


DEN SORTE BOKS I DEN HVIDE VERDEN

EN PRAXIOGRAFISK ANALYSE



Aalborg Universitet - København



Titel: Den sorte boks i den hvide verden

Undertitel: En praxiografisk analyse

Semester: Teknoantropologi – TAN4

Dato: 31/05/2024

Semesterprojekt: P4

Vejleder: Reza Tadayoni

Gruppe 5:

Andreas Sommer Thastum / 20222147

Frederick Aleksander Nilsen 20203704

Lasse Ørgård Slot / 20223520

Nicolaj Stevnsborg / 20225022

Thomas Julsgaard / 20222144

Tegn: 121.091

Sider: 50,45

Bilag: 7

Abstract

This cross-disciplinary project is an investigation between our research group at Aalborg University and Radiological Artificial Intelligence Testcenter (RAIT), a research unit committed to researching, testing and implementing Artificial Intelligence (AI) systems in the capital region of Denmark. RAIT requested assistance with communicating the complexities of AI in radiology in layman's terms. By interviewing different actors related to radiology in the Danish Health Care System, we explored how they engage with, and thereby understand, AI in their respective professional contexts. By conducting a praxiographical analysis, we demonstrated the various ways in which the actors practise AI, thereby emphasising that AI is a highly *situated* and *contextual* technology. We found two major factors that complicate the field of AI in radiology. Firstly, the fact that the term *AI* refers to a large variety of different systems constitutes a potential cause of miscommunication between the actors in the field, as there is no guarantee that – when talking about AI – the actors are talking about the same *types* of AI. Secondly, our praxiographical findings reveal that even when the actors share a common-language of AI, the communication is complicated by their different AI-practices. Finally, we mediated our findings through multiple digital infographics, to relay the complex insights in an easy-and-digestible manner and concretise the actors' different practices, thus enabling them to reflect upon their own practice and learn about the others'.

Indholdsfortegnelse

1 Indledning	4
2 Problemfelt á Mason	5
2.1 Ontologisk ståsted	5
2.2 Epistemologiske spørgsmål	7
2.3 Intellectual puzzle: En akademisk undren	8
2.4 Forskningsspørgsmål	8
3 Domæne	10
3.1 Kunstig Intelligens	10
3.2 Machine Learning	15
3.2.1 Fra algoritme til model	15
3.2.2 Data – udgangspunktet for ML	15
3.2.3 Mønstergenkendelse – hvordan en ML-algoritme lærer	15
3.2.4 Typer af ML	17
3.2.5. Statistiske modeller og Drift	17
3.3 Hvad er radiologi?	18
3.4 AI i radiologi	20
3.4.1 Hvilke typer AI til hvilke typer radiologi?	20
3.4.2 Hvorfor AI i radiologi?	20
3.4.3 Hvad er CE-mærkning?	22
4 Metode	23
4.1 Empiri	23
4.1.1 Bearbejdning af empiri	25
4.2 Brugerinvolvering: Den teoretiske præmis	27
4.2.1 Prototype som grænseobjekt	27
4.3 Brugerinvolvering: Metoden	28
5 Teori	30
5.1 Praxiografi	30
5.2 Riiskjærs logikker	31
5.2.1 Offentlig styringslogik	31
5.2.2 Markedslogik	31
5.2.3 Lægeprofessionslogik	32
5.2.4 Samspillet mellem logikkerne	32
5.3 Mol og Riiskjær: Et teoretisk rammeværk	33
6 En praxiografisk analyse	34
6.1 Introduktion	34
6.2 RAIT	34
6.3 Niels – MelaTech	36

6.4 Mads – Radiobotics.....	38
6.5 Jakob – Sygehus Lillebælt.....	39
6.6 Christian – RAIT	41
6.7 Anders – RAIT	43
6.8 Bodil – Herlev-Gentofte Hospital	43
6.9 Figur over aktørernes praksisser	46
6.10 Konvergerende ontologier.....	46
6.10.1 Jakob & Bodil	47
6.10.2 Mads & Niels	48
6.10.3 Niels & RAIT.....	49
6.11 Divergerende ontologier	50
6.11.1 Jakob & RAIT.....	50
6.11.2 Bodil & Mads.....	52
6.12 Delkonklusion	53
<i>7 Produkter</i>	<i>55</i>
<i>8 Diskussion.....</i>	<i>66</i>
8.1 Vi var de første til opgaven	66
8.2 Praxiografiske refleksioner	67
8.3 Praxiografisk analyse vs. teknisk virkelighed.....	68
8.4 Metodiske refleksioner.....	70
<i>9 Konklusion.....</i>	<i>71</i>
<i>Litteratur.....</i>	<i>73</i>

1 Indledning

Det danske sundhedsvæsen er under pres. Dette skyldes i høj grad demografiske ændringer; befolkningen er sundere end nogensinde, den forventede levetid er stigende, fødselsraten er faldende og en konsekvens heraf er, at aldersfordelingen i befolkningen ændres.

Ungdomsbefolkningen er faldende, seniorbefolkningen er stigende og det udfordrer sundhedssektoren på både hænder og ressourcer (Danske Regioner, 2015; EU-Kommissionen, 2023).

Udviklingen af ny medicin, behandlingsformer og -teknologier muliggør tidligere diagnosticering og bedre behandling, stadig flere sygdomme kan behandles, forekomsten af kronisk sygdom er stigende og øget efterspørgsel efter ny informationsteknologi strækker sundhedsvæsenets ressourcer – både personale og økonomi – tyndt (Dansk Selskab for Kvalitet i Sundhedssektoren, 2020; Danske Regioner, 2015).

Udgifterne til sundhedsvæsenet vokser hurtigere end samfundsøkonomiens vækst og én af flere fornuftige veje til at afbøde dette er, at vi skal drive sygehusene endnu mere effektivt. En måde hvorpå dette kan realiseres er ved at implementere kunstig intelligens (fra engelsk: *Artificial Intelligence*, herefter **AI**) til at aflaste det pressede personale, således at de har tid til andre patientnære opgaver (Danske Regioner, 2015; Gaardhøj, 2023).

Billeddiagnostisk – radiologisk – afdeling på hospitalerne er én af de mest højteknologiske afdelinger. Her udføres de fleste former for billeddiagnostik, hvilket omfatter CT- og MR-skanninger, ultralyd, interventionsundersøgelser og -behandling samt røntgenundersøgelser. RAIT (Radiologisk AI Testcenter) er et forskningssamarbejde mellem Herlev/Gentofte- og Bispebjerg/Frederiksberg Hospitals røntgenafdelinger. De har til formål at accelerere udviklingen, valideringen og implementeringen af AI indenfor det billeddiagnostiske område – et komplekst område, som kræver stor faglig indsigt for at kunne forstå AI's styrker og begrænsninger (RAIT, 2024b).

Igennem de sidste 3 år har RAIT forsket i og indsamlet viden om klinisk validering (testning), værdiskabelse og implementering af AI i radiologi. Disse komplekse indsigter ønskes af RAIT formuleret til nogle letforståelige budskaber til lægfolk. Dette projekt er et samarbejde mellem en gruppe teknoantropologi-studerende fra Aalborg Universitet (AAU) og RAIT.

AAU og Copenhagen Health Innovation (CHI) samarbejder om at udvikle nye løsninger på sundhedssektorens udfordringer og det er igennem CHI, at RAIT har stillet deres projektcase. Den præcise opgaveformulering fra RAIT lyder som følger:

Vi har brug for at få indrammet kompleksiteten og identificeret forskellige forståelser til enkelte alignet budskaber, der er nemt forståelige for de fleste (bilag 1)

2 Problemfelt á Mason

For at konkretisere vores projektdesign og gøre RAITs opgaveformulering akademisk interessant, har vi taget inspiration fra kapitlet *Finding a focus and knowing where you stand* fra Jennifer Masons bog *Qualitative Research* (2002). Mason præsenterer fem spørgsmål, der kan hjælpe med at gå fra en generel undersøgelsesinteresse – den stillede opgave fra RAIT – til et effektivt projektdesign – vores akademiske produkt (ibid.: 13). De fem spørgsmål er: (1) The Social 'Reality': Your Ontological Perspective (2) Knowledge and Evidence: Your Epistemological Position (3) Your Broad Research Area (4) Your Intellectual Puzzle and Your Research Questions (5) Your Aims and Purpose (ibid.: 14-22). Igennem besvarelsen af disse spørgsmål kan man finde essensen af ens undersøgelse og konkretisere den i form af en *akademisk undren* og konkrete forskningsspørgsmål (ibid.: 13).

2.1 Ontologisk ståsted

Ifølge Mason er det vigtigt, at man som noget af det første i et projekt diskuterer, hvilke ontologiske positioner projektgruppens medlemmer har. Dette skal sikre at gruppemedlemmerne hver især tænker deres individuelle ontologiske standpunkt igennem ift. hvad der konstituerer den sociale virkelighed (Mason, 2002: 14). Ikke alle ontologiske positioner er kompatible med hinanden, og det er derfor vigtigt at man tidligt i projektet får belyst eventuelle uenigheder og snakket dem igennem. Gøres det ikke, risikerer man ubevidst at undersøge projektet med forskellige indgangsvinkler, som potentielt modsiger hinanden senere i projektet (ibid.: 15).

Vi har i vores gruppe taget udgangspunkt i tabel 1.1 fra Masons tekst (2002: 15), se figur 1 nedenfor. I tabellen præsenterer Mason forskellige ontologiske positioner bestående af et eller flere ord (enkelte ontologier fylder to linjer). Vi udvalgte relevante ord fra de præsenterede ontologier, og kombinerede de af dem vi fandt kompatible.

people, social actors, humans bodies, subjects, objects minds, psyches rationality, emotion, thought feeling, memory, senses consciousness, subconsciousness, instincts understandings, interpretations motivations, ideas, perceptions attitudes, beliefs, views identities, essence, being selves, individuals, subject positions others, collectivities representations, cultural or social constructions	experiences, accounts stories, narratives, biographies evolution, development, progress texts, discourses words, codes, communications languages actions, reactions, behaviours events interactions, situations, social relations social or cultural practices social processes rules, morality, belief systems material cultures, objects, things time	institutions, structures, the 'material', markets cultures, societies, groups producers, consumers nature, genes, humans, animals empirical patterns, regularities, order, organization, connectedness empirical haphazardness spontaneity, disorder, disorganization, chaos and disconnectedness underlying mechanisms one objective reality, multiple realities or versions.
--	---	--

Figur 1: Forskellige ontologiske positioner (Mason, 2002: 15).

Multiple realities or versions – en vigtig pointe er, at vi vil møde forskellige virkelighedsforståelser hos vores forskellige aktører og formentlig opleve, at uenigheder i feltet opstår på baggrund af disse. Derfor er det vigtigt for os at kortlægge hver aktørs ontologiske standpunkt og præsentere disse til RAIT, så de kan sikre et bedre samarbejde.

Cultures, practice, group – vi blev i vores opstartsmøde med RAIT gjort opmærksom på, at et af de store problemer i implementeringen af AI er forskellige arbejdskulturer på forskellige hospitaler. Dette viste os, at problemerne ikke blot var tekniske, men også kulturelle. Derfor er det relevant, og vigtigt, at vi har fokus på kultur og arbejdspraksisser i undersøgelsen. Praksisser er også centrale for vores praxiografiske analyse, fordi det er gennem disse praksisser, at vi kan undersøge hvordan de forskellige aktører praktiserer, forstår og fortolker AI i en sundhedsmæssig kontekst.

Institutions, markets – i vores undersøgelsesfelt udspiller dynamikker mellem markedet (AI-leverandører) og institutioner (sundhedsvæsenet). For at forstå samspillet mellem disse aktører, er det vigtigt, at vi gør os nogle overvejelser omkring, hvad de hver især repræsenterer og hvordan de 'opfører' sig forskelligt fra, og ift., hinanden.

Narratives, disorganization, motivation - da feltet består af mange aktører, som hver især har deres egen agenda ift. implementeringen af AI i sundhedsvæsenet, finder vi det interessant at

undersøge hvilke narrativer, der eksisterer i aktørernes AI-praksisser, hvad de hver især arbejder imod, og hvad deres motivation er.

Understanding, interpretation, rules, morality – eftersom vi arbejder indenfor sundhedssektoren, spiller regler og etik en særlig vigtig rolle sammenlignet med andre felter. Vi er nødt til at forstå disse regler og etiske dilemmaer for at kunne agere etisk forsvarligt.

2.2 Epistemologiske spørgsmål

Efter at have defineret vores ontologiske ståsted – *hvad konstitueres vores undersøgelsesfelt af?* – må vi forholde os til, hvordan vi kan opnå viden om dette felt. Mason (2002: 16) skriver, at epistemologiske spørgsmål handler om at overveje, hvad der 'tæller' som evidens eller viden inden for det partikulære felt. Imidlertid kompliceres vores epistemologiske diskussion af Mols', og dermed praxiografiens, sammensmeltning af ontologi og epistemologi. Denne onto-epistemologiske filosofi udgør det videnskabsteoretiske fundament for praxiografien og bygger på idéen om, at mennesker og verden ikke er adskilte størrelser, men hele tiden gensidigt påvirker og former hinanden; virkeligheden bliver dermed løbende konstrueret i performative sociomaterielle praksisser (Ratner, 2021: 143). Verden og vores erkendelse af den, er et produkt af hvordan vi *performer* den (ibid.: 141) og som konsekvens umyndiggøres videnskabens traditionelle erkendelsesteori: vi kan ikke længere stå 'uden for' verden for at erkende dens beskaffenhed (ibid.: 143).

Uagtet ovenstående epistemologiske kompromittering, udgør aktørernes praksisser en kilde til viden om vores felt. Idéen er, at vi, gennem aktørernes forskellige praksisser, kan få adgang til (nogle af) de elementer, vi præsenterede i ovenstående afsnit om ontologi. Vi kan f.eks. undersøge hvordan en aktørs forståelse og fortolkning bliver udtrykt gennem en given praksis. Selvom onto-epistemologien slører skellet mellem verden og vores viden om den, er den praxiografiske metodologi både mere pragmatisk og mere konkret. Den fordrer en etnografisk undersøgelse af, hvordan et objekt (eller fænomen) bliver praktiseret i forskellige sociomaterielle praksisser, og dermed eksisterer som multipelt fænomen (ibid.: 147). Imidlertid understreger Mol (som del af sin onto-epistemologiske pointe) at videnskabelig metode aldrig kan være en passiv måde at opnå viden om verden på, men at det metodiske netop er en interfererende instans, der er med til at forme subjektets erkendelse (Mol, 2002: 155-159).

2.3 Intellectual puzzle: En akademisk undren

Projektets undersøgelsesfelt er betinget af den konkrete problemstilling givet af RAIT:

Vi har brug for at få indrammet kompleksiteten og identificeret forskellige forståelser til enkelte alignet budskaber, der er nemt forståelige for de fleste (bilag 1).

I kontekst af implementeringen af AI-systemer indenfor det billeddiagnostiske område, handler det overordnede undersøgelsesfelt om, hvordan vi kan forstå, identificere, reducere og formidle (teknologiens) kompleksitet til lægfolk (f.eks. beslutningstagere). Denne formulering kan imidlertid ligge til grund for en lang række *forskellige* undersøgelsesfelter, og det er derfor nødvendigt at markere, hvor vores partikulære undersøgelsesfelt befinder sig i det akademiske landskab. Ovenstående ontologiske og epistemologiske overvejelser udgør det videnskabsteoretiske fundament for vores konkrete undersøgelsesfelt. Kort sagt vil vi beskæftige os med de forskellige aktørers praksisser omkring AI i radiologien, for dermed at forstå fænomenets kompleksitet.

Mason (2002: 17-18) opfordrer os til at overveje det, hun kalder et *intellectual puzzle*; en akademisk undren. Hvad er vores akademiske undren? Hvad er det, vi ikke forstår og som vi vil forsøge at undersøge? Det korte, men, ikke desto mindre, meget komplekse spørgsmål...

Hvordan praktiseres AI af de forskellige aktører?

... udgør fundamentet for vores akademiske undren. Dét er det grundlæggende spørgsmål, vi ikke forstår og som vi vil forsøge at undersøge.

2.4 Forskningsspørgsmål

Mason beskriver forskningsspørgsmålets rolle i et projektdesign, som måden man forbinder hvad man ønsker at undersøge, med hvordan man vil undersøge det (Mason, 2002: 20).

Forskningsspørgsmål formuleres på baggrund af ens akademiske undren og må ikke være formuleret på en sådan måde, at deres svar kun er interessante, hvis det bliver besvaret på en bestemt måde (ibid.: 20). Vi har på nuværende tidspunkt følgende forskningsspørgsmål:

Hvad kan de forskellige aktørers AI-praksisser fortælle os om feltets nuancer og hvordan kan vi bruge viden om disse praksisser til bedre at kommunikere domænet kompleksitet til lægfolk?

Dette spørgsmål er interessant at stille, da besvarelsen, uanset hvad den bliver, gør os klogere på de forskellige praksisser, der er i spil. Vi får også lettere ved at reducere feltets kompleksitet ned til simple budskaber (hvilket var en af de primære arbejdsopgaver RAIT stillede os) hvis vi kan identificere *hvor* det komplekse bliver problematisk.

3 Domæne

3.1 Kunstig Intelligens

I litteraturen – hvad enten det er videnskabelige artikler, nationale strategier fra den danske regering eller faglitteratur – flourer der mange forskellige forståelser af begrebet kunstig intelligens (fra engelsk: *Artificial Intelligence*, herefter **AI**), hvilket besværliggør tydelig kommunikation og nemt fører til misforståelser.

Eksempler på forskellige forståelser:

Begrebet kunstig intelligens (KI) dækker over, når computere, robotter eller andre maskiner udviser en opførsel eller adfærd, som normalt ville kræve intelligens (Lauritsen & Lauritsen, 2019).

Kunstig intelligens er et paraplybegreb, der dækker over systemer baseret på algoritmer, som er trænet til at finde og genkende mønstre i store datasæt (big data) (Danske Patienter, s.d.).

Artificial intelligence, then, refers to the output of a computer. The computer is doing something intelligent, so it's exhibiting intelligence that is artificial (Jeffcock, 2018).

AI beskrives herover som paraplybegreb – altså et begreb, der har flere betydninger med én eller flere ting til fælles – og samtidig som noget konkret i form af en computers output og kunstig, intelligent adfærd. Så hvad er AI *egentlig*?

I dette afsnit vil vi søge at redegøre for, hvad ordet *Artificial Intelligence* omfatter – både konceptuelt og teknologisk (uden at erklære vores definition alt-omgribende) – for at give læseren en grundforståelse for, hvad AI er og for at bidrage til at tydeliggøre kommunikationen.

De citerede kilder fra litteraturen siger egentlig ikke noget forkert og de er heller ikke modstridende. For at kunne forstå hvorfor, er vi nødt til at forstå udtrykkets oprindelse og udvikling.

Udtrykket *Artificial Intelligence* blev møntet i 1956 af John McCarthy ved hans afholdelse af den første konference på området. McCarthy definerede oprindeligt AI som:

(...) *the science and engineering of making intelligent machines* (Manning, 2020).

Til videre at forklare begrebet *intelligent machines* kan vi benytte os af Lauritsen & Lauritsens (2019) beskrivelse af AI, som lyder:

(...) *når computere, robotter eller andre maskiner udviser en opførsel eller adfærd, som normalt ville kræve intelligens.*

Dette beskriver tydeligt, hvad *machines* står for, men hvad er intelligens? IBM Data and AI Team (2023) beskriver AI som maskiner, der kan imitere menneskelige kognitive funktioner såsom problemløsning og erfaringslæring. IBM (2022a) beskriver ligeledes ethvert system (se her den tidligere definition af maskiner) i stand til at simulere menneskelige tankeprocesser og intelligens som havende ‘kunstig’ (*Artificial*) intelligens, hvilket forstærker Jeffcock’s (2018) pointe om, at AI refererer til computerens output, der ergo må være kunstigt.

Konceptuelt kan vi nu nedbryde og forklare begge ord i *Artificial Intelligence* til følgende:

- *Artificial*: Kunstig, simulering/imitering udført af systemer/maskiner
- *Intelligence*: Menneskelige kognitive funktioner og tankeprocesser

Med ovenstående definition af ordets bestanddele, er AI en kunstig simulering/imitering af menneskets kognitive funktioner og tankeprocesser udført af systemer/maskiner.

Der findes tre overordnede konceptuelle kategorier af AI, som beskriver dens intelligens og ‘styrke’ (henholdsvis *weak* og *strong* AI) (IBM Data and AI Team, 2023):

- Artificial Narrow Intelligence (ANI) | Weak AI
- Artificial General Intelligence (AGI) | Strong AI
- Artificial Super Intelligence (ASI) | Strong AI

ANI – som navnet antyder – er en AI, der fokuserer på en specifik opgave indenfor et smalt segment af den menneskelige intelligens, såsom ansigts- og talegenkendelse eller computer vision (ibid.). AGI og ASI klassificeres som Strong AI, da de imiterer og inkorporerer

menneskelig adfærd mere tydeligt, såsom evnen til at tolke følelser og toneleje. En AGI's evner er sammenligneligt med et menneskes, mens en ASI – som navnet hentyder – har superintelligens og dermed vil overgå et menneskes intellekt og kognitive evner markant. Strong AI findes ikke endnu, men læseren vil nok have stødt på dem i diverse Science Fiction serier/film (ibid.). Af de tre overordnede konceptuelle kategorier af AI eksisterer AGI og ASI ikke endnu, og når AI fremover nævnes i opgaven, så refererer vi til Artificial Narrow Intelligence eller Narrow AI. AI's tidligere definition som paraplybegreb tydeliggøres, fordi begrebet både omfatter en konceptuel forklaring af AI, en kategorisering i form af Weak og Strong AI og vi vil i de følgende afsnit åbne op for den tekniske beskrivelse af AI.

I *National Strategi for Kunstig Intelligens* (Finansministeriet & Erhvervsministeriet, 2019) beskrives AI som:

(...) systemer baseret på algoritmer – dvs. matematiske formler – der ved at analysere og finde mønstre i data kan identificere den mest hensigtsmæssige løsning.

Omend definitionen ikke er forkert, er den mangelfuld. Årsagen kræver lidt forklaring.

AI har – groft set – to grundlæggende tilgange (IBM, 2022a):

- *Rule-based AI*, hvor systemet får specificeret regler til at løse problemet.
- *Example-based AI*, hvor systemet bliver givet eksempler, som den kan lære fra og derved på egen hånd analysere og finde mønstre i.

Rule-based AI benytter algoritmer – her beskrevet som en sekvens af utvetydige regler/instruktioner – til præcist at fortælle systemet, hvilke skridt AI'en skal tage for at løse et givent problem/opnå det ønskede mål. De(n) valgte algoritme(r) bestemmer, hvordan AI'en 'tænker' (ibid.).

Example-based AI benytter store mængder af data til at lave modeller. En AI trænes til at analysere og finde mønstre i data – såsom vejrforhold, brugerprofiler og videoer. Resultatet af denne proces er en model, der kan løse det studerede problem. Dette kan sammenlignes med at studere til eksamen, hvor man som udgangspunkt starter med lidt eller ingen forståelse, lærer ved at studere materiale og derefter kan anvende det lærte (ibid.).

Med denne viden kan vi bygge videre på beskrivelsen fra *National Strategi for Kunstig Intelligens* og have følgende, tekniske beskrivelse af AI:

AI er et overordnet begreb, der refererer til systemer baseret på algoritmer, der kan identificere den mest hensigtsmæssige løsning ud fra – afhængigt af tilgang – utvetydige regler eller eksempel-baseret læring.

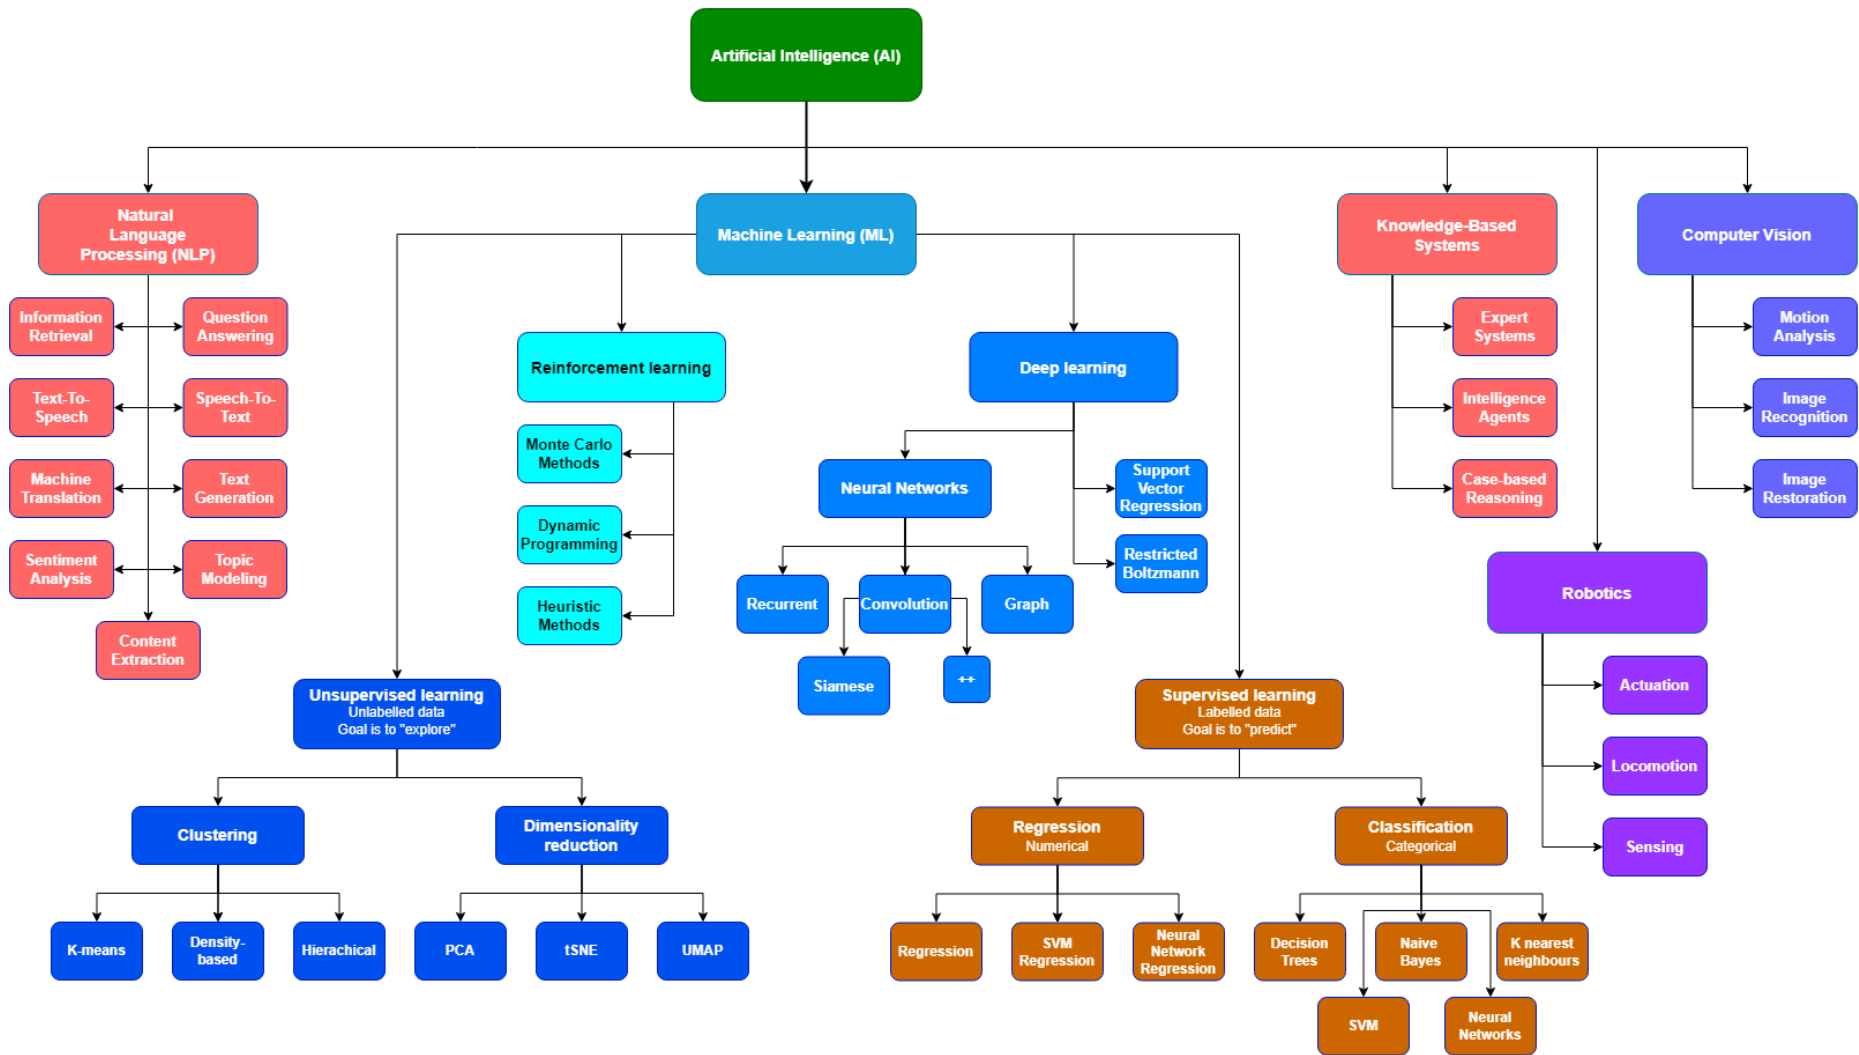
Vi kombinerer den konceptuelle og tekniske beskrivelse og får:

AI er en kunstig simulering/imitering af menneskets kognitive funktioner og tankeprocesser udført af systemer/maskiner, baseret på algoritmer, der kan identificere den mest hensigtsmæssige løsning.

AI tager mange former og inkluderer – men er ikke begrænset til (IBM, 2022a):

- Tekst-til-tale (natural language processing)
- Tekstanalyse – deduktion af indsigt og mønstre (natural language understanding)
- Transskribering og sprogforståelse (speech-to-text og natural language processing)
- Autonom bevægelse gennem 3D-rum baseret på sensorer/sanser (robotics)
- Ekstrapolering af information fra billeder (computer vision)
- Mønstergenkendelse i store mængder af data (machine learning)

På næste side kan du se et ikke-udtømmende diagram af hvad AI omfatter.



Figur 2: Et ikke-udtømmende overblik af AI.

3.2 Machine Learning

Machine Learning (herefter ML) er – som figur 2 viser – én af flere undergrupper af AI og de to begreber bliver ofte brugt omskifteligt, hvilket er misvisende og kan føre til misforståelser – som vi forsøgte at udbedre i forrige afsnit. Det er her vigtigt at pointere for læseren, at al ML er AI, men ikke al AI er ML.

ML er én af de mest anvendte former for AI og handler – i sin grundessens – om at få AI til at løse en opgave uden at blive givet specifikke instruktioner. ML handler – med andre ord – om at få et system til at lære. I stedet for at give AI'en regler til at løse et problem, bliver den givet eksempler og skal selv finde sammenhænge og mønstre (IBM, 2022b; Lauritsen & Lauritsen, 2019).

3.2.1 Fra algoritme til model

For at forstå, hvordan ML fungerer, bliver vi nødt til at definere ML-processen; hvor man går fra *ML-algoritme* til *ML-model*. Denne proces inkluderer flere trin. Først og fremmest kræves et godt datasæt – data udtrækkes, forarbejdes og renses (eks. for fejlindtastninger).

Algoritmen fastlægger ud fra et sæt af regler, hvordan systemet skal lære fra mønstre og sammenhænge i datasættet. Efter finjustering er resultatet en ML-model, der kan anvendes på lignende dataelementer, analysere dem og tage beslutninger ud fra datadrevne erfaringer (Lauritsen & Lauritsen, 2019).

3.2.2 Data – udgangspunktet for ML

For at fungere optimalt og sikre præcision, kræver ML-modeller store mængder af data. Den tekniske definition af data beskriver det som en samling af information – eksempelvis i form af tekst, billeder eller tal. Et datapunkt kaldes et *dataelement* og en samling af data kaldes et *datasæt*. Indenfor ML skelnes mellem to former for data – *mærket* og *umærket*. Hvis et datasæt er mærket, betyder det, at hvert enkelt dataelement har en kort præcis beskrivelse tilknyttet (Lauritsen & Lauritsen, 2019).

3.2.3 Mønstergenkendelse – hvordan en ML-algoritme lærer

Mønstergenkendelse (fra engelsk: *Pattern Recognition*, **PR**) er den grundlæggende, fundamentale proces, hvorved en ML-algoritme lærer ud fra et datasæt og resulterer i den

færdige model, som benyttes til forudsigelser/beslutninger (Fieguth, 2022). Den Danske Ordbog (Det Danske Sprog- og Litteraturselskab, 2023) beskriver det *at lære som*:

at tilegne sig kundskaber eller færdigheder, samt: efterhånden blive i stand til at gøre noget bestemt eller forstå og anerkende noget bestemt.

Hvis vi sammenfører ordbogens definition med vores tidligere eksempel om at studere til eksamen, så forstås det *at lære*, som:

At udlede og forstå information fra noget bestemt for at tilegne sig kundskaber eller færdigheder.

Mønstergenkendelse (PR) er processen, hvorved input måles, analyseres og klassificeres som tilhørende en specifik *klasse*. En klasse er et bestemt mønster/en bestemt gruppe af mønstre, der i én eller anden forstand er tilsvarende og endvidere kan skelnes fra andre, ud fra mønstrets *målbare egenskaber/attributter* (Fieguth, 2022).

PR er et dagligt aspekt af den menneskelige eksistens og forstås som den perceptuelle proces, hvorved sensorisk input – hørelse, berøring, smag, lugt eller syn – bliver sanset, analyseret og genkendt (klassificeret), enten instinktuelt (underbevidst) eller ud fra erfaring (bevidst). Eksempelvis kan det at læse denne tekst siges at være PR i og med, at vores øjne (syn) afbilder et ord/en karakter på nethinden, hvorefter det sanses, omdannes i hjernen til en neural repræsentation, der endvidere analyseres. Hvis ordet/karakteren genkendes, bliver det klassificeret med en etiket og betydning (ibid.).

I relation til ML, så er formålet med PR at give en maskine perceptuelle egenskaber, således at den kan udlede og forstå brugbar information fra data – eller med andre ord, give AI'en muligheden for at lære.

3.2.4 Typer af ML

ML kan overordnet inddeles i fire typer af læring:

- Supervised Learning (mærket data)
- Unsupervised Learning (umærket data)
- Reinforcement Learning
- Deep Learning

Supervised Learning (SL) specialiserer sig i at forbinde dataelementets dimensioner – dets nøgleegenskaber – med deres respektive mærke. Dette bruges til at lave forudsigelser, og SL kan lave to typer af forudsigelser; *classification* og *regression*, henholdsvis opdeling af data (ting) i kategorier og forudsigelse af kontinuerte værdier. SL handler essentielt om at give algoritmen nok eksempler, som den kan bruge til at lave præcise forudsigelser (IBM, 2022b; Lauritsen & Lauritsen, 2019).

Unsupervised Learning (UL) søger at udforske og finde fællestræk, uafhængigheder og naturlige grupperinger i umærket data på egen hånd. UL's styrke er naturlig gruppering – også kaldet *clustering* – og er som konsekvens af dette utrolig effektiv til at finde særheder og uregelmæssigheder i et datasæt (IBM, 2022b; Lauritsen & Lauritsen, 2019).

Reinforcement Learning (RL) er en type af ML, hvor systemet lærer at interagere med et bestemt miljø (sted/rum) eller en specifik situation optimalt. Dette gøres ved, at systemet prøver nye teknikker, hvor positiv (optimal) adfærd belønnes og negativ adfærd straffes. RL kan sammenlignes med opdragelse og dannelse (IBM, 2022b; IBM Data and AI Team, 2023).

Da data fra den virkelige verden ikke altid kan opdeles præcist i umærket og mærket data, kan et behov opstå, hvor en kombination af SL- og UL-teknikker benyttes, og heraf kommer *Deep Learning*. DL benytter mange lag af matematiske operationer i et neuralt netværk til at identificere interessante karakteristika såsom kanter og former, der hjælper modellen med at træffe en beslutning (IBM, 2022b; Lauritsen & Lauritsen, 2019).

3.2.5. Statistiske modeller og Drift

Tidligere beskrev vi ML-processen – hvordan en ML-algoritme trænes og testes iterativt på et datasæt, finjusteres således den kan leve op til de ønskede krav til performance o.l., hvorved det resulterer i en anvendbar ML-model, der sættes i produktion. Denne model kan enten

være *statisk* eller *dynamisk*. En dynamisk ML-model – efter den er sat i produktion – fortsætter med at træne/lære fra de data, som den behandler og den nye viden inkorporeres i modellen løbende. En statisk ML-model benyttes udelukkende til at behandle data og lærer/opdateres ikke aktivt (Google Developer Program, 2022).

Drift indenfor ML refererer til den potentielle ændring i data (samt de mekanismer og begreber, de givne data repræsenterer) over tid, der forårsager en afvigelse mellem den aktive fordeling af data og den fordeling af data, som blev brugt til at skabe den underliggende ML-model. Dette kan resultere i, at modellen ikke længere laver præcise forudsigelser på *real-world data*. Drift kan opdeles i to kategorier; *data drift* og *model drift*, der groft set omhandler afvigelser i henholdsvis datainput og modellens datakategorisering. Model drift kan ikke ske, hvis ikke der er data drift til at ændre modellen (Microsoft Learn, 2024)

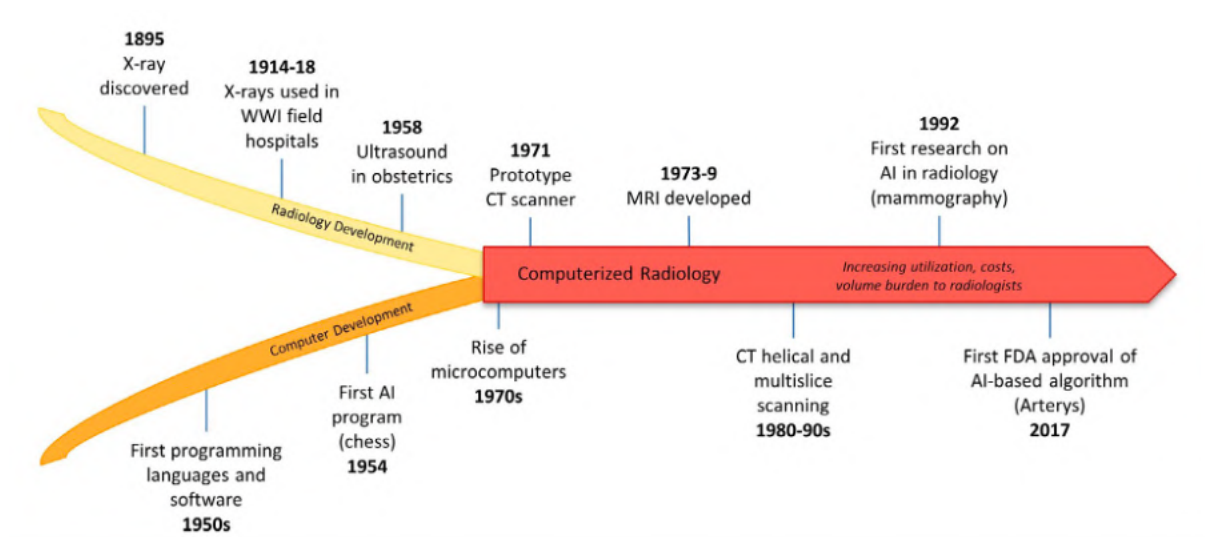
3.3 Hvad er radiologi?

I dette afsnit vil vi kort redegøre for hvad radiologi er, samt præsentere en historisk gennemgang af den teknologiske udvikling inden for radiologien, der har muliggjort AI-integration. Dette skal give læseren en – om end overfladisk – forståelse for det teknologiske felt vores projekt er situeret i, og om hvorfor radiologien er specielt interessant, når det kommer til AI i sundhedsvæsenet.

Radiologi er et medicinspecialt med fokus på diagnosticering af skader og sygdomme ved hjælp af billeddiagnostiske teknikker (Wikipedia, s.d-a). For at blive uddannet radiolog, skal man først være læge, hvorefter man videreuddanner sig til at blive speciallæge inden for radiologi. Fra medicinbachelor til speciallæge i radiologi tager minimum 12 år (Uddannelsesguiden, s.d).

For at læseren kan forstå hvorfor radiologi er særligt interessant for AI-integration, vil vi kort gennemgå radiologiens teknologiske udvikling. Den første radiologiske billedteknik blev opdaget af Wilhelm Röntgen i 1895 (Najjar, 2023: 2). Som navnet hentyder, var teknikken røntgenfotografi, og markerede starten på det vi i dag kender som radiologiske billedteknikker. Den næste store opdagelse inden for radiologisk billedteknologi var ultralyd: Den første artikel skrevet om ultralyd blev udgivet i 1948 og detaljerede hvordan en russisk ingeniør under første verdenskrig havde foreslået at bruge ultralyd til at søge efter ubåde

under vandet (Wikipedia, s.d-b). I 1950'erne skete der store teknologiske fremskridt inden for feltet og i 1958 blev ultralyd for første gang brugt på maven af en gravid kvinde (Driver, Bowles, Bartholmai, & Greenberg-Worisek, 2020: 1). Indtil udviklingen af mikroprocessorchips i 1970'erne var billedteknikkerne en langsom og analog proces (ibid.). Dette ændrede sig i takt med computerteknologiens sideløbende udvikling, som muliggjorde at processere og oplagre store mængder data og katalyserede ekstrem udvikling inden for radiologisk billedteknologi (ibid.). I 1970'erne blev både computertomografi (CT) og magnetisk resonans imaging (MR) opfundet: En CT-skanning er en avanceret form for røntgenskanning, hvor en computer på baggrund af en række røntgenbilleder fremstiller tværsnitbilleder af kroppen, så radiologen kan fremstille en 3D-model af de(n) fotograferede del(e) af kroppen på sin computer (Sundhed.dk, 2024a). En MR-skanning bruger radiobølger og magnetisme til at fremstille billedstrømme af kroppens indre og er ligeledes afhængig af computeren for at processere og fremstille disse (Sundhed.dk, 2024b). Nedenstående figur viser hvordan radiologiske billedteknikker og computerteknologi sideløbende udviklede sig indtil de blev kombineret i 1970'erne.



Figur 3: Historisk udvikling af AI og radiologi (Driver et al, 2020: 2).

Efter den fulde computerintegration i radiologien begyndte forskningen i 1992 at undersøge, hvorvidt AI-systemer kunne integreres og starte den næste 'eksplosion' af innovation i radiologien (ibid.). Næste afsnit vil redegøre for i hvilken grad AI i dag er integreret i radiologien.

3.4 AI i radiologi

Indenfor radiologien har AI potentialet til at forbedre og effektivisere domænet. Idéen om at komplementere, eller sågar erstatte, den menneskelige radiolog med computationel beslutningstagen, er på sin vis ikke et nyt fænomen i radiologien. Siden start 2010'erne har diskursen af AI's disruptive implikationer i den radiologiske verden været påtrængende (Najjar, 2023), som noget der hele tiden blot er en armlængde væk. Det skal dog pointeres, at de underliggende algoritmer, som udgør den kunstige intelligens' intelligens, er i konstant udvikling, hvilket også har effekt på implementeringen.

3.4.1 Hvilke typer AI til hvilke typer radiologi?

I Pianykh, Langs, Dewey, Enzmann, Herold, Schoenberg & Brinks tekst: *Continuous Learning AI in Radiology: Implementation Principles and Early Applications* (2020), fremhæves tre former for kunstig intelligens, som benyttes i radiologien: (1) Operationel AI der optimerer håndtering af patienter, hvilket inkluderer behandlingsplan og planlægning. (2) Diagnostisk AI kan hjælpe med diagnosticeringen af patienter. Og (3) forudsigende AI, som kan hjælpe med at forudsige sygdomsforekomst, udvikling og tilbagefald, og eventuelle behandlingsindgreb (ibid.: 6). Til gengæld er det vigtigt, at modellen er trænet på samme type radiologiske scanninger, som modellen vil håndtere i praksis. For eksempel er firmaet Radiobotics' diagnostiske AI-model *RBfracture*, trænet på X-ray scanninger, eftersom det er den type scanninger som modellen skal diagnosticere (Radiobotics, 2024: 1). Dette gør sig gældende for hver en type af scanning, og derudover for hver en type af skade. Radiobotics har udviklet en AI-model til at diagnosticere knæskader (RBKnee), en anden til at diagnosticere hofteskader (RBHip) og en tredje til at diagnosticere simple knoglebrud (RBFracture) (Radiobotics, s.d.).

3.4.2 Hvorfor AI i radiologi?

En af de nødvendige ingredienser for at kunne skabe en operationel AI er en stor mængde valid data. AI har et stort billeddiagnostisk potentiale, eftersom ML-modeller er højt kompatible med mønstergenkendelse på billeder og digitaliseringen af sundhedssektoren har medført, at store datasæt af radiologisk materiale er klar til brug (Thrall, Li, Li, Cruz, Do, Dreyer & Brink, 2018: 1). Og som Chockley & Emanuel (2016: 1418) skriver i deres artikel *The End of Radiology? Three Threats to the Future Practice of Radiology*, kan AI processere store mængder data i *realtid* (ibid.). Derudover er AI ikke præget af faldgruber såsom træthed eller humørsvingninger. Chockley og Emanuel skriver (ibid.):

Machine learning can handle significantly more complex data sets than human beings can. Whereas a human may become overwhelmed trying to read a particularly complicated scan or interpret a particularly large set of data, a computer does not have those cognitive limitations.

Hermed bliver det menneskelige element elimineret, og derfra bliver der skabt en konsistent og pålidelig måde at få hurtige resultater på. Med ovenstående in mente kunne man være fristet til at spørge: *Hvorfor bruger man ikke kunstig intelligens i radiologien?*

Svaret er, at AI allerede spiller en stor rolle i radiologien. Allerede fra 1980'erne blev AI implementeret i takt med at computerens processorkraft blev markant højere (Hosny, Parmar, Quackenbush, 2018: 501). Fra 80'erne og frem er disse systemer kun blevet mere centrale i radiologens arbejdsgang, hvor AI bliver brugt til at støtte radiologernes beslutninger.

Et eksempel på en tidligere implementeret type af AI-system er CAD (*computer assisted detection*), hvis formål er at assistere med at identificere suspekke abnormaliteter i scanninger (Castellino, 2005: 17). CAD blev taget i brug for at reducere antallet af oversete – og potentielt farlige – diagnose-relevante detaljer. CAD bliver således brugt efter den initiale læsning af scanningen, som en slags *dobbelttjek*, for at reducere behovet for et menneskeligt dobbelttjek (ibid.). CAD-systemer er ikke fejlfrie; en undersøgelse fra 2005 viste, at CAD foretog flere fejlagtige bemærkninger end sande testresultater. Af denne grund er yderligere evaluering nødvendigt i brugen af denne type AI (ibid.: 18). Samme problem præger den nyere type af CAD – *computer assisted diagnosis*, der vurderer patogenitet og malignitet i tumorer. CAD blev brugt i 74% af mammografiske scanninger i 2010 (Oakden-Rayner, 2019: 1). Det viste sig til gengæld, at CADs fejlanvisninger gør radiologer 20% langsommere (per scanning), da radiologen skal afvise alle de fejl programmet begår (ibid.). Det er blandt andet disse problematikker, som nye AI-teknologier – såsom *deep learning* – potentielt kan udbedre (ibid.). Som Keith Loira skriver i artiklen *Putting the AI in Radiology* (2018: 1)...

(...) 'AI-lite' is already being used in radiology in a number of ways, such as computer-aided detection for cancer, auto-segmentation of organs in 3D postprocessing, natural language processing to facilitate critical results reporting, consultation of best guidelines for recommendations, and quantification and kinetics in postprocessing.

... skal AI i radiologien ikke forstås som noget revolutionerende eller *nyt*, men derimod som en central teknologi under konstant udvikling, der har et stort potentiale.

3.4.3 Hvad er CE-mærkning?

For at AI må anvendes i sundhedssektoren indenfor EU's grænser, er det obligatorisk, at den er CE-godkendt. Dette regulativ er til for at undgå uhensigtsmæssig brug af teknologi, på samme måde, som at præparater også skal igennem testfaser, før de kan komme på markedet til kommercielt brug (EU, s.d). Denne proces bliver foretaget af et bemyndiget organ, som sikrer at den valgte teknologi overholder alle EU-regler og -krav. Prisen og tiden afhænger af hvilken certificeringsprocedure, der er nødvendig for den pågældende teknologi, hvilket afhænger af, hvor kompleks teknologien er (ibid.). For eksempel er der to forskellige procedurer alt efter, hvor autonom ens AI er. Den førnævnte AI-model: *RBfracture* af Radiobotics, benytter en CE IIA-godkendelse. En CE IIA, er til produkter som er relevante iht. følgende beskrivelse (Obelis Group, 2019):

Class Iia devices generally constitute low to medium risk and pertain mainly to devices installed within the body in the short term

For at AI-systemet må lave mere alvorlige indgreb, skal teknologien have en certificeringsprocedure som er tilsvarende (ibid.).

4 Metode

4.1 Empiri

Opgaven vi er blevet sat til at løse af vores samarbejdspartnere fra RAIT, er naturligvis central for vores projekt-metodiske tilgang. Udfordringen handler om (1) at få indrammet kompleksiteten, (2) at identificere forskellige forståelser vedrørende AI i radiologien og (3) at få formidlet denne kompleksitet og disse forståelser i mere letfordøjelige termer. Først skal kompleksiteten – hvad end denne viser sig at indebære – indrammes og de forskellige forståelser skal identificeres; dernæst skal dette konkretiseres og forsimples. Vores første udfordring er derfor at få indrammet kompleksiteten og identificeret forståelserne.

Kompleksitet er en diffus størrelse og umiddelbart svær at håndtere. For at støbe et solidt fundament for vores senere arbejde, benyttede vi projektets første uger på at studere de tekniske og sundhedspraktiske aspekter af kunstig intelligens; såsom hvordan algoritmerne er struktureret, hvilke typer af AI-systemer, der egner sig til hvilke dele af den radiologiske praksis og hvilke potentialer og udfordringer AI har for radiologien og sundhedsvæsenet generelt (Shen, Wu & Suk, 2017; Shaw, Rudzicz, Jamieson & Goldfarb, 2019; Rajkomar, Dean & Kohane, 2019; Najjar, 2023; Hosny, Parmar, Quackenbush, Schwartz & Aerts, 2018; Badillo, Banfai, Birzele, Davydov, Hutchinson, Kam-Thong, Siebourg-Polster, Steiert & Zhang 2020). Denne indledende fase skulle ruste os bedre til at forstå det fagsprog vi i de senere faser forberedte os på at møde; idéen var at vi ville være i stand til at forholde os mere kritisk og bedre forstå de fagprofessionelle aktørers lingo.

Med et bredere (om end stadig meget ydmygt) vidensgrundlag, kontaktede vi vores samarbejdspartnere fra RAIT for at planlægge et opstartsmøde. Formålet var at de kunne specificere opgavens indhold og udpensle udfordringens karakter. Vi havde brug for at finde ud af hvordan vi skulle tilgå opgaven og havde allerede diskuteret, hvilken metodik der kunne være relevant. Mødet blev afgørende for at få overblik over projektets egentlige omfang.

Efter mødet med RAIT konkluderede vi at den mest oplagte metodik til at indramme kompleksiteten og til at identificere aktørernes forskellige forståelser, var det semistrukturerede interview. Metodisk er interviewet formentlig den mest benyttede tilgang til kvalitativ forskning (Tanggaard & Brinkmann, 2020: 33). Ved opstartsmødet introducerede RAIT os for en række aktører, der (ifølge dem) kunne være relevante at interviewe. Det var

derfor en prioritet, at vi kunne strukturere vores interviews nok til at AI forblev centrum for dialogen, men at vi på den anden side tillod de respektive aktører at nuancere dialogen med netop deres forståelser af emnet. Derfor ræsonnerede vi, at det semistrukturerede interview kunne understøtte dette empiriske puslespil. Denne metodik fordrede netop, at vi inden et givent interview gjorde os klart, hvad vi ønskede at vide noget om (Tanggaard & Brinkmann, 2020: 42), men at vi på samme tid varetog en nødvendig fleksibilitet med hensyn til mulige afveje under selve interviewinteraktionen. Sidstnævnte var essentielt, hvis vi skulle indramme emnets kompleksitet, fordi vi derved lod den interviewede aktør udforske denne kompleksitet for os. For at understøtte vores semistrukturerede interview, udarbejdede vi til hvert interview en interviewguide. Formålet med denne guide var at forberede, hvad vi ville vide noget om og dermed at centrere dialogen omkring AI – dette skulle sikre en rød tråd gennem alle interviews.

Vi synes kort det er værd at nævne hvordan vi fik kontakt til de i alt syv informanter, vi endte med at interviewe. RAIT anbefalede os at kontakte en medstifter af virksomheden Radiobotics, der udvikler AI til detektion af fraktur på røntgenbilleder. En lidt uformel dialog efter interviewet sporede os ind på et andet potentielt interview med en cheflæge og afdelingsleder fra Sygehus Lillebælt. Resten af de syv interviews fik vi direkte eller indirekte adgang til gennem vores kontaktpersoner i RAIT. Det stod os hurtigt klart, at vi uden RAIT som samarbejdspartnere havde haft væsentligt sværere ved at skabe kontakt til så mange forskellige aktører, især de sundhedsfaglige. Interviewet med Bodil Ørkild, vicedirektør på Gentofte og Herlev Hospital, havde formentlig været noget nær umuligt at få stablet på benene uden vores kontaktpersoner i RAIT.

Det var vigtigt for os, at vores empiriske grundlag repræsenterede en diversitet af holdninger – fra forskellige lejre – og ikke alene var en privilegering af RAITs perspektiv. Derfor lod vi det teknoantropologiske perspektiv guide vores valg af informanter. Det var centralt at vi fik talt med brugere (i denne sammenhæng radiologer der bruger, eller i fremtiden kommer til at bruge teknologien i praksis), udviklere (private firmaer, f.eks. Radiobotics, der aktuelt arbejder på at udvikle et AI-baseret produkt til radiologien) og beslutningstagere (politikere, direktører eller afdelingsledere, der har en stemme når det kommer til implementeringen af disse teknologier). Vi supplerede desuden vores egne syv interviews med to podcasts, hvor Louise Brown (MF, LA) interviewer Ulrik Rokkedal, CEO for Human Bytes (Brown, 2023a)

og Mikael Boesen, professor i diagnostisk radiologi og medstifter af RAIT (Brown, 2023b). Således kom vi, synes vi selv, nogenlunde omkring trekantens tre hjørner.

Efterhånden som vi fik afviklet de syv interviews, observerede vi, at flere af informanterne gentog de samme pointer. I interviewundersøgelser er det altid relevant at forholde sig til hvor mange interviews det giver mening – og er realistisk – at gennemføre. En større mængde er ikke altid en fordel, da en stor datamængde kræver tilsvarende stor bearbejdning og grundigt analytisk håndværk (Tanggaard & Brinkmann, 2020: 36-37). Som Tanggaard og Brinkmann skriver (ibid.: 37) interviewer man ideelt set, indtil materialet når et mætningspunkt og yderligere interview ikke giver flere relevante oplysninger om det, man ønsker at vide noget om. Det var netop dette mætningspunkt, vi begyndelsesvist kunne observere under de sidste par interviews. Dette betyder naturligvis ikke at vi har afstøvet alle afkroge af vores undersøgelsesfelt, men det vidner om at vores empiri afspejler de centrale aktørers umiddelbare hovedpointer. Med denne indsigt stopper vi vores interviewfase og indleder en bearbejdning af vores empiri.

4.1.1 Bearbejdning af empiri

Første forudsætning for at vi kunne arbejde med den indsamlede empiri var, at vi fik transskriberet alle interviews: både de syv vi selv afviklede og de to podcasts. Efter at have transskriberet to interviews manuelt begyndte vi at eksperimentere med Good Tapes, som er en transskriberingssoftware udviklet af Zetland. Fremgangsmåden blev som følger: Vi uploadede hver især et interview, som blev auto-transskriberet i Good Tapes. Nu bestod arbejdet i at vi hver især læste transskriberingen igennem mens vi lyttede til interviewet. Dermed kunne vi rette eventuelle fejl og validere at transskriberingen var i orden. Efter denne fase sad vi tilbage med seks transskriberinger og vi diskuterede hvordan vi bedst muligt kom videre i processen. Da opgaven, som ovenfor beskrevet, er at indramme kompleksitet, identificere forståelser og simplificere dette til letforståelige budskaber, blev vi enige om at første bearbejdning skulle være en fælles gennemlæsning og kodning af de i alt seks transskriberinger. Formålet var, at vi fik mulighed for at diskutere den indsamlede empiri meget tekstnært.

Vi gennemførte derfor en induktiv kodningsproces, hvor vores fokus var at få indrammet kompleksiteten og identificeret forskellige forståelser for AI i radiologien. Den første kodningsrunde efterlod os med en række forskellige, og relativt snævre koder, som f.eks.:

Budgettering
Værdiskabelse
CE-godkendelser
Patientpopulation
AI er ikke bare AI
Monitoreringssystem
Eksistensberettigelse
Standardiseringsproblematik

Formålet med den indledende kodningsproces var at udforske feltet gennem vores empiri for derved at blive klogere på, hvad denne 'kompleksitet' egentlig indebar. Komplexiteten var en flyvsk, diffus, uhåndterbar størrelse som vi havde til opgave at tæmme, demarkere og formidle. I anden kodningsfase, i visse sammenhænge betegnet focused coding (Bossen & Lauritsen, 2021: 71-72) arbejdede vi på at samle første fases koder i større kategorier. Idéen med denne fase er at konstruere større sammenhænge ud fra data. Vi lod empirien guide konstruktionen af disse mere overordnede kategorier, men vores konkrete opgave var ligeledes central for disse kategorier. Nedenfor oplystes (i vilkårlig rækkefølge) resultatet af anden (og i skrivende stund sidste) kodning:

Udfordringer i CE-mærkningen
Monitorering af performance
Validering af værdiskabelse
Juridiske dataudfordringer
Hospitaler er forskellige
Uforudsete konsekvenser
Formidling af AI

Disse koder er det vi kalder feltets 'komplekse indsigter' og det er disse indsigter vi skal arbejde med at formidle for RAIT.

4.2 Brugerinvolvering: Den teoretiske præmis

Det følgende afsnit vil kort introducere læseren til det teoretiske såvel som metodiske fundament for brugerinvolvering. Formålet er, at læseren får en bedre forståelse for, hvordan vi har inddraget vores samarbejdspartnere fra RAIT i udviklingen af vores endelige produkt. Participatorisk brugerinvolvering opstod og udvikledes i 1970'ernes Europa – specielt Skandinavien (Sanders og Stappers, 2008: 7). Formålet med participatorisk design var at skabe metoder, der skulle være med til at oprette en sikker og stabil videnskanal for at forhindre misforståelser (ibid.). Dog skal det understreges at participatorisk design ikke er en metode, men derimod en paraplybetegnelse for de værktøjer, som besidder de ovennævnte egenskaber (ibid.: 5). For at give mere konkret forståelse, bruger vi *codesign* til at belyse hvad brugerinvolveringsdesign er. I *codesign* spiller brugeren en aktiv rolle gennem hele den iterative designfase, hvor brugeren bliver behandlet som ekspert og meddesigner. Ergo skal brugeren behandles på lige fod med designeren og forskeren (ibid.: 11). I denne metode får brugeren plads til at komme med idéer og konceptuelle input til, hvad produktet skal rumme. Disse idéer skal spille som nøglerolle i produktets udformning (ibid.: 12). For at beskrive brugerinvolverings essens meget kort, på tværs af alle dens metoder og værktøjer, skaber udvikleren et produkt *med* brugeren (Sanders, 2002). Denne tanke har været den overordnede motivation for brugen af brugerinvolvering i vores projekt. Nedenfor vil vi beskrive den kombinerede metode – prototype som grænseobjekt – som vi har brugt til at skabe en brugerinvolverende designproces.

4.2.1 Prototype som grænseobjekt

Prototyper er en simpel udgave/repræsentation af en designidé. En *prototype* kan vise sig i alle former, digitalt såvel som fysisk (Houde & Hill 1997: 3). Kombineret med dette er der en åbenlys mulighed for at drage inspiration fra *codesign*, og bruge prototyper i en iterativ proces. Med inspiration fra Rhinow, Koeppen og Meinel (2012: 4) bruger vi disse prototyper som grænseobjekter. Grænseobjekter er et artefakt, som bliver brugt til at skabe tydelig kommunikation mellem parter fra forskellige discipliner (Carlille, 2002: 453). Et grænseobjekt behøver, ligesom prototypen, ikke være en ting, men kan være alt fra koncepter til idéer. Det eneste grænseobjektet skal besidde, er evnen til at sammenfatte forståelse mellem flere forskellige felter (ibid.). Det vil sige, at vores prototype er et grænseobjekt, idet den skaber forståelse mellem vores samarbejdspartner og os i den iterative designproces.

4.3 Brugerinvolvering: Metoden

Under vores opstartsmøde med RAIT, forventningsafstemte vi hvad det færdige produkt skulle være. Vi blev enige om, at vi som del af opgaven ville lave et produkt, som RAIT kunne tage med videre til relevante beslutningstagere. Da hverken RAIT eller beslutningstagerne har tid til at læse vores akademiske rapport, er produktet på sin vis lige så vigtigt som rapporten. Formålet med produktet er, at det skal agere formidlende instans mellem RAIT og diverse beslutningstagere. Produktet bliver derfor nødt til at simplificere de komplekse indsigter, der er i forbindelse med billeddiagnostisk AI i radiologisk regi, ned til simple(re) budskaber, som lægfolk kan forholde sig til. Som beskrevet i forrige afsnit brugte vi primært interviews under indsamlingen af vores empiri, men vi ønskede at tage samarbejdet med RAIT et skridt videre end blot samtale: Vi ønskede at indgå i en iterativ designproces. Med inspiration fra vores kursus *Facilitering af brugerinvolvering i teknologisk innovation*, valgte vi at facilitere en iterativ designproces, hvor vi gennem en email-korrespondance og en efterfølgende online-workshop itererede på prototyper i fællesskab med RAIT. Idéen med denne workshop var, at få bedre adgang til RAITs ekspertviden, når vi havde noget konkret, som de kunne forholde sig til. For at forsimple de komplekse indsigter, blev vi først nødt til at sikre, at vi havde forstået dem korrekt. Derfor lavede vi et dokument, hvor vi skrev alle de komplekse indsigter, vi havde indsamlet under vores empiriindsamling. Dette dokument sendte vi til RAIT, så de kunne give os feedback.

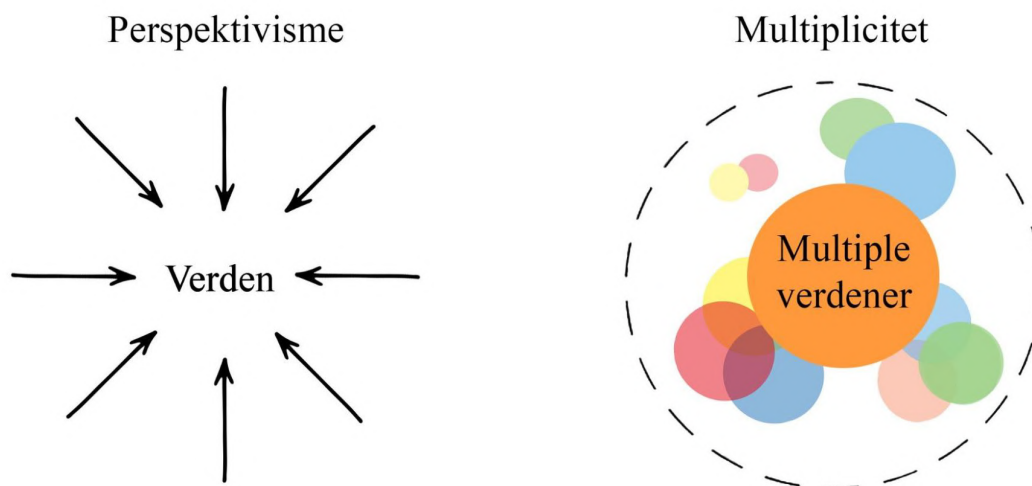
Dette dokument var vores første prototype af det endelige produkt (infografikker). Efter at vores to kontaktpersoner i RAIT havde læst og kommenteret på vores prototype, gennemgik vi deres kommentarer og inkorporerede dem i den næste iteration. Da vi var klar med anden iteration af vores prototype, planlagde vi et virtuelt møde over Microsoft Teams. Prototypen var igen et dokument med komplekse indsigter. Hvor første prototype var fokuseret på at få bekræftet, at vores forståelse for feltet og dets indsigter stemte overens med RAITs, var anden prototypes formål at få feedback på enkelte formuleringer. Den online workshop var vores sidste chance for at snakke med RAIT før opgavens deadline, så det var vigtigt at fokusere på formidlingsmæssigt vigtige detaljer. Dette gjorde vi ved at gennemgå de komplekse indsigter minutiøst, så vi kunne ændre enkelte ord, de ikke kunne lide. Idéen var, at de formuleringer som RAIT var enige i, skulle bruges i det færdige produkt. De formuleringer som RAIT enten ville have ændret en smule, eller helt slettet, fik vi alternative bud på. Efter mødet gik vi i gang med at inkorporere ændringerne i den tredje og endelige iteration af de komplekse

indsigter. Efter færdiggørelsen af den endelige prototype gik vi i gang med at designe den visuelle infografik. Vi ville gerne have haft en ekstra workshop, hvor vi kunne diskutere det visuelle produkt, men dette var desværre ikke muligt, da RAIT ikke havde tid til flere møder. Brugerinvolveringen havde ikke blot til formål at øge RAITs tilfredshed med slutresultatet, men skulle tillade os at indgå i et partnerskab, hvor vi ikke blot designede *for* men også *med* RAIT.

5 Teori

5.1 Praxiografi

Annemarie Mol (13. september 1958–) er en hollandsk professor i antropologi ved Amsterdam Universitet (University of Amsterdam, 2024). Hendes forskning udfordrer idéen om verden som værende entydig og objektiv, og appellerer i stedet til en forståelse af verden, som noget der *gøres* i en række sociomaterielle praksisser (Ratner, 2021: 141-144). Hendes filosofi står dermed i opposition til ontologi og epistemologi som adskilte størrelser, fordi verdens beskaffenhed (ontologi) og vores viden om den (epistemologi) begge bliver til i praksis og vi ikke længere blot kan stå på afstand af verden og erkende, opdage eller repræsentere den (ibid.: 143). Hun tager afstand fra idéen om *perspektivisme*: at verden synes forskellig, fordi aktører beskuer den fra forskellige perspektiver, netop fordi perspektivismen antager at et objekt er entydigt og har et veldefineret sæt af egenskaber (ibid.: 146).



Figur 4: Visualisering af perspektivisme og multiplicitet

Mol mener at vi i stedet bør interessere os for, og undersøge, hvordan objekter praktiseres i forskellige sociomaterielle praksisser. Hvis vi gør dette, vil vi se, at objektet (og verden) aldrig eksisterer uafhængigt af den praksis hvori det er situeret (ibid.). Konsekvensen af hendes filosofi er radikal: med Mols praxiografi – dvs. kortlægningen af hvordan et objekt, et fænomen, eller verden bliver til i sociomaterielle praksisser – *multipliseres* virkeligheden. Denne pointe udfolder hun både med *Ontological politics. A word and some questions* (1999) og *The Body Multiple* (2002). I førstnævnte udfolder Mol konsekvensen af virkeligheden som

en *multipel* størrelse og beskriver implikationerne ved at gå fra en singular ontologi til multiple ontologier. I sidstnævnte eksemplificerer Mol sin filosofi med udgangspunkt i anæmi (blodmangel). Hun beskriver hvordan tilstanden eksisterer som et multipelt fænomen, fordi den *praktiseres* på forskellige måder: klinisk, laboratorisk og patofysiologisk (Mol, 1999: 77-78). Pointen er at anæmi *er* forskellige ting alt efter hvordan det *praktiseres*.

En af de centrale aspekter af vores opgave, handler om at identificere forskellige forståelser af AI. I analysen udfører vi derfor en praxiografisk kortlægning af hvordan de forskellige aktører praktiserer AI. Idéen er at tage Mols filosofi seriøs og vise, at disse forskellige forståelser (hvis de altså viser sig at være forskellige) skyldes at AI er situeret i forskellige sociomaterielle praksisser.

5.2 Riiskjærs logikker

I dette afsnit vil vi præsentere Erik Riiskjærs idé om de fire dominerende logikker inden for sundhedsvæsenet, og efterfølgende hvordan disse relaterer sig til hinanden. De fire logikker er: *Offentlig styringslogik, markedslogik, lægeprofessionslogik og plejefprofessionslogik* (Riiskjær, 2014: 22). Ifølge Riiskjær dækker *logik*-begrebet over en samlet opfattelse af, hvordan en aktør forstår sin egen mission i en afgrænset del af verdenen (ibid.). En logik kan forstås som praksisformer, grundværdier, teknologier og ting der tages for givne, som sammen danner et større videns og kulturelt system (ibid.). I denne opgave har vi valgt ikke at bruge plejefprofessionslogikken, da ingen af vores informanter praktiserer denne.

5.2.1 Offentlig styringslogik

De centrale elementer inden for den offentlige styringslogik er ord som lighed, samfundsnytte, demokrati, rationel planlægning og regeloverholdelse (Riiskjær, 2014: 23). Logikken fokuserer på værdifordelingen i samfundet og bygger på en idé om, at demokratisk proces bedst fordrer neutrale og rationelle beslutninger der tilgodeser samfundets interesser (ibid.). Logikken er kendetegnet ved, at den har fokus på mange hensyn og interesser på samme tid, og ser et kompromis mellem disse som en succesfuld løsning (ibid.).

5.2.2 Markedslogik

Grundstenene i markedslogikken er, at alting altid kan gøres enklere, og at det frie marked er den bedste løsning til at maksimere samfundsværdi og velfærd (Riiskjær, 2014: 23).

Logikken tror på at den bedste metode til at maksimere effektivitet er at splitte

arbejdsopgaver op sådan, at de klart kan beskrives og måles (ibid.). Udover dette ønskes en klar rollefordeling, så man altid ved hvem, der har ansvaret for hvad. Konkurrence ses som dynamikken, der skal sikre, at de mest omkostningseffektive praksisser vinder frem (ibid.). Politik ses som et nødvendigt onde, og logikken tror på, at tekniske og økonomiske overvejelser bør prioriteres over alt andet (ibid.: 24).

5.2.3 Lægeprofessionslogik

Lægeprofessionslogikken har grundlæggende to hensyn, der prioriteres over alt andet; at sikre den bedste behandling til den enkelte patient og at sikre faglig udvikling for den samlede profession (Riiskjær, 2014: 24). Logikken kan ses som et institutionelt værdisystem, der udover på hospitalerne lige så tydeligt kommer til udtryk i forskerverdenen, i medicinalindustrien, i videnskabelige tidsskrifter og via sundhedsorganisationer (ibid.). Det er herfra, at de medicinske idéer opstår og realiseres under det pres, der kommer fra de andre logikker (ibid.). Logikken ser lægen som patientens advokat og der er et stort fokus på tillid: Patienten skal have tillid til, at lægen gør alt hvad de kan, for at give den bedste behandling, uden at skulle tage hensyn til andet end patientens bedste (ibid.).

5.2.4 Samspillet mellem logikkerne

Logikkerne er i konkurrence lokalt såvel som på samfundsniveau (Riiskjær, 2014: 24). Vi vil fremhæve et par eksempler på hvor disse logikker kommer i konflikt, og hvor de danner alliancer. Et tydeligt eksempel på hvor logikkerne kommer i ontologisk konflikt er når det kommer til bevilling af ressourcer til behandlingsforløb. Der kan opstå konflikt mellem lægeprofessionslogikken og den offentlige styringslogik, når det kommer til ressourcebevillinger (ibid.: 25): lægen har aflagt et løfte om at give den bedst mulige behandling til den enkelte patient uden at tage andre hensyn som eksempelvis økonomi. Dette står i kontrast til den offentlige styringslogik, som skal prioritere midler på tværs af samfundet og kan komme i problemer i andre sektorer, hvis sundhedssektoren går over budget i jagten på de bedst mulige behandlinger. Også markedslogikken kan komme i konflikt med lægelogikken, når der eksempelvis kommer ikke sundhedsfagligtuddannede managers på hospitalerne (ibid.: 24). Den offentlige styringslogik og markedslogikken ses sammen som lægeprofessionens værste fjende (ibid.). Riiskjær understreger, at logikkerne ikke skal forstås som absolutte, men at individer oftest vil rumme elementer fra mere end blot én logik (ibid.: 26).

5.3 Mol og Riiskjær: Et teoretisk rammeværk

Gennem analysen forsøger vi, vha. Mols praxiografi (se afsnit 5.1), at undersøge hvordan AI bliver praktiseret af de forskellige aktører og dermed at kortlægge disse sameksisterende, men forskellige, sociomaterielle praksisser med AI i centrum. I første del af analysen fokuserer vi på det praxiografiske kortlægningsarbejde, idet vi forsøger at definere de forskellige aktørers *AI-ontologier*. Formålet med denne praxiografiske analyse er at undersøge, om vi kan blive klogere på, hvorfor der (ifølge RAIT) eksisterer en række forskellige forståelser af AI og potentielt at åbne døren på klem til et løsningsforslag. Tanken er, at vi vil have lettere ved at præcisere hvorfor, og hvor, kommunikationen glipper, hvis vi kan identificere, hvordan de forskellige aktører praktiserer AI. Som en fordybelse af vores praxiografiske analyse, vil vi i anden del af analysen forsøge at supplere det praxiografiske kortlægningsarbejde med idéen om *logikker*, som beskrevet i forrige afsnit (5.2). En logik bliver af Riiskjær (2014: 22) beskrevet som følger:

En logik er båret af enkeltindivider, som producerer og reproducerer deres verdensbillede via deres handlinger, deres redskaber og anvendte teknologier.

Vores analytiske tanke bag denne teoretiske supplerings er, at de forskellige logikker er en slags præ-definerede ontologier og at vi dermed kan underbygge vores eget praxiografiske kortlægningsarbejde med en anden etableret teori – en slags teoretisk triangulering. Da en logik (med udgangspunkt i ovenstående definition) er en form for sociomateriel praksis, begår vi ikke nogen videnskabsteoretiske forbrydelser: praxiografi og logikker synes både ontologisk, epistemologisk og metodologisk compatible.

Det er vigtigt for os at understrege at denne supplerings *ikke* er en ny, selvstændig analyse, men at den skal ses i direkte forlængelse af vores praxiografiske kortlægningsarbejde og dermed er del af samme analyse. Formålet er simpelt: Ved at kategorisere vores eget praxiografiske kortlægningsarbejde efter præ-definerede logikker, vil vi nuancere vores analyse og forhåbentligt give den mere teoretisk tyngde.

6 En praxiografisk analyse

6.1 Introduktion

En praxiografisk undersøgelse kan være med til at kortlægge og opspore, hvordan et fænomen eksisterer og virkeliggøres på forskellige måder af en række sameksisterende aktører (Elmholdt & Ratner: 2021: 40). Vores praxiografiske undersøgelse er dermed et analytisk forsøg på at identificere hvordan og – ikke mindst – hvorfor AI forstås forskelligt af de forskellige aktører. Den praxiografiske ontologi og epistemologi nødvendiggør imidlertid, at vi forholder os en anelse mere radikalt til disse 'forståelser', fordi der i dens videnskabsteoretiske fundament ligger en antagelse om, at verden ikke er entydig eller singular (ibid.). I stedet bygger den på en idé om, at viden om *virkeligheden* og *virkeligheden* opstår i en række sameksisterende sociomaterielle praksisser (Ratner: 2021: 141). Udover at identificere de forskellige forståelser for AI, har vi en analytisk interesse i at udfordre en entydig AI-forståelse, fordi vi mener at denne singulære 'AI-ontologi' både er teoretisk ukorrekt og filosofisk uholdbar.

Vores analytiske opgave er at vise læseren, at AI ikke blot er et entydigt fænomen, der bliver fortolket forskelligt, men at AI netop *er* noget forskelligt alt efter, hvordan det praktiseres af den konkrete aktør. Dermed er det også vigtigt at understrege, at vi, når vi skriver *AI*, egentlig refererer til billeddiagnostisk AI, fordi denne type AI er mest relevant i en radiologisk sammenhæng. Kun i ét af de syv interviews (Niels Kvorning) er der tale om andet end billeddiagnostisk AI. Denne forudsætning er vigtig at have *in mente*, da vores praxiografiske analyse ellers kan komme til at virke ualmindeligt selvsigende og åbenlys. Analysen tager udgangspunkt i vores syv interviews, der hver især vil blive analyseret med henblik på at kortlægge, hvordan den interviewede aktør beskriver sin praksis af AI. Efter den praxiografiske kortlægning vil vi placere hver aktør under den af Riiskjærs logikker, vi finder relevant. Dette gøres for at give et rammeværk for videre analytisk sammenligning af aktørerne.

6.2 RAIT

RAIT, Radiologisk AI Testcenter, er et tværfagligt forskningssamarbejde mellem Herlev, Gentofte, Bispebjerg og Frederiksberg Hospital (RAIT, 2024b). Projektet går ud på at etablere et solidt videns- og kompetencegrundlag ift. at sikre en gennemtænkt udvikling,

validering og implementering af AI-systemer til radiologien i Region Hovedstaden (ibid.). De er dermed situeret i et forskningsorienteret miljø, hvilket har stor indflydelse på, hvordan de praktiserer – og dermed forstår – AI. For at forstå deres AI-ontologi, kan det være behjælpeligt at overveje deres epistemologiske grundposition: Hvordan opnår de og indsamler de den viden, projektet er sat i verden for at strukturere?

RAIT opnår viden om AI ved at forske i det, og denne forskning manifesterer sig typisk som ph.d.-projekter. De praktiserer dermed AI som et felt, der forskes i. RAITs projekt handler ikke alene om at implementere AI i radiologien, men om at gøre det uden at skade en eneste patient i processen. Dette forsigtighedsprincip stemmer fint overens med ovenfor beskrevne epistemologi, fordi det uddyber, hvorfor grundig forskning er nødvendig før implementering af noget så komplekst som AI. Et af RAITs centrale anliggender, og et af de spørgsmål, de forsøger at besvare gennem deres forskning, handler om holistisk værdiskabelse: Hvordan sikrer de, at AI rent faktisk skaber værdi?

Svaret på ovenstående spørgsmål kan RAIT, qua deres epistemologiske position, kun tilnærme sig gennem (deres) forskning. De praktiserer dermed AI som noget komplekst, der ikke uden grundigt forarbejde lader sig integrere i det eksisterende sundhedssystem. En sidste pointe cementerer deres forsigtige, forsknings-orienterede AI-praksis: RAIT nævner flere gange vigtigheden af at udvikle et monitoreringssystem sideløbende med, at AI implementeres i sundhedsvæsenet. Formålet er kontinuerligt at sikre patientsikkerhed og værdiskabelse på hospitaler, hvor AI implementeres. Ovenstående analyse tegner et billede af RAIT som en aktør, der praktiserer AI i en forskningsmæssig kontekst. Denne pointe er måske ikke så overraskende, da RAIT er en forskningsenhed, men ved at udfolde ovenstående praksis, kan vi bedre identificere og ekspliciterer RAITs forståelse af AI: De forstår AI i lyset af deres egen forskningspraksis, hvori AI praktiseres som et komplekst forskningsobjekt, der først skal belyses grundigt før det (måske) skal implementeres.

Vi mener, at RAIT – som forskningsenhed – praktiserer AI ud fra en lægeprofessionslogik med elementer fra den offentlige styringslogik. Lad os først argumentere for hvorfor vi mener, at RAIT primært ligger i lægeprofessionslogikken. Hvis vi kigger på de to grundhensyn som logikken bygger på, er de at sikre den enkelte patients bedst mulige behandling samt udvikling for den samlede lægeprofession. Disse to hensyn ses tydeligt i RAITs arbejde: Først og fremmest er de et testcenter, der forsker i, hvordan AI bedst kan

skabe værdi inden for radiologi – altså prøver de at fremme lægeprofessionen. Dette i sig selv behøver ikke være for patientens skyld, og isoleret set kunne de have gjort dette med en markedslogik og økonomisk gevinst som den primære drivkraft. Det er først, når vi undersøger RAITs motivation, at vi med sikkerhed kan sige, at de befinder sig i lægeprofessionslogikken. Ved vores opstartsmøde med RAIT fortalte vores kontaktperson, at det vigtigste for dem var, at implementeringen af AI ikke kompromitterer patientsikkerheden og stiller patienten dårligere, end hvis de havde været AI foruden. Her ses det tydeligt, at RAITs fokus ligger på patienten før noget andet. Der hvor de får elementer fra den offentlige styringslogik, er når det kommer til holistisk værdiskabelse. RAIT ved godt, at der er stor ressourcemangel i det danske sundhedsvæsen, så hvis vi skal implementere ny teknologi – hvilket koster penge – skal det også spare penge et andet sted: Det er altså ikke nok, hvis AI'en udelukkende fremmer diagnosekvaliteten; hvis ikke den kan tjene sig selv ind, har sygehusene ikke råd til den. RAIT bliver altså nødt til at gå på kompromis med deres patientfokuserede logik, hvis de vil have politisk mandat.

6.3 Niels – MelaTech

Niels Kvorning Ternov er postdoc ved Herlev og Gentofte Hospital, hvor han leder forskningsprojektet AISC om AI-augmenteret feedback og træning i diagnosticering af hudkræft (LinkedIn, 2024). Han er også CEO og medstifter af MelaTech ApS, som er et spinoff fra hans forskningsprojekt (ibid.). Niels er situeret med det ene ben i AI-forskning og det andet i udviklingen af et kommercielt AI-produkt og praktiserer derfor både AI som et forskningsobjekt og som et kommercielt produkt. Disse to overlappende praksisser er definerende for, hvordan Niels virkeliggør, og dermed forstår, AI. Vi har identificeret to overordnede pointer, der illustrerer hvordan Niels praktiserer AI:

Den første handler om, *hvor* det giver mening at implementere AI. Niels fokuserer (i sin forskning og kommercielt) på at skabe værdi med mennesker, ikke med maskiner (bilag 2: 09.40). Hans pointe er, at det ikke giver mening at implementere AI i diagnostisk sammenhæng, men at vi i stedet bør fokusere på AI, der kan løfte lægernes tunge papirarbejdsbyrde.

Så hvorfor udvikle kunstig intelligens, der dybest set går ind og kigger på den proces, der tager et sekund. Altså det tager vitterligt under et sekund at diagnosticere noget. Hvorfor kigge på den proces i stedet for den anden proces, der tager 15 minutter at dokumentere og håndtere osv (bilag 2: 03.15).

Niels' ontologi er derfor centreret omkring, hvad der aktuelt er muligt med AI (og endnu vigtigere: hvad der ikke er muligt). Han forholder sig optimistisk over for AI's diagnostiske potentialer (bilag 2: 11.24), men praktiserer det som noget, der aktuelt skal kunne skabe værdi. Denne ontologi er et produkt af hans forskning og den er især interessant, fordi den forklarer hans kommercielle fokus, hvor AI praktiseres som et uddannelsesmæssigt værktøj såvel som en administrativ platform. Vores anden pointe, som handler om, at det offentlige ikke er et godt miljø for innovation, er med til at kontekstualisere Niels' kommercielle AI-praksis:

Det offentlige er jo ikke lavet til innovation. (...) Hvem skulle så drifte, hvis det virkede? Regionerne, de sagde, prøv at høre, vi er en driftsorganisation, vi er ikke en innovationsenhed (bilag 2: 18.55; 26.11).

Ovenstående citat er med til at forklare, hvorfor Niels både praktiserer AI som et forskningsobjekt og som et kommercielt produkt. Hvis han havde haft muligheden for at innovere i det offentlige, havde en kommercialisering ikke været nødvendig. Han uddyber:

Jeg blev tvunget fra at være forsker til at være iværksætter. Ikke fordi jeg havde lyst til det. Men fordi jeg fik besked på, at der er i dybt set ikke nogen i det offentlige, der betaler den her type udviklingsprojekter. Der skulle noget ekstra i ens kapital, og der skulle være en business case (bilag 2: 13.55).

Hvor Niels' forskningsorienterede AI-praksis informerer hans kommercielle AI-praksis, er sidstnævnte alene situeret i en kommerciel kontekst, fordi de offentlige strukturer ikke tillader tilsvarende innovation. Ovenstående kortlægning af Niels' hybride ontologi er med til at tydeliggøre, og forklare, hans forståelse af AI som noget der både forskes i, men som der også skal være økonomisk incitament til at støtte.

Vi mener, at Niels er ligeligt splittet mellem lægeprofessionslogikken og markedslogikken. Dette baserer vi på, at han på den ene side er lægeuddannet med en position som postdoc på Herlev-Gentofte hospital, og på den anden side driver startuppet *MelaTech*. Niels mener selv, at han er blevet tvunget fra en striks lægeprofessionslogik til (delvist) at adoptere en markedslogik: *det offentlige er jo ikke lavet til innovation* (bilag 2: 18.55). Markedslogikken kommer til syne, når Niels taler om at regionerne skal gøre det lettere for dets ansatte at

innovere og lave iværksætterier (en af grundstenene i markedslogikken). Han mener, at det offentlige skal køres mere som en virksomhed for at sikre effektivitet. Selvom Niels beskriver sig selv som en forsker tvunget ud i det private, ligger hans fokus – qua hans startup – lige så meget på økonomien som på at hjælpe danske patienter.

6.4 Mads – Radiobotics

Mads Jarner Brevadt er COO og medstifter af Radiobotics, der udvikler AI-software til diagnosticering af knoglefraktur i radiologien. Han praktiserer AI gennem sit firma, hvilket implicerer et behov for at skabe omsætning (bilag 3: 01.37). Derfor praktiseres AI som noget, der skal sælges og som et produkt, der eksisterer i konkurrence med lignende AI-produkter på markedet. Den kommercielle ontologi definerer ligeledes, hvordan Mads taler om AI: Hans fokus er især på, hvordan deres produkter er med til at styrke den kliniske effektivitet. AI praktiseres dermed som et kommercielt produkt og hans optimistiske narrativ med fokus på produktets store potentialer forstærker denne praksis. I forlængelse af firmaets kommercielle eksistensberettigelse, praktiserer Mads AI som noget, der skal studeres inden det implementeres.

Vi har jo lavet en række studier (...) Det er ligesom første step man gør for at validere ens AI teknologi. Det er også de her evidens man bruger, når man skal submitte til regulatorisk-godkendelse. Vi skal have CE-mærket i Europa og FDA-godkendelse i USA osv. (bilag 3: 04.15).

Ovenstående pointe kan virke selvsigende, men er vigtig for at nuancere hans forståelse af AI relativt til de andre aktører. Når Mads fortæller, at de (Radiobotics) har lavet deres egne studier, skal det forstås i kontekst af deres kommercielle AI-praksis: Studierne er nødvendige for, at deres produkter kan CE-mærkes og FDA-godkendes; uden disse godkendelser, kan produkterne ikke sælges. Under interviewet fortæller Mads om nogle af de barrierer, der står i vejen for implementeringen af deres produkter. Han lægger især vægt på (1) manglende budgettering ude på hospitalerne, hvilket betyder, at der ikke er sat penge af til at implementere nye teknologier; og (2) at der mangler organisatoriske processer og intern projektledelse til rent faktisk at lave de her implementeringer. Mads' kommercielle AI-praksis kontekstualiserer ovenstående barrierer, og hans forståelse er dermed katalyseret af firmaets eksistensberettigelse. Det sidste aspekt af Mads kommercielle AI-praksis, kommer til udtryk gennem firmaets lobbyarbejde:

Vi er også med i nogle brancheorganisationer, som også prøver at snakke på vores vegne. Blandt andet er vi medlem af Copenhagen Health Tech Hub og Dansk Erhverv - så vi prøver også at være en del af debatten, som prøver at påvirke den. Vores hovedformål politisk er at sige, at I skal lægge budget bag jeres krav - fordi så skal vi nok stå klar med produkterne (bilag 3: 16.00).

Dette lobbyarbejde er en forlængelse af firmaets kommercielle praksis og agerer brobygning mellem den konkrete produktudvikling og den efterfølgende implementering: Hvis der fra politisk hold ikke støttes op omkring en sådan implementering, kan de udvikle nok så gode produkter, men vil aldrig kunne implementere – og dermed sælge – dem. Ovenstående kortlægningsarbejde illustrerer hvordan Mads gennem Radiobotics praktiserer AI som et kommercielt produkt, men også at denne praksis består af en række specifikke agendaer, f.eks. forskningsstudier, identificering af implementeringsmæssige barrierer og politisk lobbyarbejde.

Mads praktiserer AI ud fra en stærk tro på markedslogikken. Han ser hospitaler, og derigennem patienter, som kunder og andre AI-systemer som konkurrenter. Hans virksomhed Radiobotics har 23 ansatte, hvoraf kun én har sundhedsfaglig uddannelse, og resten er ingeniører og af diverse administrative uddannelser. AI praktiseres som et produkt, der skal sælges, og alt hvad Mads foretager sig, i professionelt virke – hvad end det er forskning eller lobbyarbejde – er for at fremme dette mål. Som han selv siger: *Vi er et firma, vi skal have omsætning og salg* (bilag 3: 01.37).

6.5 Jakob – Sygehus Lillebælt

Jakob Møller er cheflæge på røntgenafdelingerne ved Sygehus Lillebælt i Vejle. Sygehus Lillebælt har som et af de eneste hospitaler i Danmark implementeret Radiobotics' AI-model, RBFracture, i deres akutmodtagelse. Systemet tændes først efter kl. 15, når radiologerne er taget hjem. Positionen som cheflæge er en vigtig faktor for, hvordan Jakob praktiserer AI. Da vi spurgte ham ind til, hvilke parametre de vurderede AI-modellens succes på, svarede han:

Det ville være noget med oplevet tilfredshed i klinisk brug, men også genindkaldelser (bilag 4: 10.30).

Især førstnævnte er interessant, fordi det er med til at definere hans AI-praksis som noget, der skal facilitere klinikernes arbejdsgang; fokus ligger på, hvordan hans medarbejdere *oplever*, at modellen påvirker deres arbejde. Denne administrative AI-praksis kommer til syne flere steder i interviewet, f.eks. da han forklarer nogle af de budgetmæssige udfordringer ved at have implementeret RBFracture. Jakob nævner to væsentlige udfordringer: For det første er det sygehusets røntgenafdeling, der finansierer systemet med deres budget, selvom den bliver brugt i akutmodtagelsen, og ikke i radiologisk afdeling. Den anden udfordring er også relateret til budget:

Hvis man skærer det helt skarpt op, så vil man jo så sige, at så skal vi jo fyre en medarbejder for at kunne betale, og så skal vi omlægge nogle lønmidler (...) til at betale nogle firmaer der laver noget AI (bilag 4: 03.47).

Igen taler Jakob om AI fra et administrativt-finansielt perspektiv, hvilket er med til at kontekstualisere hans AI-praksis som et primært administrativt anliggende. Imidlertid er Jakob administrative AI-praksis formet af hans overordnet pragmatiske tilgang til sin administration af det kliniske. Denne pragmatiske tilgang binder hans administrative og kliniske praksisser sammen ved at agere kompas for de administrative beslutninger og sætte kursen for den kliniske succes:

Altså uden at det er perfekt, så kan det være godt nok til den brug, man har (bilag 4: 06.57).

Denne pragmatiske tilgang til implementeringen kommer igen til syne, da Jakob taler om kvaliteten af den konkrete model. Hans pointe er, at den ikke behøver at være bedre end radiologerne, men blot yde tilstrækkelig beslutningsstøtte til den uerfarne læge, der sidder alene på akutmodtagelsen om natten (bilag 4: 01.34). Jakob fortæller os efterfølgende, at de (røntgenafdelingen) lige havde kasseret en AI, der kunne diagnosticere sammenklappede lunger, fordi den ikke ramte en høj nok sensitivitet (bilag 4: 07.40). Dette er en forlængelse af Jakobs, og afdelingens, pragmatiske AI-praksis, hvor AI praktiseres, som noget der skal afprøves, før en potentiel implementering. Ovenstående kortlægning tegner et billede af en AI-praksis centreret omkring det administrative, men guidet af et klinisk behov for tilfredshed. Dette er, qua Jakobs position som cheflæge, ikke så overraskende. Imidlertid

fandt vi hans pragmatiske implementeringsstrategi interessant, fordi den står i stærk kontrast til nogle af de andre aktørers eksistensberettigelser og implementeringsmæssige tilgange.

Jakob praktiserer AI ud fra en offentlig styringslogik med et snært af markedslogikkens mere pragmatiske nuancer. Han er cheflæge og ser AI som et værktøj, der skal aflaste uerfarne læger på akutafdelingen, og sænke ventetiden for patienterne. Han går gerne på kompromis med teknologiens isolerede performance, fordi han stoler på lægernes ekspertise:

Klinikeren skal stadigvæk bruge deres viden, og det er faktisk fordi, at de har en patient foran sig. Så hvis for eksempel, at den påpeger et brud i en knogle, hvor patienten ingen symptomer har, jamen så er det tydeligvis forkert, det den har tolket. Og der har man jo fordelene ved at have patienten foran sig, så går man hen og så trykker man på fingeren eller på benet, og så kan det være, at patienten ikke er øm der, og så ved man, at det her er jo så en falsk positiv case (bilag 4: 04.26).

Jakob ser lægerne som velinformerede, rationelt tænkende individer, der kan træffe de rette beslutninger på baggrund af logisk tænkning.

6.6 Christian – RAIT

Christian Hedeager Krag er ph.d.-studerende ved Herlev og Gentofte Hospital. Han praktiserer dermed – og ikke så overraskende – AI gennem, og *som*, forskning. Denne forskningscentrerede praksis kommer til udtryk i de nedslag Christian laver under vores interview. Det bærende fundament for Christians forskningscentrerede AI-praksis er at finde evidens for, at AI-modellerne reelt skaber klinisk værdi; denne evidens betinges af forskningen:

Så hvis der ikke er studier, der viser, at det går patienterne bedre, hvorfor skal det offentlige sundhedsvæsen så bruge penge på noget, hvis det ikke giver en patientfordel? Så det er jo også lidt en mavepuster for nogle af de firmaer, den besked (bilag 5: 06.11).

AI praktiseres som noget, der skal implementeres, *hvis* der kan findes evidens for, at det giver klinisk værdi. Ovenstående cementerer dermed AI som et forskningsmæssigt anliggende for Christian. Selv da Christian taler om etiske og juridiske udfordringer i forbindelse med et forskningsprojekt, forholder han sig alene til disse ift., hvilke implikationer de kan få for det

konkrete forskningsprojekt. Denne pointe virker måske åbenlys, men eksemplet vidner om, at Christian er dybt situeret i en forskningsmæssig AI-ontologi: Denne praksis definerer, hvordan han forholder sig til – og fortolker – sit fagprofessionelle felt i sin helhed. Under interviewet taler Christian om, at AI i nogle situationer ikke behøver at være 'perfekt', men blot god nok til den konkrete case (bilag 5: 09.37). Denne pointe betinger imidlertid en kontinuerlig monitorering af den konkrete model, fordi det ellers er umuligt at vurdere, om modellen fungerer 'godt nok'. Christian fortæller, at sådanne monitoreringssystemer er essentielle for, at AI kan implementeres og skales over hele landet:

Hvis vi skal tænke på hele landet og at det her skal implementeres, og køre godt i fremtiden, så skal man have en platform eller et værktøj, til at kunne monitorere løbende. Medmindre vi bare vil risikere at satse på, at det virker, men det er også måske lidt overmodet med en ny teknologi (bilag 5: 35.21).

Ovenstående taler igen ind Christians praksis af AI, som noget der skal undersøges, noget der skal forskes i, og noget der skal være evidens for. Et monitoreringssystem er incitament til kontinuerlig forskning, og Christian skriver dermed sig selv, og sine forskningskolleger, ind i den fortsatte implementeringsproces af AI i radiologien. Ovenstående kortlægning tegner et billede af en forskningscenteret AI-praksis, hvor hele det omgivende fagfelt forstås og fortolkes i kontekst af AI.

Christian praktiserer – ligesom RAIT – AI ud fra en lægeprofessionslogik, men hvor RAIT har elementer fra den offentlige styringslogik, praktiserer Christian udelukkende AI ud fra lægeprofessionslogikken. Han fokuserer på forskning for patientens skyld, og ser det vigtigste succeskriterie som øget diagnosesikkerhed – højere kvalitetsbehandling for patienten.

Tid nævnes ofte som en værdi, og den tror jeg ikke så meget selv på. Måske i nogle use cases, men jeg tror mere værdien er i sikkerhed for dem, der er mere grønne i feltet. For eksempel unge læger i akutmodtagelsen, som står på nattevagten (bilag 5: 28.59).

Christian sætter patientens sikkerhed over andre hensyn, og er ikke så fokuseret på, hvorvidt AI'en er arbejdskraftsbesparende eller ej, så længe den giver værdi for patienterne.

6.7 Anders – RAIT

Anders Lenskjold er en del af RAITs forskningsenhed, hvor han som postdoc forsker i radiologi og AI (RAIT, 2024c). Hans AI-praksis skal dermed også forstås i lys af hans forskningsmæssige interesse. Ligesom Christian, praktiserer Anders AI som – og gennem – sin forskning. I vores interview refererer han f.eks. både til en ph.d.-psykolog, til sin egen publikation og til flere forskellige andre studier. Dette fokus er med til at definere Anders' forskningscentrerede ontologi. En interessant nuancering, eller konsekvens, af hans forskning er, at desto mere forskning han laver (bl.a. hans ph.d.) desto mere skeptisk bliver han overfor AI's nuværende potentialer:

Jeg er personligt blevet mere skeptisk efter at have lavet den her PhD med AI (bilag 6: 22.46)

Han spekulerer også I, om den forventningsmæssige diskrepans, der eksisterer mellem teknisk utopi og klinisk realitet, blandt andet skyldes, at der fra firmaernes side bliver presset på med løfter om, at deres AI-systemer vil skabe besparelser i sektoren, selvom der ikke eksisterer evidens for sådanne sammenhænge. Anders forstår AI som noget, der kan facilitere den kliniske arbejdsgang; f.eks. ved at agere virtuel kollega for personalet og, gennem beslutningsstøtte, lette den tunge arbejds- og ansvarsbyrde. Ovenstående kortlægning tegner endnu et billede af en forskningscenteret AI-praksis, hvor AI praktiseres som et nødvendigt forskningsobjekt for en presserende politisk implementeringsagenda af en potentielt umoden teknologi.

Anders praktiserer, ligesom Christian, udelukkende AI på baggrund af en lægeprofessionslogik. Dette er ikke overraskende, eftersom han er uddannet læge og tidligere ph.d.-studerende i RAIT. Anders og Christian er begge enige om, at AI's vigtigste rolle er at skabe værdi for patienterne.

6.8 Bodil – Herlev-Gentofte Hospital

Bodil Ørkild er vicedirektør på Herlev- og Gentofte Hospital og er i denne sammenhæng ansvarlig for 7.000 ansatte og cirka 500.000 patienter om året. Hun er, i kraft af sin kapacitet som vicedirektør, beslutningstager på regions- og nationalt niveau og praktiserer dermed AI

ud fra et primært administrativt perspektiv. Dette bliver især tydeligt, da vi diskuterer hvilke succesparametre, hun vil måle en given AI-model på:

Så min top 1, det er en arbejdskraftbesparende AI-løsning – den køber jeg i morgen og jeg kan godt skaffe midlerne. Men bedre kvalitet køber jeg ikke. Patientusikkerhed køber jeg ikke (bilag 7: 19.22).

Ovenstående vidner om, at Bodil praktiserer AI ud fra et administrativt perspektiv, fordi netop arbejdskraft repræsenterer en væsentlig aktuel problematik i sundhedsvæsenet. Hun praktiserer dermed AI som noget, der potentielt kan have konsekvenser for sundhedsvæsenets organisatoriske struktur. En interessant nuance – eller forlængelse – af hendes administrative AI-praksis, handler om måden hun situerer sig selv i denne praksis på. Hun mener, at medarbejderne skal komme til hende, fordi de efterspørger løsningen på et problem og at netop denne efterspørgsel åbner op for implementeringen af en eventuel AI-løsning:

Ja, men derfor synes jeg heller ikke, at jeg skal overbevise dem. De skal komme til mig og sige, vi har et problem. Kan du ikke hjælpe mig? Så hvis de efterspørger, så er det jo meget nemmere at få noget implementeret. Fordi så er det ikke mig, så er det ikke top down, så er det bottom up (...) Men man kan jo ikke efterspørge noget, man ikke ved, man savner (bilag 7: 14.39).

Den sidste sætning er især interessant, fordi den tilføjer en formidlingsmæssig opgave til Bodils administrative AI-praksis: Det er, som vicedirektør, hendes opgave at de ansatte får den fornødne viden, så de kan forholde sig (kritisk) til de eksisterende AI-løsninger på markedet. En succesfuld formidling betyder, at AI (hvis det implementeres) kan implementeres bottom-up i stedet for top-down. Mens Bodil plæderer for, at en bottom-up kronologi vil facilitere både implementering og skalering, argumenterer hun for, at manglende transparens og frygt kan have modsatte effekt:

Men frygt og manglende transparens er det, der gør, at vi ikke kommer udover stepperne (bilag 7: 16.48).

Udover denne interne organisatoriske formidlingsopgave, har hun også en ekstern politisk formidlingsopgave:

Sophie Løhde har været ude, statsministeren har været ude og alle siger, at AI er løsningen også på sundhedsvæsenets problemer. Og det kan det godt være om rigtig, rigtig, rigtig mange år (bilag 7: 05.32).

Dermed omfatter hendes AI-praksis også en ekstern formidling til politikerne, fordi de politiske rammer betinger, hvad der er muligt at implementere og skalere inden for sundhedsvæsenet. Hun taler flere gange om at den største barriere for en implementering af AI i sundhedsvæsenet er en *organisatorisk umodenhed*. Dermed må Bodil også praktisere AI som noget, der aktuelt er inkompatibelt med den organisatoriske struktur (fordi den er umoden) og som derfor kræver politisk indgriben for at ændre. Derfor består en del af hendes AI-praksis i at påvirke det politiske miljø, således at de organisatoriske rammer skubbes og tillader en implementering af AI (hvor det giver mening). Ovenstående kortlægning tegner et billede af Bodils AI-praksis som et administrativt anliggende. Imidlertid forlænges denne administrative praksis af et formidlingsmæssigt behov, der skal opbløde den organisatoriske struktur og moderere de politiske forventninger.

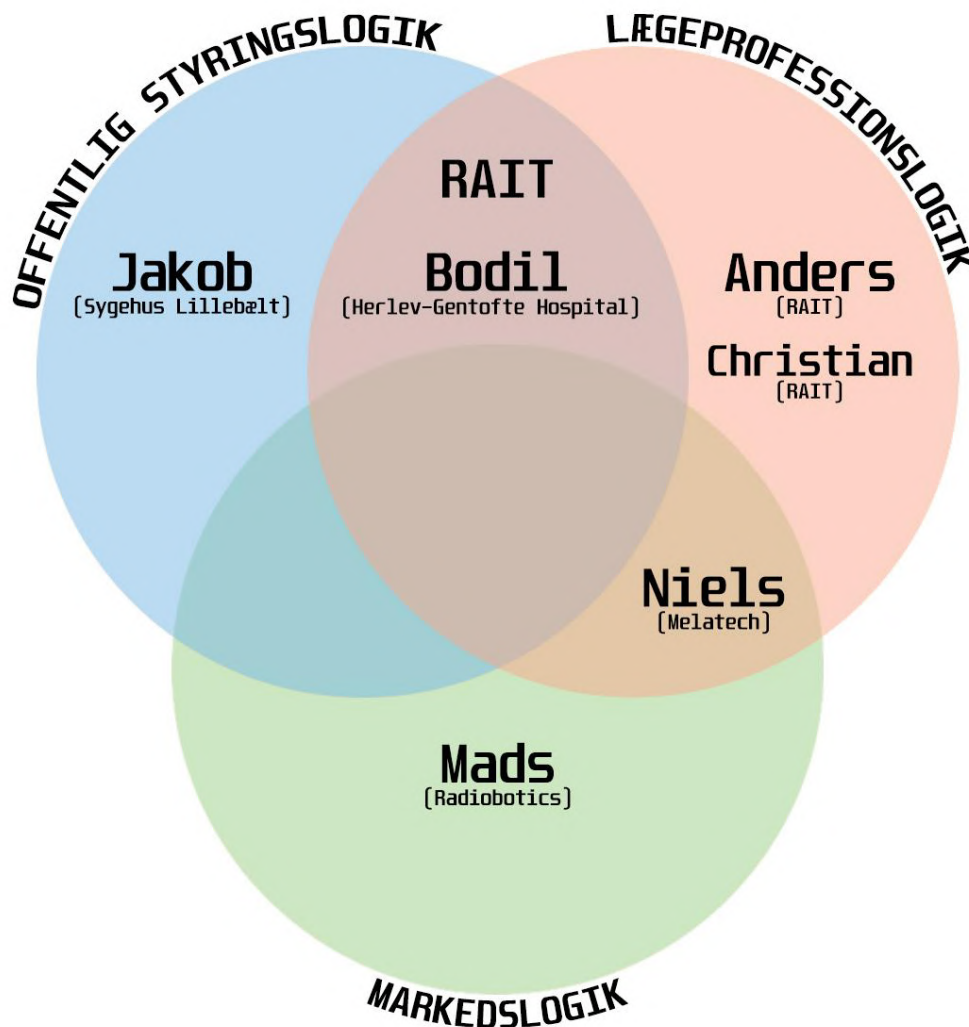
Bodil praktiserer AI i forlængelse af hendes offentlige styringslogik. For hende er AI et værktøj, der skal aflaste visse områder af sundhedsvæsenet for at frigøre midler, der kan bruges andre steder. Logikken bliver tydelig i følgende udtalelse:

Hvis nu vi var (...) en federe arbejdsplads, så var der flere unge, der ville arbejde i hospitalsvæsenet. Men så er der jo ingen til at være politibetjente, eller folkeskolelærer, eller pædagoger, eller whatever it is. Eller IT-udviklere, eller antropologer. Så vi må jo ikke kannibalisere på de unge mennesker. Vi må ikke tage en større andel... (bilag 7: 18.45).

Udtalelsen viser, at Bodil ikke kun er fokuseret på at forbedre hospitalets kvalitet, men faktisk tager hensyn til hele den offentlige sektor i sine beslutninger. Dette er et tydeligt eksempel på, hvordan den offentlige styringslogik og derigennem hensynet til hele den offentlige sektor, kommer til udtryk i hendes beslutningsproces. Bodil er uddannet hjertelæge med mange års erfaring, så elementer fra lægeprofessionslogikken springer uundgåeligt frem i hendes forståelse af AI. Bodil plæderer for en bottom-up-implementering, således at de ansatte kan efterspørge AI-løsninger på konkrete problemer, hvor det giver mening. Logikken søger – som tidligere nævnt – at sikre den bedste behandling til den enkelte patient og at sikre faglig udvikling for den samlede profession, hvilket en bottom-up implementering fordrer.

6.9 Figur over aktørernes praksisser

For at få et samlet overblik over aktørernes forståelser af AI, har vi lavet nedenstående figur for at visualisere, hvor de hver især placerer sig ift. Riiskjærs logikker.



Figur 5: Aktører indsat i Riiskjærs logikker

6.10 Konvergerende ontologier

I dette afsnit vil vi sammenligne de aktører, hvis ontologi har samme dominerende logik. Dette skal forstås som en forlængelse af vores praxiografiske analyse og formålet er, at vi ved at sammenligne de aktører, der minder mest om hinanden, får en bedre forståelse for deres respektive praksisser.

6.10.1 Jakob & Bodil

Eftersom Jakob og Bodil begge har chefstillinger, fordrer dette et bestemt ansvar og praksis. Men det betyder ikke, at de er placeret i samme cirkel på ovenstående figur. Som fastlagt i Bodils ontologi-afsnit (se afsnit 6.8) mener hun ikke, at det aktuelt er muligt at implementere AI i sundhedsvæsenet, som konsekvens af sundhedssystemets organisatoriske umodenhed. Bodils logikker viser sig, idet hun ønsker en *bottom-up*-tilgang til implementeringen, som tidligere nævnt fordrer faglig udvikling (lægefaglig logik) og derudover også understøtter den demokratiske proces (offentlig styringslogik). Jakob har derimod valgt at implementere en AI i troen på, at produktion og effektivitet vil stige. Denne praksis af AI, belyser den måde Jakobs logik læner sig mod markedet, eftersom han prioriterer effektivitet og enkelthed. Som nævnt i afsnit 6.5, anser han genindkaldelser som et grundlæggende succeskriterium. En anden kontrast til Bodil, er Jakobs udfordring med budgetteringen (se bilag 4: 6.06):

Ja, og det er helt oplagt noget, som vi går og bøvler lidt med. Som vi skal have en anden løsning på. Fordi ellers, så kan vi jo bare... om nogle år... lukke røntgen afdelingen, fordi vi har brugt alle vores penge på forskellige AI-systemer.

Hvorimod Bodil fortæller (se bilag 7: 19.22):

Så min top 1, det er arbejdskraftbesparende AI-løsning, den køber jeg i morgen og kan godt skaffe midlerne.

De to ovenstående citater skal være med til at kontekstualisere de to individuelle administrative praksisser og logikker på to forskellige hospitaler. De viser, at selvom både Jakob og Bodil har ledelsesroller, er de fundamentalt forskellige. Qua Bodils position som vicedirektør har hun adgang til flere midler og kan tage flere beslutninger. Dog kommer dette med et større ansvar; både for flere mennesker, men også for flere medarbejdere. Især sidstnævnte er med til at konstituere Bodils ontologi og distancere hende fra Jakobs. Bodil nævner selv, at hun ikke længere er på arbejdsgangen mere, men er derimod blevet en *kontormus* (se bilag 7: 03.18). Man ser specielt Jakob og Bodils praksis og forståelse af AI afvige i deres succesparametre. Her ses Bodil have størst interesse i arbejdskraftbesparelser (se afsnit 6.8), hvorimod Jakob har en direkte interesse i kvalitetssikkerhed og effektivitet, i form af *genindkaldelser*. Derfor positionerer vi Jakob i den offentlige-markedslogik, mens vi placerer Bodil i den offentlige-læge professionslogik.

6.10.2 Mads & Niels

Mads og Niels er begge to højtstillede på deres respektive arbejdspladser. Dog er der forskel i baggrunden for de to ontologier. De er helt fundamentalt forskellige i uddannelse: Mads er uddannet ingeniør, hvorimod Niels er uddannet læge. Dette giver sig til kende i måden, hvorved de to firmaer blev oprettet, og studierne bag. Som nævnt i afsnit 6.4, er Mads' motivation for at lave studier kommercielt betinget, fordi studierne er nødvendige for, at han kan få CE- eller FDA-godkendt sine AI-modeller og dermed for at kunne sælge sit produkt. Sidstnævnte er en forudsætning for at skabe omsætning, hvilket er en virksomheds eksistensberettigelse. For at de kan overleve, bliver de nødt til at sælge, og for at sælge bliver de nødt til at være positive og optimistiske vedrørende hans teknologi – ellers vil ingen investere i deres produkter. Hertil skal det bemærkes at Mads og Niels har interesse i to *vidt* forskellige typer af AI. Niels praktiserer en vejledende AI – denne type behøver ikke CE-godkendelse – og Mads har taget en anden rute med den diagnostiske AI. Dette belyser – og forklarer – Niels' fod i den lægelige lejr, værende hans forståelse af feltet. Han siger i vores interview:

Hvis du går ud til 100 læger og spørger dem: 'Kan du godt lide at diagnosticere?' Så vil 99% af dem sige: 'Ja. De synes, det er mega fedt at diagnosticere.' Det er derfor vi bliver læger (bilag 2: 2.56).

Det er denne forståelse af feltet, som har formet hans praksis, da han erkender, at det ikke er det diagnostiske arbejde, som er et problem for lægerne/radiologerne, men derimod den dokumenterende del. Niels siger:

Så hvorfor udvikle kunstig intelligens, der dybest set går ind og kigger på den proces, der tager et sekund. Altså det tager vitterligt under et sekund at diagnosticere noget. Hvorfor kigge på den proces i stedet for den anden proces, der tager 15 minutter at dokumentere og håndtere osv (bilag 2: 03.15).

Det er blandt andet denne forskel i deres fokus, som adskiller Mads' og Niels' AI-ontologier fra hinanden. Mads' forskning kommer med et incitament til, og krav for, salg. Forskning er nødvendigt for, at han kan få CE-mærket og FDA-godkendt sit produkt, og er dermed nødvendigt for at produktet kan sælges. Niels' kommercielle produkt er derimod et resultat, eller forgrening, af hans forskningsprojekt. Det er derfor, at Niels omtaler sig selv som være blevet: *tvunget fra at være forsker til at være iværksætter* (se bilag 2: 13.55). Denne kronologi

er vigtig, da den belyser den ontologiske forskel, og spørgsmålet om *hvordan* Mads og Niels kom til at praktisere AI på den måde, som de gør. Mads er mere salgsfokuseret, og har en ambition om at diagnostiske modeller skal overtage radiologernes arbejde. Niels praktiserer AI som noget, der skal aktivere lægerne og hjælpe dem med at effektivisere deres arbejde. Ikke ved at gå ind i selve diagnosticeringsprocessen, men ved at mindske det administrative papirarbejde, f.eks. journalføring. Ovenstående pointer taget i betragtning, er den mest markante forskel i, hvordan Mads og Niels praktiserer AI, at Radiobotics forsker i AI for at validere, berettige og dermed sælge deres AI-produkter, hvorimod MelaTech og deres AI-produkter eksisterer som konsekvens af Niels' forskning. De praktiserer dermed AI diametralt.

6.10.3 Niels & RAIT

Niels og RAIT besidder mange af de samme træk i deres logik(ker), og i hvordan de praktiserer AI. Som tidligere beskrevet, er begge aktører forskningsorienterede, fordi de mener, at AI skal testes, før det bliver implementeret i praksis. Begge aktører har en lægelig uddannelsesbaggrund, hvilket er med til at forklare både den ovennævnte forskningspraksis og den lægefaglige logik. Det bliver tydeligt, at deres AI-praksisser og logikker divergerer i vores ontologiafsnit, hvor vi beskriver Niels' ontologi som værende modstridende til den offentlige styringslogik. Her er Niels' torn i øjet hans oplevelse vedrørende innovation i den offentlige sundhedssektor. I modsætning til RAIT – som udelukkende er underlagt den offentlige sektor – har Niels lavet sit eget firma. Selvom de begge ønsker forskning indenfor deres respektive felter, er deres AI-praksis yderligere polariseret, eftersom de praktiserer to forskellige former for AI. I modsætning til RAIT har Niels på nuværende tidspunkt ikke en interesse i implementeringen af *diagnostisk* AI, men fokuserer på AI-augmenteret feedback og træning i diagnosticering af hudkræft.

En stor forskel på Niels og RAIT er interessen for udvikling. RAIT er bundet til det offentlige og har dermed ikke noget økonomisk incitament til at udvikle, hvorimod Niels kun kan udvikle AI, så længe MelaTech er økonomisk bæredygtig. Derudover *udvikler* RAIT ikke nogen AI, hvilket gør deres praksis af AI dominerende forskningsrelateret, i form af validering og lokalisering af værdiskabelse. RAIT kræver kontinuerlig overvågning og testning af AI, for at være sikker på, at en implementering ikke skader patienter. Det skal dog nævnes, at Niels er enig i en patientsikker tilgang, men hvor RAIT ønsker et system, der muliggør dette, har han valgt at udvikle et produkt, der undgår kravet om kontinuerlig

overvågning. Hans praksis af AI fralægger sig al direkte involvering med patienterne, eftersom *Dermloop* (MelaTechs AI-løsning) udelukkende bliver brugt som uddannelseshjælp til lægefaglige. Som nævnt i afsnit 6.3, er Niels' holdning, at værdi bliver skabt med mennesker, og *ikke* maskiner. Ovenstående belyser Niels og RAIT's AI-praksisser som modstridende, da Niels fokuserer på den administrative og uddannelses-fokuserede værdiskabelse, hvorimod RAIT's fokus ligger i den diagnostiske værdiskabelse.

6.11 Divergerende ontologier

I dette afsnit vil vi sammenligne de aktører som ontologisk ligger længst fra hinanden, i forsøget på at finde/udpege ligheder og forskelle mellem dem. RAIT, Christian og Anders er i nedenstående afsnit slået sammen til RAIT, da de alle er, eller har været, en del af RAIT. Dette tillader os at nuancere analysen med citater og forståelser fra alle tre aktører. Ligesom forrige afsnit, er dette en forlængelse af vores praxiografiske analyse og formålet er, at vi ved at sammenligne de aktører, der divergerer mest fra hinanden, får en bedre forståelse for årsagen til deres ligheder og forskelle.

6.11.1 Jakob & RAIT

Som beskrevet i afsnit 6.5 ligger Jakob primært i den offentlige styringslogik med elementer fra markedslogikken; omvendt ligger RAIT primært i lægeprofessionslogikken med elementer fra den offentlige styringslogik. Forskellene mellem aktørerne bliver tydelige, når vi sammenligner deres ontologier: Jakob har med sin pragmatiske implementeringsstrategi købt og implementeret Radiobotics' RBFracture-model i akutmodtagelsen, efter blot at have testet det på et enkelt datasæt; og uden at have et kontinuerligt monitoreringssystem på plads. Dette går diametralt imod, hvordan RAIT praktiserer AI: For RAIT er AI et kompliceret forskningsobjekt, der skal undersøges grundigt før en eventuel implementering. Her ses, hvordan disse to aktører – grundet deres ontologiske forskelle – handler forskelligt ift., hvordan AI smartest implementeres og valideres: Jakob implementerer AI-modellen i praksis på baggrund af udviklerens postulater samt en enkelt test på et lokalt datasæt. Hvis modellen performer tilfredsstillende på datasættet, bliver den implementeret i klinisk brug og bliver en del af arbejdspraksissen. Da vi under vores interview spurgte ind til, hvorvidt Jakob løbende har nogen til at monitorere AI-modellens præcisionsrate, svarede han:

Så langt... Ja, så langt er vi ikke kommet med det endnu (bilag 4: 09.03).

Dette kolliderer med RAITs forståelse for, hvad der er nødvendigt for at implementere AI-systemer i radiologien: I vores opstartsinterview med RAIT fortalte vores kontaktperson, at hvis nogen kunne få billeddiagnostisk AI til at fungere uden først grundigt at have testet den på lokale data og løbende systematisk at monitorere dens præcision, så ville det være rent held. Jakob validerer AI'ens værdiskabelse ved at forholde sig til klinikernes oplevede tilfredshed. Der er fordele og ulemper ved begge tilgange: I Jakobs pragmatiske tilgang, bliver AI-systemet ikke testet og monitoreret systematisk, hvilket RAIT kræver det, men til gengæld kræver det ikke samme mængde ressourcer at implementere. Dertil er Jakobs metode både teknologisk og juridisk mulig i dag, hvilket RAITs ikke er; de kræver en grundig test og validering af modellen på lokale data, som skal skabe evidens for den kliniske værdiskabelse. Dette skal sikre, at den lokale præcisionsrate stemmer overens med den rate som udbyderen har lovet, men er kompliceret af de juridiske rammer som Sundhedsloven og GDPR sætter for de lokale patientdata. Efterfølgende vil man skulle opsætte et løbende monitoreringssystem, hvor radiologer skal bruge noget af deres tid på at dobbelttjekke systemets bedømmelser. Christian (Ph.d-studerende i RAIT) beskriver et muligt forslag til, hvordan dette kunne fungere:

Blandt andet kunne man have et setup, hvor nogle af lægerne sidder som en del af deres kliniske arbejde og annoterer billeder. F.eks. inde i CLIC-plattformen... Så går man ind i CLIC og måske lige kigger på et par AI-svar og siger, om de var rigtige eller forkerte, og så går de tilbage til deres kliniske arbejde. Det kunne være en løsning. (bilag 5: 20.36)

Tanken bag denne løsning er, at scanninger diagnosticeret af uerfarne læger – med hjælp fra en AI – bliver dobbelttjekket af erfarne radiologer, hvilket skal sikre, at der ikke sker fejl-diagnosticeringer. Fordelen ved denne form for løbende monitorering er, at man systematisk sikrer AI'ens præcisionsrate, hvilket ifølge RAIT er absolut nødvendigt for ansvarlig implementering. Ulemperne er, at denne proces – i dag – tager lang tid og er omkostningstung. Formålet med CLIC-systemet (hvis det bliver færdigudviklet og nationalt udbredt) er at sænke den tids- og pengemæssige investering i prævalideringen. RAIT har endnu ikke fundet en løsning på, hvordan de effektivt kan monitorere en AI's præcisionsrate. Den tydelige forskel mellem, hvordan Jakob og RAIT praktiserer AI, ses dermed i deres tilgang til validering og implementering.

6.11.2 Bodil & Mads

Bodil er hospitalsvicedirektør og praktiserer AI som et administrativt værktøj, der skal spare tid for radiologerne eller patienterne. Mads er COO i Radiobotics, som udvikler AI-løsninger, og praktiserer AI som et produkt, der skal sælges. Sammenligningen af disse praksisser tydeliggør, hvorfor de ligger i hver deres ende af figur 5. De forholder sig forskelligt til, hvor barrieren for implementering af AI i sundhedsvæsenet ligger. Når vi spørger Mads, er det mangel på budget og standardiseret procedure på politisk niveau, der er problemet:

Vores hovedformål politisk er at sige, at I [politikkerne] skal lægge budget bag jeres krav - fordi så skal vi nok stå klar med produkterne (bilag 3: 16.00).

Bodils forståelse er imidlertid anderledes:

Så min top 1, det er arbejdskraftbesparende AI-løsning, den køber jeg i morgen og kan godt skaffe midlerne. (bilag 7: 19.22)

Ifølge Bodil kan hun – i sin lokale kontekst – godt finde budgettet til AI-systemerne.

Problemet er imidlertid, at værdiskabelsen ved en implementering ikke altid er stor nok:

Jeg kan ikke bruge, at jeg kan spare per radiologitid, at han kan bruge 3 minutter mindre per røntgenbillede. For det er 3 minutter, jeg ikke kan bruge til noget. Det er det samme som at gå hen og hente kaffe og komme tilbage igen. Altså det kan jeg ikke bruge. Så kan man sige, det er jo det leverandører gør, så siger de, nå ja, men 5 minutter per læge, og du har 1500 læger. [...] Det er jo mange timer. Ja, men jeg kan ikke summere det sammen til de 1500, Så giver det ikke mening, det der med tid. Men hvis jeg kan spare 5 mand en dag, så kan jeg bruge det (bilag 7: 20.00).

Bodil fremhæver, at på trods af, at AI'en kan effektivisere erfarne radiologers arbejdsgang, så kan de få minutter, som modellen kan spare radiologen, ikke overordnet set bruges til noget produktivt. Pointen er, at selv hvis AI'en kan spare hver radiolog tre minutter i løbet af deres arbejdsdag, medfører dette ikke en overordnet øget værdiskabelse, da tre minutter ikke er nok til at varetage andre opgaver. Her ses det tydeligt, at Bodils fokus med AI ligger på, at det kan spare hænder, der som konsekvens kan varetage andre arbejdsopgaver. Denne forventning til AI, bliver imidlertid svær for udviklerne at opfylde, indtil de får CE-godkendt deres modeller til fuldt autonomt at diagnosticere uden menneskelig involvering.

I forlængelse af ovenstående ses en forskel i, hvordan de måler værdiskabelse; altså hvad deres succeskriterium er for deres respektive AI-praksis. I vores interview med Mads viste han, hvordan deres AI-system – på et hospital i England – havde nedsat deres genindkaldelsesrate. Denne case bruger Radiobotics som eksempel på, hvordan deres model er værdiskabende. Implementeringen førte til, at færre patienter blev fejlbehandlet, hvilket øgede hospitalets behandlingskvalitet og diagnosesikkerhed. Bodil er uenig i, at AI'ens værdiskabelse ligger i behandlingskvaliteten:

Vi har jo super kvalitet i sundhedsvæsenet (...) bedre kvalitet, den køber jeg ikke inden for AI (...) De udfordringer, vi har i sundhedsvæsenet, det er, at vi har det, der hedder dobbeltdemografisk pres. Det vil sige ingen unge mennesker og for mange gamle. Så vi bliver ældre og ældre, og det er dem, der kommer på sygehuset, men vi har ingen unge til at løfte opgaven. Så hvis de kunne komme med en AI-løsning, der kan være arbejdskraftbesparende, så køber jeg den med det samme (bilag 7: 17.56).

Diskrepansen mellem udviklernes (Radiobotics') og hospitaladministrationens (Bodils) succeskriterier, kan være årsagen til, at de er uenige om, hvorvidt den nuværende begrænsning for AI-implementering ligger hos udviklerne eller hospitalerne. En vigtig nuance at have *in mente* er, at de fremlagte succeskriterier er situeret i to forskellige kontekster; henholdsvis det engelske og det danske sundhedsvæsen.

6.12 Delkonklusion

I ovenstående har vi udarbejdet en praxiografisk analyse, hvor vi har kortlagt de forskellige måder, som vores aktører praktiserer AI på. Derefter har vi kontekstualiseret disse forskellige praksisser i henhold til Riiskjærs (2014) logikker, for at understøtte vores eget praxiografiske kortlægningsarbejde med et andet etableret teoretisk rammeværk. Efterfølgende har vi sammenlignet de forskellige aktørers AI-ontologier for at eksplicite *hvordan* disse praksisser divergerer mod, eller konvergerer med, hinanden. Vores praxiografiske kortlægningsarbejde viser ikke alene, *at* AI praktiseres forskelligt, men også *hvordan* denne forskellighed manifesterer sig konkret. En af de opgaver – vi fik stillet af RAIT – var at identificere forskellige forståelser af (billeddiagnostisk) AI. Ovenstående analyse skal ses som vores bud på at identificere disse forståelser. Ved at eksplicite *hvordan* hver aktør *praktiserer* AI, fremfor blot at genfortælle, hvordan de *forstår* AI, håber vi, at de forskellige aktører vil have lettere ved at forstå hinanden. Pointen ved at vise, hvordan noget gøres,

fremfor, hvordan det forstås rent diskursivt, er, at der i den konkrete, materielle praksis ligger en masse nuancer gemt – måske endda for aktørerne selv.

7 Produkter

Følgende afsnit indeholder de produkter, vi, i samarbejde med RAIT, har udarbejdet. Arbejdet resulterede i to produkter: Det ene produkt visualiserer de komplekse indsigter, vi gennem etnografiske interviews har indsamlet fra feltet. Det andet produkt er en syntese af de praksisser, vi gennem vores analytiske arbejde har identificeret. Konceptuelt er idéen med vores første produkt – *Komplekse indsigter* – at øge produktets tilgængelighed, og dermed gøre det lettere for RAIT at dele de komplekse indsigter med div. interessenter. Derfor tog vi en beslutning om at digitalisere vores produkter. Hertil skabte vi en oversigtsplakat, der har til formål at dirigere læseren til de otte forskellige, digitale infografikker, der indeholder feltets komplekse indsigter vedr. billeddiagnostisk AI. Vores andet produkt – *Praksisser* – er en visualisering, som opstiller tre generaliserede forestillinger om hhv. forskerens, beslutningstagernes og udviklerens tankemønstre og incitamentsstrukturer. Idéen er, at når læseren sætter sig ind i, hvordan feltets øvrige aktører tænker og praktiserer AI, så vil visualiseringen facilitere forståelse blandt hverandre. Nedenfor ses begge produkter.

PRAKSISSE

Den lægefaglige forsker prioriterer at sikre den bedste behandling for hver enkelt patient og at fremme faglig udvikling i sundhedssektoren.

Formålet er at levere løsninger baseret på evidens og dybdegående analyse.

Beslutninger tages med omhu for at sikre, at de er baseret på bedst tilgængelig data og forskning.



**DEN LÆGEFAGLIGE
FORSKER**

Beslutningstageren arbejder for at balancere forskellige hensyn og interesser og ser succes som evnen til at opnå kompromiser, der gavner alle parter.

Centrale værdier er lighed, samfundsnytte og rationel planlægning.

Regler og lovgivning er vigtige værktøjer for at sikre en fair og velordnet beslutningsproces.



**DEN ADMINISTRATIVE
BESLUTNINGSTAGER**

Udvikleren er drevet af troen på, at effektivitet og samfundsværdi bedst opnås gennem innovation og konkurrence på et frit marked.

For udvikleren er det vigtigt at forenkle processer og opgaver, så de kan beskrives, måles og optimeres.

Økonomiske og tekniske overvejelser prioriteres højest, og politik anses som nødvendigt, men sekundært.



**KUNSTIG INTELLIGENS
UDVIKLER**

Figur 6: Visualisering af forskellige AI-praksisser

KOMPLEKSE INDSIGTER

**VALIDERING AF
VÆRDISKABELSE**



**MONITORERING AF
PERFORMANCE**



**HOSPITALER ER
FORSKELLIGE**



**UDFORDRINGER I
CE-MÆRKNINGEN**



**FORMIDLING
AF AI**



**JURIDISKE DATA
UDFORDRINGER**



**UFORUDSETE
KONSEKVENSER I**



**UFORUDSETE
KONSEKVENSER II**



SCAN QR-KODERNE

**FOR AT LÆSE DIG KLOGERE PÅ HVORFOR AI I
RADIOLOGIEN ER SVÆR AT IMPLEMENTERE & SKALERE**

Figur 7: QR-kode-oversigt af komplekse indsigter

VALIDERING AF VÆRDISKABELSE

Hvis et hospital indkøber en AI, vides det ikke – på forhånd – om den skaber værdi i den kliniske drift.

Årsagen er blandt andet, at AI-modellen risikerer at lave fejl, hvis modellens træningsdata og hospitalets patientdata divergerer for meget.

Det nødvendiggør, at AI-løsningerne skal testes, før de indkøbes, men på nuværende tidspunkt mangler hospitalerne en digital IT-infrastruktur, hvorfra de selv kan teste og validere modellerne på lokale data.

For at opnå en succesfuld implementering kræves det også, at der afsættes midler til klinisk validering, hvilket der generelt ikke er øremærket midler til.



Figur 8: Validering af værdiskabelse

MONITORERING AF PERFORMANCE

Før AI-modeller kan implementeres er det nødvendigt at opsætte et monitoreringssystem, som overvåger, hvorvidt modellerne opretholder den præcision de blev testet til under indkøb.

Uden et monitoreringssystem vil man ikke kunne opdage, hvorvidt hospitalets patientdata – over tid – divergerer fra modellens træningsdata, hvilket i værste tilfælde kan have konsekvenser for patientsikkerheden.

En sådan IT-infrastruktur skal etableres før vi kan begynde at tænke på national implementering og skalering af AI i radiologien. Det skal desuden afklares, hvem der i fremtiden skal stå med driften af dette.



Figur 9: Monitorering af performance

HOSPITALER ER FORSKELLIGE

Hospitaller er forskellige. Det betyder, at et AI-system på et givent hospital kan have markant værdiskabelse, mens det på andre hospitaler ingen værdiskabelse vil have.

Helt grundlæggende skyldes dette fem overordnede forskelligheder på hospitalerne:

- 1) Sygdomsprævalens**
- 2) Populationssammensætning**
- 3) Forskelle i arbejdsgange**
- 4) Tilgængelige ressourcer**
- 5) Bemandingstider**

Succesfuld implementering af AI på ét hospital er ikke ensbetydende med, at det kan skaleres nationalt. Derfor skal det grundigt valideres, hvorvidt en AI skaber værdi for det enkelte hospital.

Med andre ord...

Der findes ingen 'one size fits all'-løsning.



Figur 10: Hospitaler er forskellige

UDFORDRINGER I CE-MÆRKNINGEN

Overordnet ses tre problematikker vedr. CE-mærkningen.

- 1) Godkendelsesprocessens lange varighed** udgør en risiko for, at den bagvedliggende AI-teknologi kan være **forældet**, når den først kommer på markedet.
- 2) I sundhedssektoren er der generelt en forventning om, at hvis en teknologi er CE-mærket, så bringer den klinisk værdi, men i realiteten er der i CE-mærkningen af AI-systemer ikke et krav om evidens herfor.**
- 3) Nogle AI-modeller er modne nok til at 'stå på egne ben' – altså være autonome, men grundet den strikse CE-mærkning er det ikke muligt. Manglen på autonomi medfører, at en radiolog skal gennemgå enhver beslutning AI'en tager. Som konsekvens er tidsbesparelsen for radiologerne minimal.**



Figur 11: Udfordringer i CE-mærkningen

FORMIDLING AF AI

En succesfuld formidling af hvad begrebet *Artificial Intelligence* omfatter, er **altafgørende for udviklingen og implementeringen af værdiskabende AI-systemer i sundhedssektoren.**

Det kræver dog en stor faglig indsigt at forstå begrebets nuancer og ligeledes teknologiens styrker og begrænsninger.

Dette er yderligere besværliggjort af de mange forskellige forståelser, begrebet *AI* har, hvilket nemt fører til misforståelser og manglende transparens.

Ved at etablere et fælles sprog sikrer man, at de involverede parter kan forholde sig til eksisterende AI-systemer ud fra samme vidensgrundlag og ligeledes efterspørge løsninger på konkrete problemer, hvor det giver mening.



Figur 12: Formidling af AI

JURIDISKE DATA UDFORDRINGER

Når sundhedsteknologier testes og valideres i drift, er det en simpel proces, men når AI-modeller skal have foretaget samme test, kompliceres processen af juridiske foranstaltninger. **Dette skyldes, at de data, modellen skal verificeres med, er patientdata, og falder ind under Sundhedsloven og GDPR.**

I dag kan man derfor juridisk kun vælge at validere modellen som enten et forskningsprojekt eller kvalitetssikringsprojekt – to juridiske rammer, der på hver sin måde komplicerer processen.

I realiteten burde driftstest hverken falde under forskning eller kvalitetssikring, men derimod have tilpassede juridiske rammer, der tillader praktisk test af modellen på patientdata. På samme vis, som man måler, at et røntgenrør udstråler den forventede mængde radioaktivitet i hver scanning, skal man kunne teste en AI-models beslutningsevne på lokale patientdata.



Figur 13: Juridiske dataudfordringer

UFORUDSETE KONSEKVENSER

GRADVIS IMPLEMENTERING & AUTOMATISERINGSBIAS

Ved at implementere en AI, hvis formål er at overtage en arbejdsopgave, er der over tid risiko for, at personalet ikke længere selv er i stand til at udføre opgaven. Hvis AI-systemet bryder sammen, kan opgaven ikke længere varetages.

Vi må derfor være sikre i de løsninger, vi implementerer, og sørge for gradvist at introducere AI parallelt med arbejdsgangen.

En forgrening af dette kaldes for *automatiseringsbias*. Flere studier viser, at **selvom en radiolog er uenig med AI'ens beslutning, så vil de betvivle deres egen dømmekraft og stole mere på modellen end på sig selv.**



Figur 14: Uforudsete konsekvenser – Gradvis implementering & automatiseringsbias

UFORUDSETE KONSEKVENSER

ARBEJDSBELASTNING & FRASORTERING AF RASKE

AI-modeller udvikles generelt med fokus på at løse de simple opgaver. Dette efterlader radiologen med de mere komplekse og udmattende udfordringer.

Denne manglende variation mellem simple og komplekse arbejdsopgaver kan medføre en øget grad af overbelastning, i et felt allerede præget af udbrændthed.

Simple scanningsresultater, hvor patienter tydeligvis er raske, er uproblematisk for en AI-model at frasortere. Dette resulterer i en tidsbesparelse for radiologen.

På kort sigt forbedres effektiviteten, men ved ikke at blive eksponeret for scanninger af raske patienter risikerer radiologen, på lang sigt, at miste sit referencpunkt. Hvis man ikke ved, hvordan en rask patient ser ud, hvordan ved man så, hvordan en syg patient ser ud?



Figur 15: Uforudsete konsekvenser – Arbejdsbelastning & frasortering af raske

8 Diskussion

8.1 Vi var de første til opgaven

Da vi fik opgaven af RAIT, var vi på bar bund. Vi vidste ikke, hvad vi skulle, hvad den (efter vores mening) kryptiske opgaveformulering betød og hvad opgaven handlede om. Vi ønskede ikke at fremstå inkompetente til vores opstartsmøde og begyndte derfor at læse op på de mange facetter og problematikker vedrørende AI. Efter mødet stod det klart, at det ikke primært var vores tekniske viden, som var essentielt for at løse opgaven, men i stedet vores evne til at indsamle viden fra forskellige aktører, således at vi kunne belyse de komplekse indsigter. Under mødet blev vi gjort opmærksom på, at vi ville være de første, men ikke de sidste til denne opgave.

Som de første til opgaven, fik vi mulighed for at dykke ned i en specifik del af AI-problematikken, uden nødvendigvis at skulle finde en decideret *løsning*. Omvendt betød det, at vi var de første, som skulle tilgå og forstå problemfeltet, hvilket nødvendiggjorde konstruktionen af et akademisk rammeværk for projektet. Hammersley & Atkinson (1995: 99-100) skriver om rollen som *acceptable incompetent*, og dét at lære felten at kende, ved at se, tale (med) og overvære felten. Denne rolle og proces kan hverken snydes eller tidsoptimeres – hverken ifølge litteraturen eller på baggrund af vores erfaringer fra tidligere projekter. Vi opdagede hurtigt, at det ikke var tid som sundhedssektoren havde mest af, og vores involvering i felten skulle derfor planlægges nøje: Hvis et interview ikke var udbytterigt, var der ikke mulighed for et opfølgende interview. På den ene side fik dette os til at gennemtænke og værdsætte hvert et sekund med informanterne og felten, men på den anden side var det svært at gennemtænke eller planlægge noget, når vores problemfelt fordrede en primært induktiv tilgang.

Dermed er det interessant at diskutere vores 'fejl' som vigtige erfaringer, der dels har hjulpet os med at åbne feltet op og dels kan give de næste akademiske aktører et forspring i deres akademiske foretagende, således at de kan fokusere på at være løsningsorienteret frem for først at bruge ressourcer på at åbne feltet.

8.2 Praxiografiske refleksioner

Følgende afsnit er en diskussion af hvordan den praxiografiske undersøgelse kan åbne op for vores – og aktørernes egne – forståelse(r) af feltet. Den skal ses i umiddelbar forlængelse af den praxiografiske analyse; men hvor vi i analysen *bedriver* praxiografi, vil vi i det følgende nedlægge et mere *refleksivt* perspektiv over vores praxiografiske undersøgelse.

Opgaven handler, først og fremmest, om at identificere forståelser, om at indramme feltets kompleksitet og derefter om at formidle disse indsigter på en letforståelig måde til beslutningstagere. Som vi allerede har berørt, kan en 'forståelse' være en diffus og flyvsk størrelse at håndtere. Hvordan identificerer vi en forståelse? Med fare for at vi bevæger os for langt ind i et uoverskueligt, fænomenologisk vildnis, vil en given forståelse altid være bundet op på et subjekts partikulære kontekst og situerethed i verden (jf. Heidegger, 2009). Det er derfor ikke uproblematisk at få adgang til denne 'forståelse'. Hvis vi nægter at kapitulere til den fænomenologiske håbløshed, må vi forsigtigt overveje hvilke metodiske kneb, der kan hjælpe os på vej.

Dog, bliver vi først nødt til kort at diskutere muligheden for et tilsyneladende attraktivt metodisk alternativ: at lade subjektet definere sin egen forståelse af feltet. Med denne metodik kunne vi lade de forskellige aktører skrive deres egen udlægning, og forståelse, af feltet. Således får vi både direkte adgang til et ellers hermetisk lukket subjekt og sparer tid, fordi vi slipper for en masse bøvl i feltarbejde. Imidlertid udfordres denne tilsyneladende attraktive – og, for os, enormt tidsbesparende – metodik både af én meget konkret og to teoretiske pointer: For det første er metodikken urealistisk, fordi alle aktørerne har en presset kalender og derfor et meget snævert tidsmæssigt råderum.

Dernæst – og det er her de teoretiske pointer kommer ind i billedet – kan det være svært at sætte ord på sin virkelighed, fordi denne virkelighed udgør ens daglige tilværelse og dermed er meget selvfølgelig for det pågældende individ. Baarts (2010: 37-43) beskriver f.eks. hvordan viden kan være *tavs*, dvs. svær eller umulig at artikulere, fordi denne viden ikke på forhånd er italesat og dermed ikke eksplicit – end ikke for subjektet, der besidder denne viden. En beslægtet pointe fra litteraturen, er Spradleys (2016: 55-56) idé om *eksplicit opmærksomhed*, der handler om, at antropologen i felten må fokusere på dagligdagens subtiliteter, fordi disse ofte underbevidst ignoreres for at undgå en overflod af indtryk. Men

hvilke implikationer har ovenstående metodiske refleksioner for vores praxiografiske analysestrategi? Med Baarts idé om *tavs* viden og Spradleys opfordring til at fokusere på det subtile, kan vores praxiografiske kortlægningsarbejde være med til at ekspliciterer aktørernes position i feltet. Dermed giver vi dem mulighed for at forholde sig til deres egen AI-praksis fra et meta-perspektiv, fordi vores kortlægning af deres AI-praksis (potentielt) ekspliciterer aspekter af deres hverdag, de normalt ville tage for givet eller slet ikke lægge mærke til.

Pointen er egentlig ikke så radikal, men handler grundlæggende om, at vi ved at beskrive en given praksis, sætter den enkelte aktør i stand til at reflektere over selvsamme praksis og måske får nye indsigter, der kan være med til at forme deres forståelse af praksissen (Mol, 2002: 155-159). Imidlertid kan vores praxiografiske kortlægning også være til gavn *mellem* aktørerne, fordi de ikke alene får mulighed for at læse om deres egen praksis, men også om, hvordan feltets andre aktører praktiserer AI – dermed kan vores analyse agere formidlende faktor mellem aktørerne. Denne pointe relaterer sig til, hvad der inden for praxiografien kaldes *koordinationsarbejde*, som handler om måden hvorpå de forskellige praktiseringer af et objekt holdes adskilt eller forbindes (Ratner, 2021: 147-148). Koordinationsarbejdet er vigtigt, fordi det tillader aktører fra forskellige ontologier at tale sammen om det praktiserede.

Vi håber, at vores analyse og produkt kan være med til at facilitere et sådant koordinationsarbejde, fordi vi ved at ekspliciterer aktørernes forskellige praksisser tydeliggør, hvor den koordinerende indsats mangler. Med risiko for at fare vild, vil vi afslutningsvist bevæge os tilbage til det fænomenologiske vildnis: I ovenstående afsnit har vi forsøgt at diskutere, at formålet med vores analyse ikke er at *identificere* aktørernes 'forståelser', men at kortlægge hvordan de *praktiserer* AI. Det skyldes blandt andet den fænomenologiske udfordring i at tilgå et subjekts erfaring (forståelse) af verden. Ved i stedet at fokusere på kortlægningen af en aktørs praksis, håber vi at kunne ekspliciterer denne praksis, så både pågældende aktør og andre relevante aktører får mulighed for selv at reflektere over hvordan denne passer ind i feltet som helhed. Dette lægger grunden til deres 'forståelser'.

8.3 Praxiografisk analyse vs. teknisk virkelighed

I det følgende vil vi fremføre et simpelt, men essentielt argument for at understøtte vores analytiske pointer. Læseren, der ikke er sig bekendt med den praxiografiske metode og filosofi, vil måske finde hele foretagendet en anelse selvsigende. Lad os først ekspliciterer

hvorfor den praxiografiske analyse på overfladen kan forekomme selvsigende. For det første virker det åbenlyst, at AI bliver brugt til forskellige formål af forskellige aktører, og for det andet eksisterer der – som vi beskriver i domænet – en masse forskellige typer af AI. Læseren ræsonnerer dermed, at forskellige AI-systemer selvfølgelig bliver brugt til forskellige formål alt efter hvilken agenda en given aktør har. Vores ærinde er udfordre dette ræsonnement, både fordi det er teknisk misvisende og fordi det reducerer den enkelte aktørs praksis ned til *alene* at handle om den konkrete teknologi. Sidstnævnte er fra et teknoantropologisk perspektiv en uholdbar reduktion og strider også mod den praxiografiske filosofi.

Den første præmis vi må etablere, er en præcisering af hvilke AI-systemer vi behandler i analysen: At alle aktører alene forholder sig til billeddiagnostisk mønstergenkendelse, er det, der åbner op for en interessant praxiografisk analyse. Hvis aktørerne imidlertid havde benyttet forskellige typer af AI, ville den praxiografiske filosofi være stærkt udfordret af den tekniske virkelighed. I et sådant tilfælde ville det være åbenlyst, at AI er noget forskelligt for de forskellige aktører, fordi der fra et teknisk perspektiv ville være tale om forskellige systemer. Den anden præmis vi vil introducere, er at udfordre det åbenlyse i, at aktørerne bruger de samme AI-modeller på forskellige måder. Selvom det kan virke åbenlyst at en vicedirektør, en forskningsenhed og en udvikler har forskellige formål med sin AI-praksis, kan den praxiografiske analyse nuancere denne umiddelbare åbenlyshed. Den giver os mulighed for at beskrive *hvordan* disse praksisser divergerer fra hinanden fremfor blot *a priori* at konstatere, at det er tilfældet. Med andre ord kan den praxiografiske analysestrategi være med til at åbne disse praksisser op, så vi bedre kan forstå, hvorfor aktørerne har svært ved at tale med hinanden om deres fælles agenda (AI), fordi denne agenda er situeret i hver aktørs respektive praksis.

Pointen er, at hvad der, på overfladen, synes åbenlyst, kan være analytisk interessant og at nuancerne først kommer til syne, når vi bearbejder det åbenlyst analytisk. Uden vores praxiografiske analyse kunne vi formentlig godt konstatere at de forskellige aktører havde forskellige *forståelser* af AI, men det er netop gennem den praxiografiske kortlægning, at vi viser, at de forskellige forståelser eksisterer som konsekvens af aktørernes forskellige AI-praksisser.

8.4 Metodiske refleksioner

Den praxiografiske analyses interesse for hvordan forskellige objekter eller fænomener *praktiseres* er epistemologisk forankret i solidt etnografisk håndværk. Dermed kan vi med rette diskutere om vores egen analyse lever op til denne standard. En umiddelbar metodisk svaghed ved vores projekt, er netop at vi kun får adgang til felten gennem interviews og dermed alene kan forholde os til, hvad vores informanter *fortæller* at de gør. Det praxiografiske arbejde bliver dermed en anelse mere komplekst, fordi vi på baggrund af interviews må udlede de forskellige aktørers praksisser.

Vi havde foretrukket at supplere vores interviews med deltagende observationsarbejde, fordi vi derigennem kunne nuancere informanternes fortællinger om dem selv med vores egne observationer: *Gør de faktisk det, de siger, at de gør?* Det havde muliggjort en endnu mere dybdegående praxiografisk analyse, fordi der i observationsarbejdet ofte opstår en masse spørgsmål forbundet med den konkrete, materielle praksis, som interviewet ikke i samme grad synliggør.

Imidlertid var vores adgang til felten begrænset af to afgørende faktorer: For det første havde alle vores informanter meget travle arbejdsdage, og det virkede derfor urealistisk at kunne strukturere et velkoordineret observationsstudie uden at kompromittere aktørernes arbejde. Den anden faktor, som er relateret til sidstnævnte kompromittering, er et etisk anliggende: Kan vi retfærdiggøre, hvis vores observationsarbejde kompromitterer den radiologiske arbejdsgang og dermed potentielt får konsekvenser for både personale og patienter? Sidstnævnte er spekulation, for et observationsstudie kan sagtens struktureres på en mindre-invasiv måde, men i den aktuelle sundhedskontekst er det en vigtig overvejelse at have, inden vi hovedløst invaderer et i forvejen-presset sundhedsvæsen.

9 Konklusion

Ved at samle op på vores vigtigste pointer og centrale fund, vil vi i det følgende afsnit besvare undersøgelsens forskningsspørgsmål:

Hvad kan de forskellige aktørers AI-praksisser fortælle os om feltets nuancer og hvordan kan vi bruge viden om disse praksisser til bedre at kommunikere domænets kompleksitet til lægfolk?

En gennemgående og central pointe for at forstå undersøgelsesfeltets nuancer er, at AI ikke refererer til én teknologi, men er et paraplybegreb, der dækker over en række forskellige teknologier, der hver yder forskellige formål (se afsnit 3.1). Det kræver stor faglig indsigt at forstå begrebets nuancer og ligeledes dets styrker og begrænsninger. Dette komplicerer kommunikationen mellem feltets aktører, når de taler om AI, fordi det ikke er en selvfølge, at aktørerne har samme vidensgrundlag eller refererer til samme *type* af AI. Imidlertid viser vores praxiografiske undersøgelse, at kommunikationen kan være kompleks, selv *når* aktørerne taler om den samme type af AI – i undersøgelsens tilfælde billeddiagnostisk AI.

Pointen er, at selv hvis aktørerne deler *diskurs*, har de forskellige *praktiseringer* af AI. Vores praxiografiske kortlægningsarbejde belyser *hvordan* AI praktiseres af de forskellige aktører og at disse praksisser er med til at forme den enkelte aktørs forståelse af feltet. Udfordringen er, at en 'forståelse' er en diffus størrelse, der er fuldstændig bundet op på et subjekts situerede erfaring af verden. Ved at fokusere på, hvordan subjektet praktiserer AI, bliver vi bedre rustet til at *fortolke* subjektets situerede erfaring af verden. Vores kortlægning af de forskellige AI-praksisser tydeliggør, at aktørernes forståelser er bundet op på, og resultatet af, deres respektive måder at praktisere AI på. Vores analytiske arbejde har derfor flere formål: Udover at *vi* får lettere ved at fortolke de forskellige aktørers forståelser af feltet, er håbet, at også feltets aktører får gavn af vores analytiske pointer, fordi de ikke alene får mulighed for at læse om deres egen praksis, men også om, hvordan feltets andre aktører praktiserer AI.

Aktørernes kon- og divergerende AI-praksisser er et vidnesbyrd om feltets kompleksitet og understreger, at en singular forståelse af AI hverken er teoretisk korrekt eller afspejler feltets nuancer, fordi AI netop *er* noget forskelligt alt efter, hvordan det praktiseres af den konkrete aktør. Pointen er, at aktørerne får mulighed for at reflektere over egen praksis og samtidig forholde sig til feltets andre praksisser, hvilket kan facilitere deres interne

koordinationsarbejde og dermed understøtte kommunikation på tværs. For at kommunikere disse pointer, har vi udarbejdet en række infografikker (se afsnit 7), som kan agere grænseobjekt. Idéen er, at infografikkerne skal styrke koordinationsarbejdet mellem aktørernes forskellige måder at praktisere AI på og kommunikere domænets kompleksitet til lægfolk.

Litteratur

- Baarts, C. (2010). Håndværket: Opbygning af viden. In K. Hastrup (Ed.), *Ind i verden: En grundbog i antropologisk metode* (pp. 35-49). Hans Reitzels Forlag.
- Badillo, S., Banfai, B., Birzele, F., Davydov, I. I., Hutchinson, L., Kam-Thong, T., Siebourg-Polster, J., Steiert, B., & Zhang, J. D. (2020). An introduction to machine learning. *Clinical Pharmacology & Therapeutics*, *107*(4), 871-885.
- Bossen, C., & Lauritzen, P. (2021). Symbolsk interaktionisme i STS: Usybligt arbejde, grænseobjekter og grounded theory. In P. Danholdt, & C. Gad (Eds.), *Videnskab, teknologi og samfund: en introduktion til STS. (1. udgave.)* (pp. 61-77). Hans Reitzels Forlag.
- Carlile, P. R. (2002). A pragmatic view of knowledge and boundaries: Boundary objects in new product development. *Organization Science*, *13*(4), 442-455.
- Castellino, R. A. (2005). Computer aided detection (CAD): an overview. *Cancer Imaging*, *5*(1), 17.
- Chockley, K., & Emanuel, E. (2016). The End of Radiology? Three Threats to the Future Practice of Radiology. *Journal of the American College of Radiology*, *13*(12, Part A), 1415-1420. 10.1016/j.jacr.2016.07.010
- Dansk Selskab for Kvalitet i Sundhedssektoren. (2020, Januar). *Kvalitetsudvikling som svar på det pressede sundhedsvæsen*. Danske Patienter. Retrieved 28. maj 2024, <https://danskepatienter.dk/arrangementer/kvalitetsudvikling-som-svar-paa-det-pressede-sundhedsvaesen#:~:text=Sundhedsv%C3%A6senet%20er%20under%20pres.,hoveder%20som%20kroner%20og%20%C3%B8rer>.
- Danske Patienter. (2019). *Brugerperspektiver på kunstig intelligens – hvad ved vi?* (). Danske Patienter. <https://danskepatienter.dk/files/media/document/Brugerperspektiver%20pa%CC%8A%20kunstig%20intelligens%20-%20hvad%20ved%20vi.pdf>
- Danske Regioner. (2015, April). *Pres på sundhedsvæsenet*. Danske Regioner. Retrieved 28. maj 2024, <https://www.regioner.dk/services/publikationer/sundhed/pres-paa-sundhedsvaesenet>
- Det Danske Sprog- og Litteraturselskab. (2023, *lære verbum*. Den Danske Ordbog. Retrieved 22. maj 2024, <https://ordnet.dk/ddo/ordbog?select=l%C3%A6re,2&query=l%C3%A6re>
- Driver, C. N., Bowles, B. S., Bartholmai, B. J., & Greenberg-Worisek, A. J. (2020). Artificial intelligence in radiology: a call for thoughtful application. *Clinical and Translational Science*, *13*(2), 216.
- Elmholt, K. T., & Ratner, H. F. (2021). Følg aktøren!: Translation og praxiografi som analysestrategier. *Aktørnetværksteori: i praksis* (pp. 29-48). Djøf Forlag.
- EU. (2024, marts 7.). *CE Marking*. Retrieved Maj 6, https://europa.eu/youreurope/business/product-requirements/labels-markings/ce-marking/index_en.htm
- EU-Kommissionen. (2023, januar.). *Konsekvenserne af demografiske ændringer i Europa*. EU-Kommissionen. Retrieved 28. maj 2024, https://commission.europa.eu/strategy-and-policy/priorities-2019-2024/new-push-european-democracy/impact-demographic-change-europe_da
- Fieguth, P. (2022). Introduction to Pattern Recognition. *An Introduction to Pattern Recognition and Machine Learning* (1st ed., pp. 5-28). Springer International Publishing. 10.1007/978-3-030-95995-1

- Finansministeriet, & Erhvervsministeriet. (2019). *National strategi for kunstig intelligens*. Regeringen.
https://digst.dk/media/19302/national_strategi_for_kunstig_intelligens_final.pdf
- Gaardhøj, L. (2023, 15. december). *Debat: Kunstig intelligens i sundhedsvæsenet er højt på regionernes liste*. Danske Regioner. Retrieved 28. maj 2024,
<https://www.regioner.dk/services/nyheder/2023/december/kunstig-intelligens-i-sundhedsvaesenet-er-hoejt-paa-regionernes-liste/>
- Google Developer Program. (2022). *Static vs. Dynamic Training | Machine Learning*. Google For Developers. Retrieved 22. maj 2024, <https://developers.google.com/machine-learning/crash-course/static-vs-dynamic-training/video-lecture>
- Hammersley, M., & Atkinson, P. (2019). *Ethnography: Principles in practice*. Routledge.
- Heidegger, M. (2009). The Question Concerning Technology. In C. Hanks (Ed.), *Technology and values: Essential readings* (). John Wiley & Sons.
- Hosny, A., Parmar, C., Quackenbush, J., Schwartz, L. H., & Aerts, H. J. (2018a). Artificial intelligence in radiology. *Nature Reviews Cancer*, 18(8), 500-510.
- Hosny, A., Parmar, C., Quackenbush, J., Schwartz, L. H., & Aerts, H. J. (2018b). Artificial intelligence in radiology. *Nature Reviews Cancer*, 18(8), 500-510.
- Houde, S., & Hill, C. (1997). What do prototypes prototype? *Handbook of human-computer interaction* (pp. 367-381). Elsevier.
- IBM. (2022a, 6 december.). *Artificial Intelligence*. IBM. Retrieved 14. maj 2024,
<https://www.ibm.com/design/ai/basics/ai/>
- IBM. (2022b, 6 december.). *Machine Learning*. IBM Design for AI. Retrieved 14. maj 2024,
<https://www.ibm.com/design/ai/basics/ml/>
- IBM Data and AI Team. (2023, 6 juli.). *AI versus machine learning versus deep learning versus neural networks: What's the difference?* IBM. Retrieved 14. maj 2024,
<https://www.ibm.com/think/topics/ai-vs-machine-learning-vs-deep-learning-vs-neural-networks>
- Jeffcock, P. (2018, 11. juli). *What's the Difference Between AI, Machine Learning, and Deep Learning?* Oracle Big Data Blog. Retrieved 14. maj 2024, <https://blogs.oracle.com/bigdata/post/whatx27s-the-difference-between-ai-machine-learning-and-deep-learning>
- Kunstig Intelligens*. Danske Patienter. Retrieved 14. maj 2024, <https://danskepatienter.dk/politik-presse/politiske-holdninger/kunstig-intelligens>
- Lauritsen, S. M., & Lauritsen, K. M. (2019). Kunstig intelligens i sundhedsvæsenet. *Sundhedsteknologi i praksis* (pp. 69-89). FADL's Forlag.
- Loria, K. (2018). Putting the AI in radiology. *Radiology Today*, 19(1), 10.
- Louise Brown. (2023a). *Hvordan kan AI redde liv #1/2 | Brown og sundheden*
- Louise Brown. (2023b). *Hvordan kan AI redde liv #2/2 | Brown og sundheden*
- Manning, C. (2020). *Artificial Intelligence Definitions*. Stanford University.
<https://hai.stanford.edu/sites/default/files/2020-09/AI-Definitions-HAI.pdf>

- Mason, J. (2002). *Qualitative researching*. Sage.
- Microsoft Learn. (2024, 30. januar). *AI Drift | Microsoft Learn*. Microsoft Learn. Retrieved 22. maj 2024, <https://learn.microsoft.com/en-us/ai/playbook/capabilities/ml-lifecycle-management/drift-and-adaptation/drift-overview>
- Mol, A. (1999). Ontological politics. A word and some questions. *The Sociological Review*, 47(1_suppl), 74-89.
- Mol, A. (2002). *The body multiple: Ontology in medical practice*. Duke University Press.
- Najjar, R. (2023). Redefining radiology: a review of artificial intelligence integration in medical imaging. *Diagnostics*, 13(17), 2760.
- Newman, P. G., & Rozycki, G. S. (1998). THE HISTORY OF ULTRASOUND. *Surgical Clinics of North America*, 78(2), 179-195. 10.1016/S0039-6109(05)70308-X
- Niels Kvorning Ternov. (30 Maj, 30 Maj). *Niels Kvorning Ternov*. Retrieved 20 April, https://www.linkedin.com/in/niels-kvorning-ternov-a47738120/?locale=en_US&trk=public_post_reshare-text
- Oakden-Rayner, L. (2019). The rebirth of CAD: how is modern AI different from the CAD we know? *Radiology: Artificial Intelligence*, 1(3), e180089.
- Obelis Group. (2019, 7. marts.). *Basics of the Medical Device Classification System*. Obelis. Retrieved 6. maj, <https://www.obelis.net/news/basics-of-the-medical-device-classification-system/>
- Pianykh, O. S., Lings, G., Dewey, M., Enzmann, D. R., Herold, C. J., Schoenberg, S. O., & Brink, J. A. (2020). Continuous learning AI in radiology: implementation principles and early applications. *Radiology*, 297(1), 6-14.
- Radiobotics. (2024a, *Radiobotics*. <https://www.radiobotics.com/>. Retrieved april 20, <https://www.radiobotics.com/>
- Radiobotics. (2024b). *Reducing Missed Fractures*. Radiobotics. <https://www.radiobotics.com/products/rbfracture>
- RAIT. (2024a, *About us*. RAIT. <https://www.rait.dk/who-is-rait>
- RAIT. (2024b, *Kan komplekse indsigter gøres til enkelte forståelige budskaber?* Copenhagen Health Innovation. Retrieved 28. maj 2024, <https://copenhagenhealthinnovation.dk/opslag/kan-komplekse-indsigter-goeres-til-enkelte-forstaaelige-budskaber/>
- RAIT. (2024c, *Steering committee*. RAIT. <https://www.rait.dk/organization>
- Rajkomar, A., Dean, J., & Kohane, I. (2019). Machine learning in medicine. *New England Journal of Medicine*, 380(14), 1347-1358.
- Ratner, H. (2021). Ontologi, topologi og multiplicitet i STS. In P. Danholdt, & C. Gad (Eds.), *Videnskab, Teknologi og Samfund. En introduktion til STS* (pp. 141-160). Hans Reitzels Forlag.
- Rhinow, H., Köppen, E., & Meinel, C. (2012). Design prototypes as boundary objects in innovation processes.
- Riiskjær, E. (2014). *Patienten som partner: en nødvendig idé med ringe plads*. Syddansk Universitetsforlag.

- Sanders, E. B. (2002). user-centered to participatory design approaches. *Design and the social sciences* (pp. 18-25). CRC Press.
- Sanders, E. B., & Stappers, P. J. (2008). Co-creation and the new landscapes of design. *Co-Design*, 4(1), 5-18.
- Shaw, J., Rudzicz, F., Jamieson, T., & Goldfarb, A. (2019). Artificial intelligence and the implementation challenge. *Journal of Medical Internet Research*, 21(7), e13659.
- Shen, D., Wu, G., & Suk, H. (2017). Deep learning in medical image analysis. *Annual Review of Biomedical Engineering*, 19, 221-248.
- Speciallæge (job)*. (2024, UddannelsesGuiden. Retrieved 13. maj 2024, <https://www.ug.dk/job/akademiskarbogledelse/laegetandogdyrlaege/speciallaege-kirurg>
- Spradley, J. P. (2016). *Participant observation*. Waveland Press.
- Tanggard, L., & Brinkmann, S. (2020). Interviewet: samtalen som forskningsmetode. In S. Brinkmann, & L. Tanggard (Eds.), *Kvalitative metoder: en grundbog (3. udgave)* (pp. 33-63). Hans Reitzel.
- Thomas Abramovitz Bjerre. (2024a, 20. marts). *CT-skanning*. Sundhed.dk. Retrieved 29. maj 2024, <https://www.sundhed.dk/borger/patienthaandbogen/undersogelser/undersogelser/ct/ct-skanning/>
- Thomas Abramovitz Bjerre. (2024b, 20. marts). *MR-skanninger*. Sundhed.dk. Retrieved 29. maj 2024, <https://www.sundhed.dk/borger/patienthaandbogen/undersogelser/undersogelser/mr/mr-skanninger/>
- Thrall, J. H., Li, X., Li, Q., Cruz, C., Do, S., Dreyer, K., & Brink, J. (2018). Artificial Intelligence and Machine Learning in Radiology: Opportunities, Challenges, Pitfalls, and Criteria for Success. *Journal of the American College of Radiology*, 15(3, Part B), 504-508. 10.1016/j.jacr.2017.12.026
- University of Amsterdam. (2024, *Prof. dr. A. (Annemarie) Mol*. uva.nl. Retrieved Torsdag 16. maj 2024 kl. 14.07, <https://www.uva.nl/en/profile/m/o/a.mol/a.mol.html?cb>
- Wikipedia. (2024a, 29 maj,). *Radiology*. Wikipedia. <https://en.wikipedia.org/wiki/Radiology>
- Wikipedia. (2024b, 29. maj,). *Ultrasound*. Wikipedia. Retrieved 29. maj 2024, <https://en.wikipedia.org/wiki/Ultrasound#Imaging>