 Model 1 AIOE som kontinuerlig variabel (Kursusdeltagelse)

Model 1 er konstrueret til at estimere effekten af AIOE-score som en kontinuerlig variabel, dermed viser den lineære sammenhæng mellem AI-eksponering og risiko for kursusdeltagelse i modellen. Resultatet viser en negativ sammenhæng mellem høj AI-eksponering og tilbøjelighed for kursusdeltagelse. Dette betyder, at jo højere AI-eksponering et job har, desto mindre sandsynligt er det, at vedkommende deltager i efteruddannelse.

Fortolkningen er todelt. For det første indebærer det, at dem i højt eksponerede erhverv såsom analytikere, økonomer og advokater allerede har relevante digitale færdigheder og derfor har mindre behov for yderligere opkvalificering. Dette fremhæves i kapitel 3.1, som hævder, at AI primært supplerer og ikke erstatter opgaver og jobstillinger i disse erhverv. Analysen tyder på, at høj AI-eksponering ikke nødvendigvis skaber læringspres, men snarere resulterer i oplevet teknologisk stabilitet og strukturel tryghed i jobstillingen.

Dette resultat står i kontrast til den generelle teoretiske forventning om, at øget eksponering for teknologisk forandring vil motivere individer til opkvalificering (kapitel 4.2). Den negative sammenhæng kan dog tolkes som, at læringsincitamentet ikke blot afhænger af teknologiens tilstedeværelse, men også af medarbejderens eksisterende kompetenceniveau. Der er flere i højtuddannede segmenter, der besidder disse kompetencer, der matcher AI's krav. Dermed minimeres behovet for yderligere kursUSDeltagelse. Det støtter teorien om, at læring i disse miljøer foregår internt og uformelt i vidensintensive miljøer, frem for via formelle kurser.

Modellen har dog kun begrænset forklaringskraft, fordi den antager en lineær sammenhæng og derfor overser mulige tærskelværdier eller ikke-lineære effekter. Dermed forventes det i modellen, at der er samme proportionelle effekter på risiko, uanset om det er lav- til mellem- eller mellem- til høj AIOE-score. Derfor kan stærke effekter, som kun opstår ved et vist niveau, blive skjult. Eksempelvis at den midterste gruppe reagerer anderledes end top og bund. Dette er en af begrundelserne bag grupperingen i Model 2.

6.1.3 Model 2 AIOE som grupperet variabel (KursUSDeltagelse)

Model 2 ser på AIOE-score som tre kategorier: lav, medium og høj eksponering. Dette giver en mere struktureret analyse af læringsmønstre i forhold til arbejdsmarkedets funktionelle AI-segmenter. Hazard ratioerne, som vist i tabel 5.5, peger klart på: Lavt AI-udsatte har en betydeligt højere deltagelsesrisiko i kurser end højt AI-udsatte.

Det er især de højt eksponerede jobstillinger, der har lavere deltagelsesrisiko. Som vist i kapitel 3.1, er disse stillinger ofte selvlærte eller internt uddannede. Desuden skyldes det, at læringsbehovene i disse funktioner ofte er mere specialiserede og derfor imødekommes gennem skræddersyede eller virksomhedsinterne løsninger, som falder uden for det indsamlede data fra Danmarks Statistik. Model 2 indikerer dermed, at AI-eksponering alene ikke er nok til at forklare opkvalificeringsadfærd. For at forstå de forskellige nuancer, der er involveret, skal man også overveje individernes status på arbejdsmarkedet.

6.1.4 Model 3 Interaktioner (KursUSDeltagelse)

Model 3 udvider analysen ved at introducere interaktioner mellem tidligere kursUSDeltagelse, jobskift og AIOE-grupper. Denne inklusion afslører, at den kumulative effekt af tidligere deltagelse i kurser har en betydningsfuld forskel imod ny deltagelse. Det er særligt i blandt personer i mellem- og højt AI-eksponerede jobstillinger. Dette indikerer, at opkvalificering i disse grupper følger en selvforstærkende dynamik, hvor én kursUSDeltagelse øger sandsynligheden for, at individet fastholdes i et aktivt læringsforløb.

For individer i meget AI-udsatte job såsom IT-konsulenter og projektledere betyder dette, at opkvalificering af nye færdigheder er et udtryk for et proaktivt karrieretræk. Eftersom det bringer jobmuligheder, og ikke blot en forebyggende selvbeskyttelse. Det kan skyldes,

at disse jobstillinger ofte er indlejret i organisatoriske rammer med højere læringskapacitet og bedre adgang til ledelsesstøtte, hvilket kan fremme gentagen kursusdeltagelse.

For lavt eksponerede individer er effekten af tidligere deltagelse mere tvetydig. Der kan være to potentielle grunde. For det første kan førstegangsdeltagere føle, at deres jobsikkerhed ikke nødvendigvis forbedres, eller at deres muligheder for intern forfremmelse udvikler sig. Derfor bliver det ikke attraktivt at deltage igen. Dette vil pege på en strukturel barriere: uden organisatorisk anerkendelse eller arbejdsmarkedsafkast er opkvalificering alene ikke nok til at skabe incitament.

Model 3 opnår ydermere den laveste AIC-værdi blandt modellerne, hvilket understøtter dens forklaringskraft. Metodisk demonstrerer modellen PWP-GT's styrke i at identificere sekventielle og hændelsesafhængige processer. Dette muliggør en mere præcis forståelse af, hvordan opkvalificering ikke blot er en respons på teknologisk forandring, men i høj grad formes af sociale betingelser og tidligere læringerfaringer. Dermed underbygges specialets overordnede tese om, at færdighedsudvikling er forankret i erfaring og kontekst snarere end alene udløst af teknologisk pres.

6.1.5 Model 1 AIOE som kontinuerlig variabel (Jobskifte)

Model 1 i jobskifteanalysen estimerer også AIOE-score som en kontinuerlig variabel og påviser en negativ sammenhæng mellem AI-eksponering og hazardraten for jobmobilitet. Resultatet indikerer, at individer i jobstillinger med høj AI-udsathed har en lavere hazardrate for at skifte job. Dette tolkes som et udtryk for, at AI i disse jobstillinger fungerer mere understøttende snarere end truende.

Dette udfordrer antagelsen om, at AI først og fremmest skaber jobusikkerhed, og understøtter i stedet teorien om arbejdsmarkedets segmentering (kapitel 4.2). Jobstillinger med høj AI-eksponering er ofte præget af specialisering og stabilitet, hvor lav mobilitet kan afspejle, at medarbejdere fastholdes i velfungerende roller. I stedet for at søge nye stillinger eksternt, udvikler de sig typisk videre inden for de eksisterende organisatoriske rammer.

Som det fremgår i kapitel 3.1 er det især professionelle som analytikere, økonomer og advokater, der har høje AIOE-scorer. Disse jobstillinger er karakteriseret ved høj grad af databehandling, analytisk arbejde og støtte til strategiske beslutningsprocesser. Her kan AI-teknologier såsom machine learning, natural language processing og automatiseret datavalidering integreres i opgaveløsninger. Eksempelvis kan AI anvendes til automatisk kontraktanalyse for jurister eller forecast-beregninger for analytikere, hvilket medfører, at den grundlæggende faglighed ikke forsvinder, men forstærkes.

I denne kontekst bliver lav jobmobilitet et udtryk for funktionel stabilitet, hvor AI-færdigheder gør medarbejderen mere værdifuld for arbejdsgiveren. Samtidig er det vigtigt at påpege, at lav mobilitet ikke nødvendigvis betyder passivitet. Det kan også indikere, at mulighederne for intern omplacering, projektarbejde eller kompetenceudvikling inden for

samme organisation er større for disse grupper. De professionelle miljøer, de befinder sig i, er typisk kendetegnet ved høj organisatorisk læringskapacitet og adgang til karriereveje, som ikke kræver jobskifte.

Modellen har dog begrænset kapacitet til at skelne mellem frivillig og ufrivillig fastholdelse. Der tages ikke højde for faktorer som udbud af stillinger, geografisk mobilitet, familiehensyn eller incitamenten på tværs af sektorer. Dette begrænser fortolkningen af lav mobilitet: Er det udtryk for arbejdsglæde og udviklingsmuligheder, eller manglende alternativer og risikoaversion?

6.1.6 Model 2 AIOE som grupperet variabel (Jobskifte)

Ved at gruppere AIOE-score i lav-, mellem- og høj eksponering synliggør model 2 strukturelle forskelle i jobmobilitet, som ikke fremgår af den lineære model. Resultaterne viser tydeligt, at lavt- og mellemeksponerede har markant højere risiko for jobskifte end højt eksponerede.

Personer med høj eksponering over for AI har generelt lav jobmobilitet, hvilket også fremgår af model 1 vedrørende jobskifte. Disse individer besidder typisk stillinger, hvor kunstig intelligens muliggør en mere effektiv og præcis udførelse af komplekse opgaver. Det gælder eksempelvis IT-projektledere, data scientists og compliance-rådgivere, hvor automatisering reducerer både tidsforbrug og fejlmargen, men samtidig øger kravene til output og kvalitetskontrol. Som følge heraf opfattes disse profiler som attraktive af arbejdsgivere, hvilket reducerer incitamentet til jobskifte, især i organisationer, hvor intern mobilitet er en reel mulighed. Disse resultater skal dog fortolkes varsomt, da modellen udvider mindre brud på PH-antagelsen. Dermed er disse antagelser for individer ikke konkrete, men en visning af tendenser og mulige repræsentationer af generel adfærd.

6.1.7 Model 3 Interaktioner (Jobskifte)

Med interaktioner mellem tidligere hændelser og AIOE-grupper tillader det vurderingen af, hvordan mobilitetsmønstre formes af både eksponering og forrige adfærd. Modellen angiver, at lavt AI-eksponerede individer med én eller flere tidligere jobskift vil have en markant højere sandsynlighed for at skifte igen. Det peger på, at der i de mest udsatte jobstillinger kan være tale om cyklisk eller strukturel mobilitet, hvor gentagne skift ikke nødvendigvis afspejler fremskridt, men snarere eksterne faktorer.

Eksempelvis kan en tidligere lønadministrator, der er blevet overflødiggjort af lønsystemintegration, efterfølgende ansættes som kontormedhjælper, hvor de administrative opgaver er i gang med at blive automatiseret. Risikoen er, at personen kan undergå en periode med hyppigere jobskift til at finde en acceptabel stilling. I sådanne tilfælde tyder det på, at gentagen mobilitet i denne gruppe ikke er et udtryk for tilpasningsevne, men for strukturel marginalisering.

I kontrast viser modellen, at tidligere jobmobilitet blandt højt eksponerede individer ikke

nødvendigvis øger fremtidig mobilitet. I nogle tilfælde reduceres sandsynligheden for nyt jobskifte. Det kan tolkes som tegn på, at tidligere skifte har ført til en stærkere match mellem færdigheder og jobkrav, for eksempel gennem karrierespring eller specialisering. Eksempelvis kan en softwareudvikler i AI-relateret udvikling, der har skiftet til en rolle, hvis opgaver fokuserer på dette område, opleve en markant højere jobtilfredshed og stabilitet efter skiftet.

Endvidere viser modellen, at kursusdeltagelse har forskellig betydning afhængigt af AIOE-niveau. Blandt lavt eksponerede individer øger tidligere kursusdeltagelse sandsynligheden for jobskifte, hvilket kan tolkes som et forsøg på at komme væk fra truede funktioner. For højt eksponerede har kursusdeltagelse mere en stabiliserende effekt og kan tolkes som en investering i karrierefremgang.

Samlet indikerer Model 3, at jobmobilitetens betydning varierer betydeligt på tværs af eksponeringsgrupper. For lavt eksponerede fremstår gentagne jobskifte som et udtryk for ustabilitet snarere end strategisk udvikling, mens mobilitet blandt højt eksponerede i højere grad afspejler målrettet karriereudvikling og leder øget jobsikkerhed. Det understreger behovet for differentierede indsatser, der ikke blot fremmer bevægelighed, men understøtter mobilitet som varig forbedring.

6.2 Model 3b - alternativ model til model 3 (jobskifte)

Medtagelsen af model 3b er for at nedbringe de brud på PH-antagelsen, grupperet AIOE-score har haft. Model 3b viser forskelligt fra model 3, at der er en indikation for den lineære antagelse i den kontinuerte model har udlignet forskelle og ikke fanger effekterne ved segmentering. Indholdsmæssigt viser de to modeller overordnede det samme i effekternes retning, men adskiller sig i styrken og klarheden af resultaterne.

I model 3 fremgår det tydeligt, at personer i højt AI-udsatte job har markant lavere mobilitet, mens den mellem AI-udsatte gruppe også viser en stærk negativ effekt. I model 3b, hvor AIOE-score behandles kontinuert, fremstår effekten langt mere afdæmpet. Det kan tyde på, at en lineær repræsentation af AIOE udjævner de skarpe forskelle, der i praksis eksisterer mellem udsathed.

Forskellen mellem modellerne bliver særligt tydelig i interaktionerne. Model 3 viser, at tidligere jobskifte har stærk positiv effekt på efterfølgende jobskifte, og denne effekt forstærkes yderligere i den højt AI-udsatte gruppe. I model 3b er disse interaktionseffekter langt mere afdæmpede og ikke signifikante, hvilket kan skyldes, at den kontinuerte model ikke fanger de samme effekter, der præger grupperne.

Konkluderende viser sammenligningen, at den grupperede model (model 3) en mere differentieret indsigt i, hvordan AI-eksponering påvirker mobilitet, men den bryder samtidig med PH-antagelsen. Den kontinuerte model (model 3b) overholder PH-antagelsen bedre, men på bekostning af nuancer i effekterne. Dette viser et trade-off mellem modelpræcision og indsigt i de opdelte grupper.

6.2.1 Efter- og videreuddannelse som mekanisme for jobmobilitet

Analysen viser, at deltagelse i efter- og videreuddannelse har en positiv sammenhæng med jobmobilitet, særligt blandt individer med høj AI-eksponering. Det indikerer, at efter- og videreuddannelse kan understøtte arbejdstagernes tilpasning til strukturelle forandringer på arbejdsmarkedet. Effekten er især markant for personer i kontorstillinger, hvor adgangen til relevante kompetenceudviklingsforløb ser ud til at øge sandsynligheden for jobskifte.

Disse resultater er i overensstemmelse med Human Capital Theory, hvor investeringer i kompetencer antages at forbedre individets produktivitet og mobilitet. Efter- og videreuddannelse kan i denne sammenhæng betragtes som en investering, der indebærer både omkostninger og potentielt afkast. Omkostningerne kan bestå af tid og udgifter, mens det forventede afkast er øget kvalifikationer eller lønforbedring. Efter- og videreuddannelse kan i denne kontekst forstås som en vigtig faktor for vertikal mobilitet, særligt i en periode med øget teknologisk påvirkning. I de anvendte PWP-GT-modeller ses en sammenhæng mellem kursusdeltagelse og øget jobmobilitet, hvilket indikerer, at efter- og videreuddannelse kan fungere som et redskab til at imødekomme ændrede kompetencekrav.

Dette styrker det teoretiske argument i kapitel 4.2.1 om, at efter- og videreuddannelse kan fungere som forberedelse til eller katalysator for vertikal mobilitet. Det tyder på, at arbejdstagere i højere grad proaktivt tilpasser sig AI-betingede forandringer via opkvalificering, frem for udelukkende at reagere på jobtab som følge af automatisering. Dette stemmer overens med (Goos et al., 2014) teori om polarisering og tilpasning.

Samtidig peger analysen på, at adgangen til efter- og videreuddannelse ikke er ligeligt fordelt. Deltagelsen er højest blandt ledere og i stillinger med lav AI-eksponering, mens højere eksponerede og uddannede i mindre grad deltager i opkvalificeringsaktiviteter. Det kan bidrage til at forstærke eksisterende forskelle i mobilitet og beskæftigelsesmuligheder. Set i lyset af dette fremstår målrettede efter- og videreuddannelsesinitiativer som et vigtigt instrument i arbejdsmarkedspolitik.

6.2.2 Jobskifte som tilpasningsstrategi

På baggrund af analysens fund kan jobskifte fortolkes som en væsentlig tilpasningsstrategi i mødet med AI-relaterede forandringer. Særligt blandt høj- og mellem-viden ses sænket mobilitet i takt med stigende eksponering for kunstig intelligens. Dette kan både afspejle muligheder for karriereudvikling i virksomheden eller at der ikke er et behov for omstilling.

For nogle arbejdstagere handler tilpasningen til ny teknologi om et bevidst valg, hvor de aktivt søger at udnytte de muligheder, som teknologiske fremskridt fører med sig. For andre er det snarere en nødvendighed, skabt af ændrede jobkrav, omstruktureringer eller en oplevelse af, at deres nuværende kompetencer ikke længere rækker. I begge tilfælde viser jobmobilitet, hvordan teknologiske forandringer påvirker bevægelserne på arbejdsmarkedet. Det understreger samtidig, at jobskifte og opkvalificering ikke er adskilte fænomener. Det er ofte to sider af samme proces, hvor arbejdstagere forsøger at tilpasse

sig et arbejdsmarked i forandring.

6.3 Fejlkilder og usikkerheder

Trods anvendelsen af detaljerede registerdata og avancerede statistiske modeller rummer analysen en række usikkerheder, blandt andet i relation til datasættet, modelstruktur, antagelser og centrale begreber.

Nedenfor gennemgås de væsentligste fejlkilder og usikkerheder.

6.3.1 Kursusvariablen er delvis proxy

En central usikkerhed i analysen knytter sig til, hvordan AI-relateret kursusdata er operationaliseret. Der findes en mindre mængde kurser, der specifikt er kategoriseret som AI-relaterede i registerdataet, men antallet er for lavt til at danne grundlag for en selvstændig analyse. Derfor var det nødvendigt at udvide gruppen af gyldige kurser gennem en proxy, baseret på beslægtede kursuskategorier såsom IT, databehandling og robotteknologi. Der er risiko for falske positiver, hvor kurser uden egentligt AI-indhold medtages, fordi de ligger i brede teknologikategorier som IT og databehandling. Samtidig forekommer falske negativer for kurser og individer, hvor kurser med reelt AI-indhold er udeladt, fordi de ikke er korrekt klassificeret i registerdataet, og personer, der har modtaget AI-opkvalificering, kan fremstå som ikke-opkvalificerede i analysen. Kursusvariablen fungerer derfor kun som en delvis indikator for AI-opkvalificering og rummer måleusikkerhed.

En anden begrænsning ved kursusvariablen er, at dataet ikke tillader, at man kan skelne mellem selvvalgt og arbejdsgiverinitieret kursUSDeltagelse. Motivationen bag deltagelse kan have betydning for effekten af opkvalificering på jobmobilitet. Da vores variabel alene afspejler, om der er deltaget i et opkvalificerende kursus, og ikke hvem der har taget initiativet, fungerer den som en ufuldstændig proxy for EVU. Det betyder, at vi i analyserne ikke kan isolere effekter baseret på typen af incitament, hvilket kan have betydning for fortolkningen af resultaterne.

6.3.2 Jobskiftevariabel

Jobskifte er defineret ud fra ændringer i ISCO-kode, branche, sektor eller arbejdskommune. Denne sammensatte tilgang giver en vis robusthed, men rummer også flere fejlkilder. Små reelle ændringer i arbejdsopgaver kan gå ubemærket hen, hvis de ikke afspejles i ISCO-koden, mens administrative ændringer kan registreres som jobskifte, uden at det reelt er tilfældet. Derudover opstår der usikkerhed omkring tidsplaceringen af skiftet, da kun årsbaserede observationer er tilgængelige. En yderligere fejlkilde opstår ved jobskift, der ikke fanges af de anvendte variabler, men kun ville kunne identificeres gennem ændringer i virksomhedstilknytning. Da en entydig sammenkobling mellem PNR og virksomhedsnummer ikke har kunnet etableres for hele datasættet, har det ikke været

muligt konsekvent at identificere sådanne skift. Dette begrænser muligheden for at afgrænse reelt jobskifte fuldstændigt og kan føre til underrapportering af mobilitet.

6.3.3 Afgrænsning til ISCO 1-4

Analysen er afgrænset til personer med job i ISCO-hovedgrupper 1 til 4 (ledere, akademikere, teknikere og kontorarbejdere). Denne afgrænsning reducerer datakompleksitet og øger relevansen i forhold til AI-eksponering, da disse grupper typisk har højere sandsynlighed for at blive påvirket af teknologiske forandringer. Dog indebærer valget en begrænset generaliserbarhed til arbejdsmarkedet som helhed. Det er et bevidst metodisk trade-off mellem fokus og bred dækning. Dette underbygger problemformuleringens fokus, men udelukker samtidig potentielt relevante grupper, eksempelvis faglærte og ufaglærte.

6.3.4 COVID-19

COVID-19-pandemien udgør en potentiel forstyrrende faktor, især i perioden 2019 til 2021. Pandemien har påvirket både kursusdeltagelse og jobmobilitet, eksempelvis gennem nedlukning af uddannelsesinstitutioner, hjemsendelser og usikkerhed på arbejdsmarkedet. Disse effekter er ikke forårsaget af AI, men kan alligevel forveksles med teknologidrevne omstillinger. Derfor er usikkerheden i denne periode forøget.

6.3.5 Modelusikkerhed Jobmodel 2 og 3

Model 2 og 3 for jobskifte anvender henholdsvis AIOE-grupper og interaktioner, som udviser tidsafhængige effekter. Men netop disse modeller er også mere sårbare over for brud på Cox-modellens proportional hazards (PH)-antagelse. Interaktionsmodellen (model 3) har svagere prædiktiv kraft og er derfor ikke egnet til præcis forudsigelse, men kan stadig give indikationer af mønstre og tendenser. Det er vigtigt at fortolke resultaterne med henblik for de underliggende antagelser og modelkompleksitet.

6.3.6 Alternative modeller

For at håndtere tidsafhængighed og PH-brud er der afprøvet flere alternative modeller:

- **Polynomier** er blevet testet for at modellere ikke-lineære tidsafhængige effekter, men viste sig ustabile. Eksempelvis gav modellen et ekstremt estimat på 12 gange højere risiko for jobskifte for højt AI-udsatte øjeblikkeligt efter første jobskift.
- **Splines** blev afprøvet for yderligere fleksibilitet, men resulterede i overfitting og meget ekstreme estimater, blandt andet en hazard ratio på 128 for samme gruppe. Det viser, at øget kompleksitet ikke nødvendigvis fører til bedre modeller. I kontekst af hinanden har begge modeller udvist tegn på overfitting, hvilket er grunden til de muligheder er forkastet.

6.3.7 Generelle udfordringer ved modelstruktur

Der er et grundlæggende trade-off mellem modelkompleksitet og fortolkbarhed. Mere fleksible modeller kan tilpasse sig data bedre, men er sværere at tolke og mere følsomme over for støj. Derudover er der risiko for både overjustering og udeladelse af vigtige faktorer, der ikke er målt eller tilgængelige. Resultaterne er derfor følsomme over for operationalisering, valg af kovariater og datastruktur.

Samlet set medfører disse usikkerheder en væsentlig begrænsning af analysens prædiktive styrke og generaliserbarhed. Resultaterne bør derfor primært tolkes som indikationer af tendenser frem for sikre effekter.

Konklusion 7

Rapportens formål har været at undersøge, hvordan digital automatisering, målt via AIOE-scoren, påvirker jobmobiliteten på det danske arbejdsmarked i perioden 2010 til 2021. Med anvendelse af PWP-GT-modeller er der foretaget en kvantitativ analyse af sammenhængen mellem AI-eksponering, jobskifte og deltagelse i opkvalificerende kurser med fokus på jobstillinger fordelt efter færdighedsniveau. Denne tilgang muliggør en differentieret vurdering af teknologiens virkning på tværs af ledere samt lav-, mellem- og højtspécialiserede jobstillinger.

Analysen viser en generel positiv interaktion mellem AI-eksponering og både jobskiftefrekvensen og deltagelse i kompetenceudvikling, særligt i høj- og mellem AI-udsatte segmenterne (jf. model 1 og 2 i afsnit 5.3 og 5.4). I høj-udsatte jobstillinger fungerer AI i stigende grad som et komplementært redskab, der understøtter arbejdets kompleksitet og effektivitet. Arbejdstagere i disse jobstillinger benytter AI aktivt og efterspørger ikke løbende opkvalificering. Mellem-udsatte segmentet udviser betydelig intern variation, hvor visse jobstillinger drager fordel af teknologien, mens andre er lavt eksponerede og dermed mere udsatte i forhold til automatisering.

Resultaterne viser også, at højt- og mellemuddannede skill-grupper deltager i signifikant lavere grad i opkvalificerende kurser (jf. model 2 og 3 i afsnit 5.3). Dette indikerer, at AI ikke blot omstrukturerer arbejdsopgaver, men også fungerer som en katalysator for mobilitet og ændrede kompetencekrav. Samtidig peger analysen på en strukturel risiko for, at teknologisk forandring øger uligheder, hvis bestemte grupper ikke opnår adgang til kompetenceudvikling.

Dermed er der behov for økonomisk og arbejdsmarkedspolitisk fokus på tilgængelig og målrettet opkvalificering. Hvis arbejdsstyrken bredt skal rustes til den digitale omstilling, kræver det en tilpasning af efter- og videreuddannelsessystemet, der er tilpasset både teknologiske krav og individuelle forudsætninger. Det tyder derfor på, at AI-eksponering både kan have inkluderende og ekskluderende effekter, hvilket er afhængigt af arbejdstageres adgang til læring og arbejdsmarkedets evne til at absorbere teknologiske skift. Samlet set viser analysen, at efter- og videreuddannelse udgør en central mekanisme for at understøtte jobmobilitet i lyset af AI-eksponering og bør betragtes som et nøgleelement i en inkluderende arbejdsmarkedstilpasning.

Afslutningsvis bør det bemærkes, at modellen har begrænset kapacitet til at skelne mellem frivillig og ufrivillig fastholdelse. Der tages ikke højde for faktorer som udbud af stillinger,

geografisk mobilitet, familiehensyn eller incitamenter på tværs af sektorer. Dette begrænser fortolkningen af lav mobilitet. Er det et udtryk for arbejdsglæde og udviklingsmuligheder, eller snarere for manglende alternativer og risikoaversion. Sådanne nuancer er centrale for at forstå, hvordan AI påvirker arbejdsmarkedet, ikke kun i forhold til omstrukturering, men også i relation til individuel handlefrihed og strukturelle barrierer.

Perspektivering 8

Specialet har bidraget med ny indsigt i, hvordan AI-eksponering påvirker jobmobilitet og kursusdeltagelse på det danske arbejdsmarked. Ved hjælp af PWP-GT modeller har det været muligt at analysere gentagne hændelser og identificere forskelle mellem forskellige skill-grupper. Resultaterne viser, at AI ikke kun påvirker selve arbejdsopgaverne, men også ser ud til at fungere som en drivkraft for kompetenceudvikling og mobilitet, særligt i grupper med høj eksponering.

Der er dog flere muligheder for at udvide analysen. En oplagt metodisk forlængelse kunne være at anvende en Poisson-regression i form af en Piecewise Exponential Model (PEM). I modsætning til Cox-modellen giver PEM mulighed for at analysere risikoen for hændelser i specifikke tidsintervaller, hvilket kan være nyttigt i forhold til at undersøge, hvordan risikoen udvikler sig over tid, for eksempel i perioder med særlige begivenheder som COVID-19 eller udrulning af nye teknologier.

Et andet perspektiv kunne være brugen af en Accelerated Failure Time (AFT) model til at analysere tiden specifikt frem til første kursusdeltagelse. Hvor Cox og PWP fokuserer på relativ risiko, giver AFT en mere direkte tolkning af, hvor hurtigt forskellige grupper reagerer. Det kunne for eksempel vise, om AI-eksponerede jobstillinger deltager hurtigere i kurser end andre. En begrænsning ved AFT er dog, at den kun kan anvendes til at se på tid til første event, og derfor ikke håndterer gentagne hændelser som i den anvendte tilgang i dette speciale.

Ud over de metodiske muligheder kan man også supplere analysen med andre datakilder samt analyseområder. Det kunne være relevant at undersøge, hvordan opkvalificeringsmønstre varierer mellem sektorer, regioner eller demografiske grupper. Gennem den type analyse kan man afdække geografiske eller strukturelle skævheder i adgangen til efter- og videreuddannelse og mobilitet. Her kan kvalitative data eller casebaserede analyser give et bedre billede af, hvilke mekanismer der i praksis fremmer eller hæmmer deltagelse i efteruddannelse.

Derudover kunne man inddrage spørgeskemadata fra virksomheder og medarbejdere. Dermed kan man opnå en dybere forståelse af de bagvedliggende mekanismer for opkvalificering og jobskifte. Dette kan bidrage med information om motivationer, barrierer og behov, der ikke fremgår af registerdata, og dermed får man et mere nuanceret billede af, hvad der driver efter- og videreuddannelse samt mobilitet.

Yderligere vil det være oplagt at forlænge analysen med en udvidet model, der dækker hele det danske arbejdsmarked. Dette vil gøre det muligt at sammenligne på tværs af sektorer, brancher og jobstillinger. På den måde kan man identificere strukturelle forskelle i mønstre for opkvalificering og mobilitet som følge af AI-eksponering.

Endelig peger resultaterne på et behov for arbejdsmarkedspolitisk indsats, som tager højde for, at især lavt eksponerede grupper deltager mindre i opkvalificering. Hvis denne tendens fortsætter, kan det føre til øget ulighed i et arbejdsmarked, der i stigende grad påvirkes af teknologi. Derfor bør fremtidige tiltag fokusere på at gøre efteruddannelse mere tilgængelig og relevant, for eksempel gennem fleksible formater, økonomisk støtte og samarbejde mellem uddannelsesinstitutioner, virksomheder og fagforeninger.

Litteratur

Andersen og Gill, 1982. P. K. Andersen og R. D. Gill. *Cox's Regression Model for Counting Processes: A Large Sample Study*. Institute of Mathematical Statistics, 10(4), 1982. doi: 10.1214/AOS/1176345976

<https://projecteuclid.org/journals/annals-of-statistics/volume-10/issue-4/Coxs-Regression-Model-for-Counting-Processes--A-Large-Sample/10.1214/aos/1176345976.full>.

Arntz et al., 2016. Melanie Arntz, Terry Gregory og Ulrich Zierahn. *The Risk of Automation for Jobs in OECD Countries: A Comparative Analysis*. OECD, 2016. doi: 10.1787/5JLZ9H56DVQ7-EN https://www.oecd.org/en/publications/the-risk-of-automation-for-jobs-in-oecd-countries_5j1z9h56dvq7-en.html.

Becker, 1964. Gary S. Becker. *Human Capital: A Theoretical and Empirical Analysis with Special Reference to Education, First Edition*, 1964

<https://www.nber.org/books-and-chapters/human-capital-theoretical-and-empirical-analysis-special-reference-education-first-edition>.

Bess et al., 2022. Mikkel Bess, Simon Juul Hviid, Erik Grenestam og Filip Rozsypal. *Pres på arbejdsmarkedet under pandemien*. Danmarks Nationalbank, 2022 <https://www.nationalbanken.dk/media/dtyiivcf/em-pres-paa-arbejdsmarkedet.pdf>.

Bessen, 2018. James Bessen. *AI and Jobs: the role of demand*. NBER, 2018 https://www.nber.org/system/files/working_papers/w24235/w24235.pdf.

Bolvig et al., 2017. Iben Bolvig, Nicolai Kristensen og Lars Skipper. *Effektevaluering af voksen- og efteruddannelsesindsatsen*. KORA, 2017. ISBN 978-87-7488-997-7 <https://www.vive.dk/da/udgivelser/effektevaluering-af-voksen-og-efteruddannelsesindsatsen-jvn484xm/>.

Borjas, 2016. George J. Borjas. *Labor economics*. New York: McGraw Hill, 7th edition, 2016. ISBN 978-0-07-802188-6.

Bureau of Labor Statistics, 2012. Bureau of Labor Statistics. *ISCO-08 x SOC 2010 Crosswalk*, 2012 https://www.bls.gov/soc/ISCO_SOC_Crosswalk.XLS.

Cazzaniga et al., 2024. Mauro Cazzaniga, Carlo Pizzinelli, Marina Mendes Tavares og Emma J Rockall. *Exposure to Artificial Intelligence and Occupational Mobility: A Cross-Country Analysis*. International Monetary Fund, 2024

<https://www.imf.org/en/Publications/WP/Issues/2024/06/07/Exposure-to-Artificial-Intelligence-and-Occupational-Mobility-A-Cross-Country-Analysis-549>.

- Dahl et al., 2024.** Gustav Elias Dahl, Rasmus Lindø Kaslund, Emilie Damm Klarskov, Frederik Olsen, Troels Lund Jensen og Sebastian Schwartz. *Kunstig intelligens på det danske arbejdsmarked*. Arbejderbevægelsens Erhvervsråd, 2024 <https://www.ae.dk/analyse/2024-09-kunstig-intelligens-paa-det-danske-arbejdsmarked>.
- Damm et al., 2021.** Emile Agner Damm, Mie Dalskov Pihl, Troels Lund Jensen og Jon Nielsen. *Det danske arbejdsmarked er skraeddersyet til fremtidens forandringer*. Arbejderbevægelsens Erhvervsråd, 2021
https://www.ae.dk/files/dokumenter/publikation/ae_temapublikation_det-danske-arbejdsmarked-er-skraeddersyet-til-fremtidens-forandringer_0.pdf
- Danmarks Statistik, 2025a.** Danmarks Statistik. *Beskæftigede (RAS)*, 2025
<https://www.dst.dk/da/Statistik/emner/arbejde-og-indkomst/beskaeftigelse-og-arbejdsloeshed/beskaeftigede-ras>.
- Danmarks Statistik, 2025b.** Danmarks Statistik. *Hver femte har været i jobbet i mindre end et år*. Arbejdskraftundersøgelsen 4. kv. 2024, 2025
<https://www.dst.dk/Site/Dst/Udgivelser/nyt/GetPdf.aspx?cid=51117>.
- Felten et al., 12 2021.** Edward Felten, Manav Raj og Robert Seamans. *Occupational, industry, and geographic exposure to artificial intelligence: A novel dataset and its potential uses*. Strategic Management Journal, 42(12), 2195–2217, 2021. ISSN 1097-0266. doi: 10.1002/SMJ.3286
<https://onlinelibrary.wiley.com/doi/full/10.1002/smj.3286>.
- Frey og Osborne, 2017.** Carl Benedikt Frey og Michael A. Osborne. *The future of employment: How susceptible are jobs to computerisation?* Technological Forecasting and Social Change, 114, 2017. ISSN 0040-1625. doi: 10.1016/J.TECHFORE.2016.08.019
<https://www.sciencedirect.com/science/article/abs/pii/S0040162516302244>.
- Goos et al., 2010.** Maarten Goos, Alan Manning og Anna Salomons. *Explaining Job Polarization in Europe: The Roles of Technology, Globalization and Institutions*. CEP, 2010. ISSN 2042-2695 <https://cep.lse.ac.uk/pubs/download/dp1026.pdf>.
- Goos et al., 2014.** Maarten Goos, Alan Manning og Anna Salomons. *Explaining Job Polarization: Routine-Biased Technological Change and Offshoring*. American Economic Review, 104(8), 2014
<https://personal.lse.ac.uk/manning/work/ExplainingJobPolarization.pdf>.
- Hau, 2024.** Mark Friis Hau. *Generativ kunstig intelligens og fremtidens arbejdsmarked Strategier og scenarier for AI-integration i Danmark*. Københavns Universitet, 2024
https://faos.ku.dk/pdf/rapport_200_-_generativ_kunstig_intelligens_og_fremtidens_arbejdsmarked.pdf.

- HBS Economics og Shapiro Futures, 2023.** HBS Economics og Shapiro Futures. *Analyse af megatrends med påvirkning af fremtidens grønne arbejdsmarked*. CONCITO, 2023
<https://concito.dk/files/media/document/Analyse%20af%20megatrends%20med%20p%C3%A5virkning%20af%20fremtidens%20gr%C3%B8nne%20arbejdsmarked.pdf>.
- Heckman, 2000.** James J. Heckman. *Policies to foster human capital*. Research in Economics, 54(1), 2000. ISSN 1090-9443. doi: 10.1006/REEC.1999.0225
<https://www.sciencedirect.com/science/article/pii/S1090944399902259>.
- Humlum og Vestergaard, 2025.** Anders Humlum og Emilie Vestergaard. *Large Language Models, Small Labor Market Effects*. NBER, 2025
https://www.nber.org/system/files/working_papers/w33777/w33777.pdf.
- Institut et al., 2017.** Sociologisk Institut, Anna Ilsøe og Louise Weber Madsen. *Digitalisering af arbejdsmarkedet*. FaOS, 2017
https://faos.ku.dk/publikationer/forskningsnotater/fnotater-2017/Fnotat_157_-_Digitalisering_af_arbejdsmarkedet.pdf.
- IRISGROUP, 2023.** IRISGROUP. *Analyse af megatrends og deres betydning for danske SMV'er*. Danmarks Erhvervsfremmebestyrelse, 2023
<https://erhvervsfremmebestyrelsen.dk/sites/default/files/2023-03/Analyse%20af%20megatrends%20og%20deres%20betydning%20for%20danske%20SMV%27er.pdf>
- Kristiansen et al., 2022.** Jonas Hulgård Kristiansen, Trine Pernille Larsen og Anna Ilsøe. *Hybrid Work Patterns: A Latent Class Analysis of Platform Workers in Denmark*. Nordic Journal of Working Life Studies, 13(S10), 55–76, 2022. ISSN 22450157. doi: 10.18291/njwls.133721
<https://tidsskrift.dk/njwls/article/view/133721/183228>.
- Larsen et al., 2024.** Trine P Larsen, Anna Ilsøe og Henriette Krøll Tell. *Digitalisering, algoritmeledelse og medarbejderinddragelse Et litteraturstudie*. FaOS, 2024
https://faos.ku.dk/pdf/Digitalisering__algoritmeledelse_og_medarbejderinddragelse.pdf.
- Leander, 2023.** Matilde Leander. *Har du styr på, om du må bruge kunstig intelligens på jobbet?*, 2023
<https://www.djoefbladet.dk/artikler/2023/08/ai-paa-arbejdspladsen?>
- Leuven et al., 2002.** Edwin Leuven, Hessel Oosterbeek, Randolph Sloof og Chris Van Klaveren. *Worker reciprocity and employer investment in training*. Tinbergen Institute, 2002 <https://papers.tinbergen.nl/02090.pdf>.
- Manyika, 2018.** James Manyika. *AI, automation, and the future of work: Ten things to solve for (Tech4Good) | McKinsey*, 2018
<https://www.mckinsey.com/featured-insights/future-of-work/ai-automation-and-the-future-of-work-ten-things-to-solve-for>.

- Mathiesen, 2023.** Ida Frederikke Mathiesen. *Jobomsætningen er faldet lidt*, 2023
<https://www.dst.dk/da/Statistik/nyheder-analyser-publ/nyt/NytHtml?cid=46636>.
- OECD, 2017.** OECD. *Education at a Glance 2017: OECD Indicators*. OECD Publishing, 2017 https://www.oecd.org/en/publications/education-at-a-glance-2017_eag-2017-en.html.
- OECD, 2021.** OECD. *OECD Skills Outlook 2021: Learning for Life*. OECD Publishing, 2021. doi: 10.1787/0AE365B4-EN https://www.oecd.org/en/publications/oecd-skills-outlook-2021_0ae365b4-en.html.
- Sørensen, 2024.** Susanne Mainz Sørensen. *Statistikdokumentation: Voksen- og efteruddannelse*, 2024 <https://www.dst.dk/da/Statistik/dokumentation/statistikdokumentation/voksen--og-efteruddannelse>.
- Teutloff et al., 2024.** Ole Teutloff, Johanna Einsiedler og Fenja Søndergaard Møller. *Large language models and the Danish labour market*. Københavns universitet, 2024 <https://www.dst.dk/Site/Dst/Udgivelser/nyt/GetAnalyse.aspx?cid=53014>.
- Teutloff et al., 2025.** Ole Teutloff, Johanna Einsiedler, Otto Kässi, Fabian Braesemann, Pamela Mishkin og R. Maria del Rio-Chanona. *Kunstig intelligens skaber nye vindere og tabere på arbejdsmarkedet*. Journal of Economic Behavior & Organization, page 106845, 2025. ISSN 01672681. doi: 10.1016/J.JEBO.2024.106845 https://nyheder.ku.dk/alle_nyheder/2025/01/kunstig-intelligens-skaber-nye-vindere-og-tabere-paa-arbejdsmarkedet/.
- Therneau og Grambsch, 2000.** T. M. Therneau og P. M. Grambsch. *Modeling Survival Data: Extending the Cox Model*. Springer New York, 1 edition, 2000. ISBN 978-1-4757-3294-8 <https://link.springer.com/book/10.1007/978-1-4757-3294-8>.
- Zahidi et al., 2020.** Saadia Zahidi, Vesselina Ratcheva, Guillaume Hingel og Sophie Brown. *The Future of Jobs Report 2020*, 2020 <https://www.weforum.org/publications/the-future-of-jobs-report-2020/>.


Supplering til analyserne




A.1 Validerings test kursus

Model	Variabel	χ^2	p-værdi
Kursus			
Model 1	Kumulative jobskifte	5.566	0.018*
	Kumulative kursusdeltagelse	20.492	6.0e-06***
	AIOE-score	0.497	0.481
	Skill grupper	19.986	0.0001***
	Alder	27.908	1.2e-07***
	Køn	7.682	0.0056**
Model 2	Kumulative jobskifte	8.440	0.00376**
	Kumulative kursusdeltagelse	18.11	1.2e-05***
	AIOE grupper	40.39	2.1e-10***
	Skill grupper	20.13	0.00015***
	Alder	31.01	2.5e-08***
	Køn	9.535	0.00222**
Model 3	Kumulative jobskifte	24.5	7.4e-07***
	Kumulative kursusdeltagelse	18.4	1.8e-05***
	AIOE grupper	49.2	4.0e-11***
	Skill grupper	22.4	3.5e-06***
	Alder	32.3	1.4e-08***
	Køn	10.1	0.00134**
	Kumulative jobskifte $\times$ AIOE grupper	18.5	9.2e-05***
	Kumulative kursusdeltagelse $\times$ AIOE grupper	31.2	1.6e-07***


Tabel A.1. Test af proportional hazards-antagelsen (Schoenfeld residualer)



Figur A.1. Schoenfeld residuale plot med ± 1 konfidensinterval for kursur model 1



Figur A.2. Schoenfeld residuale plot med ± 1 konfidensinterval for kursur model 2




Figur A.3. Schoenfeld residuale plot med ± 1 konfidensinterval for kursus model 3


A.2 Validerings test jobskifte

Model	Variabel	χ^2	p-værdi
Jobskifte			
Model 1	Kumulative jobskifte	54.350	1.7e-13***
	Kumulative kursusdeltagelse	0.815	0.367
	AIOE-score	169.207	<1e-16***
	Skill grupper	160.771	<1e-16***
	Alder	3660.852	<1e-16***
	Køn	8.822	0.003**
Model 2	Kumulative jobskifte	49.019	2.5e-12***
	Kumulative kursusdeltagelse	0.008	0.928
	AIOE grupper	7188.944	<1e-16***
	Skill grupper	283.069	<1e-16***
	Alder	3233.986	<1e-16***
	Køn	2.053	0.152
Model 3	Kumulative jobskifte	53.268574	2.9e-13***
	Kumulative kursusdeltagelse	0.000365	0.98
	AIOE grupper	9122.755082	<2e-16***
	Skill grupper	270.278051	<2e-16***
	Alder	3149.472742	<2e-16***
	Køn	2.063974	0.15
	Kumulative jobskifte $\times$ AIOE grupper	7524.131621	<2e-16***
	Kumulative kursusdeltagelse $\times$ AIOE grupper	46.309216	8.8e-11***
Model 3b	Kumulative kursusdeltagelse	0.714	0.398
	Kumulative jobskifte	53.502	2.6e-13***
	AIOE-score	155.881	< 2e-16***
	Skill grupper	550.056	< 2e-16***
	Alder	3662.225	< 2e-16***
	Køn	8.778	0.003**
	Kumulative jobskifte $\times$ AIOE-score	126.823	< 2e-16***
	Kumulative kursusdeltagelse $\times$ AIOE-score	2.070	0.150


Table A.2. Test af proportional hazards-antagelsen (Schoenfeld residualer)




Figur A.4. Schoenfeld residuale plot med ± 1 konfidensinterval for jobskifte model 1



Figur A.5. Schoenfeld residuale plot med ± 1 konfidensinterval for jobskifte model 2




Figur A.6. Schoenfeld residuale plot med ± 1 konfidensinterval for jobskifte model 3




Figur A.7. Schoenfeld residuale plot med ± 1 konfidensinterval for jobskifte model 3b

A.3 AIOE kontinuerlig effekt for kursusdeltagelses model 1



Figur A.8. AIOE-score kontinuerlig effekt på risiko for kursusdeltagelse

A.4 AIOE kontinuerlig effekt for jobskifte model 1



Figur A.9. AIOE-score kontinuerlig effekt på risiko for jobskifte