

En analyse af low-code og pro-code visualiseringsværktøjer med afsæt i virksomheders datamodenhed.

Abstract


1. Introduktion

Digital transformation er ikke længere forbeholdt store virksomheder med omfattende IT-afdelinger. I Danmark er SMV'er blevet en integreret del af den digitale økonomi. Visualiseringsværktøjer spiller en central rolle i denne transformation, især når det gælder dataanalyse og beslutningsstøtte. Imidlertid er spørgsmålet om, hvorvidt en virksomhed bør benytte low-code eller pro-code teknologier, langt fra entydigt. Ofte vil valget af teknologi udspringe af allerede eksisterende licenser hos leverandører, eller en medarbejders forudgående kendskab til et specifikt værktøj. På den korte bane sikrer dette fart i dét at komme i gang med at visualisere data. På den lange bane, risikerer virksomhederne at stå med en endnu mere kompleks opgave, hvis valget af værktøj ikke understøtter forretningsbehovet. En virksomheds datamodenhed kan indikere, hvor virksomheden skal starte. Dette paper søger at komme med konkrete anbefalinger til valg af teknologi ved at besvare følgende forskningsspørgsmål:

1. Hvordan relaterer forskellige niveauer af datamodenhed sig til valget af low-code og pro-code visualiseringsværktøjer?
2. Hvilke faktorer ved datamodenhed påvirker brugen af disse værktøjer i praksis?
3. Hvad er fordelene og ulemperne ved at vælge low-code vs. pro-code værktøjer i relation til virksomhedens behov og mål?
4. Hvilke faktorer er de mest afgørende i valg af visualiseringsværktøj?

2. Litteraturstudie

Den oprindelige Technology Acceptance Model (TAM) af Davis (1989) identificerede *Perceived Usefulness* (PU) og *Perceived Ease of Use* (PEOU) som de to primære determinanter for teknologiaccept. Altså, villigheden til at tage nye teknologier i brug og bruge dem i praksis. Disse faktorer påvirker brugernes intention om at anvende teknologien og deres faktiske adfærd. Hvis teknologien opleves som nyttig og nem at anvende, øges sandsynligheden for accept markant.



(Worthington, 2021)

Denne grundmodel genfindes i nyere studier. Pradeep et al. (2024) viste, at manglende træning og underudnyttelse af BI-værktøjer i sundhedssektoren hæmmede realiseringen af teknologiens nytte, selvom brugen var høj. Det fremgik, at brugerne kun anvendte de mest basale funktioner, hvilket indikerer, at *oplevet brugbarhed (PU)* påvirkes negativt af utilstrækkelig træning og støtte.

Pan et al. (2024) udvidede TAM ved at inddrage tillid og læringsmotivation som vigtige drivkræfter for studerendes brug af AI-kodeassistenter. Her viste det sig, at studerende med høj motivation for at lære havde større tilbøjelighed til at tage teknologien i brug – mens bekymringer om afhængighed og tab af dømmekraft begrænsede adfærden.

Denne motivation relaterer til PEOU i form af oplevet læringsindsats, hvor teknologier med lav kognitiv barriere har større sandsynlighed for adoption.

Det er i særdeleshed relevant for dette projekt, da Razak et al. (2024) også fandt, at præstationsforventning og brugervenlighed var blandt de vigtigste faktorer bag virksomheders accept af low-code/no-code-platforme – direkte i tråd med Davis' model. Her kobles brugervenlighed til både en lav oplevet læringsindsats og intuitivitet i grænsefladen, samt tilgængelig støtte. Denne støtte kunne være i form af dokumentation, et community eller onboarding-værktøjer. Her spillede også opfattede risici og sociale påvirkninger en rolle, men det var især den oplevede lethed og værdi, der bar adoptionen.

Alexandra Instituttet (2020) peger i samme retning i rapporten "Find vej i din dataindsats", der blev udarbejdet som del af Big Data Business Academy-projektet med støtte fra Industriens Fond. Rapporten bygger på erfaringer fra ca. 20 danske SMV'er på tværs af brancher, som deltog i forløb om datadrevet værdiskabelse. På baggrund af disse virksomheders praksis opstillede Alexandra Instituttet en model med fem faser for datamodenhed – fra "Monitorere driften" til "Konstant synkronisering" – der beskriver, hvordan virksomheder gradvist bevæger sig mod mere avanceret dataanvendelse. Modellen tilbyder konkrete anbefalinger til SMV'er. De fremhævede, at teknologi først skaber værdi, når brugervenlighed, organisatorisk forankring og brugerkompetencer er på plads. Særligt i virksomheder på et lavt datamodenhedsniveau er letanvendelige løsninger og intern træning afgørende for at lykkes med analyseværktøjer. Dette står i kontrast til mere datamodne organisationer, hvor behovet for skræddersyede og komplekse løsninger vokser.

Alexandra Instituttets model er valgt som den primære datamodenhedsramme i dette paper, men dette valg bør ses i lyset af det bredere forskningsfelt inden for

datamodenhedsmodeller. Der findes en række etablerede modeller, som hver især anskuer datamodenhed fra forskellige perspektiver.

Inden de enkelte modeller præsenteres, er det relevant at adressere kildernes karakter. Det datamodenhedsfelt, dette paper trækker på, befinder sig i et grænseland mellem peer-reviewed forskning og det, der i forskningsterminologien kaldes "grå litteratur" – altså rapporter, hvidbøger og standarder udgivet af brancheorganisationer, konsulenthuse og forskningsinstitutter uden formel peer review. Begge typer kilder inddrages i denne paper, men med en bevidst skelnen i argumentationen. Alexandra Instituttet er et dansk GTS-institut (Godkendt Teknologisk Service), der udfører anvendt forskning og teknologiudvikling med offentlig medfinansiering. Selvom rapporten "Find vej i din dataindsats" (2020) ikke er peer-reviewed, er den udarbejdet i regi af Big Data Business Academy med støtte fra Industriens Fond og bygger på et systematisk forløb med ca. 20 danske SMV'er. Den karakteriseres dermed som forskningsbaseret praksislitteratur – empirisk forankret, men ikke videnskabeligt valideret efter klassisk standard. CMMI Institute (nu en del af ISACA) er derimod ikke et forskningsinstitut, men en standardsættende organisation, hvis Data Management Maturity Model (2014) er udviklet som et kommercielt vurderingsrammeverk. DMM-modellen anvendes således her som referenceramme, ikke som forskningsbaseret evidens. Tilsvarende er DAMA International (Data Management Association) en professionel medlemsorganisation, og DAMA-DMBOK (2017) et konsensusbaseret referenceværk udarbejdet af praktikere. Som CMMI er DAMA grå litteratur, men inddrages, fordi det udgør den facto-standard for terminologi inden for datamanagement. Den peer-reviewede forskning på området bidrager med komplementær empirisk evidens. Aagaard et al. (2021) har eksempelvis udviklet DMAT-modellen (Digital Maturity Assessment Tool) i en dansk industriel kontekst og demonstreret, hvordan modenhedsvurderinger kan anvendes i konkrete teknologi-interventioner i SMV'er. Aagaards DMAT-model og Alexandra-modellen

deler en grundlæggende fase-tankegang og praksisorientering mod danske SMV'er, men hvor DMAT har sit empiriske afsæt i industrielle IoT-interventioner, hviler Alexandra-modellen på bredere datadrevet værdiskabelse. De to modeller komplementerer dermed hinanden, og Alexandra-modellen anvendes som primær ramme, mens DMAT inddrages som teoretisk validering af, at den faseopdelte tilgang har bredere anvendelighed i en SMV-kontekst,

CMMI Data Management Maturity (DMM) Model, udviklet af CMMI Institute, er en af de mest udbredte modeller i forskningen. Den opererer med fem modenhedsniveauer og vurderer datamodenhed på tværs af dimensioner som datastrategi, datakvalitet, datagovernance og platforme (CMMI Institute, 2014). Modellen er dog primært designet til større organisationer med formaliserede processer og kan derfor være vanskelig at anvende direkte i en SMV-kontekst.


DAMA-DMBOK (Data Management Body of Knowledge) tilbyder en bredere referenceramme med 11 vidensområder, herunder datakvalitet, metadata og dataarkitektur (DAMA International, 2017). Modellen fungerer primært som et referencework snarere end et konkret vurderingsværktøj, hvilket gør den mindre egnet til den praksisnære tilgang, dette paper tilstræber.

EU-Kommissionens Digital Maturity Assessment Tool (DMAT), udviklet af Joint Research Centre, er specifikt rettet mod SMV'er og vurderer digital modenhed på tværs af seks dimensioner: digital forretningsstrategi, digital parathed, menneskecentreret digitalisering, datastyring, automatisering og AI samt grøn digitalisering (European Commission JRC, 2023). DMAT er dog en bredere digitaliseringsmodel, der rækker ud over datamodenhed alene. Det bør bemærkes, at dette EU-værktøj deler navn og akronym med den DMAT, som Aagaard et al. (2021) præsenterer ovenfor; der er tale om to forskellige værktøjer med hvert sit ophav og formål. Aagaards er udviklet i et dansk industrielt IoT-miljø, mens EU-Kommissionens fungerer som ramme for European Digital Innovation Hubs (EDIH'er).

Kronbæk og Haugaard (2025) har i en dansk forskningsmæssig kontekst arbejdet med Kræmmersgaards digitaliseringsmodenhedsmodel i en SMV-sammenhæng og påpeget, at valget af modenhedsmodel bør afspejle den specifikke undersøgelseskontekst, herunder virksomhedstype og forskningsspørgsmålets karakter.


I denne undersøgelse er Alexandra Instituttets model valgt, fordi den er specifikt udviklet til danske SMV'er, opererer med et klart faseopdelt forløb, der kobler direkte til konkrete forretningsbehov, og dermed muliggør en direkte sammenstilling med TAM-begreberne PU og PEOU. Hvor CMMI DMM og DAMA-DMBOK primært adresserer organisatorisk datagovernance, og DMAT favner bredere digitaliseringsaspekter, tilbyder Alexandra-modellen en praksisnær ramme, der fokuserer på, hvordan data faktisk anvendes i virksomhedens beslutningsprocesser – fra simpel rapportering til avanceret automatisering. Denne kobling til anvendelse gør modellen særligt velegnet som analytisk ramme for en TAM-baseret vurdering af visualiseringsværktøjer.

Denne progression i datamodenhed harmonerer med Gartners (Gartner, 2012) beskrivelse af en trinvist udviklingsforløb, hvor organisationer bevæger sig fra bagudskuende til fremadskuende dataanvendelse. Gartner identificerer fire analyseformer: *descriptive*, *diagnostic*, *predictive* og *prescriptive analytics*, som hver repræsenterer stigende analytisk kompleksitet og forretningsværdi.



(Gartner, 2012)

Disse niveauer svarer i høj grad til de fem faser i Alexandra Instituttets model – fra "Monitorere driften" til "Konstant synkronisering":



(Alexandra Instituttet, 2020)

Koblingen mellem de to modeller viser sig tydeligt:

- Fase 1, "Monitorere driften", henviser til *descriptive analytics*, hvor data bruges til at forstå, hvad der er sket.
- Fase 2, "Lære om forretningen", afspejler *diagnostic analytics*, hvor data analyseres for at forklare hændelser.
- I Fase 3, "Udvikle konkurrenceevnen", ser man primært anvendelse af predictive analytics, hvor virksomheder forudsiger fremtidige udfald. I Fase 4, "Gentænke forretningen", kan der desuden argumenteres for elementer af prescriptive analytics, idet gentænkningen af forretningen også kan indebære databaserede anbefalinger til, hvordan konkrete ændringer bør foretages – ikke blot hvad der vil ske, men hvad der bør gøres.
- Fase 5, "Konstant synkronisering", relaterer til *prescriptive analytics* og videre, hvor dataanvendelse understøtter automatisering, beslutningsstøtte og realtidsoptimering.
- Det er væsentligt at præcisere, at Alexandra-modellens fem faser ikke skal forstås som et strengt lineært eller temporært afgrænset forløb, hvor en virksomhed gennemløber faserne i en fast rækkefølge. Faserne udtrykker snarere typologiske niveauer af datamodenhed, som en virksomhed kan befinde sig på samtidigt inden for forskellige forretningsområder. I den konkrete use-case eksisterer fase 1–2-behov, altså basal rapportering til trænerstab, parallelt med fase 4–5-behov i form af realtidsanalyse under kamp, og bevægelsen mellem faser sker dermed ikke som en lineær progression, men som spring drevet af konkrete behov og muligheder. Metodisk betyder det, at vurderingen af PU og PEOU per fase forstås som situeret i den specifikke use-case, og ikke som en universel kronologi, virksomheder bevæger sig igennem.

Ved at koble de to modeller får man et mere nuanceret billede af, hvordan virksomheder ikke blot øger deres teknologiske kapacitet, men også udvikler organisatoriske kompetencer og forståelse for datadrevet værdiskabelse. Det understreger, at teknologisk modenhed ikke kan stå alene. Det kræver samtidig organisatorisk tilpasning og et klart strategisk formål med dataindsatsen.

I denne udvikling bliver behovet for mere fleksible og kraftfulde teknologier, såsom pro-code, mere fremtrædende, fordi low-code ikke altid rummer tilstrækkelig funktionalitet til komplekse analyser og inkludering af Machine Learning og AI.


Udvikling set fra Gartners perspektiv har klare implikationer i forhold til TAM. Som Davis (1989) fremhæver, er teknologiadoption afhængig af den oplevede nytteværdi, *Perceived Usefulness*, og den oplevede brugervenlighed, *Perceived Ease of Use*. I takt med stigende datamodenhed vil ønsket om mere avanceret analyse kunne forøge de forventninger, brugerne har til teknologiens funktionalitet, nærmere bestemt dens nytte. Dette afspejles også hos Razak et al. (2024), som viste, at præstationsforventning og evnen til at understøtte komplekse opgaver spiller en central rolle i teknologiaccept. Samtidig kan ønsket om avanceret funktionalitet komme på bekostning af brugervenlighed.

Dermed bliver teknologiaccept ikke statisk, men påvirkes dynamisk af virksomhedens datamodenhed og afvejningen mellem funktionalitet og tilgængelighed.

3. Metode

I dette paper anvendes en hermeneutisk metodisk tilgang kombineret med en teknologivurdering baseret på Technology Acceptance Model (TAM) og Alexandra Instituttets model for datamodenhed. Formålet er at analysere og sammenligne to forskellige teknologiske løsninger, Power BI (low-code) og Shiny (pro-code), med henblik

på deres anvendelighed i forhold til virksomheders datamodenhed og brugernes interaktion med teknologien.




Power BI, fase 1
Egen tilvirkning



Shiny, fase 1
Egen tilvirkning

Analysen bygger på en komparativ use-case: Et dashboard udvikles parallelt i begge værktøjer med samme funktionalitet, hvilket muliggør en direkte sammenligning af brugervenlighed, fleksibilitet, integrationsevne og andre centrale faktorer. Denne tilgang sikrer en praksisnær vurdering, hvor teknologien ses i samspil med både brugerbehov og organisatorisk kontekst:



Egen tilvirkning, 2026

Use-casen er konstrueret med udgangspunkt i reelle datasæt fra professionel dansk fodbold. Den organisatoriske kontekst er en dansk professionel fodboldklub, der opererer i den næstøverste række. Ud fra datamodenhedsparametre, repræsenterer klubben en typisk SMV-struktur med begrænset dedikeret datakapacitet, hvor

dataarbejdet primært varetages af få nøglepersoner snarere end en egentlig dataafdeling. Denne organisatoriske virkelighed gør klubben velegnet som case, idet den gennemløber et datamodenhedsforløb, der er sammenligneligt med mange andre danske SMV'er – fra basale rapporteringsbehov til avanceret realtidsanalyse. Datasættet er sammensat fra flere kilder og indhentningsmetoder, hvilket afspejler en stigende datakompleksitet i takt med Alexandra-modellens faser. I de tidlige faser (fase 1–2) anvendes strukturerede data fra Divisionsforeningen, indhentet via Snowflake, til basale rapporterings- og overbliksmål. I fase 3 suppleres med webscrapede data fra Transfermarkt samt data indhentet via API, hvilket muliggør tværgående analyser på tværs af datakilder. I de avancerede faser (fase 4–5) inddrages realtidsdata indhentet live under kampe via API, hvilket stiller krav til teknologien, som Power BI ikke kunne honorere – her var det udelukkende muligt at realisere løsningen i Shiny. Denne progression i datakompleksitet, fra statiske filer via API-integration til realtidsindhentning, afspejler direkte de stigende krav, som Alexandra-modellens faser beskriver, og gør use-casen velegnet til at belyse forskelle i PU og PEOU mellem low-code og pro-code på tværs af datamodenhedsniveauer. Nedenfor er et overblik over de relevante faser, dets gruppering og de relevant use-cases for hver fase:

Ud fra datamodenhedsparametre, klubben I de tidlige faser (fase 1–2) anvendes strukturerede data fra Divisionsforeningen (Divisionsforeningen, u.d.), den danske ligaorganisation for professionel fodbold, indhentet via en Snowflake data warehouse-integration (Snowflake Inc., u.d.). Data omfatter holdstatistik, kampresultater og spillerdata på aggregeret niveau – altså data, der egner sig til descriptive analytics og basale rapporteringsbehov. I fase 3 suppleres med webscrapede data fra Transfermarkt.com (Transfermarkt, u.d.), en kommerciel platform for spillerdata og markedsværdier, samt event- og positioneringsdata fra SkillCorner indhentet via REST API (SkillCorner, u.d.). Disse datakilder muliggør tværgående analyser, hvor markedsdata, performance-data og positioneringsdata kan kombineres på tværs. I de avancerede faser (fase 4–5) inddrages realtidsdata

indhentet live under kampe via streaming-API, hvor data leveres med under-sekund latens. Denne datatype stiller specifikke krav til arkitekturen, herunder vedvarende websocket-forbindelser, reaktiv databehandling og lav-latens visualisering – krav, som Power BI's batch-orienterede arkitektur ikke kunne honorere, mens Shiny's reaktive programmeringsmodel (Chang et al., 2024) muliggjorde implementeringen.

Ud fra datamodenhedsparametre, klubben Konkret varetages alt dataarbejde i klubben af én person – forfatteren selv – som del af en primær analytikerfunktion. Der er ingen dedikeret dataafdeling, og dataarbejdet er således stærkt personafhængigt, både teknisk og kompetencemæssigt. De primære aftagere af analyser og dashboards er chefræneren, assistenttræneren og den sportslige ledelse. Analyserne efterspørges ad hoc snarere end som del af en fast, struktureret proces, og initiativet kommer ofte fra analytikeren selv eller en lille kreds omkring trænerstaben. Øvrige medarbejdere i klubben besidder ikke den tekniske kunnen til selv at trække data eller opdatere dashboards, hvilket betyder, at dataarbejdet reelt er afhængigt af én nøgleperson. Denne organisatoriske virkelighed er ikke unik for denne klub, men afspejler en udbredt situation i danske SMV'er, hvor dataindsatsen hviler på enkeltpersoners kompetencer og engagement snarere end på forankrede organisatoriske processer. Klubben har ingen formuleret datastrategi, og den største barriere for mere datadrevet arbejde er en kombination af manglende viden om mulighederne og begrænset villighed til at investere i datakompetencer.

Begge dashboards er udviklet og vurderet af forfatteren selv, som har professionel erfaring med både Power BI og R/Shiny. Vurderingen af Perceived Usefulness (PU) og Perceived Ease of Use (PEOU) er dermed baseret på forfatterens egen oplevelse som udvikler og bruger af de to løsninger. Det er vigtigt at anerkende, at denne tilgang indebærer en implicit bias: Forfatteren er en erfaren teknisk bruger og kan derfor ikke fuldt ud repræsentere den oplevede brugervenlighed for ikke-tekniske brugere, særligt på de lavere datamodenhedsniveauer (fase 1–2), hvor målgruppen typisk har begrænset teknisk erfaring. Denne begrænsning påvirker undersøgelsens reliabilitet, idet

vurderingerne af PEOU på lavere modenhedsniveauer i højere grad er baseret på forfatterens faglige vurdering end på faktisk brugeroplevelse. Validiteten styrkes dog af, at vurderingerne konsekvent er forankret i den teoretiske litteratur (Davis, 1989; Razak et al., 2024) og i Alexandra-modellens fasespecifikke kriterier.

Den hermeneutiske metode, som den er beskrevet hos Gadamer (1960/2004), anvendes især til at fortolke relationen mellem del og helhed – altså mellem de enkelte funktioner i værktøjerne og deres betydning i en konkret forretningssammenhæng. Denne forståelse nuanceres yderligere gennem TAM's førnævnte begreber *Perceived Usefulness* (PU) og *Perceived Ease of Use* (PEOU), der danner grundlag for vurdering af brugernes oplevede nytte og anvendelighed af løsningen. I denne sammenhæng relateres PU til, i hvilken grad brugeren oplever, at værktøjet understøtter virksomhedens datamodenhedsniveau og konkrete behov. Det kunne være evnen til at generere indsigt, automatisere processer eller simulere scenarier. PEOU inddeles i konkrete aktiviteter i løsningen, som bestemmes ud fra hvad Alexandra-modellen definerer som værende det overordnede fokus i den givne fase.

Perceived Ease of Use (PEOU) vurderes mere subjektivt og kvalitativt end PU, og analyseres ud fra en række kriterier, der er udledt fra den teoretiske litteratur om teknologiaccept (Davis, 1989; Razak et al., 2024; Pan et al., 2024). På baggrund af disse studier er fem centrale dimensioner identificeret, som tilsammen belyser den oplevede brugervenlighed:

1. *Læringskurve og oplevet indsats* – hvor hurtigt og effektivt kan brugeren tilegne sig teknologien og føle sig kompetent?
2. *Intuitivitet og tilgængelig støtte* – hvor let er det at finde og anvende funktioner uden omfattende instruktion, og hvilke ressourcer kan hjælpe?

3. *Kompleksitet vs. fleksibilitet – balancen mellem fast ramme og funktionel frihed. Ressourceallokering – den tid, kompetence og økonomi, der kræves for at implementere og vedligeholde løsningen, herunder om virksomheden har kapacitet til at afsætte de nødvendige ressourcer.*

Disse kriterier fortolkes i lyset af den organisatoriske kontekst og brugernes teknologiske baggrund. På baggrund af vurderingerne af både PU og PEOU gennemføres analysen af use casen, og det er ud fra disse to dimensioner, at projektets anbefalinger vedrørende valg og tilpasning af visualiseringsværktøjer til virksomhedens datamodenhed formuleres. Dermed fungerer TAM ikke blot som en teknologisk målestok, men som et fortolkningsredskab, der belyser samspillet mellem bruger, teknologi og organisatorisk modenhed. I udviklingen af løsningerne, vil nedenstående skabelon anvendes til at identificere PE. Altså, den *oplevede brugervenlighed* i hhv. low-code og pro-code løsningerne:

Analysen forankres i Alexandra Instituttets fem faser for datamodenhed, som anvendes til at vurdere, hvordan hhv. low-code og pro-code værktøjer understøtter virksomheder på forskellige datamodenhedstrin fra simpel dataindsamling til fuld automatisering og innovation. Dette giver en dybere forståelse af, hvordan teknologivalg bør tilpasses virksomhedens aktuelle datakapacitet og strategiske behov. Hver fase analyseres særskilt og afsluttes med en anbefaling til virksomheden på de givne datamodenhedsniveauer. Denne struktur muliggør samtidig en fremadskuende refleksion over, hvordan et givent værktøj ikke blot kan løse aktuelle behov, men også understøtte bevægelsen mod højere datamodenhed. Dermed kobles Perceived Usefulness (PU) til virksomhedens strategiske udviklingsretning.

Refleksion over forforståelse og bias indgår som en integreret del af den hermeneutiske metode. I tråd med Brinkmann & Tanggaard (2015) betragtes forforståelse ikke som en fejlkilde, der kan elimineres, men som et uundgåeligt og produktivt udgangspunkt for

fortolkning, der skal gøres explicit og reflekteres over. Udviklerens, her forfatterens, tekniske baggrund og præferencer kan således påvirke vurderingen af de to løsninger, hvorfor der løbende inddrages refleksioner over, hvordan Power BI og Shiny matcher både brugernes teknologiske færdigheder og organisationens modenhedsniveau. Den hermeneutiske tilgang bidrager her til at afdække de underliggende forståelser og antagelser, der præger brugerens oplevelse af teknologien. Eksempelvis hvilke funktioner der opleves som værdiskabende, og hvilke der fremstår forstyrrende eller unødigt komplekse.

Den metodiske tilgang kombinerer således kvalitative fortolkninger med en struktureret teknologivurdering og skaber grundlag for en kontekstuel og brugernær evaluering af løsningerne i en datadrevet forretningspraksis. Analysen forstås ikke som en lineær én-gangs vurdering af pro-code eller low-code, men som en iterativ fortolkningsproces, hvor forståelsen af løsningernes enkelte elementer løbende justeres i lyset af helheden og den konkrete forretningskontekst.

Under udviklingen og afprøvningen af løsningerne bevæges der således frem og tilbage mellem specifikke funktioner – såsom filtrering, visualiseringstyper og interaktionsmuligheder – og deres betydning for beslutningsstøtte, samarbejde og organisatorisk læring. Forforståelse og bias håndteres explicit ved, at udviklernes tekniske erfaring med hhv. low-code og pro-code løbende gøres til genstand for refleksion i analysen. Hvor der opstår forskelle i vurderingen af Power BI og Shiny, inddrages både TAM-begreberne PU og PEOU samt Alexandra-modellens datamodenhedsfaser som fortolkningsrammer: Er forskellen et udtryk for reel brugermæssig nytte eller oplevet brugervenlighed, eller skyldes den primært udviklerens præferencer og historiske erfaringer? På denne måde anvendes hermeneutikken, i Tanggaards forstand, ikke blot som et abstrakt videnskabsteoretisk

ståsted, men som en praktisk fortolkningsramme, der sikrer gennemsigtighed og refleksivitet i vurderingen af de to værktøjer.

4 Analyse og resultater

Analysen af PEOU vurderer oplevet brugervenlighed i forhold til de funktioner og krav, der stilles i forskellige faser af datamodenhed. Den baseres på tre centrale kriterier:

1. Læringskurve og oplevet indsats

Her fokuseres på, hvor hurtigt og effektivt brugeren kan tilegne sig de nødvendige færdigheder for at anvende værktøjet i praksis. Det omfatter både den første introduktion til værktøjet og den løbende anvendelse i daglige opgaver. En lav læringskurve og lav oplevet indsats øger chancen for vedvarende brug.

2. Intuitivitet og tilgængelig støtte

Dette kriterium vurderer, i hvor høj grad værktøjet opleves som logisk og let at navigere i, samt om brugeren har nem adgang til hjælp og vejledning. Det kunne være i form af dokumentation, tutorials, support eller kollegial vidensdeling. En intuitiv grænseflade med tydelig struktur og støttemuligheder kan reducere behovet for teknisk erfaring.

3. Komplexitet vs. fleksibilitet

Her ses på balancen mellem hvor mange muligheder værktøjet tilbyder, og hvor krævende det er at udnytte dem. Høj fleksibilitet kan give plads til skræddersyede løsninger og avanceret funktionalitet, men kan også medføre højere kompleksitet og øget behov for tekniske færdigheder. Omvendt kan lav kompleksitet understøtte hurtig adgang til resultater, men dog komme på bekostning af tilpasningsmuligheder.

Analysen er gennemført som en hermeneutisk fortolkningsproces, hvor vurderingerne af konkrete funktioner i den udviklede løsning i Power BI og Shiny løbende er blevet

sammenholdt med den overordnede forretningskontekst – i dette tilfælde en professionel dansk fodboldklub – og virksomhedens placering i Alexandra Instituttets datamodenhedsmodel. De tre PEOU-kriterier udgør de analytiske briller, mens PU anvendes til at vurdere, i hvilken grad løsningen faktisk understøtter de opgaver og beslutninger, der er centrale på det pågældende datamodenhedsniveau.

I det følgende præsenteres først de overordnede forskelle mellem Power BI (low-code) og Shiny (pro-code), hvorefter resultaterne foldes ud fase for fase med udgangspunkt i Alexandra-modellens fem datamodenhedstrin. Hver fase afrundes med en anbefaling til valg af værktøj.

4.1 Overordnet sammenligning af Power BI og Shiny

På tværs af alle faser viser analysen, at Power BI generelt scorer højt på PEOU for brugere uden dyb teknisk baggrund. Læringskurven opleves som relativt lav, særligt når der allerede findes interne ressourcer eller online-materiale, der kan understøtte opstarten. Intuitiviteten styrkes af en grafisk, menu-drevet tilgang, hvor mange standardhandlinger som filtrering, simple beregninger, standardvisualiseringer kan udføres uden kode. Dette betyder, at forretningsbrugere hurtigere kan opnå en oplevelse af kompetence og selvstændighed.

Shiny placerer sig modsat med en mere stejl læringskurve, hvor grundlæggende kendskab til R og web-logik er en forudsætning. Til gengæld giver Shiny betydelig fleksibilitet og tilpasningsmulighed: Når kompetencerne er til stede, kan både datalogik, visualiseringer og interaktionsmønstre skræddersys tæt til domænet og virksomhedens eksisterende data- og IT-infrastruktur. For avancerede brugere og organisationer med stærke data science-miljøer betyder dette, at PU kan blive meget høj – netop fordi løsningen kan designes, så den matcher komplekse behov.

Hermeneutisk set peger dette på en grundlæggende spænding mellem del og helhed: Funktioner, der i isolation kan virke komplekse og ressourcekrævende. Eksempelvis kodning af særlige interaktioner i Shiny kan i en helhedsbetragtning bidrage til betydelig værdi, hvis de gør det muligt at udnytte virksomhedens datakapacitet fuldt ud. Omvendt kan en tilsyneladende enkel og overskuelig løsning i Power BI miste sin nytte, hvis den ikke kan følge med, når datamængder, kompleksitet eller forretningskrav vokser.

Overført til den konkrete case tegner denne spænding sig tydeligt. Case-klubben har allerede adgang til Power BI, og de primære aftagere er cheftræner, assistent og sportslig ledelse, som alle er ikke-tekniske brugere. Det trækker mod low-codes høje PEOU, mens klubbens ambition om realtidsanalyse under kamp rummer behov, som kun Shiny kan honorere, og dermed trækker mod pro-codes fleksibilitet. Fordi hele dataarbejdet hviler på én nøgleperson, bliver valget mellem de to imidlertid lige så meget et organisatorisk som et teknisk spørgsmål. Den pointe udfoldes fase for fase nedenfor.

4.2 Fase 1–2: Tidlig datamodenhed og basale rapporteringsbehov

I de tidlige faser af Alexandra-modellen er fokus typisk på at skabe overblik over eksisterende data, etablere fælles rapporter og understøtte simple, operationelle beslutninger. Her er ressourcer til dataarbejde ofte begrænsede, og brugerne har kun begrænset erfaring med avancerede BI-værktøjer.

For disse virksomheder viser use-case-analysen, at Power BI's lave læringskurve og menu-drevne tilgang er en klar fordel. PEOU vurderes af forfatteren som høj: Standardvisualiseringer og enkle dashboards kan etableres uden programmering, og brugerne kan forholdsvis hurtigt lære at filtrere og udforske data gennem interaktive elementer. Intuitiviteten understøttes desuden af let tilgængelige skabeloner og online-ressourcer, som kan reducere behovet for ekstern konsulentbistand.

PU vurderes ligeledes positivt i denne fase, fordi Power BI's grundlæggende funktionalitet typisk rækker til at besvare de spørgsmål, virksomhederne stiller sig: Hvad sker der? Hvor meget? Hvor ofte? Der er sjældent behov for avancerede modeller, simuleringer eller specialiserede brugerrejser, som ville kræve en pro-code-løsning.

Shiny vurderes i denne kontekst som mindre hensigtsmæssig. Den oplevede brugervenlighed er lav for ikke-tekniske brugere, og transitionsomkostningen ved at opbygge de nødvendige kompetencer vil ofte overstige den oplevede nytte. Hermeneutisk peger dette på, at en organisation på dette modenhedsniveau typisk har en forforståelse af "dataarbejde" endnu er præget af behovet for basale rapporter og ikke af forestillinger om avanceret modellering eller automatisering.

Dette billede understøttes af nyere dansk SMV-forskning. Kronbæk og Haugaard (2025) finder i deres interviewbaserede undersøgelse af midtjyske SMV'er, at digitaliseringen sjældent drives af intern strategisk ambition, men derimod af eksternt pres i form af lovkrav, kundekrav og cybersikkerhedshensyn. De peger desuden på, at mange SMV'er mangler intern teknologiforståelse og beslutningskraft, som ofte outsources til eksterne konsulenter – med det paradoks til følge, at ledelsen oplever kontrol, mens afgørende digitale beslutninger reelt træffes uden for organisationen. Set i lyset af Kræmmersgaards digitaliseringsmodenhedsmodel placerer Kronbæk og Haugaard mange af de undersøgte virksomheder på de lavere modenhedsniveauer, hvor digitalisering primært anvendes til effektivisering af eksisterende manuelle processer snarere end som strategisk forankret forretningsudvikling. Denne pointe rimer på den observation, der gøres i nærværende case: Klubben har adgang til Power BI gennem eksisterende licenser og en analytiker med tekniske kompetencer, men uden organisatorisk forankring og strategisk retning forbliver dataarbejdet drevet af enkeltpersoners initiativ frem for af en samlet ledelsesmæssig prioritering.

Set i den konkrete organisatoriske kontekst understøttes denne vurdering af, at klubben allerede har adgang til Power BI gennem sin eksisterende Microsoft 365-aftale – en situation der er typisk for mange danske klubber og SMV'er. Dette eliminerer en væsentlig økonomisk barriere og gør det muligt at komme i gang uden yderligere licensinvesteringer. Da chefræner, assistent og sportslig ledelse er de primære aftagere, og ingen af dem har teknisk baggrund til selv at kode løsninger, er Power BI's visuelle, menu-drevne tilgang afgørende for, at de overhovedet kan interagere med data selvstændigt. Organisatorisk er udfordringen dog, at selv Power BI kræver en person, der kan opbygge og vedligeholde dashboards – og i en klub med kun én dataperson er denne personafhængighed en reel risiko for kontinuiteten i dataindsatsen.

Anbefaling for fase 1–2: Power BI anbefales som primært værktøj. Fokus bør være på at opbygge simple, men stabile dashboards, der skaber fælles sprog og synlighed omkring centrale nøgletal. Shiny og andre pro-code-løsninger bør kun overvejes, hvis der findes stærke interne R-kompetencer eller særlige krav, som ikke kan løses i low-code.

4.3 Fase 3-4: Mellemhøj datamodenhed: Integreret analyse og tværgående forståelse

I de midterste faser af Alexandrainstituttets datamodenhedsmodel øges kravene til dataintegration, historik og mere avanceret analyse. Virksomhederne begynder at kombinere data fra flere kilder og ønsker at understøtte tværgående indsigter og mere komplekse beslutninger. I use-casen afspejles dette ved, at data fra Transfermarkt (indhentet via webscraping) og SkillCorner (indhentet via API) blev integreret med de eksisterende data fra Divisionsforeningen, hvilket stillede krav til både datarensning og sammenkædning på tværs af kilder.

I denne fase viser use-case-analysen et mere nuanceret billede (jf. Davis, 1989, s. 320, om forholdet mellem PU og PEOU ved stigende kompleksitet). Power BI bevarer en relativt høj PEOU for brede brugergrupper, men begrænsninger i fleksibilitet kan

begynde at presse PU nedad: Specialiserede beregninger, tilpasningskrævende interaktioner eller særlige visualiseringstyper kan kræve workarounds eller ekstern ekspertise. I use-casen viste dette sig konkret ved integration af webscrapede og API-baserede data, hvor Power BI's begrænsede muligheder for datamanipulation gjorde processen omstændelig sammenlignet med R's fleksible datahåndtering i Shiny. Læringskurven for superbrugere stiger, fordi de må arbejde "udenom" værktøjets standardlogik for at realisere de ønskede funktioner.

Shiny fremstår her som et potent supplement, særligt når der er behov for at understøtte specifikke faglige workflows. For datakyndige brugere vurderes PU i use-casen som høj, fordi værktøjet giver mulighed for at modellere forretningslogik præcist og integrere med eksisterende R-økosystemer. I use-casen kunne data fra SkillCorner API og Transfermarkt webscrapes sammenkædes og transformeres direkte i R, uden behov for mellemliggende datalag. PEOU for den brede brugergruppe er dog fortsat lav, hvorfor Shiny sjældent vil kunne stå alene som organisationsdækkende visualiseringsværktøj.

Set gennem en hermeneutisk linse er denne fase kendetegnet ved, at organisationens forståelseshorisont udvides. Brugerne får nye erfaringer med data, som udfordrer deres oprindelige forventninger til, hvad et dashboard kan og skal kunne. Dette skaber en ny fortolkning, hvor tidligere "tilstrækkelige" løsninger revurderes i lyset af nye behov.

Organisatorisk rejser kombinationsstrategien imidlertid væsentlige spørgsmål for en klub af denne størrelse. At vedligeholde to parallelle systemer kræver bredere teknisk kompetence og mere tid – ressourcer, som klubben aktuelt ikke har. I praksis betyder det, at kombinationsstrategien forudsætter, at den ene dataperson mestrer begge værktøjer, hvilket øger personafhængigheden yderligere. Hvis denne nøgleperson forlader klubben, står organisationen med to systemer, som ingen andre kan vedligeholde – en risiko, der er højere end ved en ren low-code-strategi, hvor sandsynligheden for at finde en erstatter med Power BI-kompetencer er

betydeligt større end for R og Shiny. Denne 'bus factor' er en organisatorisk realitet, som bør indgå i vurderingen af, hvornår en klub reelt er klar til at introducere pro-code.

Anbefaling for mellemhøj modenhed er en kombinationsstrategi. Power BI bruges som front-end for en bred gruppe forretningsbrugere, mens Shiny anvendes til specialiserede dashboards og analytiske værktøjer til superbrugere og dataanalytikere. Valget mellem low-code og pro-code bør ikke ses som enten-eller, men som et både-og, hvor de to typer værktøjer dækker forskellige dele af organisationens behov.

4.4 Høj datamodenhed: Avanceret modellering, automatisering og innovation

På de højeste datamodenhedsniveauer er fokus rettet mod avancerede analyser, modeller, automatiserede dataflows og datadrevne innovationer. Data er ikke blot et beslutningsstøtteværktøj, men udgør en integreret del af virksomhedens forretningsmodel.

I denne kontekst skifter balancen mellem kompleksitet og fleksibilitet markant. Power BI kan fortsat spille en vigtig rolle som formidlings- og rapporteringslag overfor ledelse og ikke-tekniske interessenter, men PU begrænses, når behovene bevæger sig mod meget specialiserede modeller eller interaktionsformer. Et for stort forsøg på at presse avancerede scenarier ind i en low-code-ramme kan medføre lavere PEOU for udviklere og superbrugere, fordi de oplever værktøjet som snærende og ufleksibelt. I use-casen blev dette særligt tydeligt ved indhentning af realtidsdata under en live kamp: Power BI kunne ikke håndtere den løbende datastrøm, hvilket betød, at denne del af use-casen udelukkende kunne realiseres i Shiny.

Shiny – og andre pro-code-værktøjer – fremstår her som særligt velegnede til at understøtte avancerede dataflows, eksperimentelle dashboards og integrerede beslutningsstøttesystemer. For de brugere, der mestrer værktøjet, vurderes både PU og PEOU højt: de oplever, at de kan realisere komplekse forretningslogikker og hurtigt

iterere på nye ideer. I use-casen blev dette demonstreret ved live-indhentning og visualisering af kampdata i realtid – en funktionalitet, der krævede websocket-integration og reaktiv databehandling, som kun var mulig i Shiny's pro-code-arkitektur. For mindre tekniske brugere vil Shiny-interfaces dog fortsat kræve omsorgsfuldt design for at sikre intuitivitet.

Hermeneutisk indebærer dette, at forståelsen af “brugervenlighed” ændrer karakter: I de højeste modenhedsfaser handler PEOU ikke kun om enkelhed, men om meningsfuld adgang til kompleksitet. En brugerflade kan være relativt kompleks og alligevel opleves som brugervenlig, hvis den understøtter brugerens måde at tænke og arbejde på i en højt specialiseret praksis.

I den konkrete use-case krævede realtidsløsningen, at analytikeren var fysisk til stede med en laptop under kampe – en setup, der forudsætter et betydeligt apparat og mandskab. Selvom løsningen teknisk kan automatiseres, så den kører uden analytikeren til stede, kræver dette en initial investering i opsætning og infrastruktur, som ligger ud over klubbens nuværende ressourcer. Organisatorisk udfordrer dette fase 4–5-anbefalingernes realisme for klubber på dette niveau: Den teknologiske kapacitet kan godt opbygges i pro-code, men uden organisatorisk forankring – herunder vilje til at investere i kompetencer, udstyr og arbejdsgange – forbliver løsningen et afhængigt af én persons tilstedeværelse og engagement. Dette peger på, at bevægelsen mod høj datamodenhed ikke kun er et teknologisk spørgsmål, men i mindst lige så høj grad et organisatorisk modningsprojekt, der kræver ledelsesmæssig opbakning og resourceallokering.

Anbefaling for høj datamodenhed: Pro-code-løsninger som Shiny bør indtage en central rolle i den analytiske kerne, mens low-code-værktøjer som Power BI primært anvendes til at distribuere indsigter bredt i organisationen. Investering i udvikler- og data science-kompetencer bliver her afgørende for at realisere den fulde nytte af pro-code-værktøjer.

4.5 Samlede anbefalinger på tværs af datamodenhed

På tværs af faserne peger analysen på tre overordnede pointer:

- Low-code som accelerator i de tidlige faser: For virksomheder på lave datamodenhedsniveauer er Power BI særligt velegnet til hurtigt at skabe synlig værdi med begrænset indsats. Den høje oplevede brugervenlighed (PEOU) gør det muligt at opbygge en datakultur og et fælles rapporteringssprog uden store investeringer i tekniske kompetencer.
- Kombinationen af low-code og pro-code i midterfaser: Når datamodenheden øges, og behovene bliver mere komplekse, bliver det utilstrækkeligt at satse entydigt på ét værktøj. Her er en todelt strategi, hvor Power BI bruges som bred formidlingsplatform og Shiny som fleksibel udviklingsplatform for avancerede use cases, ofte den mest hensigtsmæssige.
- Pro-code som strategisk kerne i de højeste modenhedsniveauer: For organisationer, hvor data er dybt integreret i forretningsmodellen, vil pro-code-værktøjer typisk være nødvendige for at realisere den fulde værdi af datamodenheden. Low-code-værktøjer bevarer en vigtig rolle som bro til ikke-tekniske brugere, men de strategisk vigtigste løsninger vil ofte være bygget i pro-code.
- Anvendt på Alexandra-modellen vurderes case-klubben overordnet til at befinde sig i fase 2–3 ("Lære om forretningen" og "Udvikle konkurrenceevnen"), med enkelte aktiviteter, der peger frem mod fase 4. De etablerede dashboards til træner- og ledelsesrapportering placerer hovedparten af dataarbejdet i fase 2, mens den ad hoc-baserede integration af eksterne datakilder, altså Transfermarkt og SkillCorner, afspejler fase 3-aktivitet. Realtidsanalyserne under kamp peger mod fase 4, men er ikke en forankret organisatorisk praksis –

de eksisterer i kraft af én persons engagement og er derfor metodisk at betragte som et eksperimentelt fase 4-udtryk frem for en realiseret modenhed. Denne sammensatte placering understreger pointen om, at fasevurderinger sjældent er entydige i praksis, og at den organisatoriske forankring, snarere end den teknologiske kapacitet, er den begrænsende faktor for klubbens videre bevægelse mod højere modenhed.

- Hertil bør tilføjes en fjerde, tværgående pointe om organisatorisk realisme: Anbefalingerne ovenfor forudsætter en grad af organisatorisk parathed, som ikke altid er til stede i praksis. I den undersøgte klub – og formentlig i mange lignende SMV'er – er den største barriere ikke teknologisk, men organisatorisk: manglende datastrategi, begrænset viden om mulighederne og utilstrækkelig villighed til at investere i datakompetencer. Uden denne organisatoriske forankring risikerer selv det bedst egnede værktøj at forblive underudnyttet eller personafhængigt. Valg af værktøj bør derfor ikke kun vurderes ud fra teknisk kapacitet og datamodenhed, men også ud fra organisationens faktiske evne og vilje til at forankre dataindsatsen bredt. En klub, der investerer i Power BI uden samtidig at opbygge interne kompetencer og arbejdsgange, vil ikke realisere den fulde værdi – og en klub, der indfører Shiny uden organisatorisk understøttelse, risikerer at skabe en løsning, der dør med den person, der byggede den.

Samlet set viser analysen dermed, at valget mellem low-code og pro-code visualiseringsværktøjer ikke kan forstås uafhængigt af virksomhedens datamodenhed og konkrete kontekst. Den hermeneutiske tilgang har gjort det muligt at se ud over en simpel teknisk sammenligning og i stedet fortolke, hvordan brugere og organisationer tillægger teknologierne mening på forskellige datamodenhedsniveauer. På den baggrund kan anbefalingerne læses som et dynamisk beslutningsgrundlag, der ikke alene peger på “det rigtige værktøj” her og nu, men også på, hvordan valg af værktøj kan understøtte bevægelsen mod højere datamodenhed.

Litteraturliste

- Aagaard, A., Presser, M., Collins, T., Beliatas, M., Skou, A. K., & Jakobsen, E. M. (2021). The Role of Digital Maturity Assessment in Technology Interventions with Industrial Internet Playground. *Electronics*, 10(1134). <https://doi.org/10.3390/electronics10101134>
- Alexandra Instituttet. (2020). Find vej i din dataindsats. <https://alexandra.dk/wp-content/uploads/2020/09/Alexandra-Instituttet-BDBA-Find-vej-i-din-dataindsats.pdf>
- Brinkmann, S., & Tanggaard, L. (2015). Kvalitative metoder, tilgange og perspektiver: En introduktion. Hans Reitzels Forlag.
- Chang, W., Cheng, J., Allaire, J., et al. (2024). shiny: Web Application Framework for R. <https://shiny.posit.co/>
- CMMI Institute. (2014). Data Management Maturity (DMM) Model. CMMI Institute.
- DAMA International. (2017). DAMA-DMBOK: Data Management Body of Knowledge (2nd ed.). Technics Publications.
- Davis, F. D. (1989). Perceived usefulness, perceived ease of use, and user acceptance of information technology. *MIS Quarterly*. <https://doi.org/10.2307/249008>
- Divisionsforeningen. (u.d.). Divisionsforeningen. <https://divisionsforeningen.dk>
- European Commission Joint Research Centre. (2023). Digital Maturity Assessment Tool (DMAT) Framework Guidelines for EDIHs. European Commission.
- Gadamer, H.-G. (2004). Truth and Method (2nd rev. ed.). Continuum.
- Gartner. (2012). Gartner's Hype Cycle Special Report for 2012.

Kronbæk, L. S., & Haugaard, A. B. (2025). Digitalisering – mellem udfordringer og potentialer. En interviewbaseret undersøgelse af digitaliseringsgrad og -parathed i små og mellemstore virksomheder i Midtjylland. Erhvervsakademi Dania.
<https://www.eaviden.dk/wp-content/uploads/2024/06/Digitalisering-i-SMVer.pdf>

Pan, J., Zhu, L., & Qin, Y. (2024). Exploring the determinants of students' intention to use AI code assistant: An extended TAM approach. MDPI.
<https://doi.org/10.3390/systems12050176>

Pradeep, R. K., Deepa, A., & Shobana, D. (2024). Big data business intelligence tools in healthcare sector using TAM and UTAUT models. EasyChair Preprints.
<https://easychair.org/publications/preprint/hTSR>

Razak, S. F., Mohd Salleh, N. S., Mustaffa, N. H., & Rahman, N. H. A. (2024). Enhancing business efficiency through low-code/no-code technology adoption: Insights from an extended UTAUT model. ResearchGate.
<https://www.researchgate.net/publication/378854141>

SkillCorner. (u.d.). SkillCorner Tracking Data. <https://skillcorner.com>

Snowflake Inc. (u.d.). Snowflake Data Cloud. <https://www.snowflake.com>

Tanggaard, L. (2015). Kvalitativ forskning - en grundbog. Hans Reitzels Forlag.

Transfermarkt. (u.d.). Transfermarkt – Football transfers, rumours, market values, news and statistics. <https://www.transfermarkt.com>

Worthington, A. K. (2021). Persuasion Theory in Action: An Open Educational Resource.
<https://ua.pressbooks.pub/persuasiontheoryinaction/>