

VILNIAUS UNIVERSITETAS EKONOMIKOS IR VERSLO
ADMINISTRAVIMO FAKULTETAS

VERSLO PROCESŲ VALDYMO STUDIJŲ PROGRAMA

Mantas Kraujelis

MAGISTRO BAIGIAMASIS DARBAS

DIRBTINIO INTELEKTO INTEGRACIJOS SĖKMĖS VEIKSNIAI IR JŲ POVEIKIS TECHNINIO KLIENTŲ APTARNAVIMO EFEKTYVUMUI	<i>SUCCESS FACTORS OF ARTIFICIAL INTELLIGENCE INTEGRATION AND THEIR IMPACT ON TECHNICAL CUSTOMER SUPPORT EFFICIENCY</i>
---	--

Darbo vadovė
Dr. Erika Vainienė

Vilnius, 2025

TURINYS

IVADAS	7
1. DIRBTINIO INTELEKTO INTEGRACIJOS Į TECHNINIO KLIENTŲ APTARNAVIMO PROCESUS TEORINIAI ASPEKTAI	11
1.1. Klientų aptarnavimo paslaugos kaip verslo proceso sampratos analizė	11
1.1.1. Klientų aptarnavimo tipologijos ir jų specifikos apžvalga	14
1.1.2. Klientų aptarnavimo procesuose taikomų metodologijų ir praktikų analizė	19
1.1.3. Aktualių problemų identifikavimas techniniame klientų aptarnavime.....	23
1.2. Pagrindinių veiklos rodiklių reikšmė techninio klientų aptarnavimo proceso efektyvumui	27
1.2.1. Klientų aptarnavime naudojamų pagrindinių veiklos rodiklių apžvalga	28
1.3. Sėkmingo DI panaudojimo veiksniai ir galimybės klientų aptarnavimo procesu	31
1.3.1. DI panaudojimo kryptys klientų aptarnavimo procesuose	34
1.3.2. Dirbtinio intelekto diegimo intensyvumo dimensijos ir vertinimas	39
1.3.3. Užduočių ir technologijų atitikimo svarba dirbtinio intelekto diegimui	41
1.4. Organizacinis pasirengimas dirbtinio intelekto kontekste	44
1.4.1. Organizacinio pasirengimo pagrindai ir techninė infrastruktūra	45
1.4.2. Žmogiškojo kapitalo, vadovybės palaikymo ir duomenų kokybės įtaka DI sprendimams	49
1.5. Klientų aptarnavimo proceso ir dirbtinio intelekto pritaikymo analizės išvados	51
2. DIRBTINIO INTELEKTO PANAUDOJIMO SĖKMĖS FAKTORIŲ KLIENTŲ APTARNAVIMO PROCESUOSE EMPIRINIO TYRIMO METODIKA	53
2.1. Tyrimo tikslas, modelis ir hipotezės	53
2.2. Tyrimo instrumentas, tiriamųjų populiacija, imtis ir atranka	60

2.3.	Tyrimo organizavimas	63
2.4.	Tyrimo metodai.....	64
3.	DI INTEGRACIJOS SĖKMĖS FAKTORIŲ IR JŲ POVEIKIO TECHNINIO KLIENTŲ APTARNAVIMO EFEKTYVIMUI TYRIMO REZULTATŲ ANALIZĖ IR VERTINIMAS.....	67
3.1.	Tyrimo respondentų rezultatų ir konstrukčių patikimumo analizė.....	67
3.2.	Tyrimo naudotų konstrukčių aprašymas	69
3.3.	Matavimo modelio analizės rezultatai	72
3.3.1.	Matavimo modelio vertinimas - LOC konstrukčiai	73
3.3.2.	Matavimo modelio vertinimas - HOC konstrukčiai	81
3.4.	Struktūrinio modelio vertinimas (HOC)	84
3.5.	Hipotezių tikrinimo rezultatai	88
3.6.	Tyrimo rezultatų diskusija	90
3.7.	Tyrimo apribojimai	92
4.	IŠVADOS IR PASIŪLYMAI.....	93
	Literatūros sąrašas.....	95
	PRIEDAI.....	124

LENTELIŲ SĄRAŠAS

1 lentelė	<i>Klientų aptarnavimo tipologijos palyginimas.....</i>	<i>16</i>
2 lentelė	<i>Techniniame klientų aptarnavime sutinkamų metodologijų vertinimas</i>	<i>21</i>
3 lentelė	<i>Techninio klientų aptarnavimo problemų sisteminė analizė</i>	<i>26</i>
4 lentelė	<i>Diegimo intensyvumo konstrukta formuojantys LOC konstruktai.....</i>	<i>57</i>
5 lentelė	<i>Organizacinio pasirengimo konstrukta formuojantys LOC konstruktai.....</i>	<i>58</i>
6 lentelė	<i>Užduoties-technologijos pasirengimo konstrukta formuojantys LOC konstruktai.....</i>	<i>59</i>
7 lentelė	<i>Techninio klientų aptarnavimo proceso efektyvumo konstrukta formuojantys LOC konstruktai.....</i>	<i>60</i>
8 lentelė	<i>Tyrimo demografiniai rezultatai.....</i>	<i>63</i>
9 lentelė	<i>Priklausomų HOC konstrukty statistinis galingumas.....</i>	<i>69</i>
10 lentelė	<i>Pirminio LOC modelio kolinearumo analizės rezultatai.....</i>	<i>74</i>
11 lentelė	<i>LOC indikatorių išoriniai koreliacijos koeficientai.....</i>	<i>77</i>
12 lentelė	<i>LOC matavimo modelio vidinis suderinamumas</i>	<i>78</i>
13 lentelė	<i>Probleminiai LOC indikatoriai.....</i>	<i>79</i>
14 lentelė	<i>Galutinio LOC matavimo modelio VIF vertės</i>	<i>80</i>
15 lentelė	<i>HOC matavimo modelio kolinearumo rezultatai.....</i>	<i>81</i>
16 lentelė	<i>HOC matavimo modelio išoriniai svoriai ir reikšmingumas.....</i>	<i>83</i>
17 lentelė	<i>HOC struktūrinio modelio VIF reikšmės</i>	<i>84</i>
18 lentelė	<i>Ryšių koeficientų rezultatai HOC struktūriniame modelyje</i>	<i>85</i>
19 lentelė	<i>Determinacijos koeficientai HOC struktūriniame modelyje.....</i>	<i>85</i>
20 lentelė	<i>Efekto dydis HOC struktūriniame modelyje</i>	<i>86</i>
21 lentelė	<i>PLSpredict testo rezultatai.....</i>	<i>87</i>
22 lentelė	<i>CVPAT testo rezultatai</i>	<i>88</i>
23 lentelė	<i>Hipotezių tikrinimo rezultatai</i>	<i>89</i>

PAVEIKSLŲ SĄRAŠAS

1 paveikslas	<i>Efektyvaus klientų aptarnavimo įtaka</i>	<i>14</i>
2 paveikslas	<i>Užduoties-technologijos atitikimo modelio reikšmė.....</i>	<i>41</i>
3 paveikslas	<i>Dirbtinio intelekto panaudojimo klientų aptarnavime tyrimo modelis</i>	<i>55</i>
4 paveikslas	<i>LOC matavimo modelio pirminis variantas</i>	<i>71</i>
5 paveikslas	<i>HOC struktūrinis modelis.....</i>	<i>72</i>
6 paveikslas	<i>Galutinis LOC matavimo modelis</i>	<i>76</i>

SANTRUMPŲ SĄRAŠAS

1. DI – dirbtinis intelektas
2. KPI – (angl. *key performance indicator*) pagrindinis veiklos rodikliai
3. IT – informacinės technologijos
4. ITIL – (angl. *Information Technology Infrastructure Library*) informacinių technologijų infrastruktūros biblioteka
5. SLA – (angl. *Service Level Agreement*) paslaugų lygmens susitarimas
6. KCS – (angl. *Knowledge-Centered Service*) į žinias orientuotos paslaugos
7. FCR – (angl. *First Contact Resolution*) pirmojo kontakto išsprendimo rodiklis
8. NLP – (angl. *Natural Language Processing*) natūraliosios kalbos apdorojimas
9. ML – (angl. *Machine Learning*) mašininis mokymasis
10. LLM – (angl. *Large Language Models*) didieji kalbos modeliai
11. CSAT – (angl. *Customer Satisfaction Score*) klientų pasitenkinimo įvertinimas
12. NPS – (angl. *Net Promoter Score*) klientų rekomendavimo indeksas
13. TOE – (angl. *Technology-Organization-Environment*) technologijos-organizacijos-aplinkos modelis
14. TTF – (angl. *Task-Technology Fit*) užduočių-technologijų atitikimas
15. PLS-SEM – (angl. *Partial Least Squares Structural Equation Modeling*) dalinių mažiausiųjų kvadratų struktūrinių lygčių modeliavimas
16. HOC – (angl. *Higher Order Constructs*) aukštesnio lygio konstruktai
17. LOC – (angl. *Lower Order Constructs*) žemesnio lygio konstruktai
18. VIF – (angl. *Variance Inflation Factor*) dispersijos išpūtimo faktorius
19. AVE – (angl. *Average Variance Extracted*) vidutinė dispersijos reikšmė
20. HTMT – (angl. *Heterotrait-Monotrait Ratio*) heterogeninio-monogeninio ryšio santykis

IVADAS

Technologijų transformacija dirbtinio intelekto srityje iš esmės keičia verslo procesų valdymo praktiką ir suteikia įmonėms naujų galimybių didinti veiklos efektyvumą. Techninis klientų aptarnavimas, sudėtinga ir žiniomis grįsta verslo dalis, tampa svarbia dirbtinio intelekto taikymo sritimi (Huang ir Rust, 2018). Tačiau, nepaisant didėjančio dėmesio dirbtinio intelekto sprendimams, vis dar trūksta aiškaus supratimo, kokie organizaciniai ir technologiniai veiksniai yra svarbiausi sėkmingai DI integracijai ir kaip jie iš tiesų veikia procesų efektyvumą. Šiandieninėje verslo aplinkoje techninis klientų aptarnavimas susiduria su tokiais iššūkiais: didėjančiu užklausų sudėtingumu, augančiais klientų lūkesčiais ir poreikiu užtikrinti greitą, tikslų ir personalizuotą aptarnavimą (Dombrowski ir Malorny, 2016; Trkman ir kt., 2015). Tradiciškai techniniu aptarnavimu užsiima specialistai, turintys galias specializuotas žinias ir pasižymintys gebėjimu spręsti sudėtingas technines problemas. Tačiau nuolat augantis problemų kiekis ir jų įvairovė skatina ieškoti naujų sprendimų, galinčių padidinti techninio aptarnavimo efektyvumą. Vienas tokių sprendimų – dirbtinio intelekto technologijų integravimas.

Dirbtinio intelekto sprendimai, apimantys natūraliosios kalbos apdorojimą, mašininį mokymąsi, didžiuosius kalbos modelius ir kitas technologijas, turi potencialo ženkliai pagerinti techninio aptarnavimo procesus (Xu ir kt., 2020). Jie gali padėti automatizuoti pasikartojančias užduotis, pateikti greitesnius ir tikslesnius atsakymus į klientų užklausas, numatyti klientų poreikius ir efektyviau paskirstyti darbo krūvį. Vis dėlto, nepaisant šių galimybių, DI diegimas įmonėse neretai susiduria su įvairiais iššūkiais, o dalis DI projektų nepasiekia numatytų rezultatų (Ångström ir kt., 2023).

Mokslinėje literatūroje pastebimas vis didesnis susidomėjimas veiksniais, lemiančiais sėkmingą DI diegimą. Atliktas Jöhnk ir kt. 2021 m. tyrimas pabrėžia organizacinio pasirengimo svarbą DI projektų sėkmei, akcentuodamas tokius aspektus kaip techninė infrastruktūra, darbuotojų kompetencijos ir vadovybės palaikymas. Taip pat Goodhue ir Thompson 1995 m. pasiūlyta užduočių ir technologijų atitikimo teorija nurodo, kad technologijų efektyvumas priklauso nuo to, kaip gerai jos atitinka atliekamų užduočių charakteristikas. Šių teorinių perspektyvų derinimas suteikia vertingą analizės sistemą siekiant suprasti dirbtinio intelekto integracijos sėkmės veiksnius techninio klientų aptarnavimo kontekste.

Darbo temos aktualumas:

Dirbtinio intelekto integracijos sėkmės veiksnių tyrimas techninio klientų aptarnavimo kontekste yra reikšmingas tiek teoriniu, tiek praktiniu požiūriu. Techninis klientų aptarnavimas vaidina esminį vaidmenį formuojant klientų pasitenkinimą, lojalumą ir įmonės reputaciją, todėl jo efektyvumo didinimas tampa strategine būtinybe (Sheth ir kt., 2023; Westlund ir kt., 2005). Neefektyvūs techniniai aptarnavimo procesai lemia ilgesnius problemų sprendimo laikus, nepakankamą techninių žinių panaudojimą ir augančias veiklos sąnaudas. Nors įmonės vis aktyviau investuoja į dirbtinio intelekto technologijas ir sprendimus, šios investicijos dažnai neužtikrina laukiamų rezultatų. Naujų DI technologijų diegimas, nesuprantant esminių sėkmės veiksnių, dažnai neveda prie pageidaujamų pokyčių (Ångström ir kt., 2023). Būtent todėl aktualu ištirti, kokie veiksniai užtikrina sėkmingą DI integravimą į techninio klientų aptarnavimo procesus ir kaip jie sąveikauja tarpusavyje.

Analizuojamos temos ištyrimo lygis:

Jau egzistuoja mokslinių publikacijų, kurios nagrinėja atskirus dirbtinio intelekto integracijos aspektus, tačiau stokojama holistinio požiūrio. DI taikymo klientų aptarnavime atlikti tyrimai (Huang ir Rust, 2018; Xu ir kt., 2020) atskleidžia DI potencialą automatizuojant įvairias klientų aptarnavimo funkcijas, tačiau nesusieja DI integracijos su organizaciniu pasirengimu ir užduočių-technologijų atitikimu. Organizacinį pasirengimą dirbtinio intelekto naudojimui vertinantys tyrimai (Jöhnk ir kt., 2021; Makarius ir kt., 2020) išryškina techninės infrastruktūros, darbuotojų kompetencijų ir vadovybės palaikymo svarbą. Užduočių-technologijų atitikimo teorija (Goodhue ir Thompson, 1995) jau yra plačiai taikoma įvairiuose informacinių technologijų kontekstuose, tačiau jos taikymas DI sprendimams, ypač techninio klientų aptarnavimo srityje, išlieka menkai ištirtas ir patikrintas. Pastebimas empirinių tyrimų trūkumas, kurie tirtų kompleksinę ryšį tarp DI diegimo intensyvumo, organizacinio pasirengimo ir užduočių-technologijų atitikimo bei jų bendro poveikio techninio aptarnavimo efektyvumui.

Darbo naujumas:

Šiuo darbu siekiama papildyti DI integracijos tyrimus sukuriant ir empiriškai patikrinant integruotą teorinį modelį, apjungiantį Technologijos-Organizacijos-Aplinkos (TOE) ir Užduočių-Technologijų atitikimo (TTF) teorinius aspektus. Tokia teorinių

modelių sintezė leidžia visapusiškiau įvertinti DI integracijos sėkmės veiksnius, įtraukiant tiek technologinius, tiek organizacinius aspektus ir vertinant jų tarpusavio sąveiką. Darbe dėmesys skiriamas naujai besiformuojančiai techninio lankstumo (angl. *technical agility*) sąvokai ir jos įtakai DI diegimo sėkmei. Techninis lankstumas, apibūdinamas kaip įmonės darbuotojų gebėjimas greitai prisitaikyti prie technologinių pokyčių, efektyviai įsisavinti naujas technologijas ir lanksčiai jas taikyti kasdienėse užduotyse, tampa vis svarbesniu veiksniumi DI integracijos procesuose.

Darbo problema:

Įmonės, siekdamos didinti techninio klientų aptarnavimo efektyvumą, vis dažniau diegia dirbtinio intelekto sprendimus. Tačiau kyla klausimas, nuo ko visgi reiktų pradėti? Dirbtinio intelekto diegimas vykdomas be sisteminio požiūrio, neatsižvelgiant į organizacinio pasirengimo lygį ar specifines techninio aptarnavimo užduočių charakteristikas, gali nulemti neefektyvias investicijas į DI sprendimus, nepasiekiamus norimus veiklos rodiklius ir nepakankamą procesų optimizavimą. Problemą galima apibendrinti klausimu: kokie veiksniai lemia dirbtinio intelekto integracijos sėkmę techninio klientų aptarnavimo procesuose ir kaip jie veikia techninio klientų aptarnavimo procesų efektyvumą?

Darbo tikslas:

Ištirti dirbtinio intelekto diegimo intensyvumo, organizacinio pasirengimo ir užduočių-technologijų atitikimo sąveiką bei įvertinti jų įtaką techninio klientų aptarnavimo procesų efektyvumui Lietuvos informacinių technologijų, telekomunikacijų ir aukštųjų technologijų gamybos sektoriuose.

Darbo uždaviniai

1. Atlikti mokslinės literatūros analizę, siekiant identifikuoti kaip yra apibrėžiami techninio klientų aptarnavimo procesai, jų elementai ir bendra svarba konkurencinei padėčiai.
2. Identifikuoti dirbtinio intelekto panaudojimo būdus ir juos tiriančią mokslinę literatūrą, išryškinant potencialias dirbtinio intelekto teikiamas naudas ir rizikas techniniame klientų aptarnavime ir apžvelgti svarbiausius DI integracijos sėkmės veiksnius.
3. Sukurti teorinį modelį skirtą ištirti dirbtinio intelekto diegimo intensyvumo, organizacinio pasirengimo ir užduočių-technologijų konstruktus techninio

klientų aptarnavimo kontekste ir atlikus empirinį tyrimą įvertinti teorinio modelio pagrįstumą.

4. Įvertinti tiesioginius ir netiesioginius ryšius tarp dirbtinio intelekto diegimo intensyvumo, organizacinio pasirengimo, užduočių-technologijų atitikimo ir techninio klientų aptarnavimo efektyvumo.
5. Pateikti rekomendacijas sėkmingam DI integravimui IT įmonėse.

Darbo metodai:

1. Mokslinės literatūros analizė, skirta teoriškai apibrėžti DI integracijos sėkmės veiksnius techniniame klientų aptarnavime.
2. Kiekybinis tyrimas, naudojant anketinę apklausą, skirtą apklausti darbuotojus iš IT, telekomunikacijų ir aukštųjų technologijų sektorių įmonių.
3. Statistinė duomenų analizė, vykdyta taikant dalinių mažiausiųjų kvadratų struktūrinių lygčių modeliavimą (PLS-SEM), siekiant patikrinti teorinį modelį ir hipotezes.

Darbo struktūra:

Darbą sudaro įvadas, trys pagrindiniai skyriai (literatūros analizė, metodologinė dalis, tyrimo analizė ir vertinimas) išvados ir pasiūlymai, literatūros sąrašas ir priedai. Darbo apimtis 88 psl. Darbe pateiktos 22 lentelės ir 6 paveikslai.

1. DIRBTINIO INTELEKTO INTEGRACIJOS Į TECHNINIO KLIENTŲ APTARNAVIMO PROCESUS TEORINIAI ASPEKTAI

1.1. Klientų aptarnavimo paslaugos kaip verslo proceso sampratos analizė

Šiuolaikinėse globalinėse rinkose, pasižyminčiose didele panašių produktų ar paslaugų pasiūla ir itin stipria konkurencija, sklandus klientų aptarnavimas yra vienas iš pagrindinių veiksnių, lemiančių verslo sėkmę (Sheth ir kt., 2023). Klientų aptarnavimas atlieka svarbų vaidmenį kuriant bendrą kliento patirtį ir užtikrinant tvarų konkurencinį pranašumą.

Klientų aptarnavimo procesas - svarbi darbo eigos sudedamoji dalis, apimanti struktūrizuotą veiklą, skirtą veiksmingai patenkinti klientų poreikius ir lūkesčius prieš, per ar po prekės ar paslaugos įsigijimo (Christopher ir kt., 1991). Šiuose procesuose, glaudžiai susijusiuose su kitais įvairiais verslo procesais, daugiausia dėmesio skiriama savalaikiam ir tiksliam atsakymui į klientų užklausas, techninių problemų sprendimui ir sklandžios kliento aptarnavimo patirties užtikrinimui. Verslo procesai, įskaitant klientų aptarnavimą, turi būti suderinti su įmonių verslo strategija, kad būtų sukuriamas maksimali pridėtinė vertė klientams ir kitoms suinteresuotosioms šalims (Tomat ir Trkman, 2019).

Vertinant klientų aptarnavimą kaip verslo procesą, svarbu suvokti jį kaip visumą – ne pavienę funkciją, o aiškiai apibrėžtą veiksmų seką, integruotą į platesnę įmonės kuriamos vertės grandinę. Vadybos literatūroje plačiai naudojamas verslo procesų valdymo (BPM) požiūris padeda tokius procesus modeliuoti, analizuoti ir nuolat tobulinti (Davenport ir Stoddard, 1994; Harmon, 2010; Rosemann ir vom Brocke, 2015). Pasitelkdamos šį požiūrį, įmonės gali aiškiai identifikuoti esmines proceso grandis, suprasti informacijos srautus ir nustatyti, kurioje stadijoje sukuriamas didžiausias vertė, o kur susidaro trukdžiai. Šis sisteminis požiūris į klientų aptarnavimą yra itin svarbus, nes aptarnavimo kokybė ir operatyvumas tiesiogiai siejasi ne tik su klientų pasitenkinimu, bet ir su kitais verslo procesais, pavyzdžiui, pardavimų, tiekimo grandinės valdymu ar rinkodaros procesais. Kuomet klientų aptarnavimo procesas yra aiškiai apibrėžtas ir nuosekliai valdomas, įmonei tampa lengviau suderinti jį su bendrais strateginiais tikslais, efektyviau paskirstyti išteklius, greičiau reaguoti į kintančius klientų poreikius ir stiprinti savo pozicijas rinkoje (Tomat ir Trkman, 2019).

Sisteminis požiūris į klientų aptarnavimą taip pat sudaro prielaidas vėliau nustatyti atitinkamus pagrindinius veiklos rodiklius ir vertinti proceso efektyvumą nuo atsakymo

laiko iki problemų sprendimo greičio ar klientų pasitenkinimo rodiklių (Asih ir kt., 2020). Esant aiškiai matuojamoms ir valdomoms proceso dalims, atsiveria galimybė taikyti pažangias priemones, pvz. dirbtinį intelektą, kuris galėtų padėti automatizuoti dažnai pasikartojančias nesudėtingas užduotis ar iš anksto prognozuoti išteklių poreikius (Adam ir kt., 2021). Taip suformuojamas tvirtas pamatas priimti duomenimis paremtus sprendimus siekiant strateginių veiklos tikslų, suteikiant įrankius tiksliniams patobulinimams, didinantiems klientų aptarnavimo proceso efektyvumą ir įmonės konkurencingumą.

Kaip verslo procesui, klientų aptarnavimui būdingas dažnas cikliškumas, tarp funkcinių pobūdžių ir priklausomybės nuo žmogiškųjų ir technologinių išteklių. Technologinė pažanga klientų aptarnavimą pavertė dinamišku ir į duomenis orientuotu procesu. Ryšio kanalų, tokių kaip gyvi pokalbiai, el. paštas ir socialinės žiniasklaidos platformos, gausėjimas reikalauja, kad įmonės integruotų daugiakanales strategijas (Gerea ir kt., 2021). Atliktas paslaugų teikimo įvairiais kanalais tyrimas rodo, kad įmonės, gebančios palaikyti nuoseklumą šiuose kanaluose, pasižymi didesniu klientų įsitraukimu ir veiklos efektyvumu (Quach ir kt., 2022).

Efektyvus klientų aptarnavimas gali suteikti keletą svarbių strateginių pranašumų produktų ar paslaugų pardavimų procesui: atsparumą ekonomikos svyravimams, didesnę pelno maržą, ir didesnę stabilumą krizių metu (Dombrowski ir Malorny, 2016). Taip pat įmonės, kurios naudoja sąveikos su klientais įžvalgoms, klientų aptarnavimo procesas gali lemti didesnę pelno augimą, paremtą glaudesniu ryšiu su klientais, spartesniu inovacijų kūrimu atsižvelgiant į klientų grįžtamąjį ryšį ir tiksliau įvertinti dabarties ir ateities poreikius (Wirtz ir Daiser, 2018). Tačiau siekiant užtikrinti sklandų klientų aptarnavimą dėl didėjančio produktų ar paslaugų kompleksiskumo, vis dažniau susiduriama su iššūkiais, siekiant pasiekti norimą efektyvumą (Dombrowski ir Malorny, 2016). Šie iššūkiai gali būti:

- dažnas aptarnavimo procesų kintamumas;
- didėjantys klientų reikalavimai klientų aptarnavimo proceso kokybei;
- augantis poreikis įvairiapusių paslaugų teikimui.

Šių iššūkių akivaizdoje tampa itin svarbu nuosekliai įvertinti klientų aptarnavimo proceso ypatybes, nustatyti pagrindinius veiklos rodiklius ir pritaikyti tinkamas valdymo ir tobulinimo priemones, kurios padėtų išlaikyti aukštą paslaugų kokybę ir užtikrinti tvarų įmonės konkurencingumą.

Klientų aptarnavimo procesas neapsiriboja vien tiesioginiu veiklos kontekstu, neretai klientų aptarnavimas yra vienas iš pirmųjų įmonės ir jos klientų sąlyčio taškų


(Ritala ir kt., 2013). Gerai struktūrizuotas klientų aptarnavimo procesas yra ne tik svarbus sprendžiant klientų problemas, bet tuo pačiu ir veikia kaip klientų grįžtamojo ryšio saugykla.

Nuosekliai vykdomas ir gerai organizuotas klientų aptarnavimo procesas daro tiesioginę įtaką klientų išlaikymo rodikliams. Išlaikomi klientai paprastai generuoja didesnes ilgalaikes pajamas, nes dažniau atnaušina paslaugų prenumeratas, reguliariai perka pakartotinai ir mažiau linkę pereiti pas konkurentus (Reichheld, 2003). Be to, lojalūs klientai dažnai tampa neformaliais įmonės ambasadoriais, savo teigiamą patirtį perteikdami asmeniniuose ir skaitmeniniuose kanaluose. Stabilus ir teigiamas grįžtamasis ryšys ne tik mažina klientų išlaikymo ir pritraukimo kaštus, bet ir prisideda prie bendro įmonės augimo ir pelningumo didėjimo. Nuolat tobulinamas klientų aptarnavimo procesas sudaro tinkamas sąlygas palaikyti šį glaudų ryšį su vartotojais, ilgainiui formuojant tvarų ir nuspėjamą pajamų srautą (Westlund ir kt., 2005).

Be klientų išlaikymo, klientų aptarnavimo proceso kokybė daro esminę įtaką ir įmonės reputacijai ir prekės ženklo vertei. Aukštos kokybės klientų aptarnavimas formuoja pozityvias vartotojų asociacijas, didina jų pasitikėjimą įmone ir skatina palankius atsiliepimus viešojoje erdvėje (Keller, 2003). Teigiamas įmonės įvaizdis savo ruožtu palengvina plėtrą į naujas rinkas, didina darbuotojų motyvaciją ir prisideda prie stabilesnės derybinės pozicijos tiekėjų ar partnerių akyse. Apibendrinta klientų pasitenkinimo įtaka pateikiama 1 paveiksle, remiantis Westlund ir kt., (2005).

1 paveikslas

Efektyvaus klientų aptarnavimo įtaka



Šaltinis: Sudaryta autoriaus, remiantis Keller (2003); Westlund ir kt. (2005)

Tinkamai struktūruotas ir procesinėmis priemonėmis valdomas klientų aptarnavimas leidžia palaikyti šiuos reputacijos pranašumus, užtikrinant, kad įmonės vertybiniai pažadai atsispindėtų praktinėje klientų patirtyje ir stiprintų prekės ženklo konkurencingumą.

1.1.1. Klientų aptarnavimo tipologijos ir jų specifikos apžvalga

Siekiant sistemiškai suprasti klientų aptarnavimo procesą kaip verslo procesą, svarbu suprasti, kad klientų aptarnavimas nėra vienybė. Įmonės teikia įvairaus tipo paslaugas, atsižvelgdamos į klientų poreikius, naudojamus komunikacijos kanalus ir sąveikos sudėtingumą (Miguel ir Miranda, 2023). Pavyzdžiui, kai kuriais atvejais klientų aptarnavimas vyksta dar prieš pardavimą. Prieš pardaviminis aptarnavimas, kurio tikslas padėti potencialiems klientams suprasti produkto ar paslaugos savybes, palyginti galimus pasiūlymus, gauti informaciją apie kainodarą ir kitas sąlygas. Toks aptarnavimo tikslas - didinti klientų pasitikėjimą ir palengvinti jų sprendimų priėmimą (Katherine N. ir Verhoef, 2016).

Socialinių tinklų ir medijų laikais vis didesnė vieta tenka aptarnavimui naudojantis socialiniais tinklais. Įmonės pastebimai dažniau reaguoja į klientų komentarus, žinutes, atsiliėjimus viešai prieinamose socialinėse platformose („X“, „LinkedIn“, „Facebook“, „Instagram“), siekdamos operatyviai spręsti iškilusias problemas ir formuoti pozityvią

įmonės reputaciją (Serralvo ir Casas, 2024). Tokios skaitmeninės sąveikos skatina interaktyvumą, leidžia geriau suprasti kliento patirtį ir nuomonę, greitai reaguoti į didelio populiarumo klausimus.

Klientų aptarnavime taip pat pastebimas vis didesnis dėmesys savitarnos sprendimams: klientai gali naudotis interaktyviais gidais, dažniausiai užduodamų klausimų (DUK) puslapiais, „Wiki“, vaizdo pamokomis ar virtualiais asistentais. Tai suteikia jiems galimybę greitai ir nesudėtingai rasti atsakymus be tiesioginio darbuotojų įsikišimo, ypač kai klausimai nėra sudėtingi. Išsamūs ir kokybiški savitarnos sprendimai mažina klientų aptarnavimo skyrių apkrovą, gerina efektyvumą ir klientams suteikia laisvę greitai ir lengvai gauti informaciją bet kuriuo metu (Shin ir Dai, 2022).

Kai kuriuose sektoriuose taikomas specializuotas klientų aptarnavimas, skirtas svarbesniems, didesnės vertės ar specifinių poreikių klientams, greitai ir specifiskai reaguojant į kliento poreikius. Tokie modeliai leidžia pasiūlyti individualizuotas paslaugas, geriau atliepiančias kliento unikalų kontekstą (Rust ir Huang, 2014). Toks klientų ir jiems teikiamų paslaugų segmentavimas padeda įmonėms sukurti išskirtines patirtis ypač svarbiems klientams, didinant pasitenkinimą ir ilgalaikį lojalumą.

Galima matyti, jog klientų aptarnavimo tipai gali būti įvairūs, kiekvienas iš paminėtų tipų turi skirtingus tikslus, metodus, reikalauja skirtingų kompetencijų ir technologinių sprendimų. Vis dėlto tarp visų aptarnavimo formų yra viena, kuri išsiskiria savo sudėtingumu ir įtaka klientams kuriama verte – techninis klientų aptarnavimas (Gajic ir Boolaky, 2015).

Techninis aptarnavimas pasižymi specifine reikšme šiuolaikinėse rinkose, kuriose siūlomi produktai ir paslaugos yra vis sudėtingesni, gausėja pažangių technologinių sprendimų, auga tiek kliento, tiek paslaugos teikėjo sąveikos dažnis. Šiame kontekste techninis aptarnavimas gali būti suprantamas kaip atskiras klientų aptarnavimo paslaugų tipas, turintis aiškų tikslą – užtikrinti sklandų, efektyvų, saugų ir tikslingą produkto ar paslaugos naudojimą visą gyvavimo ciklą (Gajic ir Boolaky, 2015). Toks aptarnavimas svarbus ne tik todėl, kad leidžia operatyviai reaguoti į nesklandumus, bet ir dėl to, kad jis prisideda prie vertės klientui išsaugojimo ir didinimo, skatina didesnę lojalumą ir padeda formuoti teigiamą įmonės reputaciją (Dombrowski ir Malorny, 2016). Sisteminis aptarnavimo tipų palyginimas pateikiamas 1 lentelėje.

1 lentelė

Klientų aptarnavimo tipologijos palyginimas

Aptarnavimo tipas	Pagrindiniai bruožai	Laiko dimensija	Komunikacijos kanalai	Sudėtingumo lygis	Pagrindinis tikslas
Priešpardaviminis aptarnavimas	Informacijos teikimas apie produktus, konsultacijos, pagalba renkantis	Prieš pardavimą	Fizinis kontaktas, telefonas, skaitmeniniai kanalai	Žemas-vidutinis	Padėti klientams priimti sprendimus, suformuoti lūkesčius
Aptarnavimas socialiniuose tinkluose	Viešas reagavimas į klientų komentarus, žinutes, atsiliepimus	Visose stadijose	Socialiniai tinklai	Žemas-vidutinis	Operatyviai spręsti problemas, formuoti teigiamą įmonės reputaciją
Savitaros sprendimai	Interaktyvūs gidai, DUK, vaizdo pamokos, virtualūs asistentai	Visose stadijose	Skaitmeniniai kanalai	Žemas-vidutinis	Suteikti klientams galimybę savarankiškai išspręsti problemas
Specializuotas aptarnavimas	Skirtas svarbesniems klientams, individualizuotos paslaugos	Visose stadijose	Daugiakanalinis, dažnai asmeninis kontaktas	Vidutinis-aukštas	Tenkinti specifinius aukštos vertės klientų poreikius
Techninis aptarnavimas	Techninių problemų sprendimas, specifinių žinių reikalaujančios konsultacijos	Dažniausiai po pardavimo	Daugiakanalinis, nuotoliu	Aukštas	Užtikrinti sklandų produkto/paslaugos naudojimą, spręsti technines problemas

Šaltinis: sudaryta autoriaus remiantis Gajic ir Boolaky, 2015; Serralvo ir Casas, 2024; Shin ir Dai, 2022

Vienas iš pagrindinių techninio aptarnavimo požymių – sudėtingesnis problemų pobūdis. (Gajic ir Boolaky, 2015). Skirtingai nuo paprastesnių klientų užklausų, susijusių su nesudėtingu informacijos paaiškinimu, techninis aptarnavimas neretai reikalauja specialių inžinerinių, informacinių technologijų, mechanikos, elektronikos ar kitų sričių žinių. Aukštųjų technologijų sektoriuje, toks aptarnavimas gali apimti programinės įrangos klaidų diagnostiką ir šalinimą, aparatinės įrangos konfigūracijų optimizavimą, sistemų integraciją ir kitus darbus, kuriems įprastos, bendrinės kompetencijos nepakanka

(Paiola ir Gebauer, 2020). Techninio aptarnavimo darbuotojai turi mokėti atpažinti problemos kilmę ir priežastį, turėti prieigą prie atitinkamų dokumentacijos šaltinių, reikiamų žinių duomenų bazių, diagnostinių įrankių, taip pat neretai gali tekti glaudžiai bendradarbiauti su kitais skyriais, prižiūrinčius kitus procesus: projektavimo, tiekimo, gamybos, marketingo.

Techninio klientų aptarnavimo užduotys pasižymi įvairiu kompleksiskumo lygiu, struktūros apibrėžtumu ir pasikartojimo dažniu. Paprastesnės, gerai struktūruotos ir dažnai pasikartojančios užduotys, tokios kaip slaptažodžių atstatymas ar standartinių nustatymų konfigūravimas, gali būti efektyviai automatizuojamos pasitelkiant dirbtinio intelekto sprendimus (Wulf ir Meierhofer, 2024). Tuo tarpu sudėtingesnės, mažiau struktūruotos problemos, reikalaujančios gilesnės analizės ir ekspertinio vertinimo, gali būti efektyviausiai sprendžiamos pasitelkiant dirbtinio intelekto technologijas kartu su inžinierių-ekspertų kompetencijomis.

Kitas svarbus techninio aptarnavimo aspektas yra jo reikšmė kliento kelionėje. Techninis aptarnavimas dažniausiai vykdomas po pardavimo, kai klientas jau įsigijo produktą ar paslaugą (Dombrowski ir Malorny, 2016). Tokiu atveju orientuojamasi į vertės išlaikymą ar didinimą, užtikrinant, kad klientas sugebėtų tinkamai pasinaudoti savo įsigytu produktu ar paslauga (Haryadi ir kt., 2022; Katherine N. ir Verhoef, 2016). Vis dėlto, techninis aptarnavimas gali būti reikšmingas ir anksčiau – pavyzdžiui, kai potencialus klientas svarsto produkto įsigijimą ir jam reikalingas papildomas paaiškinimas ar techninės konsultacijos dėl produkto ar paslaugos specifikacijų ar optimaliausių panaudojimo galimybių. Tokiu atveju efektyvus ir kokybiškas techninis aptarnavimas gali tapti pranašumu, padedančiu klientui priimti sprendimą, taip parodant, kad įmonė pasirengusi ir sugeba užtikrinti visapusišką produkto ar paslaugos palaikymą ir po pardavimo akto (Haryadi ir kt., 2022).

Būtina paminėti ir daugialypį techninio klientų aptarnavimo sprendžiamų problemų pobūdį. Paprastesnės, pasikartojančios problemos, tokios kaip pirminė įrangos konfigūracija, slaptažodžio atstatymas, paprastų klaidų šalinimas, gali būti greitai išsprendžiamos remiantis standartizuotomis procedūromis ir automatizuotomis priemonėmis (Følstad ir Brandtzæg, 2017). Tuo tarpu sudėtingesni atvejai, susiję su nestandartiniais trukdžiais, integracijos nesklandumais ar kompleksiniais gedimais, reikalauja gilios ekspertinės kompetencijos, neretai sukauptos per ilgesnę darbuotojų patirtį ir užfiksuotos vidinėse žinių bazėse. Šiose situacijose teorinis įmonės gebėjimas taikyti procesų valdymo metodologijas, matuoti veiklos rodiklius, sistemingai kaupti ir naudoti žinias tampa itin svarbus (Chee ir Husin, 2020). Gerai struktūruotas procesas gali

nulemti, kad techninio aptarnavimo inžinieriai specialistai greičiau sugebės identifikuoti problemą, suras sprendimą žinių bazėse arba sukurs naują sprendimą, kuris vėliau taps prieinamas kitiems darbuotojams (Lineberry, 2019a).

Didesnis techninių problemų sudėtingumas pasireiškia ir poreikiu taikyti aktualias verslo procesų valdymo metodikas, siekiant užtikrinti efektyvų darbo planavimą ir vykdymą. Pavyzdžiui, ITIL standartai IT sektoriuje padeda organizuoti incidentų valdymą ir problemų sprendimą (Ogosi Auqui ir kt., 2023), o KCS metodologija – sistemingai kaupti technines žinias žinių bazėse, kad vėliau darbuotojai galėtų greitai remtis sukaupta patirtimi. Tokiu būdu techninis aptarnavimas tampa ne tik užduočių atlikimu, bet ir mokymosi procesu, kuriuo siekiama ilgalaikės naudos – efektyvesnio žinių valdymo, greitesnio reagavimo ir geresnės klientų patirties (Lineberry, 2019a).

Techninis aptarnavimas yra ne tik vertikalus įgūdžių ir žinių klausimas, bet ir horizontali grandis, jungianti skirtingas įmonės funkcijas. Klientų aptarnavimo skyriaus darbuotojai privalo bendradarbiauti ir dalintis grįžtamojo ryšiu su produktų vystymo, kokybės užtikrinimo ir kitų skyrių specialistais, siekiant efektyviai spręsti klientų problemas ir užtikrinti pastovų tobulėjimą (Chee ir Husin, 2020). Toks bendradarbiavimas reiškia, kad sėkmingas techninio aptarnavimo procesas reikalauja ne tik gerai parengtų procedūrų, bet ir atviros organizacinės kultūros, paremtos sklandžia informacijos kaita, nuolatiniu tobulėjimu ir eksperimentavimu (Betim ir kt., 2018).

Techninio aptarnavimo efektyvumas taip pat priklauso ne tik nuo technologinių sprendimų, bet ir nuo organizacinio pasirengimo. Tai apima tinkamos techninės infrastruktūros sukūrimą, darbuotojų kvalifikacijos kėlimą, pastovų procesų optimizavimą ir tinkamos organizacinės kultūros formavimą, kuri būti palanki technologiniams pokyčiams (Jöhnk ir kt., 2021). Techninio aptarnavimo darbuotojai turi sugebėti efektyviai bendradarbiauti su kitais skyriais, dalintis žiniomis ir greitai prisitaikyti prie naujų darbo metodų bei įrankių. Todėl vertinant dirbtinio intelekto sprendimų potencialą techninio klientų aptarnavimo procesų efektyvumui didinti, būtina atsižvelgti ne tik į technologinius aspektus, bet ir į platesnį organizacinį kontekstą.

Apibendrinant galima teigti, kad klientų aptarnavimo paslaugų tipologija yra plati ir apima įvairius poreikius ir problematiką, tačiau techninis aptarnavimas joje užima ypatingą vietą. Tai specializuotas, sudėtingesnis ir klientui teikiamos vertės didinimą užtikrinantis procesas, kuris susijęs su nuolatiniu kompetencijų gilinimu, atnaujinimu, žinių centralizavimu ir efektyviu jų panaudojimu. Tai savo ruožtu prisideda prie didesnio visos įmonės veiklos efektyvumo, geresnės klientų patirties ir tvaresnio konkurencinio pranašumo.

1.1.2. Klientų aptarnavimo procesuose taikomų metodologijų ir praktikų analizė

Siekiant sistemingai valdyti ir organizuoti klientų aptarnavimo procesus, jų kompleksiskumą, efektyvų problemų sprendimą ir nuoseklumą, siekiant gerinti paslaugų kokybę, praktikoje naudojamos įvairios metodologijos ir gerosios praktikos. Aktualių metodologijų pritaikymas padeda aiškiai struktūruoti procesus, apibrėžti darbuotojų atsakomybes, nustatyti veiklos standartus ir sistemingai kaupti ir naudoti žinias. Kadangi klientų aptarnavimas (ypač techninis) tam tikrose situacijose tampa esmine įmonės konkurencinio pranašumo dalimi, tinkamai pasirinktos ir pritaikytos metodologijos leidžia mažinti operavimo kaštus, kelti paslaugų kokybės lygį, o rezultate didėja klientų pasitenkinimas ir lojalumas (Devineni, 2023; Malca ir kt., 2024).

Viena iš populiariesnių metodologijų klientų aptarnavimo procesams valdyti yra naudojamos struktūruotos, ITIL metodologijos principais grįstos sistemos, siekiančios standartizuoti incidentų, problemų ir pokyčių valdymą ir užtikrinti nuspėjamą paslaugų teikimo eigą, pateikia gerųjų praktikų rinkinį, padedantį nustatyti ir prioretizuoti paslaugų incidentus, iš anksto apibrėžti reagavimo procedūras ir nuolat vertinti pokyčių poveikį aptarnavimo kokybei (Rajagopal ir Ramkumar, 2023). Toks sisteminis požiūris užtikrina, kad rolės, atsakomybės ir laiko terminai būtų aiškiai apibrėžti, o pagrindiniai procesai – nuosekliai stebimi ir tobulinami. Vis dėlto, ITIL metodologijoms neretai pritrūksta lankstumo ir gebėjimo greitai adaptuotis prie nuolat kintančių klientų poreikių ar technologinių aplinkos pokyčių, todėl įmonės neretai ieško papildomų, ciklišką tobulinimą skatinančių praktikų (Soukayna ir kt., 2020).

Kitas klientų aptarnavime sutinkamas darbų vykdymo modelis – SLA – paslaugų lygmens susitarimai, kuriais nustatomi konkretūs veiklos vykdymo reikalavimai ir tikslai, kuriuos įmonės įsipareigoja užtikrinti. Šie susitarimai gali apibrėžti maksimalius reagavimo ar sprendimo pateikimo į užklausas laikus, taip pat SLA gali numatyti priimtina paslaugų kokybės lygį ir kitus sutartinius parametrus (Swain ir Garza, 2023). Praktikoje SLA padeda aiškiai nustatyti rodiklius, pagal kuriuos vertinamas procesų atitikimas sutartiems standartams, tačiau jie neretai nepakankamai skatina vidinį procesų tobulinimą ar lankstumą. Kitaip tariant, SLA veikia kaip kontrolės ir matavimo įrankis, suteikiantis formalų susitarimo pagrindą, bet neskatinantis nuolatinio mokymosi ir adaptacijos.

Siekiant užtikrinti efektyvią žinių sklaidą, įmonės vis dažniau pasitelkia žinių kaupimo - KCS (angl. *Knowledge-Centered Service*) metodologiją. Pagrindinė idėja – žinių kaupimas ir naudojimas sprendžiant klientų problemas yra integruojamas į kasdienę praktiką, o ne vykdomas kaip atskiras, nuo proceso atitrūkęs veiksmas. KCS principai ragina aptarnavimo specialistus kiekvieną unikalų išspręstą atvejį užfiksuoti

struktūrizuotose žinių bazėse, kuriose informacija tampa lengvai prieinama kitiems darbuotojams, kartais ir pačiam klientui per savitarnos įrankius (He ir Abdous, 2013). Tokiu būdu ne tik mažinama pasikartojančių užklausų sprendimo trukmė, bet ir gerėja sprendimų kokybė, nes yra kaupiama kolektyvinė patirtis. Naudojant KCS, įmonės artėja prie ciklinio tobulinimo modelio: kiekvienas naujas unikalus sprendimas tampa mokymosi šaltiniu, padedančiu ateityje panašias problemas išspręsti greičiau, naudoti jau sukauptas žinias ir sistemingai kelti klientų aptarnavimo lygį (Petersen, 2019).

KCS metodologija ypač aktuali techninio aptarnavimo kontekste, kur problemos dažnai reikalauja specializuotų žinių ir gilesnio supratimo apie produktų architektūrą, programinės įrangos versijas, aparatinės įrangos komponentus ar kitus specifinius aspektus. Šiuo atveju žinių bazės gali tapti centriniu informacijos šaltiniu, prie kurio prijungiami tiek klientų aptarnavimo darbuotojai, tiek automatizuoti pagalbos įrankiai - virtualūs DI asistentai, paieškos sistemos, semantinės analizės algoritmai (Sultan ir kt., 2023). Taip sprendžiamos kelios problemos vienu metu: trumpėja problemų sprendimo laikas, mažėja klaidų tikimybė, darbuotojai atlaisvinami nuo pasikartojančių užklausų, o klientai gauna galimybę greičiau rasti atsakymus savarankiškai (Lineberry, 2019).

Kita klientų aptarnavimo ir kituose verslo procesuose sutinkama metodologija – LEAN, pirmiausia akcentuoja, kad kiekvienas laukimas be tikslo, perteklinis klaidų taisymas ar informacijos dubliavimas yra „atliekos“, kurios mažina procesų efektyvumą (Rüttimann ir Stöckli, 2016). Tokie trukdžiai gali atsirasti tuomet, kai specialistai ilgai ieško instrukcijų skirtinguose dokumentuose, keliskart atlieka tą patį veiksmą tvarkydami užklausą ar yra priversti papildomai laukti dėl neapibrėžtos eskalavimo tvarkos (Al-Baik ir Miller, 2014). LEAN skatina sistemingai dekomponuoti procesus, identifikuoti, kuriose vietose yra atliekami nereikalingi veiksmai ir juos pašalinti. Pavyzdžiui, jei informacijos paieška žinių bazėje reikalauja daugiau nei keleto veiksmų, tai rodytų jog reikia peržiūrėti ir atnaujinti duomenų struktūrą, integruoti patobulintus paieškos algoritmus ar netgi pritaikyti automatizuotus sprendimus. Taip atsiskleidžia svarbus LEAN principas – nuolatinė ciklinė analizė ir tobulinimas. Tai reiškia, jog radus naujų procesinių spragų ar pasikartojančių trikdžių, darbuotojai turi koreguoti instrukcijas, sukurti paprastesnes procedūras ar sujungti kelis nedidelius veiksmus į vieną efektyvesnį žingsnį (Martin ir kt., 2014). Taip didinamas našumas ir sumažinama klaidų rizika, o galutinis rezultatas – operatyvesnis užklausų vykdymas ir sklandesnė klientų patirtis (Dombrowski ir Malorny, 2016).

Analizuojant klientų aptarnavime taikomas metodologijas, svarbu atkreipti dėmesį į jų sąsają su užduočių-technologijos atitikimo (angl. *Task-Technology Fit*, toliau - TTF)

teorija. Šis teorinis modelis pabrėžia, kad technologijos efektyvumas priklauso nuo to, kaip gerai ji atitinka atliekamų užduočių charakteristikas (Goodhue ir Thompson, 1995). Minėtos metodologijos (ITIL, KCS, LEAN) sukuria sistemingą pagrindą, leidžiantį aiškiau apibrėžti ir klasifikuoti techninio klientų aptarnavimo užduotis pagal jų struktūros lygį, sudėtingumą, pasikartojimo dažnį ir kitas charakteristikas. Šis klasifikavimas savo ruožtu padeda nustatyti, kokie technologiniai sprendimai (įskaitant dirbtinio intelekto sprendimus) yra tinkamiausi užduotims atlikti. Metodologijų vertinimas pateikiamas 2 lentelėje.

2 lentelė

Techniniame klientų aptarnavime sutinkamų metodologijų vertinimas

Metodologija	Pagrindinis tikslas	Pagrindiniai principai	Privalumai	Trūkumai
ITIL	Standartizuoti IT paslaugų valdymą ir užtikrinti procesų nuspėjamumą	Incidentų, problemų ir pokyčių valdymo standartizavimas. Aiškiai apibrėžtos rolės ir atsakomybės. Procesų cikliška peržiūra	Procesų nuoseklumas ir stabilumas. Aiškios atsakomybės.	Ribotas lankstumas. Didelis dokumentacijos kiekis.
SLA	Apibrėžti paslaugų teikimo lygį ir atsakomybių ribas	Konkrečių aptarnavimo metrikų nustatymas. Aiškūs kokybės parametrai.	Lengviau išmatuojami rezultatai. Aiškūs lūkesčiai. Paskatų ir sankcijų mechanizmas	Galima per didelė orientacija į susitarimų vykdymą. Mažai skatina tobulėjimą.
KCS	Optimizuoti žinių kaupimą, dalijimąsi ir panaudojimą	Žinių fiksavimas darbo eigoje. Kolektyvinė žinių bazės plėtra. Cikliškas žinių atnaujinimas	Efektyvesnis problemų sprendimas. Trumpesnis mokymosi laikas. Žinių išsaugojimas ir perpanaudojimas	Reikalauja kultūrinio pokyčio. Efektyvumui būtini geri įrankiai. Papildoma darbuotojų apkrova
LEAN	Šalinti procesų "atliekas" ir skirti dėmesį vertę kuriančioms užduotims	Vertės klientui identifikavimas. Nuolatinis procesų tobulinimas (Kaizen). Proceso "atliekų" šalinimas	Efektyvesnis resursų panaudojimas. Trumpesni atlikimo laikai. Lankstumas	Sudėtingas pritaikymas paslaugoms. Gali mažinti atsparumą netikėtiems iššūkiams. Reikalauja kultūrinio pokyčio

Šaltinis: sudaryta darbo autoriaus, remiantis Lineberry, 2019; Rüttimann ir Stöckli, 2016; Swain ir Garza, 2023

Visgi, techniniame aptarnavime, kaip ir kituose verslo procesuose neretai būtina derinti kelias metodologijas, kad būtų pasiekiamas norimas efektyvumas. Pavyzdžiui, KCS skatina sklandų ir nuoseklų žinių perdavimą, LEAN – padeda atskleisti perteklinius

veiksmus ar kitas procesines spragas, o SLA (kartu su ITIL) – aiškiai apibrėžti atsakomybes ir užtikrinti, kad įmonė laikysis minimalių ar tikslinių kokybės ir laiko rodiklių (Pawliczek ir kt., 2022). Vienos metodologijos pritaikymas savaime paprastai neišsprendžia visų problemų, todėl dauguma šiuolaikinių įmonių stengiasi kurti hibridinius modelius. Tokiuose modeliuose vienur akcentuojama LEAN kultūra, kitur – ITIL standartai arba SLA vykdymo stebėseną, o visa tai jungia KCS užtikrinamas žinių valdymas (Pankowska, 2019), be kurio techninis klientų aptarnavimas sunkiai būtų pasirengęs išspręsti didesnės apimties ar neįprastas problemas.

Minėtų metodologijų diegimas ir efektyvus taikymas įmonėse tiesiogiai priklauso nuo organizacinio pasirengimo lygio. Metodologijų, tokių kaip ITIL, KCS ar LEAN, sėkmingas taikymas priklauso nuo to, ar įmonė yra pasirengusi reikalingiems struktūriniais ir kultūriniais pokyčiams (Narayanamurthy ir kt., 2018). Pavyzdžiui, KCS metodologijos taikymas reikalauja ne tik žinių bazės infrastruktūros, bet ir darbuotojų, gebančių efektyviai dokumentuoti ir dalintis žiniomis, bei vadovybės, kuri pripažįsta žinių valdymo svarbą ir skiria tam reikiamus resursus.

Negana to, bet kurios metodologijos tikslingas taikymas reikalauja darbuotojų mokymų, nuolatinio vadovybės indėlio ir pasiryžimo kultūriniais pokyčiams (Heikkinen ir kt., 2023). Jei darbuotojai nėra tinkamai informuoti apie procesų keitimo tikslus ar neturi reikiamų įgūdžių, gali kilti pasipriešinimas naujovėms, o galutinis rezultatas – fragmentiškai arba formaliai pritaikyti metodai, neatnešantys apčiuopiamos naudos. Kita vertus, kai diegimas vyksta kryptingai, yra naudojamos aiškios mokymosi gairės ir analizuojamas grįžtamasis ryšys, tokios metodikos, kaip KCS, LEAN, ITIL ar SLA, gali padidinti įmonės pajėgumą reaguoti į kylančius iššūkius ir pokyčius (Heikkinen ir kt., 2023).

Nors aptartos metodologijos siūlo struktūruotus požiūrius į klientų aptarnavimo procesų valdymą, jų taikymas praktikoje susiduria su iššūkiais ir apribojimais. ITIL metodologija, nors ir suteikia visapusišką procesų valdymo sistemą, kritikuojama dėl pernelyg biurokratinio požiūrio ir riboto lankstumo, kas yra trūkumas greitai kintančioje verslo aplinkoje (Shang ir Lin, 2010). Griežtas ITIL principų laikymasis gali apsunkti inovacijų diegimo spartą ir mažinti įmonės gebėjimą greitai reaguoti į netikėtus pokyčius. SLA, nors ir padeda aiškiai apibrėžti klientų lūkesčius, gali sukelti siauro požiūrio efektą, kai darbuotojai orientuojasi tik į sutartyse numatytus rodiklius, neatsižvelgdami į klientų pasitenkinimą ar ilgalaikę vertę įmonei, neskiriant papildomo laiko procesų ar žinių tobulinimui, o sutelkdami didesnę dėmesį į SLA susitarimų įvykdymą. (Swain ir Garza, 2023). KCS metodologija, nors ir ypač veiksminga žinių valdymui, reikalauja

fundamentalaus organizacinės kultūros pokyčio ir nuolatinio palaikymo iš vadovybės. Be šių sąlygų, KCS taikymas virsta formaliu procesu be realios pridėtinės vertės (Lineberry, 2019c). LEAN principų taikymas paslaugų sektoriuje, ypač žiniomis grįstose srityse kaip techninis aptarnavimas, susiduria su nematerialių nuostolių identifikavimo problema ir rizika, kad perdėtai optimizuojami ir supaprastinami procesai praranda atsparumą netikėtiems pokyčiams ar nestandartinėms situacijoms (Rüttimann ir Stöckli, 2016).

Apibendrinant, ši lankstesnė, ciklišku grįsta procesų tobulinimo kultūra, apjungianti su darbų ir žinių valdymo metodologijomis suteikia įmonėms galimybę ne tik sumažinti pasikartojančių užduočių kiekį ar trumpinti atsako laiką, bet ir sėkmingai adaptuotis prie technologinių ir rinkos pokyčių. Tai aktualu ir techninio aptarnavimo kontekste – kur minėtų metodologijų hibridiniai modeliai padeda sėkmingai valdyti sudėtingus, daug kompetencijų reikalaujančius procesus. Skirtingų metodikų sinergija padeda subalansuoti formalumą ir aiškią struktūrą su reikiamu lankstumu. Tačiau, kaip ir visos metodologijos, jos neapsieina be trūkumų, į kuriuos būtina atsižvelgti taikant šias metodologijas, ypač jei taikomos kelios metodologijos vienu metu, svarbu įvertinti galimas rizikas, kurios gali atsirasti jas diegiant. Vis gi, šių metodologijų taikymas sukuria tvirtą pagrindą dirbtinio intelekto ir kitų pažangių technologijų integracijai į techninio klientų aptarnavimo procesus, užtikrinant tinkamą užduoties ir technologijos atitikimą, bei efektyvesnį organizacinį pasirengimą pokyčiams.

1.1.3. Aktualių problemų identifikavimas techniniame klientų aptarnavime

Nors ir anksčiau paminėtos metodologijos siūlo įvairius būdus, kaip prasmingai valdyti, tobulinti ir matuoti klientų aptarnavimo procesus, įmonės vis dar susiduria su iššūkiais, trukdančiais pasiekti pastovią ir aukštą klientų aptarnavimo kokybę (West ir kt., 2022). Šios problemos gali kilti dėl įvairių priežasčių: struktūrinių trūkumų, technologinės brandos stokos, nepakankamų žinių valdymo ir organizavimo praktikų naudojimo ar riboto strateginio požiūrio į klientų aptarnavimą kaip į svarbų verslo procesą (Lucio-Nieto ir kt., 2012).

Viena iš pagrindinių techninio klientų aptarnavimo problemų - pasikartojančių ir mažos vertės užduočių gausa (Xu ir kt., 2020). Tokios užduotys neretai sudaro reikšmingą dalį visų klientų užklausų srautų, tačiau jų poveikis galutinei kliento aptarnavimo kūriniui vertei – ribotas. Pavyzdžiui, tai gali būti elementarios užduotys (slaptažodžių atstatymas, nesudėtingų procedūrų paaiškinimas), kurias klientas galėtų savarankiškai atlikti, jei turėtų prieigą prie kokybiškų savitarnos įrankių ar automatizuotų sistemų (Rodriguez ir kt., 2024). Tokios mažos vertės užduotys eikvoja kvalifikuoto personalo

laiką, neleidžia jiems koncentruotis į sudėtingesnes, didesnę vertę kuriančias problemas ir taip mažina viso proceso efektyvumą. Mažos vertės užduotys taip pat dažnai neleidžia sistemiškai gerinti aptarnavimo kokybės, nes pastangos sutelkiamos į nuolatines, pasikartojančias veiklas, vietoje to kad būtų analizuojamos giluminės priežastys, lemiančias ilgesnį sprendimo laiką ar sudėtingų problemų nesavalaikį išsprendimą (Patrício ir kt., 2023).

Kita svarbi problema – pagrindinių veiklos rodiklių stoka arba jų nepakankama integracija į sprendimų priėmimo procesus (Dias, 2021; Gadekar ir kt., 2022). Be objektyvių, kiekybinių matavimo priemonių, tokių kaip vidutinis atsakymo laikas, pirmojo kontakto išsprendimo rodiklis, klientų pasitenkinimo indeksas (CSAT, NPS), SLA įgyvendinimo lygis ar kitų, su klientų aptarnavimu procesu susijusių metrikų, įmonės dažnai priima sprendimus remdamosi nuojautomis, neformaliomis patirtimis arba fragmentiška informacija (Dias, 2021). Dėl to sudėtinga išsiaiškinti tikrąsias aptarnavimo proceso neefektyvumo priežastis, nustatyti prioritетines tobulinimo sritis. Taip pat sudėtinga vertinti, ar padaryti pakeitimai iš tiesų duoda norimą rezultatą. KPI integracijos trūkumas taip pat gali kliudyti integruoti pažangias technologijas, pavyzdžiui, dirbtinį intelektą, nes be tinkamų duomenų sunku parinkti tinkamiausias užduotis automatizavimui (Alex ir kt., 2024; Badmus ir kt., 2024).

Neefektyvus resursų valdymas glaudžiai susijęs su prieš tai šiame poskyryje įvardintomis dviem problemomis. Jei nėra aiškių KPI, nežinoma, kokioms užduotims skiriama daugiausia laiko, nesuvokiama, kur yra didžiausi srautų *butelio kakliukai*, kiek reikėtų investuoti resursų į žinių valdymą ar technologijas, kokias metodologijas reiktų taikyti kad sumažėtų pasikartojančių užduočių kiekį (Vaid ir Sharma, 2022). Neefektyvus resursų valdymas gali pasireikšti ir netinkamu personalo kompetencijų valdymu: aukštos kvalifikacijos specialistai atlieka paprastus veiksmus, tuo tarpu sudėtingoms problemoms pritrūksta laiko ar pakankamų žinių (Pekarcikova ir kt., 2024). Kitas svarbus turimų resursų valdymo aspektas – nepakankamas gebėjimas numatyti ir valdyti kintančius užklausų srautus. Pavyzdžiui, jei per sezoninius laikotarpius užklausų kiekis stipriai išauga, o įmonė nepasirengusi greitai perskirstyti resursų ar pasitelkti automatizacijos, auga laukimo laikas, mažėja klientų pasitenkinimas, didėja darbuotojų stresas.

Be anksčiau minėtų trijų esminių problemų, egzistuoja ir platesnis problemų spektras, turintis įtaką aptarnavimo efektyvumui. Viena iš tokių problemų – daugiakanalis aptarnavimo kontekstas, kuriame klientai tikisi pagalbos ne tik telefonu ar el. paštu, bet ir per socialines medijas, pokalbių programėles, programų viduje integruotus pokalbių langus. Kiekvienas naudojamas kanalas turi savo specifiką, atsakymo greičio standartus,

duomenų valdymo taisyklės, todėl informacijos srautai gali išsiskaidyti, sunkėja bendras proceso valdymas (Patrício ir kt., 2008). Neturint holistinio požiūrio, gali būti sunku užtikrinti nuoseklumą visuose kanaluose, integruoti KPI matavimus tarp skirtingų sistemų ir prognozuoti bendrą užklausų apimtį. Tai savo ruožtu dar labiau apsunkina išteklių valdymą ir didina neefektyvumą, ypač jei dauguma užklausų yra pasikartojančios, bet aptarnaujamos skirtingose platformose be bendro koordinavimo (Parul ir Chhaya, 2024).

Dar viena svarbi problema yra strateginio požiūrio stoka. Klientų aptarnavimas kartais gali būti suvokiamas tik kaip operatyvinis veiksmas, greita reakcija į klientų prašymus, o ne kaip strateginės vertės kūrimo elementas (Trkman ir kt., 2015). Jei įmonė neturi aiškios strategijos, kaip aptarnavimas turėtų prisidėti prie ilgalaikių verslo tikslų, rizikuojama įstrigti tik reaguojančiame, *gaisrus gesinančiame* režime. Tai reiškia, kad sprendžiamos tik trumpalaikės problemos: neanalizuojant, kas lemia didelį užklausų kiekį, arba investuojama į papildomus įrankius be aiškaus supratimo, kokią problemą jie turėtų išspręsti (Tucker ir Pitt, 2009). Strateginio požiūrio stoka siejasi ir su KPI trūkumu, nes be aiškių rodiklių sunku nustatyti, ar aptarnavimo procesas vystomas strateginių tikslų link.

Neefektyvus duomenų ir žinių valdymas – dar vienas veiksnys, susijęs tiek su pasikartojančių užduočių apimtimi, tiek su KPI stoka, tiek su resursų valdymo problemomis. Jei įmonėje nėra sistemiškai kaupiamos ir prižiūrimos žinios apie dažniausias problemas ir jų sprendimo būdus, kiekvienas naujas atvejis gali būti sprendžiamas iš naujo (Bianchini ir kt., 2024; Garrick ir Chan, 2017). Tai lemia ne tik didesnę laiko sąnaudų kiekį, bet ir didesnę klaidų tikimybę, nes prarandama galimybė panaudoti kolektyvinę patirtį ir anksčiau išmoktas pamokas. Žinių trūkumas taip pat apsunkina KPI kūrimą ir interpretavimą, nes be konteksto sunku suprasti, kodėl vienas rodiklis blogėja ar gerėja, ką jis iš tikrųjų atspindi ir kokių veiksmų reikėtų imtis norint pakeisti situaciją (Lastrucci ir kt., 2024). Visos minėtos problemos apibendrinamos 3 lentelėje.

3 lentelė

Techninio klientų aptarnavimo problemų sisteminė analizė

Problemų kategorija	Priežastis	Pasekmės
Proceso efektyvumo	Pasikartojančių ir mažos vertės užduočių gausa	Laiko nuostoliai, žemas darbuotojų produktyvumas, resursų švaistymas
Matavimo ir kontrolės	Pagrindinių veiklos rodiklių stoka arba nepakankama jų integracija į procesus	Subjektyvus sprendimų priėmimas, silpnas procesų tobulinimo pagrindas
Operacinio valdymo	Neefektyvus resursų paskirstymas ir naudojimas	Padidėję operavimo kaštai, darbuotojų perkrovimas, netolygus darbo krūvis
Daugiakanalio aptarnavimo	Klientų aptarnavimas per skirtingus kanalus	Informacijos fragmentacija, nesuderinti procesai tarp kanalų
Strateginio požiūrio	Techninis aptarnavimas traktuojamas kaip operatyvinė, o ne strateginė funkcija	Trumpalaikis problemų sprendimas, sudėtingesnis strateginių tikslų pasiekimas
Žinių valdymo	Neefektyvus duomenų ir žinių kaupimas bei dalijimasis	Pakartotinis jau išspręstų problemų sprendimas, ilgesnis reakcijos laikas

Šaltinis: sudaryta darbo autoriaus, remiantis: Dias, 2021; Ishaq Bhatti ir kt., 2014; Parul ir Chhaya, 2024; Vaid ir Sharma, 2022; Xu ir kt., 2020

Visi minėti iššūkiai yra tarpusavyje susiję - pasikartojančios užduotys, nulemdamos laiko švaistymą, mažina galimybes gilintis į strateginius klausimus, tokius kaip procesų optimizavimas, žinių bazės gerinimas ar naujų KPI integravimas. Be KPI sunku nustatyti, kiek laiko ar kaštų prarandama dėl neoptimizuotų procesų, tad mažėja aiškus supratimas, į kokius sprendimus reiktų investuoti, kad jie leistų sumažinti perteklinį darbą (Gadekar ir kt., 2022). Neefektyvus resursų valdymas sustiprina šias problemas, nes neturint duomenų sudėtinga nuspręsti, kiek investuoti į automatizaciją ar kokias darbuotojų kompetencijas reiktų plėtoti. Šie struktūriniai barjerai sumažina įmonės lankstumą diegiant technologines naujoves, tokias kaip DI, procesų gavyba (angl. *process mining*), pažangius analizės įrankius (Olan ir kt., 2022).

Šiuo metu aktualios problemos klientų aptarnavimo procesuose apima ne tik pasikartojančių mažos vertės užduočių gausą, KPI stoką ir neefektyvų išteklių valdymą, bet ir platesnį integruotos strategijos, daugiakanalio aplinkos valdymo, žinių sklaidos ir prasmingos duomenų analizės iššūkių spektrą. Šių problemų kompleksinis sprendimas reikalauja sisteminio, duomenimis grįsto požiūrio, kuris leistų ne tik šalinti esamus trūkumus, bet ir kurti tvirtą pamatą pažangiems technologiniams sprendimams diegti.

Apibendrinant 1.1 poskyrį, techninį klientų aptarnavimo procesą būtina suvokti ne vien kaip operatyvinį atsakinėjimą į gaunamas klientų užklausas, bet ir kaip visapusišką verslo procesą, tiesiogiai darantį įtaką įmonės strateginiams tikslams ir kuriamai ilgalaikiai

vertei klientams. Sisteminiis požiūris į aptarnavimą, metodinis vykstančių procesų identifikavimas ir nuoseklus tobulinimas leidžia kurti didesnę naudą klientams, didinti jų pasitenkinimą ir lojalumą. Tačiau aptarnavimo procesas tampa vis kompleksiškesnis dėl didėjančių klientų lūkesčių ir spartaus technologijų vystymosi, todėl siekiant sėkmės būtinos duomenimis grįstos analizės, tikslingas metodologijų taikymas, inovatyvių technologijų diegimas ir aktyvi organizacinė adaptacija.

1.2. Pagrindinių veiklos rodiklių reikšmė techninio klientų aptarnavimo proceso efektyvumui

Siekiant užtikrinti procesų efektyvumą, būtinas aiškus ir objektyvus procesų vertinimo pagrindas. Šiuo tikslu įmonės pasitelkia pagrindinius veiklos rodiklius, kurie leidžia naudojant renkamus duomenis matuoti, lyginti ir vertinti procesų efektyvumą, kokybę ir teikiamą vertę (Ishaq Bhatti ir kt., 2014). Duomenimis grįstas procesų valdymas leidžia išvengti subjektyvių vertinimų, atsitiktinių pokyčių įvedimo ar pernelyg lėto prisitaikymo prie kintančios aplinkos (Lastrucci ir kt., 2024). KPI tampa įrankiu, padedančiu nustatyti, kurie procesų aspektai veikia gerai, o kurie – ne, kuriose srityse reikėtų investuoti į mokymus, technologijas ar procesų peržiūrą ir kaip konkretūs pokyčiai atrodo ilgalaikėje perspektyvoje (Anggradewi ir kt., 2019).

Vienas iš pagrindinių KPI stebėjimo panaudos atvejų – gebėjimas suderinti trumpalaikius operacinius tikslus su ilgalaikiais strateginiais tikslais (Parasuraman ir Grewal, 2019). Pavyzdžiui, jei įmonė siekia sumažinti vidutinį problemų sprendimo laiką, tam gali būti parenkami tokie rodikliai kaip vidutinis atsakymo laikas ar pirmojo kontakto išsprendimo rodiklis (angl. *First Contact Resolution*). Šie duomenys leidžia įvertinti ar įvedami nauji pokyčiai tikrai turi norimą efektą – mažina operacines sąnaudas ir kelia klientų pasitenkinimo lygį (Kennerley ir Neely, 2003; Laihonon ir Pekkola, 2016).

Taip pat KPI leidžia nustatyti prioritetus ir valdyti išteklius (Lavy ir kt., 2014). Jei analizė rodo, kad didelė dalis užklausų susijusi su paprastomis, dažnai pasikartojančiomis problemomis, tokia įžvalga signalizuoja apie galimybę diegti savitarnos sprendimus arba patobulinti žinių bazę, pasitelkiant KCS principus (Child ir kt., 2020). Tuo pačiu KPI padeda atlikti vertinimus, ar šios priemonės iš tiesų sumažina darbuotojų apkrovą ir sutrumpina užduočių atlikimo laiką (Ishaq Bhatti ir kt., 2014).

KPI yra vienas iš esminių elementų, padedančių sukurti nuoseklų, duomenimis grįstą požiūrį į vykstančius procesus (Micheli ir Mura, 2017). Jie sudaro pagrindą, kuriuo duomenimis gali remtis visos kitos taikomos priemonės – personalo mokymai, automatizavimo įrankiai.

1.2.1. Klientų aptaravime naudojamų pagrindinių veiklos rodiklių apžvalga

Techninis klientų aptarnavimo procesas, kaip apžvelgta 1.1 poskyryje, yra sudėtinga, daugiapakopė ir nuolat kintanti aplinka, kuri daro tiesioginę įtaką įmonės veiklos efektyvumui, kaštų struktūrai, klientų pasitenkinimui ir bendrai konkurencinei pozicijai rinkoje (Dombrowski ir Malorny, 2016; Sheth ir kt., 2023). Norint efektyviai valdyti šį procesą, vien strateginio mąstymo ar tinkamo metodologijų pasirinkimo nepakanka – būtinas ir solidus duomenimis grįstas pagrindas. Pagrindiniai veiklos rodikliai čia atlieka svarbų vaidmenį, nes leidžia aiškiai įvardyti, kokius procesus vertinti, kokius tikslus kelti ir kaip objektyviai vertinti pokyčius, atsirandančius pritaikant naujas metodologijas ar technologijas. (Child ir kt., 2020; Ishaq Bhatti ir kt., 2014) .

Neretai klientų aptarnavime sutinkami KPI - reakcijos greitį ir operacinį našumą atspindintys rodikliai. Vienas iš dažniausiai minimų yra vidutinis atsakymo laikas (angl. *average response time*). Šis rodiklis rodo, kiek laiko vidutiniškai praeina nuo kliento užklausos gavimo iki pirmojo atsakymo pateikimo. (Abdullateef ir kt., 2011; Płaza ir Pawlik, 2021). Jei aptarnavimo procesas orientuotas į greitą reakciją, trumpas atsakymo laikas gali rodyti, kad personalo, technologijų ir organizacinių priemonių derinys veikia efektyviai.

Vis dėlto, šis KPI nėra savaime pakankamas – operacinis greitis dar nereiškia aukštos kokybės (Ishaq Bhatti ir kt., 2014). Todėl vidutinį atsakymo laiką tikslinga derinti su kitu KPI – pirmojo kontakto išsprendimo rodikliu (First Contact Resolution, FCR). FCR parodo, kiek užklausų išsprendžiama dar pirmojo kontakto su klientu metu, nelaukiant atsakymo ar papildomos informacijos iš kitų skyrių ar darbuotojų. Aukštas FCR rodiklis rodo, kad procesai yra gerai struktūruoti, aptarnavimo specialistai turi reikiamas kompetencijas ir priemones, o žinių valdymas organizuotas taip, kad dauguma problemų gali būti išspręstos nesudėtingai. KCS metodologija čia gali veikti kaip stiprus katalizatorius: sistemingai kaupiamos ir atnaujinamos žinios leidžia greitai surasti reikiamą sprendimą (Abdullateef ir kt., 2011).. Tokiu būdu FCR tampa ne tik našumo rodikliu, bet ir kokybinio proceso brandos indikatoriumi (Dombrowski ir Malorny, 2016).

Kitas svarbus KPI tipas – klientų pasitenkinimo rodikliai. Nors operacinio našumo rodikliai, kaip vidutinis atsakymo laikas ar FCR - svarbūs, jie ne visada atspindi kliento emocinę reakciją į aptarnavimą (Pozza, 2014). Todėl dažnai naudojami klientų pasitenkinimo matavimai, pavyzdžiui, CSAT (angl. *Customer Satisfaction Score*) – klientų pasitenkinimo įvertinimas ar NPS (angl. *Net Promoter Score*) – klientų rekomendavimo indeksas. CSAT paprastai matuojamas prašant kliento įvertinti, kiek jis patenkintas gautu aptarnavimu, o NPS identifikuoja, kiek tikėtina, kad klientas

rekomenduotų įmonę kitiems (Baquero, 2022). Aukšti pasitenkinimo rodikliai rodo, kad procesas ne tik efektyvus, bet ir orientuotas į kuriamą vertę klientui. Jie taip pat leidžia išsamiau analizuoti, kurios priemonės (pavyzdžiui, dirbtinio intelekto pagrindu veikiančios savitarnos sistemos ar personalo mokymai) daro didesnę teigiamą įtaką kliento patirčiai (Naveen, 2023).

Svarbūs ir veiklos stabilumą ir patikimumą atspindintys rodikliai. Dažnu atveju jie reiškia, kad įmonė, turėdama sutartus laiko terminus ar kokybės standartus, turi objektyvų vertinimo matą, pagal kurį vertina, ar procesai atitinka klientų reikalavimus (Monahan ir Yearworth, 2008). Iš esmės šie rodikliai leidžia greitai diagnozuoti, kuriose proceso vietose atsiranda operaciniai trūkumai: ar tai būtų vėluojantis atsakymas į užklausas, neužtikrintas minimalus paslaugų kokybės lygis, ar nepakankama kokybės kontrolė (Porcelli, 2014). Šiam KPI tipui priskirtini ir SLA laikymosi rodikliai, nes jie aiškiai parodo, ar įmonė pasiekia iš anksto numatytus paslaugų parametrus. Pavyzdžiui, jei įmonė nusprendžia, kad 95 % užklausų privalo būti atsakyta per 24 valandas, tada SLA įgyvendinimo rodikliai padeda nustatyti, ar šis tikslas realiai pasiekiamas: jei rodikliai rodo, kad per 24 val. yra atsakoma 85 % užklausų, galima teigti kad dalis proceso neatitinka užsibrėžtų standartų, ir reikia spręsti, kaip gerinti resursų planavimą, vykdyti mokymus ar diegti naujus technologinius įrankius (Monahan ir Yearworth, 2008).

Klientų aptarnavimo procesuose taip pat būna vertinami komunikacijos kanalų efektyvumo rodikliai, kurie parodo, kaip efektyviai sprendžiamos skirtingais kanalais (el. paštu, telefonu, pokalbių langais, socialiniais tinklais) gaunamos klientų užklausos. Tokie rodikliai padeda įmonėms nustatyti, kurie komunikacijos kanalai yra efektyviausi skirtingo tipo užklausoms spręsti, ir optimizuoti kanalų naudojimą (Wolf ir Steul-Fischer, 2023). Pavyzdžiui, gali būti matuojama, kiek laiko vidutiniškai užtrunka išspręsti problemą kiekviename kanale, kiek kainuoja vienos užklausos sprendimas skirtinguose kanaluose, ir kokia dalis klientų išsprendžia savo problemas savarankiškai, naudodamiesi savitarnos įrankiais. Ši informacija padeda priimti pagrįstus sprendimus dėl investicijų į skirtingų komunikacijos kanalų vystymą ir optimizavimą.

Resursų optimizavimo rodikliai taip pat yra turi reikšmingą vaidmenį techniniame aptarnavime. Jie padeda įvertinti, kaip efektyviai paskirstomi žmogiškieji ir techniniai ištekliai, sprendžiant skirtingas problemas. Tokie rodikliai gali apimti darbuotojų apkrovos lygį, užklausų pasiskirstymą tarp skirtingų kompetencijų darbuotojų, resursų paskirstymą pagal problemų prioritetus (Giotopoulos ir kt., 2024). Šie rodikliai ypač svarbūs įmonėms, kurios susiduria su sezoniniais užklausų svyravimais arba turi ribotus aukštos kvalifikacijos resursus.

Technologinio efektyvumo rodikliai vertina, kaip efektyviai panaudojamos technologijos klientų aptarnavimo procesuose. Šie rodikliai gali apimti automatizuotai išspręstų užklausų dalį, savitarnos įrankių naudojimo dažnumą, dirbtinio intelekto sprendimų tikslumą ir t.t. (Andrade ir Tumelero, 2022). Techniniame aptarnavime, kur technologijos vaidina svarbų vaidmenį, tokie rodikliai padeda įvertinti technologinių investicijų grąžą ir padeda nustatyti, kuriose srityse technologinis atnaujinimas galėtų duoti didžiausią naudą.

Egzistuoja ir integruoti, holistiniai KPI, apimantys daugiakanalį aptarnavimo kontekstą. Šiuolaikiniai klientai kontaktuoja su įmonėmis per įvairius kanalus: mob. telefoną, el. paštą, pokalbių programas, socialinius tinklus ir kt. (Quach ir kt., 2022). Tam, kad KPI atspindėtų realią procesų būklę, būtina integruoti skirtingų kanalų duomenis ir vertinti bendrą klientų aptarnavimo ekosistemą (Fahim ir kt., 2024). Pavyzdžiui, galima sekti kanalo perjungimo rodiklį (kiek klientų pradeda klausimą vienu kanalu, o vėliau migruoja į kitą), o tuomet matuoti, ar ši migracija sumažina pasitenkinimą, ilgina atsakymo laiką ar didina klaidų tikimybę. Tokie KPI padeda suvaldyti daugiakanalės aplinkos sudėtingumą ir identifikuoti, kur skirtingų kanalų integracija nėra sklandi (Fahim ir kt., 2024).

Svarbu atkreipti dėmesį, kad KPI turi būti matuojami nuosekliai ir ilgesnį laikotarpį. Vienkartiniai matavimai leidžia susidaryti tik momentinį vaizdą, bet neparodo ilgalaikių tendencijų (Patti ir kt., 2020). Nuoseklus rodiklių stebėjimas leidžia matyti, kaip keičiasi proceso rodikliai po naujų priemonių diegimo, pvz. ar pagerėjo FCR po to, kai buvo integruotas naujas žinių valdymo įrankis, ar sumažėjo atsakymo laikas po dirbtinio intelekto sprendimo integravimo, ar pagerėjo CSAT (Patti ir kt., 2020).

Tačiau svarbiausia – KPI turi būti ne tik renkami, bet ir naudojami sprendimams priimti. Efektyvus KPI naudojimas reiškia ne tik jų stebėjimą, bet ir nuolatinę analizę, priežasčių nustatymą ir tikslų tobulinimo veiksmų planavimą (Martins de Andrade ir Sadaoui, 2017). Techniniame aptarnavime, kur procesai dažnai būna sudėtingi ir kompleksiški, toks sisteminis požiūris į KPI analizę tampa ypač svarbus.

Apibendrinant 1.2 poskyrį, pagrindinių veiklos rodiklių identifikavimas, rinkimas ir analizė klientų aptarnavimo procesuose sudaro tvirtą pagrindą sąmoningiems, duomenimis pagrįstiems sprendimams priimti. Tinkamai parinkti ir nuosekliai stebimi KPI leidžia ne tik įvertinti esamą procesų būklę, bet ir efektyviau valdyti išteklius, greičiau atpažinti pasikartojančias problemas, vertinti inovacijų poveikį ir teikiamą rezultatą, pvz. ar DI sprendimų diegimas teikia objektyvią naudą. Be šių rodiklių įmonės veiklą

neapibrėžtoje aplinkoje, kurioje subjektyvumas ir netikslingos iniciatyvos trukdytų vykdyti kryptingą klientų aptarnavimo procesų tobulinimą.

1.3. Sėkmingo DI panaudojimo veiksniai ir galimybės klientų aptarnavimo procese

Ankstesniame poskyryje (1.1) apžvelgta, kad techninis klientų aptarnavimas, kaip verslo procesas, priklauso nuo įmonės gebėjimo efektyviai valdyti operacijas, duomenis, žinias ir sprendimų priėmimą (Dombrowski ir Malorny, 2016; Garrick ir Chan, 2017; Trkman ir kt., 2015). Išryškėjo keletas esminių iššūkių: pasikartojančių mažos vertės užduočių gausa (Xu ir kt., 2020), KPI stokos apsunkintos tobulinimo pastangos, sunkumai integruojant įvairias metodologijas (pvz., KCS, LEAN) ir tikslingai pasirenkant technologijas (Hristov ir Chirico, 2019). Žvelgiant į klientų aptarnavimo procesą, dirbtinis intelektas tampa potencialiai svarbiu įrankiu, galinčiu padėti ne tik automatizuoti pasikartojančias užduotis, bet ir generuoti vertingas analitines įžvalgas, leidžiančias geriau suprasti procesų eigą, efektyviau rinkti ir interpretuoti KPI, ir priimti labiau pagrįstus strateginius sprendimus (Obiki-Osafiele ir kt., 2024).

DI galima apibūdinti kaip plataus spektro technologijų rinkinį, kuris suteikia galimybę analizuoti ir mokytis iš istorinių duomenų, atpažinti ir prognozuoti tendencijas ir rekomenduoti geriausius sprendimus procesuose (Inavolu, 2024; Obiki-Osafiele ir kt., 2024). Tai reiškia, DI gali padėti nustatyti, kurios užduotys tinkamiausios automatizacijai, prognozuoti piko laikotarpius, numatyti, kokios žinios bus reikalingos ateityje ar net realiu laiku teikti pasiūlymus, kaip efektyviau išspręsti tam tikrą problemą. Technologiškai DI galimybės apima (minimos klientų aptarnavimui aktualios galimybės):

- Natūraliosios kalbos apdorojimą (angl. *Natural language processing*, toliau – NLP), skirta kompiuterinėms sistemoms suprasti, interpretuoti ir generuoti žmogaus kalbą (Zhou ir kt., 2020). NLP apima technologines komponentes, tokias kaip sintaksinė analizė, semantinė interpretacija, sentimentų analizė ir kontekstinio supratimo mechanizmai. Tai leidžia automatizuotai apdoroti ir analizuoti tekstinę informaciją.
- Mašininis mokymasis (angl. *Machine learning*, toliau – ML), orientuotą į algoritmų ir modelių kūrimą, kurie leidžia sistemoms mokytis iš duomenų ir tobulėti atlikdamos užduotis be tiesioginio programavimo (Raj, 2019). ML apima įvairius metodus, tokius kaip prižiūrimas mokymasis, neprižiūrimas mokymasis ir sustiprinamasis mokymasis (Raj, 2019). ML leidžia automatizuoti duomenų analizę, pagerinti duomenų apdorojimo efektyvumą,

prisitaikyti prie nuolat kintančių duomenų rinkinių, kas suteikia galimybę sistemai nuolat tobulėti ir efektyviau vykdyti sudėtingas užduotis (Sidey-Gibbons ir Sidey-Gibbons, 2019);

- Procesų gavybą - integruojant duomenų analizės ir verslo procesų valdymo technologijas (Adesina ir kt., 2024). Ji apima įrankius ir metodus, skirtus išgauti, analizuoti ir modeliuoti verslo procesų duomenis iš įmonėje naudojamų informacinių sistemų. Technologiškai procesų gavyba apima automatizuotą duomenų ekstrakciją, procesų modelių rekonstrukciją, veiklos metrikų skaičiavimą ir vizualizaciją, leidžiančią detaliai analizuoti ir optimizuoti procesų veikimą (Zerbino ir kt., 2021);
- Pokalbių robotus ir autonomines sistemas (virtualius asistentus), paremtas keliomis DI technologinėmis sritimis, tokias kaip, didžiaisiais kalbos modeliais (angl. *Large Language Models*, toliau - LLM), NLP ir ML, kartu su automatizuotais atsakymų generavimo mechanizmais (Aslam, 2023). Tai leidžia kurti autonomines vartotojų sąsajas, kurios gali leidžia bendrauti su vartotojais realiuoju laiku, apdoroti jų užklausas ir teikti atsakymus ir veiksmus remiantis iš anksto apibrėžtomis taisyklėmis ir mokymosi rezultatais (Udeh ir kt., 2024).

Integravus minėtas DI technologines galimybes į vieningą sistemą, tai suteikia galimybę automatizuoti sudėtingus procesus, pagerinti duomenų analizės tikslumą ir suteikti gilesnį supratimą apie klientų poreikius ir elgseną (Huang ir Rust, 2021; Pendyala ir Lakkamraju, 2024). Toks kompleksinis dirbtinio intelekto įrankių derinys ne tik didina operacinį efektyvumą ir tikslumą, bet ir suteikia galimybę sistemai adaptuotis prie kintančių sąlygų ir nuolat tobulėti, remiantis naujai gautais duomenimis ir įžvalgomis (Huang ir Rust, 2021). Rezultatas – išmanioji, lanksti ir savarankiško mokymosi sistema, kuri geba teikti aukštos kokybės paslaugas ir optimizuoti veiklos procesus, prisidedant prie klientų patirties gerinimo ir įmonės veiklos efektyvumo didinimo.

Siekiant struktūruotai analizuoti DI sprendimų taikymą techninio klientų aptarnavimo kontekste, tikslinga šias technologijas organizuoti pagal hierarchinį modelį, apimančią tris lygmenis:

1. Pirmasis lygmuo apima bazines DI technologijas – mašininį mokymąsi, natūraliosios kalbos apdorojimą, kas sudaro pamatą daugeliui sudėtingesnių DI sprendimų.

2. Antrasis lygmuo jungia bazines technologijas į konkrečias funkcijas atliekančius sprendimus, tokius kaip virtualūs asistentai, procesų gavybos įrankiai ar prognozavimo sistemos.
3. Trečiasis lygmuo apima kompleksinius sprendimus – hibridines DI sistemas (sudarytų iš keleto konkrečias funkcijas atliekančių sprendimų), apimančias žmogaus-DI bendradarbiavimo platformas, pritaikytas plataus spektro funkcijų atlikimui, pvz. atlikti visas klientų aptarnavimo specialisto funkcijas.

Toks hierarchinis požiūris leidžia sistemiškai vertinti DI technologijų sudėtingumą, integracijos lygį. Tolimesnėse darbo dalyse vartojama sąvoka "DI sprendimai" apima visų trijų lygmenų technologijas, nebent yra nurodoma kitaip.

Svarbu pabrėžti, kad DI naudojimas nėra savaiminis sprendimas, o vienas iš sudedamųjų elementų didesnėje procesų tobulinimo ekosistemoje (Wamba-Taguimdje ir kt., 2020). Atsižvelgiant į tai, kad verslo procesai dažnai kenčia nuo informacijos fragmentacijos, duomenų trūkumo ir analitinių galimybių stokos, DI gali tapti katalizatoriumi, leidžiančiu pereiti nuo vienkartinio procesų analizavimo ir tobulinimo bandymų prie sistemingos ir pastovios procesų analizės ir tobulėjimo (Gomes ir kt., 2022). Pavyzdžiui, analizuojant didelio masto duomenų rinkinius – užklausų istorijas, pokalbių žurnalus, klientų atsiliepimus – DI gali padėti identifikuoti esminius pasikartojančius klausimus, sudėtingiausias problemas ar ilgiausiai trunkančius sprendimų žingsnius. Šios išvalgos leidžia ir strategiškai planuoti, kaip pagerinti žinių bazę, kokius KPI reikėtų aktyviai stebėti, kokias kompetencijas reikėtų ugdyti darbuotojams.

Vis dėlto, DI integravimas į techninį klientų aptarnavimo procesą taip pat gali susidurti ir su reikšmingais iššūkiais. (Kinkel ir kt., 2022) tyrime, kuriame dalyvavo gamybos įmonės, nustatyta, kad didelė dalis įmonių susiduria su technologiniais barjeriais diegdamos DI sprendimus, ypač dėl sistemų nelankstumo ir negebėjimo spręsti nestandartines problemas. Techninio aptarnavimo kontekste tokie barjerai gali pasireikšti sprendžiant naujas, precedento neturinčias problemas, kurioms reikalinga ilgalaikė inžinerinė kompetencija.

Sėkmingas DI integravimas reikalauja kokybiškų duomenų. Moksliniai tyrimai rodo, kad duomenų kokybė yra vienas iš kritinių veiksnių, lemiančių DI projektų sėkmę (Whang ir kt., 2023). Techniniai dokumentacija dažnai būna fragmentuota, nepakankamai struktūruota arba stokoja reprezentatyvumo, kas gali riboti DI sistemų efektyvumą. Be to, DI integravimas reikalauja aiškiai apibrėžtų KPI, tinkamos IT infrastruktūros ir verslo

vadybos kompetencijos norint nustatyti, kur DI sprendimai gali kurti didžiausią vertę (Aung ir kt., 2021; Brock ir von Wangenheim, 2019).

Organizaciniai veiksniai taip pat vaidina svarbų vaidmenį diegiant DI technologijas. Tyrimai organizacinės psichologijos srityje rodo, kad technologinių inovacijų diegimas dažnai susiduria su žmogiškosios dimensijos iššūkiais (S. Kumar ir Mittal, 2024). Tyrimą atlikę (Makarius ir kt., 2020) teigia, kad sėkmingam DI diegimui reikalinga sociotechninė perspektyva, kurioje technologijos ir žmonės bendradarbiauja kaip partneriai. Jų tyrimas pabrėžia, kad diegiant DI būtina formuoti organizacinę kultūrą, skatinančią teigiamą požiūrį į technologijas.

Lygiagrečiai su techniniais ir organizaciniais aspektais, DI naudojimas kelia ir svarbių etinių bei duomenų apsaugos klausimų. Savo publikacijoje (Dignum, 2018) identifikuoja tris pagrindines etikos dimensijas DI kontekste: etika DI sistemose (įdiegtos etinės vertybės), etika kuriant DI sistemas (etiškas kūrimo procesas) ir etika aplink DI sistemas (socialinės pasekmės). (Meurisch ir Mühlhäuser, 2021) sisteminė DI duomenų apsaugos apžvalga pabrėžia, kad įmonės privalo sukurti aiškias duomenų apsaugos strategijas, atitinkančias reguliacinius reikalavimus, tokius kaip bendrasis duomenų apsaugos reglamentas (BDAR). Nepakankamas dėmesys šiems aspektams gali ne tik kelti teisinės grėsmės, bet ir pakenkti vartotojų pasitikėjimui DI sprendimais.

Kultūrinis kontekstas taip pat turi įtakos DI diegimo sėkmei. Savo darbe (Dwivedi ir kt., 2021) pateikia konceptualų požiūrį į DI diegimo iššūkius, atkreipdami dėmesį į tai, kad organizacinė kultūra ir socialinis kontekstas daro įtaką technologijų priėmimui. 2023 m. atliktas (Uren ir Edwards, 2023) tyrimas rodo, kad įmonės, turinčios inovacijoms palankią kultūrą, sėkmingiau diegia dirbtinio intelekto technologijas.

Apibendrinant, DI taikymas techninio klientų aptarnavimo procesuose turi didelį potencialą didinti procesų (tame tarp ir techninio klientų aptarnavimo) efektyvumą, tačiau moksliniai tyrimai rodo, kad efektyviam šio potencialo realizavimui būtina holistinė strategija, apimanti techninius, organizacinius ir etinius aspektus. Subalansuotas požiūris į visas šias dimensijas gali užtikrinti, kad DI sprendimai taptų reikšmingu efektyvumo didinimo įrankiu ir prisidėtų prie tvarios organizacinės transformacijos.

1.3.1. DI panaudojimo kryptys klientų aptarnavimo procesuose

Vienas iš sparčiausiai populiarėjančių ir perspektyviausių DI panaudojimo būdų klientų aptarnavime – virtualių asistentų (agentų) ir pokalbių robotų integravimas į klientų aptarnavimo sistemas. Tai kompleksiniai sprendimai, kurie apima didžiaisiais kalbos modeliais, tokiais kaip „ChatGPT“, „Gemini“, „Claude“, paremtas pokalbių sistemas

(Bhayana, 2024; Wei ir kt., 2024). Šios sistemos turi prieigą prie išorinių (ir vidinių) žinių bazių, analitikos sistemų ir veikia kartu su mašininio mokymosi technologijomis. Tokie virtualūs asistentai veikia realiu laiku, interpretuoja klientų ar darbuotojų užklausas, pasinaudodami prieinamais duomenimis suranda reikiamą informaciją ir pateikia atsakymus be žmogaus įsikišimo (X. Wang ir kt., 2022; Wei ir kt., 2024). Tokios virtualių asistentų sistemos atlieka ne tik atsakymo į pateiktus klausimus funkciją, jos atlieka ir analitinę funkciją – naudojant semantinės analizės technikas, renka duomenis apie sistemos vartotojo intencijas, emocinę nuostatą (Kamateri ir kt., 2019; Płaza ir kt., 2022). Taip pat tokios DI sistemos geba rinkti duomenis apie dažniausiai gaunamus klausimus ir dažniausiai panaudojamus žinių šaltinius klausimams atsakyti, kas leidžia efektyviai valdyti svarbiausius duomenų šaltinius ir atitinkamai planuoti tolimesnius žinių bazių atnaujinimus (Beheshti, 2023).

Vienas iš pagrindinių DI virtualių asistentų sistemų tikslų - spręsti pasikartojančias, žemos vertės užklausas, kuri ne tik užima darbuotojų laiką, bet ir neleidžia darbuotojam praleisti daugiau laiko sprendžiant sudėtingesnes, didesnę vertę kuriančias problemas

. Tokios užklauskos, nors ir būtinos atsakyti, turi ribotą vertę įmonių strateginiams tikslams, jų apdorojimas rankiniu būdu ilgainiui gali tapti reikšmingu kaštų ir techninio klientų aptarnavimo proceso efektyvumo iššūkiu. Tokios DI sistemos suteikia galimybę klasifikuoti užklausas pagal jų pobūdį, sudėtingumą ir pasikartojimo dažnį. Sistemoje esantys mašininio mokymosi modeliai naudodami istorinių užklauskų duomenimis, gali išmokti atskirti tipines, dažnai kartojamas užklausas nuo retesnių, specifinių problemų (Nti ir kt., 2022). Taip mažinant darbuotojų skiriamą laiką, mažos vertės darbams ir leidžia juos priskirti prie sudėtingesnių, didesnės vertės užklauskų sprendimo (Xu ir kt., 2020a).

Svarbus virtualių asistentų taikymo klientų aptarnavimo procesuose aspektas yra natūraliosios kalbos apdorojimo algoritmų pritaikymas. Šie algoritmai suteikia galimybę analizuoti ne tik kliento pateikiamus duomenis, bet ir jo nuotaiką, nepasitenkinimo lygį ar problemos sprendimo skubumą (Juglan ir kt., 2023). Pavyzdžiui, jei algoritmai nustato, kad klientas yra nusivylęs ar susierzinęs dėl produkto ar paslaugos kokybės, DI sistema gali automatiškai nukreipti užklauską į labiau patyrusio specialisto rankas. Tai užtikrina ne tik greitą reakciją į kliento poreikius, bet ir stiprina kliento pasitikėjimą įmonės teikiamomis paslaugomis. Be to, tokie algoritmai gali generuoti atsakymus, kurie yra labiau suderinti su kliento emocine būseną (Juglan ir kt., 2023). Tai užtikrina, kad klientas jaustųsi vertinamas, išklaustas ir atitinkamai informuotas apie galimus sprendimus.

Dar viena sritis, kurioje dirbtinis intelektas tampa vertingu įrankiu - personalizuotos patirties ir rekomendacijų teikimas klientams (Bhuiyan, 2024). DI

sistemos geba ne tik analizuoti kliento istoriją, bet ir išsamiai vertinti ankstesnes užklausas, atliktus pirkimus ir kitą svarbią informaciją apie klientą. Remdamasis šia duomenų analize, DI geba pasiūlyti labiausiai tinkamus sprendimus, atitinkančius individualius kliento poreikius ir pageidavimus (V. Kumar ir kt., 2019). Toks personalizavimas gerina kliento patirties kokybę, prisideda prie kryžminio pardavimo strategijų įgyvendinimo, klientų lojalumo didinimo ir ilgalaikio pelningumo augimo (Ameen ir kt., 2020). Be to, personalizuotos rekomendacijos įgalina įmones giliau suprasti klientų poreikius ir preferencijas – šis aspektas yra esminė bet kurios sėkmingos rinkodaros strategijos dalis (Pozza, 2014).

DI sistemų veikimas grindžiamas ne vien automatizacija, bet ir mokymosi procesu (Di Vaio ir kt., 2020). Šis mokymosi procesas, būdingas DI sistemoms, taip pat yra glaudžiai susijęs su KCS metodologija. Kadangi ši metodologija orientuota į pastovų žinių bazės tobulinimą, DI modeliai padeda identifikuoti, kurios informacijos dalys žinių bazėje yra naudingos ir atkreipia dėmesį į tas sritis, kuriose trūksta tam tikrų straipsnių, instrukcijų ar pavyzdžių (Di Vaio ir kt., 2020). DI sistemos taip pat geba automatizuotai kurti naują dokumentaciją, įskaitant straipsnius, instrukcijas ar mokomuosius gidus, kas leidžia sumažinti rankinio turinio kūrimo krūvį (A. Wang ir kt., 2021). Toks nuolatinis grįžtamasis ryšys leidžia nuolat žinių bazę atnaujinti ir adaptuoti prie realių klientų poreikių, tokiu būdu efektyviau sprendžiant iškilusias problemas.

Svarbu paminėti procesų gavybos panaudojimą DI sistemose. Ši technologija leidžia analizuoti aptarnavimo procesų grandinę, identifikuoti probleminius procesus taškus ar pasikartojančius „butelio kakliukus“, ir efektyviai planuoti resursų paskirstymą

Pavyzdžiui, analizuojant istorinius duomenų srautus, procesų gavyba ir DI gali ne tik prognozuoti piko laikotarpius, bet ir padėti parinkti optimalias strategijas šiems laikotarpiams valdyti (Massaro, 2022). Šios išvalgos tampa esminės sprendžiant pajėgumų planavimo klausimus, užtikrinant savalaikį reagavimą į klientų užklausas, mažinant atsakymų vėlavimus ir optimizuojant sąnaudas. Tokiu būdu DI atlieka strateginę funkciją, kuri padeda įmonėms pagrįsti investicijas į technologijas, optimizuoti personalo darbą, planuoti mokymus, atnaujinti žinių bazę ir kurti naujus produktus (Gautam ir kt., 2023).

Be to, procesų gavybos technologija leidžia įmonėms ne tik identifikuoti veiklos silpnas vietas, bet ir imtis atitinkamų priemonių jų šalinimui. Tai glaudžiai dera su LEAN metodologijos principais ir ilgainiui padeda reikšmingai sumažinti veiklos sąnaudas, padidinti bendrą įmonės efektyvumą (Khakpour ir kt., 2024). Tai suteikia galimybę efektyviai valdyti resursus, užtikrinant įmonės gebėjimą greitai prisitaikyti prie rinkos

pokyčių ir klientų poreikių. Šios funkcijos padeda ne tik optimizuoti operacinius procesus, bet ir kurti pridėtinę vertę, įgalinant verslą priimti tikslesnius strateginius sprendimus.

Žvelgiant iš KPI panaudojimo perspektyvos, DI technologijos atveria naujas galimybes ne tik automatizuoti duomenų rinkimą, bet ir aktyviau identifikuoti naujus, prasmę turinčius rodiklius (Duan ir kt., 2019). Pavyzdžiui, virtualių asistentų naudojimas leidžia išsamiai analizuoti užklausų ir pokalbių žurnalus, iš jų išgauti atsakymų kokybės indeksus, atpažinti pasikartojančias problemas ir padėti kurti naujus KPI, skirtus procesų optimizavimui. Be to, DI padeda suprasti KPI sąsajas ir jų tarpusavio priklausomybę, pavyzdžiui, DI gali padėti analizuoti, ar trumpesnis atsakymo laikas visada užtikrina didesnę klientų pasitenkinimą (CSAT), ar egzistuoja netiesinės sąsajos, kuriose pernelyg didelis greitis gali sumažinti sprendimų kokybę. Tokia analitinė įžvalga suteikia įmonėms galimybę priimti labiau subalansuotus sprendimus ir išvengti paviršutiniško KPI interpretavimo.

DI sprendimai, kurie yra skirti duomenų analizei, žinių valdymui ir pasikartojančioms užduotims automatizuoti, prisideda ne tik prie trumpalaikio veiklos efektyvumo didinimo, bet ir prie ilgalaikės įmonės brandos. Jau ankstesniame poskyryje (1.2) aptarta mokslinė literatūra apie duomenų svarbą, KPI reikšmę ir technologijų ir metodikų sinergiją šiame kontekste įgauna papildomą svarbą. DI tampa ne tik įrankiu, leidžiančiu automatizuoti procesus, bet ir katalizatoriumi, kuris įgalina sistemas susijungti į vieningą, duomenimis grįstą, dinamišką klientų aptarnavimo ekosistemą (Tran, 2024).

Nepaisant DI technologijų privalumų, verta paminėti ir iššūkius, su kuriais susiduria įmonės, diegdamos DI sistemas. Vienas esminių iššūkių yra susijęs su duomenų prieinamumu ir kokybe, jų tinkamumu DI sistemų apmokymui ir naudojimui - jei įmonė iki šiol nerenka neturi struktūruotų duomenų apie klientus, užklausas ar trūksta esminių veiklos duomenų, DI modeliams tampa sudėtinga veikti efektyviai, nėra galimybės jų apmokyti arba gali atsirasti šališka informacija, kas neigiamai veiktų DI veikimą (Ahmadi, 2023; Aldoseri ir kt., 2023). Dar viena svarbi problema – tinkamos IT infrastruktūros užtikrinimas. Įmonės turi ne tik gebėti įdiegti modernias technologijas, bet ir laikytis duomenų saugumo, privatumo ir apsaugos reikalavimų. Tai ypač svarbu šiuolaikiniame reguliavimo aplinkos kontekste, kur klientų duomenų apsauga tampa ne tik etiniu, bet ir teisiniu prioritetu (Hamon ir kt., 2024).

Tinkamas darbuotojų apmokymas taip pat yra esminis DI sprendimų diegimo elementas. Įmonėms būtina užtikrinti, kad darbuotojai gebėtų pasitikėti DI teikiamomis rekomendacijomis, suprastų jų logiką ir mokėtų kritiškai įvertinti siūlomus sprendimus.

Šiuo atveju svarbu užtikrinti, kad DI sprendimai ir jų paskirtis būtų aiškiai suprantami visiems įmonės darbuotojams. Tokia praktika ne tik mažina pasipriešinimą technologijų naujovėms, bet ir skatina aktyvų darbuotojų įsitraukimą į DI integracijos procesą.

Kitas svarbus DI sprendimų diegimo aspektas yra jų integracija su metodologijomis, ir platesniu organizaciniu kontekstu. Kaip anksčiau aptarta, tokios metodikos kaip KCS arba LEAN reikalauja nuolatinės duomenų analizės ir grįžtamojo ryšio mechanizmų. DI gali veikti kaip pagalbininkas, padedantis darbuotojams greičiau suprasti, kurie sprendimai veikia efektyviai, o kurie reikalauja tobulinimo (Makarius ir kt., 2020). Tam būtina atvira ir mokymuisi palanki organizacinė kultūra, kurioje darbuotojai suvoktų, kad DI nėra jų tiesioginis konkurentas, o partneris, padedantis didinti jų produktyvumą ir suteikiantis įžvalgų, kurios kitu atveju liktų nepastebėtos. Tai reikalauja ne tik technologinių sprendimų diegimo, bet ir organizacinės transformacijos, kurios metu darbuotojai yra mokomi ir skatinami prisitaikyti prie naujų darbo metodų (Makarius ir kt., 2020).

Taip pat svarbu apibrėžti aiškas rodiklių sistemas, kurios leistų objektyviai įvertinti DI sprendimų naudą (Krichen ir Abdalzaher, 2024; Martínez-Plumed ir Hernández-Orallo, 2018). Pavyzdžiui, galima stebėti, ar naudojant DI sistemas sumažėjo vidutinis atsakymo laikas, ar pakilo FCR rodiklis, ar pagerėjo klientų pasitenkinimo indeksas, sumažėjo pasikartojančio darbo krūvis. Šie matavimai yra svarbūs ne tik siekiant pagrįsti investicijas, bet ir užtikrinant nuolatinį sprendimų tobulinimą (Hristov ir Chirico, 2019). Reguliarus DI sistemų efektyvumo vertinimas leidžia užtikrinti, kad šios technologijos yra naudojamos optimaliai ir atitinka įmonės strateginius tikslus.

Apibendrinant, virtualūs asistentai DI ir DI sistemos jau peržengė tradicinės automatizacijos ribas, gebėdami sukurti pridėtinę vertę per automatizuota mažos vertės užklausų atsakymą, analitinę įžvalgą, kliento patirties personalizavimą, užklausų konteksto interpretavimą ir pagalbą vykdant strateginį procesų tobulinimą. Integruojant šiuos metodus su KCS, LEAN ir KPI analize, įmonės gali ne tik optimizuoti klientų aptarnavimo procesus, bet ir strategiškai planuoti ateities veiksmus, remiantis duomenų analize ir rinkos tendencijomis. Nors DI nėra universalus sprendimas visiems iššūkiams, tinkamai įdiegtos DI sistemos palengvina sprendimų priėmimą, didina klientų aptarnavimo procesų efektyvumą ir prisideda prie įmonių transformacijos link duomenimis grįstos, dinamiškos ir lanksčios ekosistemos.

1.3.2. Dirbtinio intelekto diegimo intensyvumo dimensijos ir vertinimas

Vertinant dirbtinio intelekto diegimo procesus techninio klientų aptarnavimo srityje, svarbu apibrėžti ir išmatuoti diegimo intensyvumą – sudėtinį rodiklį, apimančį įvairias dimensijas, kurios atspindi, kaip plačiai ir giliai įmonė diegia DI sprendimus (Holmström, 2022). Dirbtinio intelekto diegimo intensyvumas nėra vienmatis rodiklis – tai kompleksinė sąvoka, apimanti keletą pagrindinių dimensijų: diegimo apimtį ir gylį, funkcinį sudėtingumą, laiko aspektus ir integracijos lygį (Y. S. Lee ir kt., 2022).

Diegimo apimtis ir gylis apima tiek horizontaliąją dimensiją (kiek skirtingų techninio klientų aptarnavimo sričių ar procesų apima DI sprendimai), tiek vertikaliąją dimensiją (kaip giliai DI integruotas į kiekvieną techninį procesą). Pavyzdžiui, viena įmonė gali naudoti DI sprendimus visame techninio aptarnavimo procese, tačiau tik paviršutiniškai automatizuojant paprastas užduotis, tuo tarpu kita įmonė gali koncentruotis tik į vieną sritį, pavyzdžiui, techninių žinių valdymą, tačiau joje diegti pažangius, kompleksinius DI sprendimus, integruotus į visus tos srities aspektus (Xu ir kt., 2020a). Toks dualumas leidžia vertinti ne tik bendrą DI paplitimą įmonėje, bet ir skvarbos gylį konkrečiuose techniniuose procesuose.

Funkcinis sudėtingumas – DI diegimo intensyvumo dimensija, atspindinti, kokio sudėtingumo technines užduotis atlieka DI sprendimai. Remiantis (Xu ir kt., 2020a) funkcinis sudėtingumas gali būti skirstomas į kelis lygius: nuo paprastos techninių užklausų klasifikacijos ir kategorizavimo (žemiausias sudėtingumo lygis) iki techninių problemų prognozavimo, sprendimų rekomendacijų generavimo, techninių sprendimų priėmimo ir, galiausiai, autonominių, savarankiškai besimokančių techninių sistemų (aukščiausias sudėtingumo lygis). Aukštesnio funkcinio sudėtingumo DI sistemos ne tik sprendžia sudėtingesnes technines užduotis, bet ir reikalauja didesnio techninių duomenų kiekio, pažangesnių algoritmų ir gilesnės žmonių bei technologijų sąveikos.

Laiko aspektai – apima tiek DI sprendimų naudojimo trukmę techninio aptarnavimo įmonėje, tiek jų evoliuciją per tą laikotarpį. Ilgesnė DI sprendimu naudojimo patirtis dažnai koreliuoja su didesniu DI sprendimų brandumu, kadangi įmonės turi galimybę mokytis iš ankstesnių techninių problemų sprendimo patirčių, tobulinti algoritmus ir procesus bei kurti efektyvesnius technikų ir DI bendradarbiavimo modelius (Yablonsky, 2021). Be to, ilgalaikė DI diegimo perspektyva leidžia kryptingai ugdyti įmonės technines kompetencijas, reikalingas maksimaliai išnaudoti DI technologijų potencialą – nuo techninių duomenų valdymo ir analizės iki techninių pokyčių valdymo ir etinių aspektų išmanymo.

Integracijos lygis atspindi, kaip glaudžiai DI sprendimai susieti su kitomis techninio aptarnavimo sistemomis ir procesais. Kaip jau buvo minėta ankstesniame poskyryje, integracija gali būti vertinama nuo autonominių (angl. *standalone*) sistemų iki visiškai į techninių problemų sprendimo darbo procesus integruotų sprendimų. Aukštesnis integracijos lygis ne tik padidina DI sprendimų efektyvumą, bet ir leidžia kurti holistinę, nuoseklią techninio klientų aptarnavimo ekosistemą, kurioje technikų ir technologijų sąveika tampa sklandesnė ir efektyvesnė (Lichtenthaler, 2020).

Techninio aptarnavimo kontekste diegimo intensyvumo vertinimas gali apimti tokius aspektus kaip automatizuotų techninių sprendimų procentas, DI valdomų techninių užklausų dalis, DI generuojamų techninių rekomendacijų tikslumas ar techninio aptarnavimo efektyvumo rodiklių pagerėjimas po DI diegimo. Vertinant DI diegimo intensyvumą techniniame klientų aptarnavime, svarbu atsižvelgti ir į organizacinį kontekstą. Įmonės, turinčios sudėtingesnius techninius produktus ar paslaugas, dažnai reikalauja pažangesnių DI sprendimų, gebančių dirbti su kompleksiniais techniniais duomenimis ir spręsti nestandartines problemas. Tuo tarpu įmonės, kurių techninės užklauskos yra labiau standartizuotos, gali pasiekti reikšmingą efektyvumo pagerėjimą net ir su mažesnio intensyvumo DI diegimu (Y. S. Lee ir kt., 2022)

DI diegimo intensyvumas taip pat stipriai koreliuoja su įmonės gebėjimu efektyviai valdyti pokyčius. Diegiant aukšto intensyvumo DI sprendimus, kurie reikšmingai transformuoja techninius procesus, būtina užtikrinti, kad techniniai specialistai ne tik suprastų šiuos pokyčius, bet ir aktyviai dalyvautų jų formavime (Holmström, 2021). Savo tyrime (Makarius ir kt., 2020) pabrėžia, kad DI integravimo lygis turėtų augti palaipsniui, kartu su įmonės technine branda ir darbuotojų gebėjimu adaptuotis prie naujų darbo metodų. Pernelyg spartus aukšto intensyvumo DI sprendimų diegimas, neatsižvelgiant į organizacinį pasirengimą, gali sukelti pasipriešinimą pokyčiams ir sumažinti tikėtiną naudą.

Apibendrinant, dirbtinio intelekto diegimo intensyvumas yra daugiamatė sąvoka, apimanti diegimo apimtį ir gylį, funkcinį sudėtingumą, laiko aspektus ir integracijos lygį. Šių dimensijų sisteminis vertinimas leidžia ne tik nustatyti esamą įmonės DI diegimo brandą, bet ir identifikuoti tobulintinas sritis, kurios galėtų padidinti technologijų naudojimo efektyvumą. Tai aktualu ir techninio klientų aptarnavimo kontekste, kur didesnė DI diegimo branda gali padėti pagerinti techninių problemų sprendimo spartą, techninių žinių valdymo efektyvumą ir bendrą klientų pasitenkinimą techninės pagalbos kokybe.


1.3.3. Užduočių ir technologijų atitikimo svarba dirbtinio intelekto diegimui

Sėkmingam dirbtinio intelekto sprendimų taikymui techninio klientų aptarnavimo procesuose nepakanka vien tik tinkamai įdiegti technologiją – kritiškai svarbus tampa technologijos ir užduoties atitikimo aspektas. TTF, kurią pirmą kartą suformulavo (Goodhue ir Thompson, 1995) teigia, kad informacinės technologijos darys teigiamą įtaką įmonės ir darbuotojo produktyvumui tuomet, kai technologijos savybės gerai atitiks atliekamų užduočių charakteristikas. Kitaip tariant, net ir labai pažangios technologijos įdiegimas negarantuoja didesnio procesų ir užduočių efektyvumo – svarbu užtikrinti, kad diegiama technologija būtų tinkamai suderinta su atliekamų užduočių specifiška, darbuotojų gebėjimais ir organizaciniu kontekstu.

TTF teorija remiasi trimis esminiais komponentais, kurie turi būti suderinti: užduočių charakteristikos, technologijos savybės ir jų tarpusavio atitikimas (Goodhue ir Thompson, 1995). Užduočių charakteristikos apima tokius aspektus kaip užduoties sudėtingumas, struktūriškumas, cikliškumas ir tarpusavio priklausomybės laipsnis. Technologijos savybės apima funkcionalumą, prieinamumą, patogumą naudoti ir integracijos lygį. Atitikimas tarp užduočių ir technologijų pasireiškia tuomet, kai technologijos savybės tinkamai atitinka užduočių reikalavimus, t.y. technologija suteikia būtent tas galimybes, kurių ir reikia efektyviam užduočių atlikimui. TTF modelis apibendrinimas 2 paveiksle.

2 paveikslas

Užduoties-technologijos atitikimo modelio reikšmė



Šaltinis: sudaryta autoriaus remiantis Goodhue ir Thompson, 1995

Dirbtinio intelekto kontekste ši teorija įgyja svarbią reikšmę, kadangi ji skiriasi nuo tradicinių technologijų vertinimo. Priešingai nei fiksuoto funkcionalumo sistemos, dirbtinis intelektas pasižymi per laiką kintančiomis savybėmis – gebėjimu mokytis iš

istorinių duomenų, prisitaikyti prie kintančių sąlygų ir tobulėti per laiką. Ši DI savybė transformuoja patį užduočių-technologijų atitikimo vertinimą, paversdama jį ne vienkartinę analizę, bet nuolatiniu, kintančiu procesu, kuriame tiek technologija, tiek jos atitikimas užduotims nuolat kinta.

Techninio klientų aptarnavimo procesuose išskiriami keli kertiniai užduočių tipai, kurių kiekvienas kelia specifinius reikalavimus DI technologijoms. Techninės informacijos ir dokumentacijos paieška reikalauja pažangių NLP galimybių, siekiant greitai identifikuoti reikiamą informaciją dideliuose dokumentų rinkiniuose. Techninių užklausų klasifikavimas ir paskirstymas reikalauja gebėjimo atpažinti problemų sudėtingumą, kontekstą ir nukreipti jas tinkamiausiems specialistams pagal jų kompetencijų profilius. Techninių problemų analizė ir sprendimų pasiūlymas reikalauja priežastinio ryšio supratimo ir gebėjimo susieti techninius simptomus su potencialiomis priežastimis (Xu ir kt., 2020). Techninių žinių valdymas ir atnaujinimas reikalauja gebėjimo automatiškai identifikuoti naujas žinias ir integruoti jas į esamą žinių bazę.

Remiantis (Pillai ir Sivathanu, 2020; Vafaei-Zadeh ir kt., 2024) atliktais tyrimais galima teigt kad TTF vertinimas DI kontekste turėtų apimti keturias pagrindines technines dimensijas, kurios yra aktualios techninio klientų aptarnavimo kontekste:

1. Funkcinis atitikimas vertina, ar DI sprendimas atlieka reikalingas technines funkcijas – tai yra pamatinis reikalavimas, nes nepakankamai funkcionalus DI sprendimai negalės padėti spręsti kompleksinių problemų. Ši dimensija apima ne tik pasikartojančių užduočių atlikimą, bet ir sistemos gebėjimą išmokyti atlikti naujas funkcijas, prisitaikant prie besikeičiančių techninio aptarnavimo poreikių.
2. Duomenų atitikimo dimensija analizuoja, ar DI sprendimas gali apdoroti turimą dokumentaciją reikiamu formatu ir apimtimi – techniniam aptarnavimui aktualus duomenys dažnai būna nestruktūruotoje tekstinėje formoje, skirtingų formatų ir sukaupiti įvairiose sistemose. DI sprendimai turi gebėti integruoti šiuos duomenis ir išgauti iš jų prasmingą informaciją, kad galėtų pateikti tikslias rekomendacijas ir sprendimus.
3. Vartotojo sąsajos atitikimo dimensija vertina, ar DI sprendimas turi patogią ir intuityvią sąsają – ši dimensija dažnai nuvertinama, tačiau ji tiesiogiai lemia technologijos priėmimą ir naudojimą kasdienėse operacijose.
4. Procesų atitikimo dimensija tiria, ar DI sprendimas sklandžiai integruojasi į esamus techninio aptarnavimo darbo procesus, nepažeisdamas nusistovėjusių praktikų ir nesukeldamas papildomų trukdžių.

Toks dimensijų įvertinimas leidžia įmonėms priimti labiau pagrįstus sprendimus dėl konkrečių DI sprendimų tinkamumo jų unikaliame techninio aptarnavimo kontekste.

Siekiant detaliau išplėsti funkcinio atitikimo dimensiją taip pat yra svarbu įvertinti DI tinkamumą skirtingo sudėtingumo užduotims, (Xu ir kt., 2020) tyrimas parodė skirtingą DI efektyvumą priklausomai nuo užduočių struktūros. Nesudėtingose, pasikartojančiose, gerai struktūruotose užduotyse, tokiose kaip standartinės informacijos pateikimas ar techninių dokumentų paieška, DI sprendimai gali pasiekti aukštą efektyvumą ir potencialiai pakeisti rankinį darbą. Tokios užduotys paprastai turi aiškiai apibrėžtus įvesties parametrus, nuoseklias sprendimo procedūras ir nuspėjamus rezultatus, dėl šių priežasčių, tokias užduotis galima nesudėtingai apdoroti ir patikėti DI sprendimams. Tačiau sudėtingesnėse, kintančios struktūros užduotyse, reikalaujančiose kūrybiško problemų sprendimo, situacinio supratingumo ir intuicijos, DI sprendimai kol kas veikia efektyviau kaip pagalbinių priemonė specialistams, o ne kaip jų pakaitalas. Tokiose situacijose DI gali padėti techninio aptarnavimo specialistams analizuojant didelius duomenų rinkinius, teikdamas rekomendacijas ar identifikuojamas galimus problemos sprendimus, tačiau galutinį sprendimą turėtų priimti žmogus, pasitelkdamas DI pateiktas įžvalgas ir papildydamas savo patirtimi ir įvairiapuse situacijos analize. Toks galimas skirtingas DI sprendimų panaudojimas tampa svarbus svarstant, kurioms techninio aptarnavimo funkcijoms pirmiausiai diegti DI sprendimus ir kaip juos integruoti su žmogiškaisiais ištekliais, siekiant optimalaus užduočių ir technologijų atitikimo.

Tačiau sėkmingas užduočių-technologijų atitikimas priklauso ne tik nuo pačių DI technologijų ir užduočių charakteristikų, bet ir nuo individualių darbuotojų sugebėjimų – jų techninių žinių lygio, patirties dirbant su DI įrankiais ir bendro požiūrio į technologinę pažangą. (Zirar ir kt., 2023) nustatė, kad aukštesnės kvalifikacijos specialistai efektyviau išnaudoja DI potencialą, ypač kai DI sprendimai sukurti taip, kad leistų jiems efektyviau pritaikyti savo žinias, o ne bandytų jas pakeisti automatizuotais procesais. Ši įžvalga išryškina svarbią koncepciją: sėkmingas DI integravimas turėtų būti orientuotas ne į darbuotojų pakeitimą, bet į jų galimybių išplėtimą, kur technologija tampa įrankiu, didinančiu žmogaus kompetencijų efektyvumą.

Svarbu pažymėti, kad užduočių-technologijų atitikimas nėra statinis konstruktas – jis kinta laike, keičiantis tiek užduočių pobūdžiui, tiek DI sprendimų galimybėms (J.-C. Lee ir Chen, 2022). Įmonės, siekiančios užtikrinti aukštą DI sprendimų efektyvumą ilgalaikėje perspektyvoje, turėtų reguliariai vertinti ir koreguoti užduočių ir technologijų atitikimą, atsižvelgdamos į besikeičiančius klientų reikalavimus ir technologinius pokyčius. Tai aktualu ir techninio aptarnavimo srityje, kurioje produktų ir sistemų

sudėtingumas nuolat auga, o kartu didėja ir techninių problemų įvairovė bei kompleksiskumas. Laike kintantis TTF vertinimas transformuoja požiūrį į DI diegimą iš statinio ir vienkartinio vertinimo į dinaminį ir nuolatinį procesą, kuriame technologijos ir organizaciniai procesai nuolat prisitaiko vieni prie kitų.

Apibendrinant, užduočių-technologijų atitikimo teorija suteikia vertingą teorinį pagrindą vertinant dirbtinio intelekto taikymą techninio klientų aptarnavimo procesuose. Ji akcentuoja esminį principą: sėkmingas DI diegimas priklauso ne tik nuo technologijos pažangumo, bet ir nuo jos gebėjimo efektyviai atitikti konkrečias techninio aptarnavimo užduočių charakteristikas. TTF leidžia sistemingiau vertinti DI sprendimų potencialą ir užtikrinti, kad diegiamos technologijos iš tiesų prisidėtų prie techninio aptarnavimo efektyvumo didinimo, o ne sukurtų papildomų trukdžių ar kompleksiskumo. Ši teorija, integruota su organizacinio pasirengimo koncepcija, kuri bus aptarta kitame skyriuje, sudaro holistinį pagrindą sėkmingam dirbtinio intelekto diegimui techninio klientų aptarnavimo procesuose.

1.4. Organizacinis pasirengimas dirbtinio intelekto kontekste

Ankstesniuose poskyriuose (1.3.1; 1.3.3; 1.3.4), išsamiai nagrinėti dirbtinio intelekto sprendimai jų taikymo galimybės techninio klientų aptarnavimo procesuose ir diegimo intensyvumas ir TTF svarba. Tačiau net ir pažangiausios DI technologijos negali sukurti norimos pridėtinės vertės, jei įmonė nėra pasirengusi jas sėkmingai integruoti į savo procesus ir kultūrą. Organizacinis pasirengimas – tai daugiamatis konstruktas, apimantis technologinį, žmogiškąjį ir valdymo aspektus, kurie kartu lemia, ar įmonė sugebės efektyviai išnaudoti DI teikiamas naudas techninio aptarnavimo tobulinimui (Jöhnk ir kt., 2021; Uren ir Edwards, 2023).

Mokslinėje literatūroje organizacinis pasirengimas dažnai analizuojamas kaip tarpinis veiksnys, galintis tiek sustiprinti, tiek susilpninti ryšį tarp technologijų diegimo ir jų poveikio įmonių veiklos rezultatams (Uren ir Edwards, 2023). Techninio klientų aptarnavimo kontekste tai reiškia, kad net ir labai pažangūs DI sprendimai, tinkamai suderinti su techninėmis užduotimis, gali neatnešti laukiamos naudos, jei įmonėje nėra reikiamos techninės infrastruktūros, darbuotojų žinių ir įgūdžių, vadovybės palaikymo ar kokybiškų DI pritaikytų duomenų. Todėl organizacinis pasirengimas tampa svarbiu veiksniumi, lemiančiu DI diegimo sėkmę techninio aptarnavimo srityje.

Šiame skyriuje aptariami esminiai organizacinio pasirengimo aspektai DI diegimui techninio klientų aptarnavimo procesuose, apimant tiek pamatinius pagrindus,

tiek praktinius aspektus, susijusius su technine infrastruktūra, žmogiškuoju kapitalu, vadovybės palaikymu ir DI naudojimui reikalingų duomenų kokybe.

1.4.1. Organizacinio pasirengimo pagrindai ir techninė infrastruktūra

Organizacinis pasirengimas yra daugialypė sąvoka, apibūdinanti organizacijos ar įmonės gebėjimą ir pasiruošimą sėkmingai integruoti ir naudoti naujas technologijas ar sistemas. Dirbtinio intelekto kontekste organizacinis pasirengimas tampa svarbiu faktoriumi dėl šių technologijų kompleksiskumo ir potencialiai nuo stipriai transformuojančio poveikio įmonės procesams ir kultūrai (Jöhnk ir kt., 2021). Pasiūlytame (Weiner, 2009) teoriniame modelyje organizacinis pasirengimas pokyčiams apima du pagrindinius elementus: kolektyvinį įsipareigojimą (angl. *collective commitment*) įgyvendinti pokyčius ir kolektyvinį efektyvumą (angl. *collective efficacy*) – tikėjimą, kad įmonė turi gebėjimus tuos pokyčius įgyvendinti.

Šie du pagrindiniai elementai – kolektyvinis įsipareigojimas ir kolektyvinis efektyvumas – praktikoje pasireiškia per konkrečius organizacinio pasirengimo aspektus. DI sprendimų diegimo kontekste kolektyvinis įsipareigojimas atsispindi per vadovybės palaikymą ir strateginį suderinimą, tuo tarpu kolektyvinis efektyvumas realizuojamas per techninės infrastruktūros tinkamumą, žmogiškojo kapitalo pasirengimą ir DI naudojamų duomenų kokybę. Šie aspektai kartu sudaro kompleksinį organizacinio pasirengimo konstrukta, kuris turi nemažą įtaką DI diegimo sėkmei.

Analizuojant organizacinį pasirengimą technologinėms inovacijoms, vertinga apžvelgti ir Technologijos-Organizacijos-Aplinkos (angl. *Technology-Organization-Environment - TOE*) teorinį modelį, kurį pirma kartą pasiūlė Tornatzky ir Fleischer (1990). Šis modelis papildo (Weiner, 2009) pateikia požiūrį, akcentuodamas, kad organizacijų sprendimą diegti ir sėkmingai adaptuoti technologines inovacijas veikia trys pagrindiniai kontekstai: technologinis, organizacinis ir aplinkos. Technologinis kontekstas apima įmonei aktualių technologijų charakteristikas, organizacinis – įmonės struktūrinius ir procesų aspektus, o aplinkos – išorinius veiksnius, tokius kaip rinkos sąlygos ir infrastruktūra (Baker, 2012). TOE modelis suteikia struktūruotą prieigą prie organizacinio pasirengimo analizės, leidžiančią sistemiškiau vertinti DI diegimo sėkmės veiksnius.

Integruojant šiuos teorinius požiūrius, techninio klientų aptarnavimo kontekste organizacinis pasirengimas DI diegimui apima penkis pagrindinius aspektus:

1. Techninę infrastruktūrą;
2. Žmogiškąjį kapitalą ir technologinį kompiuterinį (DI) raštingumą;

3. Vadovybės palaikymą;
4. Strateginį suderinamumą/palaikymą;
5. DI naudojimui reikalingų duomenų (dokumentų) kokybę.

Šie penki aspektai veikia ne atskirai, o kaip vientisa sistema – panašiai kaip grandinė, kurios stiprumas priklauso nuo silpniausios grandies. Dažnai būtent silpniausias organizacinio pasirengimo aspektas nulemia bendrą DI diegimo sėkmę ar nesėkmę (Jöhnk ir kt., 2021).

Techninės (IT) infrastruktūros parengtumas yra pamatinis aspektas, suteikiantis įmonėms technologinį pamatą sėkmingai integruoti ir naudoti DI sprendimus techninio aptarnavimo procesuose. Tai apima ne tik fizinius kompiuterijos išteklius, bet ir tinkamą sistemų architektūrą, duomenų valdymo infrastruktūrą, komunikacijos tinklus ir programinės įrangos komponentus, kurie visi kartu sudaro vieningą techninę ekosistemą, kurioje veikia dirbtinio intelekto sprendimai (Akter ir kt., 2023).

Techninio klientų aptarnavimo kontekste techninės infrastruktūros parengtumas apima keletą esminių elementų. Pirmiausia, reikalingi pakankami skaičiavimo resursai – DI algoritmai, ypač pažangiausi mašininio mokymosi ir LLM modeliai, reikalauja didelių skaičiavimo pajėgumų. Įmonės privalo užtikrinti pakankamus išteklius, nesvarbu, ar jie būtų vietiniai (angl. *on-premise*), debesijos pagrindo ar hibridiniai (Akter ir kt., 2023). Nepakankami skaičiavimo pajėgumai gali riboti galima DI sprendimų sudėtingumą ir mažinti jų veikimo greitį, kas ypač kritiškai svarbu realaus laiko techninio aptarnavimo scenarijuose.

Antra, būtina užtikrinti tinkamą įmonėje esamų duomenų valdymo ir saugojimo infrastruktūrą – DI modelių mokymui ir tobulinimui reikalingi dideli duomenų kiekiai, kuriuos būtina saugiai ir efektyviai valdyti, užtikrinant tiek prieinamumą, tiek saugumą. Techninio aptarnavimo kontekste tokia infrastruktūra turi gebėti tvarkyti ir valdyti įvairių formatų duomenis – nuo struktūruotų užklausų duomenų iki nestrukūruotų techninių dokumentų ar darbuotojų užrašų, komentarų ir kitų žinių šaltinių (Uren ir Edwards, 2023; Zha ir kt., 2023). Be to, infrastruktūra privalo atitikti reguliacinius reikalavimus, susijusius su klientų, darbuotojų ir kitų jautrių duomenų apsauga ir privatumu.

Kitas svarbus elementas – sisteminės integracijos galimybės. Kad DI sprendimai būtų efektyvūs ir jais būtų sklandžiai naudotis techninio aptarnavimo procesuose, jie turi būti integruoti su esamomis sistemomis: užklausų valdymo platformomis, techninių žinių bazėmis, diagnostikos įrankiais ir kitomis techninėmis sistemomis (Zdravković ir kt., 2021). Tokia integracija techniniame lygmenyje įgyvendinama per tris pagrindinius mechanizmus:

- Duomenų integracijos procesus, kurie užtikrina skirtingų formatų ir šaltinių informacijos transformavimą į standartizuotą struktūrą;
- Funkcines sąsajas, kurios suteikia tiksliai apibrėžtus metodus tarpusavio komunikacijai tarp skirtingų sistemų;
- Sistemų orchestravimo mechanizmus, koordinuojančius visų sistemų darbo eigas.

Atliktame (Zdravković ir kt., 2021) tyrime atskleidžiama, kad svarbus vaidmuo tenka tarpinės programinės įrangos (angl. *middleware*) sprendimams. Tokia programinė įranga veikia kaip tarpininkė, mažindama skirtingų sistemų kompleksiskumą ir suteikianti bendrą kalbą jų tarpusavio komunikacijai. Sistemų integracijos apribojimai gali tapti veiksniumi, ribojančiu DI efektyvumą, jei skirtingose aplinkose veikiančios sistemos negauna reikiamos kontekstinės informacijos ir duomenų, reikalingų užtikrinti DI sprendimų efektyvumą.

Duomenų kokybė ir tinkamas jų paruošimas taip pat gali būti priskiriami prie vieno iš pagrindinių veiksnių DI sprendimų efektyviam funkcionavimui. Galima sakyti, kad duomenys yra DI "kuras" – be kokybiškų, tinkamai struktūruotų ir prieinamų duomenų net ir pažangiausi DI sprendimai negebės teikti prasmingų rezultatų (Whang ir kt., 2023). Šis aspektas yra svarbus ir techninio klientų aptarnavimo kontekste, kur sprendimai turi būti priimami greitai, remiantis dideliais ir įvairialypiais techninių duomenų rinkiniais. Remiantis (Whang ir kt., 2023) duomenų kokybė DI kontekste apima keletą dimensijų:

1. Duomenų prieinamumas – gebėjimas identifikuoti, pasiekti ir panaudoti visus prieinamus duomenis ir dokumentus, reikalingus DI sistemų mokymui ir funkcionavimui. Tai apima ne tik vidinius techninius duomenis (pvz., trikčių šalinimo istoriją, problemų sprendimo žingsnius), bet ir išorinius duomenis (pvz., produktų techninę dokumentaciją, industrijos standartus ar reglamentus) (Whang ir kt., 2023).
2. Duomenų tikslumas ir nuoseklumas – techninių duomenų tikslumas, nuoseklumas, patikimumas ir aktualumas. Sisteminėje DI naudojamų duomenų apžvalgoje (Zha ir kt., 2023) pabrėžia, kad duomenų kokybė yra vienas iš pagrindinių veiksnių, lemiančių DI projektų sėkmę, ypač techniniame kontekste, kur netikslūs duomenys gali lemti klaidingus DI pateikiamus sprendimus.
3. Duomenų struktūravimas ir standartizavimas – duomenų organizavimas pagal nuoseklią taksonomiją, klasifikacijos sistemas ir standartizuotas meta-duomenų

schemas, leidžiančias efektyviai rasti ir išgauti informaciją ir ją panaudoti DI sprendimuose.

4. Duomenų valdymas ir saugumas – procesai, nuostatai ir procedūros, užtikrinančios duomenų saugumą, konfidencialumą, atitiktį reglamentams ir etišką jų naudojimą DI sprendimams.

Empiriniai tyrimai atskleidžia, kad duomenų kokybė yra esminis veiksnys DI sprendimų efektyvumui ir ilgaamžiškumui. Savo darbe (Sculley ir kt., 2015) kalbą apie „paslėptą techninę skolą“, kuri pasireiškia ML sistemose, duomenų priežiūra tampa didžiausia priežiūros našta – atsiradus nedidelėms klaidoms duomenų surinkimo ar transformavimo etape, jas tampa labai sudėtinga ištaisyti vėliau, o tai gali iškreipti ir modelio sprendimus. Be to, (Sambasivan ir kt., 2021) aprašė „duomenų kaskadas“ – reiškinį, kai nedidelės duomenų ar dokumentų kokybės problemos ankstyvuose duomenų apdorojimo žingsniuose, sekančiuose DI sprendimų vystymo cikle sukelia grandininę klaidų reakciją. Galiausiai, (Bender ir Friedman, 2018) duomenų sistemų kokybės apžvalgoje pažymi, kad nepakankamas duomenų reprezentatyvumas ir nuoseklumas gali lemti DI sprendimų šališkumą bei prastą bendrą našumą, todėl pirminė investicija į duomenų kokybę, aiškią struktūrą ir taksonomiją yra būtina, siekiant kad DI sprendimai techninio aptarnavimo procesuose teiktų efektyvius sprendimus ir rekomendacijas.

Vertinant infrastruktūros ir duomenų parengtumą, svarbu taikyti sisteminių požiūrį, apimančią ne tik esamos infrastruktūros ir duomenų kokybės vertinimą, bet ir ilgalaikę perspektyvą – infrastruktūrinės galimybes augti ir prisitaikyti prie DI sprendimų tobulėjimo bei duomenų kiekio didėjimo. Techninė infrastruktūra ir duomenų valdymo sistemos, kurios gali būti pakankamos pradiniam DI diegimui, laikui bėgant gali tapti ribojančiu veiksniu, kai įmonės siekia plėsti savo DI sprendimus ar diegti pažangesnius DI modelius, reikalaujančius didesnių skaičiavimo našumų ir kokybiškesnių duomenų rinkinių. Todėl planavimo etape svarbu atsižvelgti ne tik į dabartinius, bet ir į būsimus techninius ir duomenų poreikius (Ribes ir Finholt, 2009).

Apibendrinant, techninė infrastruktūra ir duomenų kokybė yra fundamentalios dimensijos, į kurias būtina atsižvelgti rengiantis DI diegimui ir pritaikymui, šios ne tik užtikrina technologinį pagrindą, bet ir apibrėžia ribas, tarp kurių DI sprendimai gali funkcionuoti. Sisteminiis ir tvarus požiūris į infrastruktūros planavimą bei duomenų valdymą, įvertinant tiek dabartinius, tiek būsimus poreikius, leidžia įmonėms kurti tvirtą pamatą sėkmingam DI diegimui techninio klientų aptarnavimo procesuose.

1.4.2. Žmogiškojo kapitalo, vadovybės palaikymo ir duomenų kokybės įtaka DI sprendimams

Nors ir techninė infrastruktūra sudaro pamatą DI sprendimų diegimui ir pritaikymui, žmogiškasis kapitalas ir darbuotojų techninis lankstumas yra nemažiau reikšmingi veiksniai, lemiantys šių sprendimų sėkmę ilgalaikėje perspektyvoje (Jöhnk ir kt., 2021). Šių aspektų svarba yra aktuali ir techninio klientų aptarnavimo procesuose, kur klientų aptarnavimo specialistai ir pagalbinės technologijos, privalo glaudžiai sąveikauti, siekiant efektyviai spręsti klientų problemas.

Žvelgiant į organizacinį pasirengimą DI diegimui ir pritaikymui, galima remtis ankstesniame poskyryje aptartu TOE modeliu, kuris pabrėžia, kad organizaciniai ir aplinkos veiksniai yra taip pat svarbūs kaip ir technologiniai aspektai. Šiame poskyryje aptariamos organizacinės ir aplinkos TOE modelio dimensijos, kurios atsiskleidžia per žmogiškojo kapitalo, vadovybės palaikymo ir duomenų kokybės aspektus. Žmogiškasis kapitalas techninio klientų aptarnavimo kontekste apima ne tik bendrąsias darbuotojų kompetencijas, bet ir specifines žinias bei įgūdžius, būtinus efektyviam DI sprendimų naudojimui. Atliktame (Cetindamar ir kt., 2024) tyrime išskiriami trys pagrindiniai DI raštingumo komponentai: bazinis DI supratimas, techninės kompetencijos ir kūrybiškumas.

Bazinis DI supratimas apima gebėjimą suvokti pagrindines DI technologijų galimybes ir apribojimus techninio aptarnavimo kontekste. Darbuotojai turi suprasti, kokio tipo problemas DI gali padėti spręsti efektyviai, o kuriose situacijose reikalingas žmogaus įsikišimas. Šis supratimas padeda formuoti realistinius lūkesčius ir išvengti technologijų pervertinimo ar nepakankamo įvertinimo. Techninės kompetencijos (įgūdžiai) reiškia praktinius įgūdžius, reikalingus darbui su DI įrankiais ir jų rezultatų interpretavimui. Tai apima gebėjimą naudotis specializuotomis sistemomis, suprasti jų veikimo principus ir efektyviai taikyti jas kasdienėse užduotyse. Atliktas (Makarius ir kt., 2020) tyrimas parodė, kad įmonės, kurios investuoja į sistemines darbuotojų mokymo programas prieš diegdamos DI sprendimus, pasiekia geresnių rezultatų nei tos, kurios to nedaro. Kūrybiškumas pasireiškia per gebėjimą lanksčiai pritaikyti DI galimybes nestandartinėse situacijose. Techninio aptarnavimo srityje dažnai tenka spręsti unikalias problemas, kurių automatizuotas sprendimas gali būti iššūkis. Kūrybiškumas leidžia darbuotojams rasti naujus būdus, kaip panaudoti DI įrankius tokiose situacijose.

Greta DI raštingumo, pastaraisiais metais vis didesnė reikšmė teikiama techniniam (technologiniam) lankstumui (angl. *technical agility*). Pavyzdžiui, (Muduli ir Choudhury, 2024) šią sąvoką apibrėžia kaip gebėjimą greitai prisitaikyti prie technologinių pokyčių,

efektyviai įsisavinti naujas technologijas ir lanksčiai jas taikyti kasdienėse užduotyse.

Techninio lankstumo samprata apima:

1. Gebėjimą greitai prisitaikyti prie naujų įrankių ir sprendimų;
2. Mokymąsi iš praktinės patirties ir klaidų;
3. Skirtingų technologijų derinimą su turimomis žiniomis.

Techninis lankstumas nėra tik individualus darbuotojo bruožas – jis formuojamas organizacinės kultūros ir tinkamos mokymosi aplinkos. Tyrimai rodo, kad įmonės, kuriančios saugią eksperimentavimo aplinką ir skatinančios tarpdisciplininį bendradarbiavimą, pasiekia aukštesnį techninio lankstumo lygį (Jöhnk ir kt., 2021). O (Levallet ir Chan, 2022) pabrėžia, kad techniškai lankstūs specialistai geba efektyviau integruoti naujas technologijas į esamus darbo procesus.

Vadovybės palaikymas sudaro trečiąjį organizacinio pasirengimo elementą, (Uren ir Edwards, 2023) tyrime nustatyta, kad be aiškios vadovybės vizijos ir strateginio įsipareigojimo, DI iniciatyvos dažnai lieka fragmentiškos ir nepasiekia numatytų tikslų. Vadovybės palaikymas techninio klientų aptarnavimo kontekste apima:

1. Strateginę viziją – aiškų supratimą, kaip DI technologijos transformuos aptarnavimo procesus;
2. Resursų skyrimą – pakankamą finansavimą ir žmogiškųjų išteklių paskirstymą;
3. Palaikančios kultūros formavimą – aplinkos, skatinančios inovacijas ir mokymąsi, kūrimą.

Savo tyrime (Mikalef ir Gupta, 2021) nustatė, kad nepakankamas resursų skyrimas yra viena pagrindinių DI diegimo nesėkmės priežasčių. O atliktas (Uren ir Edwards, 2023) tyrimas parodė, kad įmonėse, kuriose DI iniciatyvos buvo aiškiai suderintos su strateginiais tikslais ir sulaukė aktyvaus vadovybės įsitraukimo, DI diegimo sėkmės tikimybė buvo žymiai didesnė.

Žmogiškasis kapitalas, techninis lankstumas ir vadovybės palaikymas kartu sudaro organizacinę organizacinio pasirengimo dimensiją, kuri papildo technologinę dimensiją (techninę infrastruktūrą ir duomenų kokybę). Šių elementų tarpusavio sąveika kuria aplinką, kurioje DI sprendimai gali būti efektyviai diegiami ir naudojami techninio klientų aptarnavimo procesuose.

Apibendrinant 1.4 skyrių, organizacinis pasirengimas DI sprendimų integracijai apima tarpusavyje susijusias dimensijas, kurios kartu lemia diegimo sėkmę. Techninė infrastruktūra ir duomenų kokybė sudaro technologinį pamatą, užtikrinantį DI sistemų veikimą. Žmogiškasis kapitalas ir techninis lankstumas atspindi darbuotojų gebėjimą

efektyviai naudotis DI sprendimais ir prisitaikyti prie technologinių pokyčių. Vadovybės palaikymas užtikrina strateginį nuoseklumą ir reikiamų resursų skyrimą. Šie komponentai veikia kaip vientisa sistema, kurioje silpniausias elementas gali riboti bendrą DI integracijos sėkmę.

1.5. Klientų aptarnavimo proceso ir dirbtinio intelekto pritaikymo analizės išvados

Atlikta literatūros analizė atskleidė kompleksinį techninio klientų aptarnavimo procesų pobūdį ir dirbtinio intelekto potencialą šių procesų efektyvumo didinimui. Apibendrinant literatūros dalį, galima išskirti šias pagrindines įžvalgas:

1. Techninis klientų aptarnavimas šiuolaikinėse įmonėse yra strategiškai svarbus verslo procesas, tiesiogiai veikiantis klientų pasitenkinimą, lojalumą ir įmonės konkurencingumą (Dombrowski ir Malorny, 2016; Sheth ir kt., 2023). Šis procesas reikalauja gilių specializuotų žinių, sistemingo procesų valdymo ir tinkamo metodologijų taikymo.
2. Pasikartojančios mažos vertės užduotys sudaro reikšmingą techninio aptarnavimo procesų dalį. Šių užduočių automatizavimas DI sprendimais galėtų atlaisvinti specialistų laiką sudėtingesnėms, aukštesnę vertę kuriančioms užduotims (Xu ir kt., 2020).
3. Dirbtinio intelekto diegimas yra daugiadimensinis procesas, aprėpiantis diegimo apimtį ir gylį, funkcinių sudėtingumą, integracijos lygį ir trukmės veiksnius (Brock ir von Wangenheim, 2019; Vafaei-Zadeh ir kt., 2024). Šie veiksniai veikia DI sprendimų efektyvumą ir rezultatus, tačiau jų tarpusavio sąveika techninių aptarnavimo procesų kontekste nėra pakankamai ištyrinėta.
4. Užduočių-technologijų atitikimo (TTF) teorija teigia, kad technologijų efektyvumas priklauso nuo jų atitikimo atliekamų užduočių charakteristikoms (Goodhue ir Thompson, 1995). Mokslinėje literatūroje pabrėžiama, kad nesuderinamumas tarp technologijos galimybių ir užduoties reikalavimų gali lemti nepakankamą technologijos išnaudojimą (Zigurs ir Buckland, 1998). Vis dar išlieka klausimas, kaip šis atitikimas veikia dirbtinio intelekto diegimo sėkmę ir techninio aptarnavimo efektyvumą.
5. Organizacinis pasirengimas, kuris remiasi technine infrastruktūra, darbuotojų kompetencijomis, vadovybės palaikymu ir duomenų (dokumentų) kokybe, yra svarbus veiksnys sėkmingam DI integravimui (Jöhnk ir kt., 2021). Žvelgiant į

atliktus tyrimus įmonės su aukštesniu organizaciniu pasirengimu pasiekia geresnių rezultatų diegiant DI sprendimus.

6. Sisteminio požiūrio svarba yra pabrėžiama (Jöhnk ir kt., 2021; Makarius ir kt., 2020) darbuose, kurie akcentuoja sisteminės perspektyvos svarbą, kur technologijos ir žmonės veikia kaip partneriai. Tačiau praktinis šios perspektyvos pritaikymas ir jos įtaka techninio aptarnavimo efektyvumui vis dar reikalauja tolimesnių tyrimų.

Nors literatūroje ir aptariami atskiri DI taikymo klientų aptarnavime aspektai, trūksta integruoto požiūrio, analizuojančio DI diegimo intensyvumo, organizacinio pasirengimo ir užduočių-technologijų atitikimo sąveiką. Literatūroje išryškėjęs dirbtinio intelekto potencialas leidžia daryti prielaidą, kad tinkamas šių trijų veiksnių suderinimas galėtų padėti reikšmingai padidinti techninio klientų aptarnavimo efektyvumą. Tačiau ši prielaida reikalauja empirinio patvirtinimo.

Atlikta literatūros analizė sudaro teorinę pagrindą tolimesniam tyrimui, kuris leis nustatyti, kaip dirbtinio intelekto diegimo intensyvumas, organizacinis pasirengimas ir užduočių-technologijų atitikimas veikia techninio klientų aptarnavimo efektyvumą.

2. DIRBTINIO INTELEKTO PANAUDOJIMO SĖKMĖS FAKTORIŲ KLIENTŲ APTARNAVIMO PROCESUOSE EMPIRINIO TYRIMO METODIKA

2.1. Tyrimo tikslas, modelis ir hipotezės

Tyrimo tikslas - kiekybiškai įvertinti dirbtinio intelekto diegimo intensyvumo, organizacinio pasirengimo ir užduočių-technologijų atitikimo įtaką techninio klientų aptarnavimo procesų efektyvumui Lietuvos įmonėse, veikiančiose informacinių technologijų, telekomunikacijų ir aukštųjų technologijų gamybos sektoriuose.

Tyrimo objektas – DI diegimo intensyvumo, organizacinio pasirengimo ir užduočių-technologijų atitikimo ryšiai su techninio klientų aptarnavimo procesų efektyvumu Lietuvos įmonėse, veikiančiose informacinių technologijų, telekomunikacijų ir aukštųjų technologijų gamybos sektoriuose.

Tyrimo uždaviniai:

1. Sukurti tyrimo modelį, paremtą DI diegimo intensyvumo, organizacinio pasirengimo, užduočių-technologijų atitikimo ir klientų aptarnavimo efektyvumo sąveikos vertinimu;
2. Parengti tyrimo metodiką ir instrumentą dirbtinio intelekto panaudojimo sėkmės veiksniams klientų aptarnavime įvertinti;
3. Apklausti Lietuvoje veikiančių įmonių klientų aptarnavimo darbuotojus ir vadovus, siekiant išsiaiškinti, kaip DI diegimas klientų aptarnavimo procesuose veikia jų efektyvumą;
4. Įvertinti organizacinio pasirengimo įtaką klientų aptarnavimo efektyvumui ir jo sąveiką su DI diegimo intensyvumu;
5. Nustatyti užduočių-technologijų atitikimo vaidmenį DI diegimo ir klientų aptarnavimo efektyvumo ryšyje.

Tyrimo modelis:

Remiantis atlikta literatūros analize, šiame darbe siūlomas integruotas teorinis modelis, dalinai apjungiantis užduočių-technologijų (TTF) atitikimo ir technologijos-organizacijos-aplinkos (TOE) struktūrą ir teorinius modelius. Toks jungtinis modelis

leidžia sistemiškai įvertinti DI sprendimų poveikį techninio klientų aptarnavimo efektyvumui ir pritaikymo sėkmingumui, atsižvelgiant į tarpinius veiksnius – organizacinį pasirengimą ir užduoties-technologijos atitikimą.

Teorinio modelio formavimui buvo apsvaistytos įvairios teorinės perspektyvos, įskaitant:

- Inovacijų difuzijos teorija - (Steiber ir kt., 2020) orientuojasi į tai, kaip ir kodėl naujos technologijos plinta tarp individų ir organizacijų. Nors ši teorija galėtų paaiškinti DI sprendimų priėmimo procesą, ji nepakankamai atsižvelgia į organizacinių veiksnių kompleksiskumą ir specifines technologijų-užduočių charakteristikas, reikalingas vertinant DI pritaikomumą techninio aptarnavimo procesuose. Inovacijų difuzijos teorija labiau tinkama analizuoti technologijų plitimą tarp organizacijų, o ne jų efektyvų pritaikymą įmonės viduje.
- Technologijų priėmimo modelis (TAM) - (Davis, 1989; Venkatesh ir kt., 2003) jame pagrindinis dėmesys skiriamas darbuotojams (ar bendrai asmenims) ir jų technologijų naudojimo ketinimams, remiantis suvokiamu naudingumu ir naudojimo paprastumu. Šis modelis, nors ir plačiai taikomas individualių technologijų priėmimo tyrimuose, yra per siauras organizaciniam kontekstui. TAM nepakankamai apima organizacinius aspektus ir išorines aplinkos sąlygas, kurios itin svarbios DI diegimo kontekste.

Vis dėlto, Technologijos-Organizacijos-Aplinkos (TOE) ir Užduočių-Technologijų atitikimo (TTF) teorinių modelių junginys buvo pasirinktas dėl kelių esminių priežasčių:

1. TOE struktūra (Tornatzky ir Fleischer, 1990) suteikia holistinį požiūrį į technologijų diegimą, apimančią ne tik technologinius, bet ir organizacinius bei aplinkos veiksnis. Tai ypač svarbu dirbtinio intelekto kontekste, nes šių technologijų diegimas stipriai priklauso nuo organizacinio konteksto ir išorinių veiksnių. TOE teorija buvo sėkmingai taikyta analizuojant įvairių informacinių technologijų diegimą, įskaitant debesijos kompiuteriją (Alshamaila ir kt., 2013), didelės apimties duomenis (angl. *big data*) (Chen ir kt., 2015). Naujausi tyrimai patvirtina, kad TOE struktūra išlieka aktuali ir DI kontekste (Jöhnk ir kt., 2021; Alsheiabni ir kt., 2019).
2. TTF modelis papildo TOE perspektyvą, atkreipiant dėmesį į technologijos ir konkrečių užduočių atitikimą. Šis aspektas ypač aktualus techninio klientų aptarnavimo kontekste, kur užduočių įvairovė reikalauja plataus mąsto

požiūrio į technologijų taikymą (Xu ir kt., 2020). TTF perspektyva leidžia įvertinti, kodėl tos pačios DI technologijos gali būti efektyvios vieniems techninio aptarnavimo procesams, bet gali būti neefektyvios kitiems.


Abiejų modelių apjungimas suteikia galimybę sumažinti kiekvieno individualių modelių turimus trūkumus. TOE modelis gali būti rizikingas dėl pernelyg bendro pobūdžio ir nepakankamo dėmesio konkrečių technologijų ir užduočių suderinamumui (Nguyen ir kt., 2022), o TTF – dėl nepakankamo organizacinių ir aplinkos veiksnių įvertinimo (Zigurs ir Buckland, 1998). Taip pat išlieka klausimas, ar dinaminiai ir sparčiai kintantis DI sprendimai efektyviai pamatuojami naudojant tradicinį TTF vertinimą. Sujungus šias perspektyvas kuriamas modelis, kuris įvertina tiek kompleksinį technologinio-organizacinio-aplinkos konteksto vaidmenį, tiek specifinį užduočių-technologijų atitikimą.

Siūlomas integruotas modelis taip pat atliepia naujesnes mokslines tendencijas, kurios pabrėžia poreikį taikyti skirtingas dimensijas apimančius teorinius konstruktus analizuojant DI diegimą (Dwivedi ir kt., 2021; Jöhnk ir kt., 2021). Šių teorinių perspektyvų integracija leidžia įvertinti ne tik tai, kaip efektyviai DI sprendimai gali būti diegiami organizaciniame kontekste (TOE dimensijos), bet ir kaip gerai jie atitinka konkrečių techninio aptarnavimo užduočių charakteristikas (TTF dimensijos).

Siūlomame modelyje DI diegimo intensyvumas, veikia kaip pradinis veiksnys, darantis tiesioginę įtaką tiek organizaciniam pasirengimui, tiek techninio klientų aptarnavimo efektyvumui. Organizacinis pasirengimas, veikia kaip tarpinis veiksnys, perduodantis DI diegimo intensyvumo poveikį techninio aptarnavimo efektyvumui. Tuo tarpu užduočių-technologijų atitikimas, moderuoja ryšį tarp DI diegimo intensyvumo ir techninio aptarnavimo efektyvumo. Techninio aptarnavimo efektyvumas, kuris yra galutinis rezultatas, praktikoje - objektyviai matuojamas pagrindiniais veiklos rodikliais (KPI), aptartais 1.2 poskyryje, tačiau šio tyrimo metu bus remiamasi subjektyvia techninio klientų aptarnavimo darbuotojų nuomone. Vizualinis tyrimo modelis pateikiamas 3 paveiksle.

3 paveikslas

Dirbtinio intelekto panaudojimo klientų aptarnavime tyrimo modelis



Šaltinis: sudaryta darbo autoriaus

Tyrimo modeliui patikrinti iškeltos šios hipotezės:

1. **H1:** DI diegimo intensyvumas klientų aptarnavime turi tiesioginį teigiamą poveikį organizaciniam pasirengimui.
2. **H2:** DI diegimo intensyvumas klientų aptarnavime turi tiesioginį teigiamą poveikį klientų aptarnavimo efektyvumui.
3. **H3:** Organizacinis pasirengimas teigiamai veikia klientų aptarnavimo efektyvumą.
4. **H4:** Užduočių-technologijų atitikimas moderoja ryšį tarp DI diegimo intensyvumo ir klientų aptarnavimo efektyvumo.

Tyrimo modelis atspindi keturis pagrindinius aukštesnio lygio (aukštesnės eilės) konstruktus (angl. *Higher order constructs*, toliau - HOC) kurie yra sudaryti iš žemesnio lygio (žemesnės eilės) konstruktų (angl. *Lower order constructs*, toliau – LOC) . Visi modelyje esantys HOC konstruktai yra daugialypiai ir matuojami per kelis žemesnio lygio konstruktus (LOC), kurie savo ruožtu matuojami keliais atspindžiais (angl. *reflective*) indikatoriais (anketos teiginiais).

DI intensyvumo HOC konstruktą sudaro, žemiau lentelėje pateikti LOC konstruktai pateikiami 4 lentelėje.

4 lentelė

Diegimo intensyvumo konstrukto formuojantys LOC konstruktai:

Žemesnio lygio konstruktai (LOC)	Teiginiai	Teorinis pagrindas
Diegimo_apimtis (7-8 teiginiai)	7. DI sprendimai naudojami daugumoje mūsų klientų aptarnavimo procesų 8. DI sistemos integruotos į pagrindinius klientų aptarnavimo etapus	(Grover ir kt., 2018; Young ir kt., 2021)
Funkcinis sudėtingumas (9-12 teiginiai)	9. DI sprendimai gali savarankiškai atlikti sudėtingas klientų aptarnavimo užduotis 10. DI sprendimai geba analizuoti klientų ankstesnių užklausų istoriją 11. DI sprendimai geba atpažinti klientų užklausų kontekstą 12. DI sprendimai geba suprasti klientų užklausų esmę	(Jöhnk ir kt., 2021b; J.-C. Lee ir Chen, 2022)
Integracijos lygis (13-14 teiginiai)	13. DI sprendimai yra visiškai integruoti į esamas klientų aptarnavimo sistemas 14. DI sprendimai automatiškai gali keistis duomenimis su kitomis įmonės sistemomis	(Zhu ir kt., 2006)
Diegimoevoliucija (15-16 teiginiai)	15. DI sprendimai yra tobulinami atsižvelgiant į klientų aptarnavimo patirtį 16. DI sprendimų funkcionalumas plečiamas pagal klientų aptarnavimo poreikius	(Xu ir kt., 2020)

Šaltinis: sudaryta darbo autoriaus

Organizacinio pasirengimo HOC konstrukta sudaro žemiau lentelėje pateikti LOC konstruktai, pateikiami 5 lentelėje.

5 lentelė

Organizacinio pasirengimo konstrukta formuojantys LOC konstruktai:

Žemesnio lygio konstruktai (LOC)	Teiginiai	Teorinis pagrindas
Techninė infrastruktūra (17-18 teiginiai)	17. Mūsų įmonė turi reikiamus techninius pajėgumus DI sprendimams klientų aptarnavime 18. Mūsų įmonė turi tinkamą duomenų valdymo infrastruktūrą skirtą klientų aptarnavimui	(Akter ir kt., 2023; Jöhnk ir kt., 2021b)
Techninis lankstumas (19-24 teiginiai)	19. Įmonės klientų aptarnavimo darbuotojai turi reikiamas žinias DI sistemoms naudoti 20. Įmonė vykdo DI technologijų mokymus klientų aptarnavimo darbuotojams 21. Klientų aptarnavimo darbuotojai geba greitai prisitaikyti prie naujų DI technologijų 22. Klientų aptarnavimo darbuotojai aktyviai eksperimentuoja su naujomis DI funkcijomis 23. Klientų aptarnavimo darbuotojai geba lanksčiai spręsti problemas naudodami skirtingus DI įrankius 24. Klientų aptarnavimo darbuotojai greitai mokosi iš DI naudojimo patirties	(Makarius ir kt., 2020b; van Laar ir kt., 2017)
Dokumentacijos kokybė (25-26 teiginiai)	25. Mūsų įmonės klientų aptarnavimui svarbūs dokumentai yra struktūruoti ir kokybiški 26. Klientų aptarnavimo dokumentai yra lengvai prieinami DI sistemoms	(Tran, 2024; Zha ir kt., 2023)
Vadovybės palaikymas (27-28 teiginiai)	27. Vadovybė aktyviai palaiko DI iniciatyvas klientų aptarnavime 28. DI projektams klientų aptarnavime skiriami adekvatūs ištekliai	(Sabherwal ir kt., 2006; Venkatesh ir kt., 2003)

Šaltinis: sudaryta darbo autoriaus

Užduoties-technologijos atitikimo HOC konstrukta sudaro žemiau lentelėje pateikti LOC konstruktai pateikiami 6 lentelėje.

6 lentelė:

Užduoties-technologijos pasirengimo konstrukta formuojantys LOC konstruktai:

Žemesnio lygio konstruktai (LOC)	Teiginiai	Teorinis pagrindas
Užduočių ir DI galimybių atitikimas (29-31 teiginiai)	29. DI sprendimai yra pritaikyti mūsų įmonės klientų aptarnavimo užduotims 30. DI sprendimų technologinės galimybės atitinka mūsų įmonės klientų aptarnavimo specialistų sprendžiamų problemų sudėtingumo lygį 31. DI sprendimai efektyviai sprendžia pasikartojančias klientų problemas	(Goodhue ir Thompson, 1995; Zigurs ir Buckland, 1998)
Funkcinis atitikimas (32-34 teiginiai)	32. DI sprendimai atlieka visas reikalingas klientų aptarnavimo funkcijas 33. DI sprendimai yra patogūs naudoti klientų aptarnavimo specialistams 34. DI sprendimai yra patogūs naudoti klientams	(Goodhue ir Thompson, 1995; Zigurs ir Buckland, 1998)
Procesų suderinamumas (35-36 teiginiai)	35. DI sprendimai sklandžiai integruojasi į esamus klientų aptarnavimo procesus 36. DI technologijos suderinamos su mūsų klientų aptarnavimo darbo metodikomis	(Karahanna ir kt., 1999; Xu ir kt., 2020)

Šaltinis: sudaryta darbo autoriaus

Techninio klientų aptarnavimo proceso efektyvumo konstrukta sudaro žemiau lentelėje pateikti LOC konstruktai pateikiami 7 lentelėje.

7 lentelė

Techninio klientų aptarnavimo proceso efektyvumo konstrukta formuojantys LOC konstruktai

Žemesnio lygio konstruktai (LOC)	Teiginiai	Teorinis pagrindas
Laiko efektyvumas (37-39 teiginiai)	37. Klientų užklausų atsakymo laikas pagerėjo naudojant DI 38. Problemų sprendimo laikas sutrumpėjo naudojant DI 39. Daugiau problemų išsprendžiama per pirmą kontaktą su klientu (pirmu kartu)	(Collier ir Bienstock, 2006; Ishaq Bhatti ir kt., 2014)
Resursų naudojimas (40-42 teiginiai)	40. Įdiegus DI sprendimus sumažėjo klientų aptarnavimo darbuotojų apkrova atsakant į pasikartojančias užklausas 41. Įdiegus DI sprendimus klientų aptarnavimo darbuotojai gali daugiau laiko skirti sudėtingoms problemoms 42. Įdiegus DI sprendimus klientų aptarnavimo resursai yra naudojami efektyviau	(Adesina ir kt., 2024; Stefanović ir kt., 2015)
Aptarnavimo kokybė (43-44 teiginiai)	43. Įdiegus DI sprendimus klientų pasitenkinimas įmonės klientų aptarnavimu pagerėjo 44. Įdiegus DI sprendimus pakartotinių klientų užklausų skaičius sumažėjo	(Anggradewi ir kt., 2019; Chee ir Husin, 2020)
Žinių valdymo efektyvumas (45-47 teiginiai)	45. Naudojant DI tapo lengviau dalintis techninėmis žiniomis 46. Techninės informacijos paieška tapo efektyvesnė 47. Naujų techninių žinių išsaugojimas pagreitėjo	(Andrade ir Tumelero, 2022; Kamateri ir kt., 2019; Olan ir kt., 2022)

Šaltinis: sudaryta darbo autoriaus

2.2. Tyrimo instrumentas, tiriamųjų populiacija, imtis ir atranka

Tyrimo instrumentas:

Tyrimo instrumentu pasirinkta struktūruota anketinė apklausa, sukurta remiantis atlikta mokslinės literatūros analize. Anketą sudaro 40 pagrindinių teiginių, skirtų įvertinti keturis pagrindinius HOC per jų LOC (kaip aptarta 2.1 skyriuje), ir 6 demografiniai klausimai.

Visiems pagrindiniams teiginiams vertinti naudota šešių balų „Likert“ skalė, kur respondentai turėjo įvertinti savo sutikimo su teiginiu laipsnį:

- 1 – "visiškai nesutinku";
- 2 – "nesutinku";
- 3 – "labiau nesutinku nei sutinku";
- 4 – "labiau sutinku nei nesutinku";
- 5 – "sutinku";
- 6 – "visiškai sutinku".

Papildomai buvo numatyta galimybė teiginius įvertinti - "0 – negaliu atsakyti/neturiu nuomonės", siekiant išvengti priverstinių atsakymų, kai respondentas neturi pakankamai žinių ar nuomonės įvertinti teiginį.

Tyrimo populiacija:

Šiame tyrime dalyvavo įmonių darbuotojai ir vadovai, dirbantys Lietuvos įmonėse, kurios veikia informacinių technologijų, telekomunikacijų arba aukštųjų technologijų įrenginių gamybos sektoriuose ir savo klientų aptarnavimo procesuose naudoja arba aktyviai diegia dirbtinio intelekto sprendimus. Skaitoma, kad šių įmonių klientų aptarnavimas yra techninis klientų aptarnavimas, dėl įmonių vykdomos veiklos pobūdžio.

Remiantis valstybės duomenų agentūros 2025 m. I K. duomenimis, "Informacija ir ryšiai" sektoriuje (EVRK J sekcija), kuris apima didelę dalį tikslinės populiacijos, dirbo 64,1 tūkst. asmenų.

Tyrimo imtis:

Imties formavimui taikytas netikimybinis tikslinės atrankos (angl. *purposive sampling*) metodas, papildytas "sniego gniūžtės" (angl. *snowball sampling*) metodu. Tikslinė atranka pasirinkta siekiant užtikrinti, kad į imtį patektų respondentai, turintys reikiamų žinių ir tiesioginės patirties su DI taikymu ir naudojimu klientų aptarnavime.

Respondentų įtraukimo į tyrimą kriterijai:

1. Dirbantys įmonėje, veikiančioje informacinių technologijų, telekomunikacijų ar aukštųjų technologijų gamybos sektoriuje Lietuvoje.
2. Tiesioginė sąsaja su klientų aptarnavimo procesais (pvz., klientų aptarnavimo specialistai, techniniai specialistai, teikiantys pagalbą klientams, šių sričių komandų vadovai).

3. Praktinė patirtis su DI sprendimų naudojimu arba jų diegimu įmonės klientų aptarnavimo veikloje.

Galutinė tyrimo imtis sudarė 252 respondentus, kurių atsakymai buvo pripažinti tinkamais tolesnei analizei. Imties dydis laikomas pakankamu taikant PLS-SEM metodologiją. Remiantis "10 kartų taisykle" (angl. *10 times rule*) (Hair, 2017), minimali reikiama imtis šiam modeliui būtų apie 40 respondentų (didžiausias formuojančių indikatorius skaičius HOC yra 4, o didžiausias įeinančių ryšių skaičius į endogeninį HOC taip pat yra 4).

Remiantis mokslinė literatūra sudėtingesniems modeliams su hierarchine struktūra ir konstruktais, literatūroje rekomenduojama turėti 200 ar daugiau respondentų siekiant užtikrinti rezultatų validumą ir statistinį reikšmingumą (Kock ir Hadaya, 2018) ką šį tyrimo imtis tenkina.

Respondentų demografinė statistika pateikiama 8 lentelėje.

8 lentelė

Tyrimo demografiniai rezultatai

Demografinis kintamasis	Kategorija	Respondentų skaičius	Respondentų dalis %
Lytis	Vyras	165	65,5
	Moteris	87	34,5
Amžius	26-35 m.	164	65,1
	36-45 m.	49	19,4
	18-25 m.	33	13,1
	46-55 m.	6	2,4
Pareigos	Klientų aptarnavimo darbuotojas(-a) / specialistas(-ė)	82	32,5
	Vidurinės grandies vadovas(-ė)	61	24,2
	Techninis specialistas(-ė)	53	21,0
	Aukštesnysis lygio vadovas(-ė)	23	9,1
	Aukščiausio lygio vadovas(-ė)	20	7,9
	Techninis specialistas(-ė) / inžinierius(-ė)	11	4,4
	Komandos lyderis(-ė) / vadovas(-ė)	2	0,8
Darbo patirtis klientų aptarnavimo srityje	4-7 metai	162	64,3
	8-10 metų	45	17,9
	1-3 metai	28	11,1
	Daugiau nei 10 metų	11	4,4
	Mažiau nei 1 metai	6	2,4
Įmonės dydis	50-249 darbuotojų	156	61,9
	250 ir daugiau darbuotojų	82	32,5
	Mažiau nei 50 darbuotojų	14	5,6
Įmonės sektorius	Informacinės technologijos	128	50,8
	Telekomunikacijos	64	25,4
	Aukštųjų technologijų įrenginių gamyba	58	23,0
	Reklamos gamyba	1	0,4
	Finansinės paslaugos	1	0,4

Šaltinis: sudaryta autoriaus

2.3. Tyrimo organizavimas

Empirinių duomenų rinkimas vykdytas 2025 m. gegužės mėnesį, naudojant „Google Forms“ apklausų vykdymo platformą. Duomenų rinkimo strategija apėmė kelis etapus:

- Naudojant profesinius tinklus;

- Sniego gniūžtės metodą, kai respondentų buvo prašoma pasidalinti anketa su kolegomis, atitinkančius tyrimo kriterijus.

Kiekvienas respondentas prieš pradėdamas anketą gavo išsamų tyrimo aprašymą, kuriame buvo aiškinami tyrimo tikslai, pateikta informaciją apie duomenų konfidencialumo užtikrinimą.

2.4. Tyrimo metodai

Surinkti anketiniai duomenys buvo analizuojami naudojant **SmartPLS 4** (Ringle ir kt., 2022) programą, taikant dalinių mažiausiųjų kvadratų struktūrinių lygčių modeliavimo (angl. *partial least squares structural equation modeling*, toliau - PLS-SEM) metodą. Šis metodas pasirinktas dėl šių priežasčių:

- Latentinių konstrukto analizės tinkamumas: tyrimo objektas apima keturis latentinius konstruktus, kurių negalima tiesiogiai išmatuoti vienu indikatoriumi. PLS-SEM skirtas analizuoti latentinius kintamuosius, leidžiantis atskirti matavimo modelį (sudarytą iš LOC konstrukto, kurie yra matuojami indikatoriais) nuo struktūrinio modelio (sudaryta iš HOC konstrukto, kurie matuojami latentinėmis LOC vertėmis) ir leidžia efektyviai įvertinti matavimo paklaidas (Hair ir kt., 2019).
- Prognozavimo galimybės: tyrimo tikslas yra ne tik patikrinti teorinius ryšius, bet ir sukurti prognozinį modelį DI diegimo, poveikiui techninio klientų aptarnavimo efektyvumui vertinti. PLS-SEM orientuotas į paaiškinamosios dispersijos maksimizavimą ir prognozinę galią, kas atitinka tyrimo tikslus (Shmueli ir kt., 2019).
- Kompleksinių modelių analizės galimybės: tyrime analizuojami keturi aukštesnio lygio konstruktai su dvylika žemesnio lygio konstrukto sudarytą iš 40 indikatorių (teiginių, kurie yra matuojami). PLS-SEM efektyviai tvarko sudėtingus hierarchinius modelius su dideliu indikatorių ir konstrukto skaičiumi (Hair ir kt., 2019)
- Tarpinio poveikio analizės galimybės: tyrimo modelyje organizacinis pasirengimas veikia kaip tarpininkas tarp DI diegimo intensyvumo ir klientų aptarnavimo efektyvumo. PLS-SEM leidžia tiesiogiai analizuoti netiesioginius efektus ir mediaciją (Preacher ir Hayes, 2008)
- Moderacijos efektų tyrimas: H4 hipotezė reikalauja analizuoti užduočių-technologijų atitikimo moderavimo poveikį. PLS-SEM suteikia galimybę

efektyviai modeliuoti sąveikos efektus tarp konstrukty (Henseler ir Fassott, 2010).

Tyrimė taikomas hierarchinis konstrukty modelis atspindintis-formuojantis (arba II tipo) taikant dviejų pakopų metodą (angl. *two-stage approach*). Žemesnio lygio konstruktai matuojami atspindinčiais indikatoriais, kurie atspindi latentinio konstrukto išraišką. Aukštesnio lygio konstruktai modeliuojami kaip formuojantys konstruktrai, kur keli žemesnio lygio konstruktai kartu formuoja aukštesnio lygio konstrukto prasmę (Becker ir kt., 2012; Hair, 2017)

Duomenų paruošimas:

Prieš pradėdant analizę, duomenys buvo kruopščiai patikrinti dėl praleistų reikšmių ir galimų išskirčių. Atsakymai "0 – negaliu atsakyti/neturiu nuomonės" buvo traktuojami kaip praleistos reikšmės.

Matavimo modelio vertinimas:

Šiame etape buvo vertinamas tiek žemesnio lygio konstrukty (LOC), tiek aukštesnio lygio konstrukty (HOC) matavimo modelių tinkamumas.

LOC matavimo modelio vertinimas:

- **Indikatorių patikimumas** : vertintas pagal išorines koreliacijas (angl. *Outer Loadings*), norima reikšmė $> 0,708$.
- **Vidinis suderinamumas**: vertintas pagal Cronbach alfa ($CA > 0,7$), Dillon-Goldstein's rho ($\rho_A > 0,7$) ir sudėtinį patikimumą (angl. *Composite Reliability* - CR; ρ_c ir ρ_a) CR arba $\rho_c > 0,7$.
- **Konvergentinis pagrįstumas** (angl. *Convergent Validity*): - vidutinė dispersijos reikšmė (angl. *average variance extracted* , toliau AVE). vertintas pagal AVE ($AVE > 0,5$).
- **Diskriminantinis validumas**: vertintas pagal Fornell-Larcker kriterijų (AVE kvadratinė šaknis didesnė už koreliacijas su kitais konstruktais), heterogeninio-monogeninio ryšio santykį (angl. *Heterotrait-Monotrait Ratio*, toliau - HTMT) ($HTMT < 0,85$ arba $< 0,90$) ir kryžmines koreliacijas (*cross-loadings*).
- **Indikatorių kolinearumas**: vertintas pagal dispersijos išpūtimo faktorių (angl. *Variance Inflation Factor*, toliau – VIF), $VIF < 5$, idealiau atveju $< 3,3$, Indikatoriai su aukštomis VIF reikšmėmis buvo šalinami.

- Formuojančių indikatorių latentinių kintamųjų reikšmės (angl. *latent variable scores*, toliau - LV scores) kolinearumas: vertintas pagal VIF (< 5).
- **Išorinių svorių (angl. *outer weights*)** reikšmingumas ir svarba: vertintas naudojant *bootstrapping* procedūrą (T statistika, p-reikšmės).

Struktūrinio modelio vertinimas:

Įvertinus matavimo modelių tinkamumą, buvo analizuojami ryšiai tarp HOC.

- **HOC konstrukto kolinearumas:** vertintas pagal VIF (<5) vidiniame modelyje.
- **Ryšio koeficientų (β) dydis, kryptis ir statistinis reikšmingumas:** vertintas naudojant *bootstrapping* procedūrą su 5000 pakartotinių imčių (angl. *resamples*) ir 95% pasikliautinumo lygmeniu (p-reikšmės).
- **Determinacijos koeficientas (R^2) ir koreguotas R^2 (R^2 adjusted):** vertintas matuojant modelio paaiškinamąją galią HOC konstruktais.
- **Efekto dydis (f^2):** vertintas matuojant kiekvieno struktūrinio ryšio santykinę svarbą.
- **Modelio prognozinis reikšmingumas:** vertintas naudojant PLSpredict procedūrą ($Q^2_{predict}$, RMSE, MAE palyginimas su LM) (Shmueli ir kt., 2019) ir CVPAT (angl. *Cross-Validated Predictive Ability Test*) (Sharma ir kt., 2022)

Hipotezių tikrinimas:

Remiantis struktūrinio modelio ryšio koeficientų statistiniu reikšmingumu (p-reikšmėmis) ir ryšio stiprumu (kryptimi), buvo daromos išvados dėl kiekvienos iškeltos hipotezės (H1-H4) patvirtinimo arba atmetimo.

Moderacijos analizė:

H4 hipotezei apie TTF_HOC moderuojantį poveikį buvo taikytas sąveikos nario (angl. *interaction term*) metodas. Buvo vertinamas sąveikos nario ryšio koeficiento statistinis reikšmingumas.

3. DI INTEGRACIJOS SĖKMĖS FAKTORIŲ IR JŲ POVEIKIO TECHNINIO KLIENTŲ APTARNAVIMO EFEKTYVIMUI TYRIMO REZULTATŲ ANALIZĖ IR VERTINIMAS

Šiame skyriuje pateikiamas išsamus dirbtinio intelekto panaudojimo galimybių techniniuose klientų aptarnavimo procesuose empirinio tyrimo rezultatų aprašymas ir analizė. Tyrimo duomenys analizuojami taikant PLS-SEM metodologiją, leidžiančią vienu metu įvertinti tiek matavimo modelių kokybę, tiek struktūrinius ryšius tarp konstruktyvų. Empirinių duomenų analizė apima tyrimo respondentų charakteristikų aprašymą, konstruktyvų patikimumo ir validumo įvertinimą, hipotezių tikrinimą bei rezultatų interpretaciją praktinio pritaikomumo kontekste.

3.1. Tyrimo respondentų rezultatų ir konstruktyvų patikimumo analizė

Siekiant įvertinti, ar surinkta tyrimo imtis (252 respondentai) yra pakankama patikimiems ir statistiškai pagrįstiems rezultatams gauti, buvo atsižvelgta į kelis esminius aspektus.

Pagrindinis sektorius, į kurį orientuotas šis tyrimas, yra "Informacija ir ryšiai" (apimantis informacines technologijas ir telekomunikacijas). Remiantis oficialia Lietuvos valstybės duomenų agentūros informacija, 2025 m. I K. "Informacija ir ryšiai" sektoriuje (EVRK J sekcija) dirbo 64,1 tūkst. asmenų. Aukštųjų technologijų gamybos sektorius, nors ir specifiškesnis, taip pat prisideda prie bendros tikslinės populiacijos, tačiau pagrindinė atskaitos populiacija laikytina minėti 64,1 tūkst. darbuotojų.

Remiantis bendraisiais imties dydžio skaičiavimo principais, reikalingas imties dydis priklauso nuo populiacijos dydžio (N), pageidaujamo pasikliautinumo lygmens (dažniausiai 95%, $Z=1,96$), maksimalios leistinos paklaidos (e, dažniausiai 5% arba 0,05) ir tiriamojo požymio pasiskirstymo populiacijoje (p, jei nežinoma, naudojama konservatyviausia 0,5 reikšmė, kas reiškia $q=0,5$) (Saunders ir kt., 2023).

Klasikinio imties dydžio skaičiavimo formulė begalinei populiacijai:

$$n_0 = (Z^2 \times p \times q) / e^2 \quad n_0 = (1,96^2 \times 0,5 \times 0,5) / 0,05^2 = (3,8416 \times 0,25) / 0,0025 = 0,9604 / 0,0025 \approx 385 \text{ respondentai}$$

Kadangi populiacija yra baigtinė ($N = 64\,100$), taikoma koreguota formulė imties dydžiui (n) apskaičiuoti:

$$n = n_0 / (1 + (n_0 - 1) / N) \quad n = 385 / (1 + (385 - 1) / 64100) = 385 / (1 + 384 / 64100) = 385 / 1,0059906 \approx 383 \text{ respondentai}$$

Šis klasikinis skaičiavimas rodo, kad norint pasiekti 95% pasikliautinumo lygmenį su 5% paklaida, esant 64,1 tūkst. dydžio populiacijai, teoriškai reikalinga maždaug 383 respondentų imtis.

Tačiau kadangi šiame tyrime taikyta PLS-SEM metodologiją, imties dydžio reikalavimai yra lankstesni nei taikant kovariacijomis pagrįstą SEM (CB-SEM) ar regresijų modelius. PLS-SEM yra laikomas tinkamu analizės metodu esant mažesnėms imtims, ypač kai modelis yra prognozinio pobūdžio, o ne griežtai teorijos testavimo, ir kai pagrindinis tikslas yra identifikuoti reikšmingus ryšius, o ne tiksliai įvertinti populiacijos parametrus (Hair ir kt., 2019).

Egzistuoja keletas pagrindinių gairių PLS-SEM imties dydžiui nustatyti:

"10 kartų taisyklė": - Pagal šią plačiai taikomą taisyklę, minimalus imties dydis turėtų būti 10 kartų didesnis už didžiausią formuojančių indikatorių (LOC) skaičių vienam formuojančiam konstruktui (HOC) arba 10 kartų didesnis už didžiausią struktūrinių ryšių, nukreiptų į vieną latentinį kintamąjį struktūriniame modelyje, skaičių (Hair ir kt., 2019)

Šiame tyrime:

- HOC konstruktai DI diegimo intensyvumas, organizacinis pasirengimas ir klientų aptarnavimo procesų efektyvumas turi po 4 formuojančius indikatorius (LOC konstruktus), o TTF turi 3. Taigi, didžiausias formuojančių indikatorių skaičius yra 4.
- Struktūriniame modelyje į klientų aptarnavimo procesų efektyvumo konstrukta nukreipti ryšiai iš DI Diegimo, , organizacinis pasirengimas, TTF ir DI diegimo intensyvumo moderatoriaus – iš viso 4 ryšiai.

Pagal šią taisyklę, minimali reikiama imtis būtų 40 respondentų. Surinkta 252 respondentų imtis gerokai viršija šį minimalų reikalavimą.

Efektų dydžiai ir statistinis galingumas:

Empiriniai tyrimai rodo, kad PLS-SEM kontekste efektų dydis (angl. *effect size*) yra svarbesnis veiksnys nei absoliutus imties dydis (Cohen, 2013). Gautos R^2 reikšmės priklausomiems HOC konstrukts yra vidutinio stiprumo (OP_HOC $R^2 = 0,476$; KAPE_HOC $R^2 = 0,634$), kas rodo, kad modelis gerai paaiškina priklausomų kintamųjų dispersiją. Efektų dydis ir statistinis galingumas pateikiamas 9 lentelėje.

9 lentelė

Priklausomų HOC konstrukty statistinis galingumas

Priklausomų kintamųjų	R-square	R-square adjusted
Klientų aptarnavimo procesų efektyvumas	0.634	0.628
Organizacinis pasirengimas	0.476	0.474

Šaltinis: sudaryta darbo autoriaus naudojantis „SmartPLS 4“ programa

Atsižvelgiant į tai, kad šiame tyrime taikoma PLS-SEM metodologija, modelis yra hierarchinis ir vidutinio sudėtingumo, o gautos R^2 reikšmės bei efektų dydžiai yra patenkinami, surinkta 252 respondentų imtis yra laikoma pakankama ir tinkama prasmingoms išvadoms daryti bei hipotezėms tikrinti magistro darbo lygmeniu. Nors klasikinis imties skaičiavimas rodo didesnę reikalingą dydį siekiant griežtų 5% paklaidos ribų visai 64,1 tūkst. populiacijai, PLS-SEM metodologijos specifiška leidžia efektyviai analizuoti duomenis ir su tokia imtimi, ypač kai dėmesys skiriamas ryšių stiprumui ir modelio nuspėjamumo galiai.

3.2. Tyrime naudotų konstrukty aprašymas

Prieš pateikiant detalią analizę, svarbu aiškiai apibrėžti tyrime naudotus konstrukty (jų pavadinimus) ir jų sudaromąsias dalis. Šiame tyrime taikomas hierarchinis konstrukty modelis, kuriame išskiriami žemesnio lygio konstrukty (LOC) ir aukštesnio lygio konstrukty (HOC).

Žemesnio lygio konstrukty (LOC):

DI diegimo intensyvumo komponentai:

- DIDI_Diegimo_apimtis - DI sprendimų panaudojimo platesniu mastu įmonės klientų aptarnavimo procesuose
- DIDI_Diegimoevoliucija - DI sprendimų tobulinimo ir vystymo procesai pagal patirtį
- DIDI_Funkcinis_sudėtingumas - DI sprendimų galimybė atlikti sudėtingas klientų aptarnavimo užduotis
- DIDI_Integracijos_lygis - DI sprendimų sąveikos su kitomis įmonės sistemomis laipsnis

Organizacinio pasirengimo komponentai:

- OP_Techninė_infrastruktūra - įmonės techninės infrastruktūros tinkamumas DI sprendimams

- OP_Techninis_lankstumas - darbuotojų gebėjimas prisitaikyti ir efektyviai naudoti DI technologijas
- OP_Dokumentacijos_kokybė - klientų aptarnavimui svarbių dokumentų struktūrizavimo ir prieinamumo lygis
- OP_Vadovybės_palaikymas - vadovybės aktyvumas palaikant DI iniciatyvas

Užduočių-technologijų atitikimo komponentai:

- TTF_DI_galimybių_atitikimas - DI sprendimų pritaikymas konkrečių klientų aptarnavimo užduočių sprendimui
- TTF_Funkcinis_atitikimas - DI sprendimų funkcionalumo atitikimas klientų aptarnavimo poreikiams
- TTF_Procesų_suderinamumas - DI technologijų suderinamumas su esamais darbo metodais

Klientų aptarnavimo efektyvumo komponentai:


- KAPE_Laiko_efektyvumas - laiko sutaupymas ir greitesnis problemų sprendimas naudojant DI
- KAPE_Resursų_naudojimas - efektyvesnis žmogiškųjų išteklių panaudojimas
- KAPE_Aptarnavimo_kokybė - klientų pasitenkinimo ir aptarnavimo kokybės pagerėjimas
- KAPE_Žinių_valdymo_kokybė - techninių žinių valdymo ir paieškos efektyvumo padidėjimas

LOC matavimo modelio pirminis variantas pateikiamas 4 paveiksle.

4 paveikslas

LOC matavimo modelio pirminis variantas

PLS-SEM: pls-sem-LOCs-full



Šaltinis: sudaryta darbo autoriaus naudojantis „SmartPLS 4“ programa


Aukštesnio lygio konstruktai (HOC):

- DI_HOC - DI diegimo intensyvumas (susideda iš 4 DIDI komponentų)
- OP_HOC - organizacinis pasirengimas (susideda iš 4 OP komponentų)
- TTF_HOC - užduočių-technologijų atitikimas (susideda iš 3 TTF komponentų)
- KAPE_HOC - klientų aptarnavimo proceso efektyvumas (susideda iš 4 KAPE komponentų)

HOC struktūrinis modelis pateikiamas 5 paveiksle.

5 paveikslas

HOC struktūrinis modelis



Šaltinis: sudaryta darbo autoriaus naudojantis „SmartPLS 4“ programa

3.3. Matavimo modelio analizės rezultatai

Tyrime taikomas hierarchinis konstrukto modelis, žemesnio lygio konstruktai (LOC), tokie kaip "DIDI_Diegimo_apimtis" ar "KAPE_Laiko efektyvumas", yra matuojami atspindinčiais indikatoriais (klausimyno teiginiais). Atspindintys indikatoriai yra laikomi konstrukto išraiška (pasekme), o pats konstruktas sukelia kovariaciją tarp savo indikatorių; tikimasi, kad jie bus stipriai tarpusavyje susiję ir pakeičiami (Becker ir kt., 2012). Aukštesnės lygio konstruktai (HOC) – "DI diegimo intensyvumas" (DI_HOC), "Organizacinis pasirengimas" (OP_HOC), "Užduočių-technologijų atitikimas" (TTF_HOC) ir "Klientų aptarnavimo proceso efektyvumas" (KAPE_HOC) – yra modeliuojami kaip formuojantys. Tai reiškia, kad HOC yra sudaryti iš jų atitinkamų LOC latentinių kintamųjų reikšmių, kurios veikia kaip formuojantys indikatoriai; šie indikatoriai (LOC) kartu formuoja HOC prasmę, jie nebūtinai turi stipriai koreliuoti tarpusavyje ir nėra pakeičiami, nes kiekvienas atspindi skirtingą HOC dimensiją (Hair, 2017). Šiam tikslui taikomas dviejų pakopų metodas (angl. *two-stage approach*), kuris yra rekomenduojamas atspindintiems-formuojantiems (arba II tipo) modeliams (Becker ir kt., 2012).

3.3.1. Matavimo modelio vertinimas - LOC konstruktai

Prieš vertinant struktūrinį modelį, skirtą hipotezių tikrinimui, būtina įsitikinti žemesnio lygio konstrukto (LOC) matavimo modelio patikimumu ir validumu. Pradinėje modelio versijoje buvo įtraukti visi klausimyne numatyti indikatoriai (teiginiai). Tačiau, atlikus pradinę analizę, kai kurie indikatoriai buvo pašalinti dėl aukštų kolinearumo (VIF) reikšmių, siekiant pagerinti modelio stabilumą ir kokybę. Pirminio LOC modelio VIF rezultatai pateikiami 10 lentelėje.

10 lentelė

Pirminio LOC modelio kolineruamo analizės rezultatai

Teiginiai	VIF
Q7	4.436
Q8	4.436
Q9	4.528
Q10	5.263
Q11	5.959
Q12	8.300
Q13	4.673
Q14	4.673
Q15	4.553
Q16	4.553
Q17	2.687
Q18	2.687
Q19	6.983
Q20	5.922
Q21	7.831
Q22	9.944
Q23	7.854
Q24	8.834
Q25	3.132
Q26	3.132
Q27	4.328
Q28	4.328
Q29	4.143
Q30	3.571
Q31	3.381
Q32	4.432
Q33	5.991
Q34	4.521
Q35	4.148
Q36	4.148
Q37	3.787
Q37	4.301
Q38	3.787
Q38	4.751
Q39	3.686
Q40	6.797
Q41	8.890
Q42	6.438
Q43	5.660
Q44	5.660
Q45	5.296
Q46	5.433
Q47	5.090

Šaltinis: sudaryta darbo autoriaus naudojantis „SmartPLS 4“ programa

Remiantis pateikta pradinio modelio kolinearumo analizės lentelė galima matyti, kad kai kurių indikatorių VIF reikšmės viršijo norimą 5 ribą (Hair, 2017), o kai kurios

netgi buvo gerokai didesnės (pvz., Q12 VIF = 8.300, Q21 VIF = 7.831, Q22 VIF = 9.944, Q23 VIF = 7.654, Q40 VIF = 6.797, Q41 VIF = 8.890). Aukštos VIF reikšmės rodo stiprų multikolinearumą tarp indikatorių, o tai reiškia, kad šie indikatoriai matuoja labai panašius aspektus ir jų buvimas modelyje gali turėti įtakos standartinėms paklaidoms bei sumažinti ryšio koeficientų stabilumą. Dėl šios priežasties, siekiant užtikrinti modelio kokybę, indikatoriai su aukščiausiomis VIF reikšmėmis buvo nuosekliai šalinami, kol likusių indikatorių VIF reikšmės tapo priimtinos.

Iš galutinio modelio buvo pašalinti šie indikatoriai:


- Iš KAPE_Resursų naudojimas konstrukto: Q40 ir Q41 dėl aukštų VIF reikšmių (atitinkamai 6.797 ir 8.890)
- Iš OP_Techninis lankstumas konstrukto: Q21, Q22, Q23 ir Q24 dėl labai aukštų VIF reikšmių
- Iš DIDI_Funkcinis sudėtingumas konstrukto: Q12 dėl VIF = 8.300
- Iš KAPE_Žinių valdymo kokybė konstrukto: Q47 dėl VIF = 5.090

Galutinis tyrime naudotas LOC matavimo modelis pateikiamas 6 paveiksle.

6 paveikslas

Galutinis LOC matavimo modelis

PLS-SEM: pls-sem-LOCs



Šaltinis: sudaryta darbo autoriaus naudojantis „SmartPLS 4“ programa

Po pakeitimų toliau buvo vertinamas galutinis LOC matavimo modelis su likusiais indikatoriais.

Indikatorių patikimumas:

Remiantis galutinio modelio duomenimis, visų likusių atspindinčių indikatorių išoriniai koreliacijos koeficientai viršija rekomenduojamą 0,708 ribą (Hair ir kt., 2019). LOC indikatorių išorinės koreliacijos koeficientai pateikiami 11 lentelėje.

11 lentelė

LOC indikatorių išoriniai koreliacijos koeficientai

LOC teiginiai	Outer loadings
Q10 <- DIDI Funkcinis sudėtingumas	0.973
Q11 <- DIDI Funkcinis sudėtingumas	0.955
Q13 <- DIDI Integracijos lygis	0.969
Q14 <- DIDI Integracijos lygis	0.973
Q15 <- DIDI Diegimo evoliucija	0.965
Q16 <- DIDI Diegimo evoliucija	0.975
Q17 <- OP Techninė infrastruktūra	0.951
Q18 <- OP Techninė infrastruktūra	0.942
Q19 <- OP Techninis lankstumas	0.957
Q21 <- OP Techninis lankstumas	0.961
Q23 <- OP Techninis lankstumas	0.956
Q25 <- OP Dokumentacijos kokybė	0.951
Q26 <- OP Dokumentacijos kokybė	0.959
Q27 <- OP Vadovybės palaikymas	0.965
Q28 <- OP Vadovybės palaikymas	0.972
Q29 <- TTF DI galimybių atitikimas	0.945
Q30 <- TTF DI galimybių atitikimas	0.920
Q31 <- TTF DI galimybių atitikimas	0.937
Q32 <- TTF Funkcinis atitikimas	0.930
Q33 <- TTF Funkcinis atitikimas	0.964
Q34 <- TTF Funkcinis atitikimas	0.955
Q35 <- TTF Procesų suderinamumas	0.952
Q36 <- TTF Procesų suderinamumas	0.980
Q37 <- KAPE Laiko efektyvumas	0.947
Q38 <- KAPE Laiko efektyvumas	0.953
Q39 <- KAPE Laiko efektyvumas	0.929
Q41 <- KAPE Resursų naudojimas	0.975
Q42 <- KAPE Resursų naudojimas	0.980
Q43 <- KAPE Aptarnavimo kokybė	0.974
Q44 <- KAPE Aptarnavimo kokybė	0.979
Q45 <- KAPE Žinių valdymo kokybė	0.969
Q46 <- KAPE Žinių valdymo kokybė	0.968
Q7 <- DIDI Diegimo apimtis	0.968
Q8 <- DIDI Diegimo apimtis	0.971

Šaltinis: sudaryta darbo autoriaus naudojantis „SmartPLS 4“ programa

Visi koeficientai yra labai aukšti (dauguma $> 0,9$), o tai rodo, kad kiekvienas likęs indikatorius stipriai koreliuoja su savo latentiniu konstruktu ir gerai jį atspindi. Tai yra pirmas žingsnis užtikrinant, kad teiginiai yra tinkamai suprasti ir matuoja numatytus aspektus.

Vidinis suderinamumas:

Remiantis konstrukto patikimumo ir validumo duomenimis:

- Cronbach alfa (CA): visų LOC Cronbach alfa reikšmės yra aukštesnės nei 0,7.

- Sudėtinis patikimumas: visų LOC sudėtinio patikimumo (ρ_c) reikšmės yra aukštesnės nei 0,7 (dauguma viršija 0,9).

Šie rodikliai patvirtina labai aukštą kiekvieno konstrukto indikatorių vidinį suderinamumą.

Konvergentinis pagrįstumas (angl. *Convergent Validity*) - vidutinė dispersijos reikšmė (angl. *average variance extracted*, toliau AVE). Visų LOC AVE reikšmės viršija rekomenduojamą 0,5 ribą. Tai reiškia, kad kiekvienas latentinis konstruktas paaiškina vidutiniškai daugiau nei pusę savo indikatorių dispersijos, o tai patvirtina gerą konvergentinį pagrįstumą (Fornell ir Larcker, 1981; Hair ir kt., 2019).

LOC matavimo modelio vidinio suderinamumo testų rezultatai pateikiami 12 lentelėje.

12 lentelė

LOC matavimo modelio vidinis suderinamumas

LOC	Cronbach's alpha	Composite reliability (ρ_a)	Composite reliability (ρ_c)	Average variance extracted (AVE)
DIDI_Diegimo_apimtis	0.936	0.939	0.969	0.940
DIDI_Diegimoevoliucija	0.938	0.956	0.970	0.941
DIDI_Funkcinis sudėtingumas	0.924	0.967	0.963	0.929
DIDI_Integracijos_lygis	0.940	0.944	0.971	0.943
KAPE_Aptarnavimo kokybė	0.951	0.961	0.976	0.954
KAPE_Laiko efektyvumas	0.938	0.942	0.960	0.889
KAPE_Resursų naudojimas	0.954	0.960	0.977	0.956
KAPE_Žinių valdymo kokybė	0.933	0.934	0.968	0.938
OP_Dokumentacijos kokybė	0.904	0.909	0.954	0.912
OP_Techninis lankstumas	0.955	0.961	0.971	0.918
OP_Techninė infrastruktūra	0.884	0.888	0.945	0.896
OP_Vadovybės palaikymas	0.934	0.944	0.968	0.938
TTF_DI galimybių atitikimas	0.927	0.942	0.953	0.872
TTF_Funkcinis atitikimas	0.947	0.980	0.965	0.902
TTF_Procesų suderinamumas	0.931	1.057	0.965	0.933

Šaltinis: sudaryta darbo autoriaus naudojantis „SmartPLS 4“ programa

Diskriminantinis validumas rodo, kiek vienas konstruktas skiriasi nuo kitų konstrukto modelyje.

- Kryžminės koreliacijos (angl. *Cross-Loadings*): kiekvieno indikatoriaus koreliacijos koeficientas su savo ("tėviniu") konstruktu yra didesnis nei jo koreliacijos koeficientai su bet kuriuo kitu konstruktu modelyje. Kas rodo kad modelis yra tinkamas. Rezultatai pateikiami **1 priede**.
- Fornell-Larcker kriterijus: pagal šį kriterijų, kiekvieno konstrukto AVE kvadratinė šaknis turi būti didesnė už to konstrukto koreliacijas su visais kitais konstruktais (Fornell ir Larcker, 1981). Šis kriterijus yra patenkintas visiems konstruktais, kas rodo gerą diskriminantinį validumą. Rezultatai pateikiami **2 priede**.
- *Heterotrait-Monotrait Ratio* (HTMT) kriterijus: visos HTMT reikšmės tarp LOC yra mažesnės už konservatyvesnį 0,85 slenkstį ir griežtesnį 0,90 slenkstį (Henseler ir kt., 2015). Tai patvirtina diskriminantinį validumą, parodant, kad konstruktai matuoja skirtingas koncepcijas. Rezultatai pateikiami **3 priede**.

Indikatorių kolinearumo statistika (VIF) galutiniame modelyje:

Remiantis galutinio modelio duomenimis, daugelio indikatorių VIF reikšmės yra **žemiau 5**, kas rodo, kad kolinearumas nėra problema. Tačiau kai kurių indikatorių VIF reikšmės vis dar yra aukštesnės nei norima riba. Probleminių indikatoriai pateikiami 13 lentelėje.

13 lentelė

Probleminiai LOC indikatoriai

Indikatoriai (teiginiai)	VIF
Q23	5.433
Q21	5.443
Q43	5.660
Q44	5.660
Q19	5.797
Q41	5.910
Q42	5.910
Q33	5.991

Šaltinis: sudaryta darbo autoriaus naudojantis „SmartPLS 4“ programa

Nors kai kurios reikšmės viršija griežtesnę 5 ribą, jos yra žemesnės nei pradiniam modelyje. Tai rodo, kad multikolinearumo problema buvo sumažinta, tačiau tam tikras indikatorių panašumas išlieka. Galutinio modelio VIF reikšmės pateikiamos 14 lentelėje.

14 lentelė

Galutinio LOC matavimo modelio VIF vertės

Teiginiai	VIF
Q17	2.687
Q18	2.687
Q25	3.132
Q26	3.132
Q31	3.381
Q30	3.571
Q39	3.686
Q37	3.787
Q38	3.787
Q10	3.823
Q11	3.823
Q29	4.143
Q35	4.148
Q36	4.148
Q45	4.273
Q46	4.273
Q37	4.301
Q27	4.328
Q28	4.328
Q32	4.432
Q7	4.436
Q8	4.436
Q34	4.521
Q15	4.553
Q16	4.553
Q13	4.673
Q14	4.673
Q38	4.751
Q23	5.433
Q21	5.443
Q43	5.660
Q44	5.660
Q19	5.797
Q41	5.910
Q42	5.910
Q33	5.991

Šaltinis: sudaryta darbo autoriaus naudojantis „SmartPLS 4“ programa

Apibendrinant LOC matavimo modelio vertinimą, po probleminių indikatorių pašalinimo, žemesnio lygio konstruktai (LOC) pasižymi aukštu patikimumu (indikatorių ir vidinio suderinamumo), bei tvirtu konvergentiniu ir diskriminantiniu validumu, patvirtintu keliais metodais: cross-loadings, Fornell-Larcker, HTMT. Išlieka nedidelis susirūpinimas dėl kai kurių likusių indikatorių VIF reikšmių, tačiau bendrai matavimo modelis yra laikomas tinkamu ir tvirtu pagrindu tolesnei analizei.

3.3.2. Matavimo modelio vertinimas - HOC konstruktai

Aukštesnio lygio konstruktai (*DI_HOC*, *OP_HOC*, *TTF_HOC*, *KAPE_HOC*) yra modeliuojami kaip formuojantys konstruktai, naudojant atitinkamų LOC LV scores, kaip juos formuojančius indikatorius.

LV scores kolinearumo statistika (VIF):

Visų LV scores VIF reikšmės yra gerokai mažesnės nei 5. Tai rodo, kad tarp formuojančių HOC indikatorių (t.y., tarp LOC, formuojančių tą patį HOC) nėra reikšmingo kolinearumo, o tai yra svarbi sąlyga teisingam formuojančių konstrukto vertinimui (Hair ir kt., 2019). HOC matavimo modelio kolinearumo statistikos rezultatai pateikiami 15 lentelėje.

15 lentelė

HOC matavimo modelio kolinearumo rezultatai:

Latentinis kintamasis	VIF
LV scores - DIDI_Diegimo_apimtis	1.375
LV scores - DIDI_Diegimo_evoliucija	1.204
LV scores - DIDI_Funkcinis sudėtingumas	1.194
LV scores - DIDI_Integracijos_lygis	1.339
LV scores - KAPE_Aptarnavimo kokybė	1.350
LV scores - KAPE_Laiko efektyvumas	1.696
LV scores - KAPE_Resursų naudojimas	1.496
LV scores - KAPE_Žinių valdymo kokybė	1.530
LV scores - OP_Dokumentacijos kokybė	1.453
LV scores - OP_Techninis_lankstumas	1.357
LV scores - OP_Techninė_infrastruktūra	1.739
LV scores - OP_Vadovybės palaikymas	1.600
LV scores - TTF_DI_galimybių atitikimas	1.398
LV scores - TTF_Funkcinis atitikimas	1.065
LV scores - TTF_Procesų suderinamumas	1.370

Šaltinis: sudaryta darbo autoriaus naudojantis „SmartPLS 4“ programa

Išorinių svorių reikšmingumas ir svarba:

Išoriniai svoriai parodo santykinį kiekvieno formuojančio indikatorius (LOC LV score) indėlį į HOC formavimą.

- *DI_HOC*: visi keturi formuojantys LOC turi statistiškai reikšmingus (visi $p < 0,001$) ir teigiamus išorinius svorius. Tai rodo, kad visi šie DI diegimo formuojantys LOC konstruktai svariai ir unikaliai prisideda prie bendro "DI diegimo intensyvumo" konstrukto.

- OP_HOC: atsiskleidžia svarbius rezultatus - OP_Techninė_infrastruktūra → OP_HOC svoris = 0,125 ($p = 0,140$) – statistiškai nereikšmingas. Šis rezultatas rodo, kad šiame modelyje ir šioje imtyje, atsižvelgiant į kitus organizacinio pasirengimo aspektus, "Techninė infrastruktūra" reikšmingai neprisideda prie šio HOC formavimo.
- TTF_HOC: Visi trys formuojantys LOC turi statistiškai reikšmingus (visi $p < 0,001$) ir teigiamus išorinius svorius.
- KAPE_HOC: Visi keturi formuojantys LOC turi statistiškai reikšmingus (visi $p \leq 0,003$) ir teigiamus išorinius svorius. HOC matavimo modelio išorinių svorių ir reikšmingumu rezultatai pateikiami 17 lentelėje.

16 lentelė

HOC matavimo modelio išoriniai svoriai ir reikšmingumas

HOC formuojantys LV scores	Original sample (O)	Sample mean (M)	Standard deviation (STDEV)	T statistics (O/STDEV)	P values
LV scores - DIDI_Diegimo_apimtis -> DI_HOC	0.438	0.440	0.075	5.859	0.000
LV scores - DIDI_Diegimoevoliucija -> DI_HOC	0.392	0.389	0.058	6.714	0.000
LV scores - DIDI_Funkcinis sudėtingumas -> DI_HOC	0.322	0.323	0.056	5.731	0.000
LV scores - DIDI_Integracijos_lygis -> DI_HOC	0.343	0.342	0.072	4.734	0.000
LV scores - KAPE_Aptarnavimo kokybė -> KAPE_HOC	0.475	0.472	0.058	8.223	0.000
LV scores - KAPE_Laiko efektyvumas -> KAPE_HOC	0.212	0.210	0.072	2.935	0.003
LV scores - KAPE_Resursų naudojimas -> KAPE_HOC	0.346	0.353	0.072	4.796	0.000
LV scores - KAPE_Žinių valdymo kokybė -> KAPE_HOC	0.324	0.320	0.069	4.686	0.000
LV scores - OP_Dokumentacijos kokybė -> OP_HOC	0.514	0.513	0.058	8.892	0.000
LV scores - OP_Techninis_lankstumas -> OP_HOC	0.463	0.458	0.057	8.184	0.000
LV scores - OP_Techninė_infrastruktūra -> OP_HOC	0.125	0.128	0.085	1.477	0.140
LV scores - OP_Vadovybės palaikymas -> OP_HOC	0.254	0.256	0.069	3.700	0.000
LV scores - TTF_DI galimybių atitikimas -> TTF_HOC	0.414	0.409	0.095	4.372	0.000
LV scores - TTF_Funkcinis atitikimas -> TTF_HOC	0.552	0.553	0.080	6.938	0.000
LV scores - TTF_Procesų suderinamumas -> TTF_HOC	0.402	0.398	0.094	4.296	0.000

Šaltinis: sudaryta darbo autoriaus naudojantis „SmartPLS 4“ programa

Apibendrinant HOC matavimo modelio vertinimą, dauguma HOC yra gerai suformuoti, jų formuojantys indikatoriai (LOC LV scores) neturi kolinearumo problemų

ir dauguma jų turi reikšmingus ir teoriškai pagrįstus išorinius svorius. Iš gautų rezultatų yra daroma išvada, kad LOC - OP_Techninė_infrastruktūra" sudaro nereikšmingą indėlį į OP_HOC, kas rodo, jog kiti organizacinio pasirengimo aspektai (dokumentacijos kokybė, techninis lankstumas, vadovybės palaikymas) yra santykinai svarbesni formuojant šį aukštesnio lygio konstruktą šiame tyrime.

3.4. Struktūrinio modelio vertinimas (HOC)

Įvertinus matavimo modelių kokybę ir užtikrinus duomenų validumą pereinama prie struktūrinio modelio, ryšių tarp aukštesnio lygio konstruktų, analizės.

Vertinant HOC konstruktų VIF vidiniame modelyje, visos VIF reikšmės yra gerokai mažesnės nei 5 (ir net mažesnės nei griežtesnė 3.3 riba), kas rodo, kad tarp HOC konstruktų, prognozuojančių tuos pačius priklausomus kintamuosius, nėra reikšmingo kolinearumo. HOC struktūrinio modelio VIF reikšmės pateikiamos 17 lentelėje.

17 lentelė

HOC struktūrinio modelio VIF reikšmės

HOC vidinio modelio ryšiai	VIF
DI_HOC -> KAPE_HOC	2.195
DI_HOC -> OP_HOC	1.000
OP_HOC -> KAPE_HOC	2.164
TTF_HOC -> KAPE_HOC	1.662
TTF_HOC x DI_HOC -> KAPE_HOC	1.083

Šaltinis: sudaryta darbo autoriaus naudojantis „SmartPLS 4“ programa

Ryšio koeficientų (Path Coefficients - β) reikšmingumas ir svarba:

- DI_HOC $\rightarrow$ OP_HOC: $\beta = 0,690$ ($p < 0,001$). Ryšys yra stiprus, teigiamas ir statistiškai stipriai reikšmingas.
- DI_HOC $\rightarrow$ KAPE_HOC: $\beta = 0,319$ ($p < 0,001$). Ryšys yra vidutinio stiprumo, teigiamas ir statistiškai labai reikšmingas.
- OP_HOC $\rightarrow$ KAPE_HOC: $\beta = 0,443$ ($p < 0,001$). Ryšys yra vidutinio stiprumo link stipraus, teigiamas ir statistiškai labai reikšmingas.
- TTF_HOC $\rightarrow$ KAPE_HOC (pagrindinis efektas): $\beta = 0,146$ ($p = 0,081$). Ryšys yra teigiamas, bet statistiškai - nereikšmingas esant įprastiniam $\alpha=0.05$ patikimumo lygmeniui.

- $TTF_HOC \times DI_HOC \rightarrow KAPE_HOC$ (moderacijos efektas): $\beta = 0,022$ ($p = 0,535$). Sąveikos efektas yra labai silpnas ir statistiškai nereikšmingas.

Ryšių koeficientų įvertinimo rezultatai pateikiami 18 lentelėje.

18 lentelė

Ryšių koeficientų rezultatai HOC struktūriniame modelyje

Ryšiai	Original sample (O)	Sample mean (M)	Standard deviation (STDEV)	T statistics (O/STDEV)	P values
DI_HOC -> KAPE_HOC	0.319	0.317	0.078	4.090	0.000
DI_HOC -> OP_HOC	0.690	0.696	0.045	15.259	0.000
OP_HOC -> KAPE_HOC	0.443	0.439	0.089	4.999	0.000
TTF_HOC -> KAPE_HOC	0.146	0.150	0.083	1.748	0.081
TTF_HOC x DI_HOC -> KAPE_HOC	0.022	0.022	0.035	0.621	0.535

Šaltinis: sudaryta darbo autoriaus naudojantis „SmartPLS 4“ programa

Determinacijos koeficientas (R^2 ir R^2 adjusted):

- OP_HOC: $R^2 = 0,476$ (R^2 adjusted = 0,474). Tai rodo vidutinę paaiškinamąją galią.
- KAPE_HOC: $R^2 = 0,634$ (R^2 adjusted = 0,628). Tai rodo didelę modelio paaiškinamąją galią šiam konstruktui.

Determinacijos koeficientų patikros rezultatai pateikiami 19 lentelėje.

19 lentelė

Determinacijos koeficientai HOC struktūriniame modelyje

Priklausomi kinetamieji	Original sample (O)	Sample mean (M)	Standard deviation (STDEV)	T statistics (O/STDEV)	P values
KAPE_HOC	0.634	0.648	0.048	13.234	0.000
OP_HOC	0.476	0.486	0.062	7.640	0.000

Šaltinis: sudaryta darbo autoriaus naudojantis „SmartPLS 4“ programa

Efekto dydis (f^2):

f^2 matuoja kiekvieno HOC konstrukto įtaką priklausomo konstrukto R^2 reikšmei:

- DI_HOC poveikis OP_HOC: $f^2 = 0,907$. Tai yra labai didelis efektas.
- DI_HOC poveikis KAPE_HOC: $f^2 = 0,127$. Tai yra tarp mažo ir vidutinio efekto.
- OP_HOC poveikis KAPE_HOC: $f^2 = 0,247$. Tai yra vidutinis efektas.
- TTF_HOC poveikis KAPE_HOC: $f^2 = 0,035$. Tai yra mažas efektas.
- TTF_HOC $\times$ DI_HOC poveikis KAPE_HOC: $f^2 = 0,003$. Efekto praktiškai nėra.

Efekto dydžio rezultatai pateikiami 20 lentelėje.

20 lentelė

Efekto dydis HOC struktūriniame modelyje

	Original sample (O)	Sample mean (M)	Standard deviation (STDEV)	T statistics (O/STDEV)	P values
DI_HOC -> KAPE_HOC	0.127	0.134	0.062	2.055	0.040
DI_HOC -> OP_HOC	0.907	0.975	0.245	3.697	0.000
OP_HOC -> KAPE_HOC	0.247	0.263	0.118	2.092	0.036
TTF_HOC -> KAPE_HOC	0.035	0.049	0.046	0.757	0.449
TTF_HOC x DI_HOC -> KAPE_HOC	0.003	0.009	0.012	0.270	0.787

Šaltinis: sudaryta darbo autoriaus naudojantis „SmartPLS 4“ programa

Prognozinis reikšmingumas (PLSpredict ir CVPAT):

PLSpredict rezultatų interpretacija:

PLSpredict procedūra leidžia įvertinti modelio gebėjimą prognozuoti naujus duomenis, kas yra itin svarbu praktiniam rezultatų pritaikomumui (Shmueli ir kt., 2019). Atlikta PLSpredict analizė su 10 dalių (folds) ir 10 pakartojimų (repetitions) atskleidė:

1. **Q²predict reikšmės** - abiejų aukštesnio lygio konstrukto (HOC) reikšmės (KAPE_HOC: 0.490; OP_HOC: 0.451) yra gerokai didesnės už nulį, kas rodo gerą

modelio prognozinį reikšmingumą. Šios reikšmės rodo, kad modelis geba paaiškinti beveik 50% prognozuojamų kintamųjų dispersijos naujuose duomenyse (Hair ir kt., 2019).

2. **RMSE ir MAE rodikliai** - šie rodikliai parodo prognozės tikslumą matuojant vidutinę prognostinių paklaidų dydį. Aukštesnio lygio konstruktsams gauti žemi RMSE (KAPE_HOC: 0.726; OP_HOC: 0.755) ir MAE (KAPE_HOC: 0.528; OP_HOC: 0.561) rodikliai rodo, kad modelio prognozės yra pakankamai tikslios.
3. **Individualių žemesnio lygio konstrukto Q²predict reikšmės** - visos reikšmės yra teigiamos (nuo 0.181 iki 0.318), kas indikuoja prognozinį reikšmingumą. Žemiausią prognozinį reikšmingumą turi "KAPE_Resursų naudojimas" (0.181), tačiau ir ši reikšmė yra pakankama prognoziniam reikšmingumui. PLSpredict testo rezultatai pateikiami 21 lentelėje.

21 lentelė

PLSpredict testo rezultatai

HOC konstruktai	Q ² predict	RMSE	MAE
KAPE_HOC	0.490	0.726	0.528
OP_HOC	0.451	0.755	0.561

Šaltinis: sudaryta darbo autoriaus naudojantis „SmartPLS 4“ programa

CVPAT rezultatų interpretacija:

CVPAT (angl. *Cross-Validated Predictive Ability Test*) yra testas, leidžiantis statistiškai palyginti PLS-SEM modelio prognozinį reikšmingumą su etaloniniais modeliais (Sharma ir kt., 2022). Šio testo rezultatai:

1. **Nuostolių (angl. *loss*) palyginimas** - PLS-SEM modelio nuostoliai (KAPE_HOC: 0.744; OP_HOC: 0.768; bendras: 0.756) yra reikšmingai mažesni nei indikatorių vidurkio (IA) modelio (atitinkamai 1.009; 1.010; 1.010). Vidutinis nuostolių skirtumas (-0.254) su t-reikšme 5.071 ir $p < 0.001$ statistiškai patvirtina PLS-SEM modelio pranašumą lyginant su regresiniais modeliais.
2. **Konstrukto lygio analizė** - CVPAT rezultatai rodo, kad PLS-SEM modelis pasižymi gera prognoze galia abiem aukštesnio lygio konstruktsams. KAPE_HOC konstruktsui nustatyta didesnė t reikšmė (4.992) nei OP_HOC (4.550), kas rodo, kad modelis geriau prognozuoja klientų aptarnavimo efektyvumo konstruktsą.

Apibendrinant, CVPAT rezultatai tvirtai atmeta nulinę hipotezę, kad nėra skirtumo tarp PLS-SEM modelio ir regresinio modelio prognozinės galios ($p < 0.001$), patvirtindami modelio prognozinį pranašumą. CVPAT rezultatai pateikiami 22 lentelėje.

22 lentelė

CVPAT testo rezultatai:

Priklausomi HOC	PLS loss	IA loss	Average loss difference	t value	p value
KAPE_HOC	0.744	1.009	-0.266	4.992	0.000
OP_HOC	0.768	1.010	-0.242	4.550	0.000
Overall	0.756	1.010	-0.254	5.071	0.000

Šaltinis: sudaryta darbo autoriaus naudojantis „SmartPLS 4“ programa

CVPAT rezultatai rodo, kad PLS-SEM modelis kuria statistiškai reikšmingai ($p < 0.001$) mažesnes prognozavimo paklaidas nei kiti regresiniai modeliai tiek KAPE_HOC, tiek OP_HOC konstruktais. Tai patvirtina gerą modelio prognozinę galią.

Apibendrinant struktūrinio modelio vertinimą, modelis pasižymi gera paaiškinamąja galia ir tvirtu prognozinio reikšmingumu.

3.5. Hipotezių tikrinimo rezultatai

Hipotezė H1:

Pirmoji hipotezė yra **patvirtinama** ($\beta = 0,690$; $t = 15,259$; $p < 0,001$; $f^2 = 0,907$). Gauti rezultatai rodo labai stiprų teigiamą ryšį ($\beta = 0,690$) tarp DI diegimo intensyvumo ir organizacinio pasirengimo. DI diegimo intensyvumas paaiškina 47,6% organizacinio pasirengimo dispersijos, o efekto dydis ($f^2 = 0,907$) yra didelis (Cohen, 2013). Šis stiprus ryšys gali būti interpretuojamas taip: technologinė transformacija veikia kaip pagrindinis postūmis organizacinei evoliucijai ir prisitaikymui. Kuo intensyviau įmonės diegia DI sprendimus, tuo daugiau jos investuoja į darbuotojų mokymą, procesų optimizavimą ir vadovybės palaikymą.

Hipotezė H2:

Antroji hipotezė yra **patvirtinama** ($\beta = 0,319$; $t = 4,090$; $p < 0,001$; $f^2 = 0,127$). Ryšys yra vidutinio stiprumo ($\beta = 0,319$), rodantis, kad DI diegimo intensyvumas tiesiogiai gerina klientų aptarnavimo efektyvumą. Šis rezultatas atitinka technologijų

priėmimo ir panaudojimo literatūros išvadas (Venkatesh ir kt., 2003) rodančias, kad tinkamas technologijų diegimas tiesiogiai gerina įmonės veiklos rezultatus.

Hipotezė H3:

Trečioji hipotezė yra **patvirtinama** su stipriu teigiamu ryšiu ($\beta = 0,443$; $t = 4,999$; $p < 0,001$; $f^2 = 0,247$). Efekto dydis yra vidutinis, bet didesnis nei tiesioginio DI poveikio efektyvumui. Šis rezultatas pabrėžia organizacinio pasirengimo svarbą DI sprendimų sėkmei.

Hipotezė H4:

Ketvirtoji hipotezė yra **atmetama**, sąveikos tarp DI diegimo intensyvumo ir užduočių-technologijų atitikimo efektas buvo labai silpnas ir statistiškai nereikšmingas ($\beta = 0,022$; $t = 0,621$; $p = 0,535$; $f^2 = 0,003$). Taip pat ir tiesioginis TTF poveikis techniniam klientų aptarnavimo procesų efektyvumui buvo statistiškai nereikšmingas ($\beta = 0,146$; $p = 0,081$). Šis rezultatas, nors ir prieštarauja TTF teorijai (Goodhue ir Thompson, 1995), galėtų būti paaiškinamas DI technologijų specifika – labai sparčiu tobulėjimu, nuolat kintančiu funkcionalumu. Kaip rodo gauti tyrimo rezultatai DI kontekste svarbesnis tampa ne pradinis statinis technologijos ir užduoties atitikimas, o įmonės gebėjimas dinamiškai derinti technologiją ir kintančias užduotis.

Hipotezių tikrinimo rezultatai pateikiami 23 lentelėje.

23 lentelė

	Hipotezė 1	Hipotezė 2	Hipotezė 3	Hipotezė 4
Hipotezės formuluoė	DI diegimo intensyvumas klientų aptarnavime turi tiesioginį teigiamą poveikį organizaciniam pasirengimui.	DI diegimo intensyvumas klientų aptarnavime turi tiesioginį teigiamą poveikį klientų aptarnavimo efektyvumui.	Organizacinis pasirengimas teigiamai veikia klientų aptarnavimo efektyvumą.	Užduočių-technologijų atitikimas moderauja ryšį tarp DI diegimo intensyvumo ir klientų aptarnavimo efektyvumo.
Rezultatas	Patvirtinta	Patvirtinta	Patvirtinta	Atmesta

Šaltinis: sudaryta darbo autoriaus

Tolimesni tyrimo rezultatai aptariami 3.6 skyriuje.

3.6. Tyrimo rezultatų diskusija

Tyrimo rezultatai atskleidžia dirbtinio intelekto diegimo intensyvumo, organizacinio pasirengimo ir klientų aptarnavimo procesų efektyvumo tarpusavio ryšių sąveiką, kuria remiantis galima pateikti šias teorines ir praktines implikacijas, siekiant įvertinti svarbiausius sėkmės veiksnius DI pritaikymui techninio klientų aptarnavimo procesuose:

1. Stiprus teigiamas ryšys tarp DI diegimo intensyvumo ir organizacinio pasirengimo rodo fundamentalų technologijų diegimo ir organizacijos transformacijos sąryšį. Toks rezultatas reiškia, kad intensyvesnis DI sprendimų diegimas ir naudojimas klientų aptarnavimo procesuose ne tik reikalauja, bet ir katalizuoja didesnę organizacinę pasirengimą. Tai reiškia, kad įmonės, siekiančios plėtoti DI sprendimus, turi būti pasiruošusios investuoti ne tik į technologijas, bet ir į darbuotojų kompetencijų vystymą, procesų optimizavimą bei dokumentacijos kokybės gerinimą. Didesnis DI diegimo intensyvumas veikia kaip transformacijos akseleratorius, formuojantis naujas technologijas priimančią įmonės kultūrą. Gauti rezultatai pagrindžia (Makarius ir kt., 2020) sociotechninę perspektyvą, kur technologijos ir organizaciniai veiksniai turėtų būti nagrinėjami kaip tarpusavyje susiję elementai, o ne atskiri komponentai.
2. Atliktas tyrimas taip pat atskleidė dvigubą DI diegimo intensyvumo poveikio svarbą klientų aptarnavimo efektyvumui. Tiek tiesioginis ryšys tarp DI diegimo intensyvumo ir klientų aptarnavimo efektyvumo, tiek netiesioginis poveikis per organizacinę pasirengimą rodo, kad DI technologijos veikia rezultatus per keletą skirtingų veiksnių. Tiesioginis poveikis atsispindi per klientų aptarnavimo užduočių automatizavimo, greičio ir tikslumo gerinimą naudojant DI sprendimus, patvirtinant Xu ir kt., 2020 m. tyrimo rezultatus, kad jau dabar galima pasiekti geresnių rezultatų automatizuojant tam tikras užduotis pasitelkiant DI sprendimus. Tuo tarpu netiesioginis poveikis per organizacinę pasirengimą rodo, kad DI sėkmė priklauso ne tik nuo technologijų galimybių, bet ir nuo įmonės gebėjimo efektyviai šias technologijas panaudoti, ką parodė ir (Jöhnk ir kt., 2021) atliktas tyrimas .

3. Kitas reikšmingas tyrimo radinys yra tai, kad organizacinis pasirengimas daro stipresnį poveikį klientų aptarnavimo efektyvumui nei tiesioginis DI diegimo intensyvumas. Tai rodo, kad įmonės su aukštesniu organizacinio pasirengimo lygiu, gali lengviau pasiekti geresnių rezultatų net ir nediegiant inovatyviausių DI sprendimų, nei įmonės naudojančius naujausius DI sprendimus, bet su silpnu organizacinio pasirengimo pagrindu (Alsheibani ir kt., 2019). Tai rodo, kad investicijų paskirstymas tarp technologijų ir organizacinio pasirengimo turėtų pirma užtikrinti, kad yra pasiektas pakankamas organizacinis pasirengimas, prieš diegiant DI sprendimus.
4. Žvelgiant į organizacinio pasirengimo HOC konstrukta sudariusius LOC konstruktus ir gautus rezultatus, galima matyti kad techninės infrastruktūros indėlis į organizacinį pasirengimą yra statistiškai nereikšmingas, kas gali keisti tradicinius investicijų į IT prioritetus (Xu ir kt., 2020). Vietoj to dokumentacijos kokybės, darbuotojų techninio lankstumo ir vadovybės palaikymo reikšmingumas rodo, kad „minkštieji“ organizaciniai darbuotojų ir įmonių įgūdžiai yra nemažiau svarbesni nei techniniai sprendimai (Jöhnk ir kt., 2021). Tai rodo, kad įmonės turėtų prioretizuoti investicijas į kompetencijų vystymą, procesų tobulinimą ir tinkamą vidinės kultūros formavimą, užuot sutelkus visą dėmesį į techninės infrastruktūros tobulinimą.
5. Užduočių-technologijų moderavimo nebuvimas tarp DI diegimo intensyvumo ir klientų aptarnavimo efektyvumo ryšio atskleidžia, kad TTF teorija, kuri veiksmingai veikė statiško technologijų kontekste, nepasiteisina DI kontekste. Šiam rezultatui galima iškelti keletą galimų teorinių paaiškinimų, remiantis literatūros analize:
 1. DI technologijų dinamiškumas - kaip buvo aptarta 1.3.2 poskyryje, DI sprendimai, skirtingai nuo tradicinių technologijų, pasižymi mokymosi ir savaiminės adaptacijos gebėjimais. Savo tyrime (Xu ir kt., 2020) pabrėžė, kad DI gali prisitaikyti prie įvairių užduočių, keisti savo funkcijas ir tobulėti laikui bėgant. Dėl šio dinamiškumo pradinis užduočių-technologijų atitikimas gali būti ne toks svarbus, nes DI sprendimai patys gali tobulėti link geresnio užduoties atitikimo.
 2. DI technologijų poveikis esamoms užduotims – (Law ir Varanasi, 2025) tyrime nustatyta, kad DI ne tik prisitaiko prie užduočių, bet ir gali transformuoti pačias užduotis. Kitaip tariant, DI diegimas keičia užduočių pobūdį, darbo praktikas ir procesus, o ne tik automatizuoja

esamus. Dėl šios transformacijos klasikinis statiškas TTF vertinimas tampa mažiau tinkamas.

3. Techninio lankstumo vaidmuo - literatūros analizėje aptarta techninio lankstumo sąvoka (1.4.2 poskyryje) taip pat tikėtina gali paaiškinti, kodėl TTF reikšmingai nemoderuoja ryšio tarp DI diegimo intensyvumo ir klientų aptarnavimo procesų efektyvumo. Jei darbuotojai pasižymi aukštu techniniu lankstumu, jie sugeba efektyviai prisitaikyti prie naujų technologijų nepriklausomai nuo pradinio technologijos-užduoties atitikimo lygio (Muduli ir Choudhury, 2024).

Šie rezultatai rodo, kad DI integracija į įmonės procesus turi būti suprantama kaip kompleksinė įmonės transformacija, o ne vien naujas technologinis sprendimas, o investicijų proporcija tarp technologijų ir organizacinio pasirengimo vystymo turėtų skirti prioritetą organizacinių aspektų tobulinimui.

3.7. Tyrimo apribojimai

Metodologiniai apribojimai:

1. Visi tyrimo konstruktai buvo matuojami subjektyviais respondentų vertinimais. Ateityje rezultatų patikimumą galėtų padidinti objektyvių įmonės veiklos rodiklių (pvz., faktinių užklausų sprendimo laikų, klientų pasitenkinimo matavimų) įtraukimas.
2. Indikatorių kolinearumo problema - nors dauguma probleminių indikatorių buvo pašalinta, kai kurių likusių indikatorių VIF reikšmės viršijo idealias ribas <5), o tai rodo tyrimo metu naudotos anketos tobulinimo poreikį.

Imties ir konteksto apribojimai

Tyrimas buvo orientuotas į Lietuvos IT, telekomunikacijų ir aukštųjų technologijų sektorius, kas riboja rezultatų pritaikymą kitoms pramonės šakoms ar šalims. Kultūriniai ir ekonominiai ypatumai galėjo daryti poveikį gautiems rezultatams.

4. IŠVADOS IR PASIŪLYMAI

Atlikus mokslinės literatūros analizę dirbtinio intelekto diegimo intensyvumo, organizacinio pasirengimo ir techninio klientų aptarnavimo srityse bei empirinį tyrimą, daromos šios išvados:

1. Literatūros analizė atskleidė, kad techninis klientų aptarnavimas yra kompleksinis verslo procesas, tiesiogiai veikiantis įmonės klientų pasitenkinimą, lojalumą ir įmonės konkurencingumą. Skirtingai nuo įprastų klientų aptarnavimo tipų, techninis aptarnavimas reikalauja specifinių kompetencijų, įvairių darbo vykdymo metodikų taikymo ir sistemingos veiklos rodiklių stebėsenos. Šiame kontekste dirbtinio intelekto technologijos turi potencialo ne tik automatizuoti pasikartojančias užduotis, bet ir teikti analitines įžvalgas, padedančias tobulinti klientų aptarnavimo procesus.
2. Empirinis tyrimas patvirtino metodologinėje dalyje iškeltą prielaidą, kad egzistuoja stiprus teigiamas ryšys tarp DI diegimo intensyvumo ir organizacinio pasirengimo ($\beta = 0,690$; $p < 0,001$). Tai rodo, kad intensyvesnis dirbtinio intelekto sprendimų diegimas veikia kaip katalizatorius, skatinantis organizacines transformacijas, darbuotojų kompetencijų vystymą ir vidinių procesų tobulinimą.
3. Atliktas tyrimas parodė, kad dirbtinio intelekto diegimo intensyvumas turi tiesioginį teigiamą poveikį techninio klientų aptarnavimo efektyvumui ($\beta = 0,319$; $p < 0,001$). Tai patvirtina technologinių sprendimų svarbą didinant aptarnavimo procesų efektyvumą.
4. Organizacinis pasirengimas veikia kaip svarbus tarpinis veiksnys tarp dirbtinio intelekto diegimo ir klientų aptarnavimo efektyvumo, su stipriu teigiamu ryšiu ($\beta = 0,443$; $p < 0,001$). Šis ryšys yra netgi stipresnis nei tiesioginis DI poveikis, kas pabrėžia organizacinių veiksnių svarbą technologijų diegimo sėkmei.
5. Organizacinį pasirengimą atspindinčių veiksnių (indikatorių) tyrimo rezultatų analizė atskleidė, kad dokumentacijos kokybė ($\beta = 0,514$; $p < 0,001$) ir darbuotojų techninis lankstumas ($\beta = 0,463$; $p < 0,001$) daro didžiausią įtaką organizaciniam pasirengimui. Tuo tarpu remiantis tyrimo rezultatais techninės infrastruktūros indėlis buvo statistiškai nereikšmingas ($\beta = 0,125$; $p = 0,140$), kas rodo, kad įmonėse didesnis prioritetas turėtų būti skiriamas darbuotojų kompetencijų ugdymui techniniame ir žinių valdymo kontekste.

6. Užduočių-technologijų atitikimo modelis, kaip moderatorius tarp DI diegimo intensyvumo ir klientų aptarnavimo efektyvumo, buvo nepatvirtintas ($\beta = 0,022$; $p = 0,535$), kas rodo, kad TTF teorija DI technologijų kontekste gali būti mažiau reikšminga ir nebeaktuali.

Remiantis išvadomis, teikiami šie pasiūlymai:

1. Įmonėms, siekiančioms diegti dirbtinio intelekto sprendimus techniniame klientų aptarnavime, siūloma: teikti pirmenybę organizaciniam pasirengimui – investuoti į darbuotojų kompetencijų vystymą, procesų tobulinimą ir dokumentacijos kokybės gerinimą prieš technologinių sprendimų diegimą. Kurti eksperimentus skatinančią įmonės kultūrą, leidžiančią darbuotojams išbandyti naujus DI panaudojimo būdus ir mokytis iš šios patirties. Aktyviai įtraukti vadovybę į DI diegimo iniciatyvas.
2. Techninio aptarnavimo procesų optimizavimui rekomenduojama: sistemiškai struktūrizuoti techninius dokumentus ir žinių bazines, nes remiantis tyrimo rezultatais dokumentacijos kokybė - reikšmingiausias organizacinio pasirengimo elementas. Investuoti į darbuotojų techninio lankstumo ugdymą, kas remiantis tyrimo rezultatais yra svarbiau, nei geresnė techninė infrastruktūra DI sprendimų diegimui.
3. Tolesniems tyrimams rekomenduojama: ištirti, kodėl užduočių-technologijų atitikimo teorija nebuvo reikšminga DI kontekste ir pasiūlyti naujus teorinius modelius, labiau pritaikytus DI sprendimų atitikimo vertinimui.

Apibendrinant, šio darbo rezultatai prisideda prie platesnio supratimo apie dirbtinio intelekto integracijos sėkmės veiksnius techninio klientų aptarnavimo srityje. Atliktas tyrimas parodė, kad organizaciniai veiksniai, yra lygiai tokie pat svarbūs, jei ne svarbesni, už diegiamus DI sprendimus, siekiant didesnio techninio klientų aptarnavimo procesų efektyvumo. Gauti rezultatai taip pat kelia klausimą dėl užduočių-technologijų atitikimo teorijos tinkamumo DI technologijų kontekste. Atsižvelgiant į šias išvagas, įmonės turėtų vertinti DI diegimą kaip holistinį procesą, kuris apima ne tik technologinius sprendimus, bet ir organizacinių gebėjimų, procesų ir kultūros transformaciją. Visapusiškas požiūris leis maksimaliai išnaudoti dirbtinio intelekto potencialą didinant techninio klientų aptarnavimo efektyvumą ir kuriant tvarų konkurencinį pranašumą.

LITERATŪROS SĄRAŠAS

- Abdullateef, A. O., Mokhtar, S. S. M., & Yusoff, R. Z. (2011). The mediating effects of first call resolution on call centers' performance. *Journal of Database Marketing & Customer Strategy Management*, 18(1), 16–30. <https://doi.org/10.1057/dbm.2011.4>
- Adam, M., Wessel, M., & Benlian, A. (2021). AI-based chatbots in customer service and their effects on user compliance. *Electronic Markets*, 31(2), 427–445. <https://doi.org/10.1007/s12525-020-00414-7>
- Adesina, A. A., Iyelolu, T. V., & Paul, P. O. (2024). Optimizing Business Processes with Advanced Analytics: Techniques for Efficiency and Productivity Improvement. *World Journal of Advanced Research and Reviews*, 22(3), 1917–1926. <https://doi.org/10.30574/wjarr.2024.22.3.1960>
- Ahmadi, A. (2023). Implementing Artificial Intelligence in IT Management: Opportunities and Challenges. *Asian Journal of Computer Science and Technology*, 12(2), 18–23. <https://doi.org/10.51983/ajcst-2023.12.2.3704>
- Akter, S., Hossain, M. A., Sajib, S., Sultana, S., Rahman, M., Vrontis, D., & McCarthy, G. (2023). A framework for AI-powered service innovation capability: Review and agenda for future research. *Technovation*, 125, 102768. <https://doi.org/10.1016/j.technovation.2023.102768>
- Al-Baik, O., & Miller, J. (2014). Waste identification and elimination in information technology organizations. *Empirical Software Engineering*, 19(6), 2019–2061. <https://doi.org/10.1007/s10664-014-9302-3>
- Aldoseri, A., Al-Khalifa, K., & Hamouda, A. (2023). Re-Thinking Data Strategy and Integration for Artificial Intelligence: Concepts, Opportunities, and Challenges. *Applied Sciences*. <https://doi.org/10.3390/app13127082>

- Alex, T., & er. (2024). Proactive Customer Support: Re-Architecting A Customer Support/Relationship Management Software System Leveraging Predictive Analysis/AI and Machine Learning. *Engineering: Open Access*, 2(1), 39–50.
- Alshamaila, Y., Papagiannidis, S., & Li, F. (2013). Cloud computing adoption by SMEs in the north east of England. *Journal of Enterprise Information Management*, 26(3), 250–275. <https://doi.org/10.1108/17410391311325225>
- Alsheiabni, S., Cheung, Y., & Messom, C. (2019). Factors inhibiting the adoption of artificial intelligence at organizational-level: A preliminary investigation. *AMCIS 2019 Proceedings*, 2. <https://research.monash.edu/en/publications/factors-inhibiting-the-adoption-of-artificial-intelligence-at-org>
- Ameen, N., Tarhini, A., Reppel, A. E., & Anand, A. (2020). Customer experiences in the age of artificial intelligence. *Computers in Human Behavior*, 114, 106548–106548. <https://doi.org/10.1016/j.chb.2020.106548>
- Andrade, I. M. D., & Tumelero, C. (2022a). Increasing customer service efficiency through artificial intelligence chatbot. *Revista de Gestão*, 29(3), 238–251. <https://doi.org/10.1108/REGE-07-2021-0120>
- Andrade, I. M. D., & Tumelero, C. (2022b). Increasing customer service efficiency through artificial intelligence chatbot. *Revista de Gestão*, 29(3), 238–251. <https://doi.org/10.1108/REGE-07-2021-0120>
- Anggradewi, P., Aurelia, Sardjananto, S., & Ekawati, A. D. (2019). Improving Quality in Service Management through Critical Key Performance Indicators in Maintenance Process: A Systematic Literature Review. *Quality - Access to Success*, 20(173), 72–79.
- Ångström, R., Björn, M., Dahlander, L., Mähring, M., & Wallin, M. W. (2023). Getting AI Implementation Right: Insights from a Global Survey. *California Management Review*, 66, 5–22. <https://doi.org/10.1177/00081256231190430>

- Asih, I., Purba, H., & Sitorus, T. (2020). *KEY PERFORMANCE INDICATORS: A SYSTEMATIC LITERATURE REVIEW*. 8, 142–155.
- Aslam, F. (2023). The Impact of Artificial Intelligence on Chatbot Technology: A Study on the Current Advancements and Leading Innovations. *European Journal of Technology*, 7(3), Article 3. <https://doi.org/10.47672/ejt.1561>
- Aung, Y. Y. M., Wong, D. C. S., & Ting, D. S. W. (2021). The promise of artificial intelligence: A review of the opportunities and challenges of artificial intelligence in healthcare. *British Medical Bulletin*, 139(1), 4–15. <https://doi.org/10.1093/bmb/ldab016>
- Badmus, O., Rajput, S. A., Arogundade, J. B., & Williams, M. (2024). AI-driven business analytics and decision making. *World Journal of Advanced Research and Reviews*, 24(1), 616–633. <https://doi.org/10.30574/wjarr.2024.24.1.3093>
- Baquero, A. (2022). Net Promoter Score (NPS) and Customer Satisfaction: Relationship and Efficient Management. *Sustainability*, 14(4), Article 4. <https://doi.org/10.3390/su14042011>
- Becker, J.-M., Klein, K., & Wetzels, M. (2012). Hierarchical Latent Variable Models in PLS-SEM: Guidelines for Using Reflective-Formative Type Models. *Long Range Planning*, 45(5), 359–394. <https://doi.org/10.1016/j.lrp.2012.10.001>
- Beheshti, A. (2023). Empowering Generative AI with Knowledge Base 4.0: Towards Linking Analytical, Cognitive, and Generative Intelligence. *2023 IEEE International Conference on Web Services (ICWS)*, 763–771. <https://doi.org/10.1109/ICWS60048.2023.00103>
- Bender, E. M., & Friedman, B. (2018). Data Statements for Natural Language Processing: Toward Mitigating System Bias and Enabling Better Science. *Transactions of the Association for Computational Linguistics*, 6, 587–604. https://doi.org/10.1162/tacl_a_00041

- Betim, L. M., Resende, L. M., Andrade Junior, P. P. de, Pontes, J., & Petter, R. R. H. (2018). Vertical and horizontal relationships in the process of innovation and learning by interacting: Study in an industry cluster. *Gestão & Produção*, 25, 205–218. <https://doi.org/10.1590/0104-530X1028-16>
- Bhayana, R. (2024). Chatbots and Large Language Models in Radiology: A Practical Primer for Clinical and Research Applications. *Radiology*, 310(1), e232756. <https://doi.org/10.1148/radiol.232756>
- Bhuiyan, M. S. (2024). The Role of AI-Enhanced Personalization in Customer Experiences. *Journal of Computer Science and Technology Studies*, 6(1), Article 1. <https://doi.org/10.32996/jcsts.2024.6.1.17>
- Bianchini, A., Savini, I., Andreoni, A., Morolli, M., & Solfrini, V. (2024). Manufacturing Execution System Application within Manufacturing Small–Medium Enterprises towards Key Performance Indicators Development and Their Implementation in the Production Line. *Sustainability*, 16(7), Article 7. <https://doi.org/10.3390/su16072974>
- Brock, J. K.-U., & von Wangenheim, F. (2019). Demystifying AI: What Digital Transformation Leaders Can Teach You about Realistic Artificial Intelligence. *California Management Review*, 61(4), 110–134. <https://doi.org/10.1177/1536504219865226>
- Cetindamar, D., Kitto, K., Wu, M., Zhang, Y., Abedin, B., & Knight, S. (2024). Explicating AI Literacy of Employees at Digital Workplaces. *IEEE Transactions on Engineering Management*, 71, 810–823. <https://doi.org/10.1109/TEM.2021.3138503>
- Chee, V. S., & Husin, M. M. (2020). The Effect of Service Quality, Satisfaction and Loyalty toward Customer Retention in the Telecommunication Industry.

International Journal of Academic Research in Business and Social Sciences,
10(9), 55–71.

Chen, D. Q., Preston, D. S., & Swink, M. (2015). How the Use of Big Data Analytics Affects Value Creation in Supply Chain Management. *Journal of Management Information Systems*.

<https://www.tandfonline.com/doi/abs/10.1080/07421222.2015.1138364>

Child, J., He, Q., Gomes, E., Meadows, M., & Angwin, D. (2020). Strategic Alliance Research in the Era of Digital Transformation: Perspectives on Future Research. *British Journal of Management*, 31(3). <https://doi.org/10.1111/1467-8551.12406>

Cohen, J. (2013). *Statistical Power Analysis for the Behavioral Sciences* (2-asis leid.). Routledge. <https://doi.org/10.4324/9780203771587>

Collier, J. E., & Bienstock, C. C. (2006). Measuring Service Quality in E-Retailing. *Journal of Service Research*, 8(3), 260–275. <https://doi.org/10.1177/1094670505278867>

Content.pdf. (s.a.). Gauta 2024 m. gruodžio 7 d., <https://dspace.lib.cranfield.ac.uk/server/api/core/bitstreams/bc494a81-3561-4c2b-b148-ce8d9fb0bc28/content>

Davenport, T. H., & Stoddard, D. B. (1994). Reengineering: Business Change of Mythic Proportions? *MIS Quarterly*, 18(2), 121–127. <https://doi.org/10.2307/249760>

Davis, F. D. (1989). Perceived Usefulness, Perceived Ease of Use, and User Acceptance of Information Technology. *MIS Quarterly*, 13(3), 319–340. <https://doi.org/10.2307/249008>

Devineni, K. R. (2023). *Improving IT Service Incident Ticket Resolution Times using Lean and Agile Methodologies*.

Di Vaio, A., Palladino, R., Hassan, R., & Escobar, O. (2020). Artificial intelligence and business models in the sustainable development goals perspective: A systematic

- literature review. *Journal of Business Research*, 121, 283–314.
<https://doi.org/10.1016/j.jbusres.2020.08.019>
- Dias, V. M. (2021, rugsèjo 29). *Smart KPI-ORIENTED decision support Dashboard for measuring the Digital Transformation success* [Info:eu-repo/semantics/masterThesis]. University of Twente.
<https://essay.utwente.nl/88663/>
- Dignum, V. (2018). Ethics in artificial intelligence: Introduction to the special issue. *Ethics and Information Technology*, 20(1), 1–3. <https://doi.org/10.1007/s10676-018-9450-z>
- Dombrowski, U., & Malorny, C. (2016). Process Identification for Customer Service in the field of the After Sales Service as a Basis for “Lean After Sales Service”. *Procedia CIRP*, 47, 246–251. <https://doi.org/10.1016/j.procir.2016.03.030>
- Duan, Y., Edwards, J. S., & Dwivedi, Y. K. (2019). Artificial intelligence for decision making in the era of Big Data – evolution, challenges and research agenda. *International Journal of Information Management*, 48, 63–71.
<https://doi.org/10.1016/j.ijinfomgt.2019.01.021>
- Dwivedi, Y. K., Hughes, L., Ismagilova, E., Aarts, G., Coombs, C., Crick, T., Duan, Y., Dwivedi, R., Edwards, J., Eirug, A., Galanos, V., Ilavarasan, P. V., Janssen, M., Jones, P., Kar, A. K., Kizgin, H., Kronemann, B., Lal, B., Lucini, B., ... Williams, M. D. (2021). Artificial Intelligence (AI): Multidisciplinary perspectives on emerging challenges, opportunities, and agenda for research, practice and policy. *International Journal of Information Management*, 57, 101994.
<https://doi.org/10.1016/j.ijinfomgt.2019.08.002>
- Fahim, M., Saleh, M., Grida, M., & Gamila, M. A. (2024). Comparative analysis of omnichannel and multichannel networks: A system dynamics approach. *Production Engineering*. <https://doi.org/10.1007/s11740-024-01293-z>

- Følstad, A., & Brandtzæg, P. B. (2017). Chatbots and the new world of HCI. *interactions*, 24(4), 38–42. <https://doi.org/10.1145/3085558>
- Fornell, C., & Larcker, D. F. (1981). Evaluating Structural Equation Models with Unobservable Variables and Measurement Error. *Journal of Marketing Research*, 18(1), 39–50. <https://doi.org/10.1177/002224378101800104>
- Gadekar, R., Sarkar, B., & Gadekar, A. (2022a). Key performance indicator based dynamic decision-making framework for sustainable Industry 4.0 implementation risks evaluation: Reference to the Indian manufacturing industries. *Annals of Operations Research*, 318(1), 189–249. <https://doi.org/10.1007/s10479-022-04828-8>
- Gadekar, R., Sarkar, B., & Gadekar, A. (2022b). Key performance indicator based dynamic decision-making framework for sustainable Industry 4.0 implementation risks evaluation: Reference to the Indian manufacturing industries. *Annals of Operations Research*, 318(1), 189–249. <https://doi.org/10.1007/s10479-022-04828-8>
- Gajic, N., & Boolaky, M. (2015). Impact of Technical Support on Customer Satisfaction: Case of Automotive Paints. *Sage Open*, 5(4), 2158244015611457. <https://doi.org/10.1177/2158244015611457>
- Garrick, J., & Chan, A. (2017). Knowledge management and professional experience: The uneasy dynamics between tacit knowledge and performativity in organizations. *Journal of Knowledge Management*, 21(4), 872–884. <https://doi.org/10.1108/JKM-02-2017-0058>
- Gautam, A. K., G, T. V., & N, M. G. (2023). Optimal Allocation of Resources and Hospital Capacity Planning for Critical Diseases using AI and Data Mining. 2023 *IEEE International Conference on ICT in Business Industry & Government (ICTBIG)*, 1–6. <https://doi.org/10.1109/ICTBIG59752.2023.10455968>

- Gerea, C., Gonzalez-Lopez, F., & Herskovic, V. (2021). Omnichannel Customer Experience and Management: An Integrative Review and Research Agenda. *Sustainability*, 13(5), Article 5. <https://doi.org/10.3390/su13052824>
- Giotopoulos, K. C., Michalopoulos, D., Vonitsanos, G., Papadopoulos, D., Giannoukou, I., & Sioutas, S. (2024). Dynamic Workload Management System in the Public Sector. *Inf.*, 15. <https://doi.org/10.3390/info15060335>
- Gomes, P., Verçosa, L., Melo, F., Silva, V., Filho, C. B., & Bezerra, B. (2022). Artificial Intelligence-Based Methods for Business Processes: A Systematic Literature Review. *Applied Sciences*, 12(5), Article 5. <https://doi.org/10.3390/app12052314>
- Goodhue, D. L., & Thompson, R. L. (1995). Task-Technology Fit and Individual Performance. *MIS Quarterly*, 19(2), 213–236. <https://doi.org/10.2307/249689>
- Grover, V., Chiang ,Roger H.L., Liang ,Ting-Peng, & and Zhang, D. (2018). Creating Strategic Business Value from Big Data Analytics: A Research Framework. *Journal of Management Information Systems*, 35(2), 388–423. <https://doi.org/10.1080/07421222.2018.1451951>
- Hair, J. F. (with Internet Archive). (2017). *A primer on partial least squares structural equation modeling (PLS-SEM)*. Los Angeles : Sage. <http://archive.org/details/primeronpartiall0000hair>
- Hair, J. F., Risher, J. J., Sarstedt, M., & Ringle, C. M. (2019). When to use and how to report the results of PLS-SEM. *European Business Review*, 31(1), 2–24. <https://doi.org/10.1108/EBR-11-2018-0203>
- Hamon, R., Junklewitz, H., Soler Garrido, J., & Sanchez, I. (2024). Three Challenges to Secure AI Systems in the Context of AI Regulations. *IEEE Access*, 12, 61022–61035. IEEE Access. <https://doi.org/10.1109/ACCESS.2024.3391021>

- Haryadi, D., Haerofiatna, H., & Alfarizi, A. W. (2022). The Role of After Sales Service on Customer Loyalty Mediated by Customer Satisfaction. *eCo-Buss*, 5(2), Article 2. <https://doi.org/10.32877/eb.v5i2.511>
- Harmon, P. (2010). The Scope and Evolution of Business Process Management. J. vom Brocke & M. Rosemann (Sud.), *Handbook on Business Process Management 1: Introduction, Methods, and Information Systems* (p. 37–81). Springer. https://doi.org/10.1007/978-3-642-00416-2_3
- He, W., & Abdous, M. (2013). An online knowledge-centred framework for faculty support and service innovation. *VINE*, 43(1), 96–110. <https://doi.org/10.1108/03055721311302160>
- Heikkinen, S., Jäntti, M., & Tukiainen, M. (2023). Continual Service Improvement: A Systematic Literature Review. J. M. Fernandes, G. H. Travassos, V. Lenarduzzi, & X. Li (Sud.), *Quality of Information and Communications Technology* (p. 30–44). Springer Nature Switzerland. https://doi.org/10.1007/978-3-031-43703-8_3
- Henseler, J., & Fassott, G. (2010). Testing Moderating Effects in PLS Path Models: An Illustration of Available Procedures. V. Esposito Vinzi, W. W. Chin, J. Henseler, & H. Wang (Sud.), *Handbook of Partial Least Squares: Concepts, Methods and Applications* (p. 713–735). Springer. https://doi.org/10.1007/978-3-540-32827-8_31
- Henseler, J., Ringle, C. M., & Sarstedt, M. (2015). A new criterion for assessing discriminant validity in variance-based structural equation modeling. *Journal of the Academy of Marketing Science*, 43(1), 115–135. <https://doi.org/10.1007/s11747-014-0403-8>
- Holmström, J. (2021). From AI to digital transformation: The AI readiness framework. *Business Horizons*. <https://doi.org/10.1016/J.BUSHOR.2021.03.006>

- Holmström, J. (2022). From AI to digital transformation: The AI readiness framework. *Business Horizons*, 65(3), 329–339. <https://doi.org/10.1016/j.bushor.2021.03.006>
- Hristov, I., & Chirico, A. (2019). The Role of Sustainability Key Performance Indicators (KPIs) in Implementing Sustainable Strategies. *Sustainability*, 11(20), Article 20. <https://doi.org/10.3390/su11205742>
- Huang, M.-H., & Rust, R. T. (2018). Artificial Intelligence in Service. *Journal of Service Research*, 21(2), 155–172. <https://doi.org/10.1177/1094670517752459>
- Huang, M.-H., & Rust, R. T. (2021). A strategic framework for artificial intelligence in marketing. *Journal of the Academy of Marketing Science*, 49(1), 30–50. <https://doi.org/10.1007/s11747-020-00749-9>
- Yablonsky, S. (2021). AI-driven platform enterprise maturity: From human led to machine governed. *Kybernetes*, 50(10), 2753–2789. <https://doi.org/10.1108/K-06-2020-0384>
- Inavolu, S. M. (2024). Exploring AI-Driven Customer Service: Evolution, Architectures, Opportunities, Challenges and Future Directions. *International Journal For Multidisciplinary Research*, 6(3), 22283. <https://doi.org/10.36948/ijfmr.2024.v06i03.22283>
- Young, A. G., Majchrzak, A., & Kane, G. C. (2021). Organizing workers and machine learning tools for a less oppressive workplace. *International Journal of Information Management*, 59, 102353. <https://doi.org/10.1016/j.ijinfomgt.2021.102353>
- Ishaq Bhatti, M., Awan, H. M., & Razaq, Z. (2014). The key performance indicators (KPIs) and their impact on overall organizational performance. *Quality & Quantity*, 48(6), 3127–3143. <https://doi.org/10.1007/s11135-013-9945-y>

- Jöhnk, J., Weißert, M., & Wyrski, K. (2021a). Ready or Not, AI Comes—An Interview Study of Organizational AI Readiness Factors. *Business & Information Systems Engineering*, 63(1), 5–20. <https://doi.org/10.1007/s12599-020-00676-7>
- Jöhnk, J., Weißert, M., & Wyrski, K. (2021b). Ready or Not, AI Comes—An Interview Study of Organizational AI Readiness Factors. *Business & Information Systems Engineering*, 63(1), 5–20. <https://doi.org/10.1007/s12599-020-00676-7>
- Juglan, K. C., Sharma, B., Gehlot, A., Singh, S. P., Hussein, A., & Alazzam, M. B. (2023). Exploring the Effectiveness of Natural Language Processing in Customer Service. *2023 3rd International Conference on Advance Computing and Innovative Technologies in Engineering (ICACITE)*, 814–818. <https://doi.org/10.1109/ICACITE57410.2023.10183107>
- Kamateri, E., Meditskos, G., Symeonidis, S., Vrochidis, S., Kompatsiaris, I., & Minker, W. (2019). *Knowledge-based Intelligence and Strategy Learning for Personalised Virtual Assistance in the Healthcare Domain*. <https://consensus.app/papers/knowledgebased-intelligence-and-strategy-learning-for-kamateri-meditskos/2b6be1c6756a538cb7e7351f54b885fc/>
- Karahanna, E., Straub, D. W., & Chervany, N. L. (1999). Information Technology Adoption Across Time: A Cross-Sectional Comparison of Pre-Adoption and Post-Adoption Beliefs. *MIS Quarterly*, 23(2), 183–213. <https://doi.org/10.2307/249751>
- Katherine N., L., & Verhoef, P. C. (2016). *Understanding Customer Experience Throughout the Customer Journey*. <https://doi.org/10.1509/jm.15.0420>
- Keller, K. L. (2003). Understanding brands, branding and brand equity. *Interactive Marketing*, 5(1), 7–20. <https://doi.org/10.1057/palgrave.im.4340213>
- Kennerley, M., & Neely, A. (2003). Measuring performance in a changing business environment. *International Journal of Operations & Production Management*, 23(2), 213–229. <https://doi.org/10.1108/01443570310458465>

- Khakpour, R., Ebrahimi, A., & Seyed-Hosseini, S.-M. (2024). Lean process mining: Adopting process mining in lean manufacturing for dynamic process mapping and avoiding waste occurrence in real time. *International Journal of Lean Six Sigma*, 16(1), 231–255. <https://doi.org/10.1108/IJLSS-03-2024-0059>
- Kinkel, S., Baumgartner, M., & Cherubini, E. (2022). Prerequisites for the adoption of AI technologies in manufacturing – Evidence from a worldwide sample of manufacturing companies. *Technovation*, 110, 102375. <https://doi.org/10.1016/j.technovation.2021.102375>
- Kock, N., & Hadaya, P. (2018). Minimum sample size estimation in PLS-SEM: The inverse square root and gamma-exponential methods. *Information Systems Journal*, 28(1), 227–261. <https://doi.org/10.1111/isj.12131>
- Krichen, M., & Abdalzaher, M. S. (2024). Performance enhancement of artificial intelligence: A survey. *Journal of Network and Computer Applications*, 232, 104034. <https://doi.org/10.1016/j.jnca.2024.104034>
- Kumar, S., & Mittal, S. (2024). Employee learning and skilling in AI embedded organizations – predictors and outcomes. *Development and Learning in Organizations: An International Journal*, 38(4), 11–15. <https://doi.org/10.1108/DLO-11-2023-0249>
- Kumar, V., Rajan, B., Venkatesan, R., & Lecinski, J. (2019). Understanding the Role of Artificial Intelligence in Personalized Engagement Marketing. *California Management Review*, 61, 135–155. <https://doi.org/10.1177/0008125619859317>
- Laihonen, H., & Pekkola, S. (2016). Impacts of using a performance measurement system in supply chain management: A case study. *International Journal of Production Research*, 54(18), 5607–5617. <https://doi.org/10.1080/00207543.2016.1181810>
- Lastrucci, A., Wandael, Y., Barra, A., Miele, V., Ricci, R., Livi, L., Lepri, G., Gulino, R. A., Maccioni, G., & Giansanti, D. (2024). Precision Metrics: A Narrative Review

- on Unlocking the Power of KPIs in Radiology for Enhanced Precision Medicine. *Journal of Personalized Medicine*, 14(9), 963. <https://doi.org/10.3390/jpm14090963>
- Lavy, S., Garcia, J. A., & Dixit, M. K. (2014). KPIs for facility's performance assessment, Part I: Identification and categorization of core indicators. *Facilities*, 32(5/6), 256–274. <https://doi.org/10.1108/F-09-2012-0066>
- Law, M., & Varanasi, R. A. (2025). *Generative AI & Changing Work: Systematic Review of Practitioner-led Work Transformations through the Lens of Job Crafting* (No. arXiv:2502.08854; Versija 1). arXiv. <https://doi.org/10.48550/arXiv.2502.08854>
- Lee, Y. S., Kim, T., Choi, S., & Kim, W. (2022). When does AI pay off? AI-adoption intensity, complementary investments, and R&D strategy. *Technovation*, 118, 102590. <https://doi.org/10.1016/j.technovation.2022.102590>
- Lee, J.-C., & Chen, X. (2022). Exploring users' adoption intentions in the evolution of artificial intelligence mobile banking applications: The intelligent and anthropomorphic perspectives. *International Journal of Bank Marketing*, 40(4), 631–658. <https://doi.org/10.1108/IJBM-08-2021-0394>
- Levallet, N., & Chan, Y. (2022). Uncovering a new form of digitally-enabled agility: An improvisational perspective. *European Journal of Information Systems*, 31(6), 681–708. <https://doi.org/10.1080/0960085X.2022.2035262>
- Lichtenthaler, U. (2020). Five Maturity Levels of Managing AI: From Isolated Ignorance to Integrated Intelligence. *Journal of Innovation Management*, 8(1), Article 1. https://doi.org/10.24840/2183-0606_008.001_0005
- Lineberry, R. (2019a). Solve and Evolve: Practical Applications for Knowledge-Centered Service. *Proceedings of the 2019 ACM SIGUCCS Annual Conference*, 70–75. <https://doi.org/10.1145/3347709.3347793>

- Lineberry, R. (2019b). Solve and Evolve: Practical Applications for Knowledge-Centered Service. *Proceedings of the 2019 ACM SIGUCCS Annual Conference*, 70–75.
<https://doi.org/10.1145/3347709.3347793>
- Lineberry, R. (2019c). Solve and Evolve: Practical Applications for Knowledge-Centered Service. *Proceedings of the 2019 ACM SIGUCCS Annual Conference*, 70–75.
<https://doi.org/10.1145/3347709.3347793>
- Lucio-Nieto, T., Colomo-Palacios, R., Soto-Acosta, P., Popa, S., & Amescua-Seco, A. (2012). Implementing an IT service information management framework: The case of COTEMAR. *International Journal of Information Management*, 32(6), 589–594. <https://doi.org/10.1016/j.ijinfomgt.2012.08.004>
- Makarius, E. E., Mukherjee, D., Fox, J. D., & Fox, A. K. (2020a). Rising With the Machines: A Sociotechnical Framework for Bringing Artificial Intelligence Into the Organization. *Organizations & Markets: Policies & Processes eJournal*.
<https://doi.org/10.1016/j.jbusres.2020.07.045>
- Makarius, E. E., Mukherjee, D., Fox, J. D., & Fox, A. K. (2020b). Rising with the machines: A sociotechnical framework for bringing artificial intelligence into the organization. *Journal of Business Research*, 120, 262–273.
<https://doi.org/10.1016/j.jbusres.2020.07.045>
- Malca, J., Barrera, A., Castillo-Sequera, J. L., & Wong, L. (2024). Framework to increase the level of customer satisfaction in telecommunication services in Peru using TQM and Business Intelligence. *2024 International Seminar on Application for Technology of Information and Communication (iSemantic)*, 272–277.
<https://doi.org/10.1109/iSemantic63362.2024.10762032>
- Martin, L. D., Rampersad, S. E., Low, D. K.-W., & Reed, M. A. (2014). Process improvement in the operating room using Toyota (Lean) methods☆. *Colombian Journal of Anesthesiology*, 42(3), 220.

- Martínez-Plumed, F., & Hernández-Orallo, J. (2018). Dual Indicators to Analyze AI Benchmarks: Difficulty, Discrimination, Ability, and Generality. *IEEE Transactions on Games*, 12, 121–131. <https://doi.org/10.1109/TG.2018.2883773>
- Martins de Andrade, P. R., & Sadaoui, S. (2017). Improving business decision making based on KPI management system. *2017 IEEE International Conference on Systems, Man, and Cybernetics (SMC)*, 1280–1285. <https://doi.org/10.1109/SMC.2017.8122789>
- Massaro, A. (2022). Advanced Control Systems in Industry 5.0 Enabling Process Mining. *Sensors (Basel, Switzerland)*, 22. <https://doi.org/10.3390/s22228677>
- Meurisch, C., & Mühlhäuser, M. (2021). Data Protection in AI Services. *ACM Computing Surveys (CSUR)*, 54, 1–38. <https://doi.org/10.1145/3440754>
- Micheli, P., & Mura, M. (2017). Executing strategy through comprehensive performance measurement systems. *International Journal of Operations & Production Management*, 37(4), 423–443. <https://doi.org/10.1108/IJOPM-08-2015-0472>
- Miguel, A., & Miranda, S. (2023). The role of digital platforms in promoting pro-sustainable behavior and conscious consumption by brands. *Ecocycles*, 9(2), Article 2. <https://doi.org/10.19040/ecocycles.v9i2.298>
- Mikalef, P., & Gupta, M. (2021). Artificial intelligence capability: Conceptualization, measurement calibration, and empirical study on its impact on organizational creativity and firm performance. *Information & Management*, 58(3), 103434. <https://doi.org/10.1016/j.im.2021.103434>
- Monahan, B., & Yearworth, M. (2008). *Meaningful Security SLAs*.
- Muduli, A., & Choudhury, A. (2024). Exploring the role of workforce agility on digital transformation: A systematic literature review. *Benchmarking: An International Journal*, 32(2), 492–512. <https://doi.org/10.1108/BIJ-02-2023-0108>

- Narayanamurthy, G., Gurumurthy, A., Subramanian, N., & Moser, R. (2018). Assessing the readiness to implement lean in healthcare institutions – A case study. *International Journal of Production Economics*, 197, 123–142. <https://doi.org/10.1016/j.ijpe.2017.12.028>
- Naveen, L. (2023). Artificial Intelligence Transforming Customer Service Management Embracing the Future. *Journal of the Oriental Institute (ISSN: 0030-5324)*. https://www.academia.edu/106102395/Artificial_Intelligence_Transforming_Customer_Service_Management_Embracing_the_Future
- Nguyen, T. H., Le, X. C., & Vu, T. H. L. (2022). An Extended Technology-Organization-Environment (TOE) Framework for Online Retailing Utilization in Digital Transformation: Empirical Evidence from Vietnam. *Journal of Open Innovation: Technology, Market, and Complexity*, 8(4), 200. <https://doi.org/10.3390/joitmc8040200>
- Nti, I. K., Adekoya, A. F., Weyori, B. A., & Nyarko-Boateng, O. (2022). Applications of artificial intelligence in engineering and manufacturing: A systematic review. *Journal of Intelligent Manufacturing*, 33(6), 1581–1601. <https://doi.org/10.1007/s10845-021-01771-6>
- Obiki-Osafiele, A. N., Agu, E. E., & Chiekezie, N. R. (2024). Leveraging artificial intelligence to enhance customer service analytics and improve service delivery. *International Journal of Management & Entrepreneurship Research*, 6(8), Article 8. <https://doi.org/10.51594/ijmer.v6i8.1412>
- Ogosi Auqui, J. A., Aguirre Rodríguez, C. E., Arenas Ñiquin, J. L., Guadalupe Mori, V. H., Vera Cuya, R. M., Pérez Rojas, E. D., & Usquiano Cárdenas, L. A. (2023). Analysis of the use of the ITIL methodology against other reference frameworks for service management 2018-2020. *Proceedings of the 21th LACCEI International Multi-Conference for Engineering, Education and Technology*

- (LACCEI 2023): “Leadership in Education and Innovation in Engineering in the Framework of Global Transformations: Integration and Alliances for Integral Development”. 21st LACCEI International Multi-Conference for Engineering, Education and Technology (LACCEI 2023): “Leadership in Education and Innovation in Engineering in the Framework of Global Transformations: Integration and Alliances for Integral Development”.
<https://doi.org/10.18687/LACCEI2023.1.1.1326>
- Olan, F., Ogiemwonyi Arakpogun, E., Suklan, J., Nakpodia, F., Damij, N., & Jayawickrama, U. (2022). Artificial intelligence and knowledge sharing: Contributing factors to organizational performance. *Journal of Business Research*, 145, 605–615. <https://doi.org/10.1016/j.jbusres.2022.03.008>
- Paiola, M., & Gebauer, H. (2020). Internet of things technologies, digital servitization and business model innovation in BtoB manufacturing firms. *Industrial Marketing Management*, 89, 245–264. <https://doi.org/10.1016/j.indmarman.2020.03.009>
- Pankowska, M. (2019). Information Technology Outsourcing Chain: Literature Review and Implications for Development of Distributed Coordination. *Sustainability*, 11(5), Article 5. <https://doi.org/10.3390/su11051460>
- Parul, B., & Chhaya, K. (2024). *Implementing Omnichannel Strategies for Global Customer Engagement: A Project and Change Management Approach*. Seventh Sense Research Group. <https://doi.org/10.14445/22312803/IJCTT-V72I4P108>
- Patrício, L., Costa, L., Varela, L., & Ávila, P. (2023). Sustainable Implementation of Robotic Process Automation Based on a Multi-Objective Mathematical Model. *Sustainability*, 15(20), Article 20. <https://doi.org/10.3390/su152015045>
- Patrício, L., Fisk, R. P., & Falcão e Cunha, J. (2008). Designing Multi-Interface Service Experiences: The Service Experience Blueprint. *Journal of Service Research*, 10(4), 318–334. <https://doi.org/10.1177/1094670508314264>

- Patti, C. H., Dessel, M. M. van, & Hartley, S. W. (2020). Reimagining customer service through journey mapping and measurement. *European Journal of Marketing*, 54(10), 2387–2417. <https://doi.org/10.1108/EJM-07-2019-0556>
- Pawliczek, A., Kolos, P., Lenort, R., Kolumber, S., & Wicher, P. (2022). MANAGEMENT TOOLS AND SYSTEMS – USAGE IN LOGISTICS COMPANIES IN THE CZECH REPUBLIC. *Acta Logistica*, 9(1), 85–98. <https://doi.org/10.22306/al.v9i1.273>
- Pekarcikova, M., Trebuna, P., Kronova, J., & Kopec, J. (2024). Increasing the Efficiency of the Value-Chain for Non-Manufacturing Processes: Analytical Approach. *European Journal of Business and Management Research*, 9(3), Article 3. <https://doi.org/10.24018/ejbmr.2024.9.3.2352>
- Pendyala, M. K., & Lakkamraju, V. V. (2024). Impact of Artificial Intelligence in Customer Journey. *International Journal of Innovative Science and Research Technology* (IJISRT), 1528–1534. <https://doi.org/10.38124/ijisrt/IJISRT24AUG807>
- Petersen, K. (2019). It Takes an IT Village to Raise a Service Desk. *Proceedings of the 2019 ACM SIGUCCS Annual Conference*, 148–151. <https://doi.org/10.1145/3347709.3347832>
- Pillai, R., & Sivathanu, B. (2020). Adoption of artificial intelligence (AI) for talent acquisition in IT/ITeS organizations. *Benchmarking: An International Journal*, 27(9), 2599–2629. <https://doi.org/10.1108/BIJ-04-2020-0186>
- Płaza, M., & Pawlik, Ł. (2021). Influence of the Contact Center Systems Development on Key Performance Indicators. *IEEE Access*, 9, 44580–44591. IEEE Access. <https://doi.org/10.1109/ACCESS.2021.3066801>
- Płaza, M., Trusz, S., Keczowska, J., Boksa, E., Sadowski, S., & Koruba, Z. (2022). Machine Learning Algorithms for Detection and Classifications of Emotions in

- Contact Center Applications. *Sensors* (Basel, Switzerland), 22.
<https://doi.org/10.3390/s22145311>
- Porcelli, I. (2014). *Valutazione dell'adozione di tecnologie di Realtà Aumentata a supporto delle reti di assistenza tecnica Evaluating the adoption of Augmented Reality in field service networks*. <https://flore.unifi.it/handle/2158/865769>
- Pozza, I. D. (2014). Customer experiences as drivers of customer satisfaction. *Management & Prospective*, 31(3), 115–138.
<https://doi.org/10.3917/g2000.313.0115>
- Preacher, K. J., & Hayes, A. F. (2008). Asymptotic and resampling strategies for assessing and comparing indirect effects in multiple mediator models. *Behavior Research Methods*, 40(3), 879–891. <https://doi.org/10.3758/BRM.40.3.879>
- Quach, S., Barari, M., Moudrý, D. V., & Quach, K. (2022a). Service integration in omnichannel retailing and its impact on customer experience. *Journal of Retailing and Consumer Services*, 65, 102267.
<https://doi.org/10.1016/j.jretconser.2020.102267>
- Quach, S., Barari, M., Moudrý, D. V., & Quach, K. (2022b). Service integration in omnichannel retailing and its impact on customer experience. *Journal of Retailing and Consumer Services*, 65, 102267.
<https://doi.org/10.1016/j.jretconser.2020.102267>
- Raj, A. (2019). A Review on Machine Learning Algorithms. *International Journal for Research in Applied Science and Engineering Technology*, 7(6), 792–796.
<https://doi.org/10.22214/ijraset.2019.6138>
- Rajagopal, M., & Ramkumar, S. (2023). Adopting Artificial Intelligence in ITIL for Information Security Management—Way Forward in Industry 4.0. V. Sarveshwaran, J. I.-Z. Chen, & D. Pelusi (Sud.), *Artificial Intelligence and Cyber*

- Security in Industry 4.0* (p. 113–132). Springer Nature.
https://doi.org/10.1007/978-981-99-2115-7_5
- Reichheld, F. F. (2003). *The One Number You Need to Grow*.
- Ribes, D., & Finholt, T. A. (2009). The Long Now of Technology Infrastructure: Articulating Tensions in Development. *J. Assoc. Inf. Syst.*, 10.
<https://doi.org/10.17705/1jais.00199>
- Ritala, P., Hyöttylä, M., Blomqvist, K., & Kosonen, M. (2013). Key capabilities in knowledge-intensive service business. *The Service Industries Journal*, 33(5), 486–500. <https://doi.org/10.1080/02642069.2011.623774>
- Rodriguez, D. V., Lawrence, K., Gonzalez, J., Brandfield-Harvey, B., Xu, L., Tasneem, S., Levine, D. L., & Mann, D. (2024). Leveraging Generative AI Tools to Support the Development of Digital Solutions in Health Care Research: Case Study. *JMIR Human Factors*, 11(1), e52885. <https://doi.org/10.2196/52885>
- Rosemann, M., & vom Brocke, J. (2015). The Six Core Elements of Business Process Management. J. vom Brocke & M. Rosemann (Sud.), *Handbook on Business Process Management 1: Introduction, Methods, and Information Systems* (p. 105–122). Springer. https://doi.org/10.1007/978-3-642-45100-3_5
- Rust, R. T., & Huang, M.-H. (2014). The Service Revolution and the Transformation of Marketing Science. *Marketing Science*, 33(2), 206–221.
- Rüttimann, B. G., & Stöckli, M. T. (2016a). Going beyond Triviality: The Toyota Production System—Lean Manufacturing beyond Muda and Kaizen. *Journal of Service Science and Management*, 9(2), Article 2.
<https://doi.org/10.4236/jssm.2016.92018>
- Rüttimann, B. G., & Stöckli, M. T. (2016b). Lean and Industry 4.0—Twins, Partners, or Contenders? A Due Clarification Regarding the Supposed Clash of Two

- Production Systems. *Journal of Service Science and Management*, 9(6), Article 6.
<https://doi.org/10.4236/jssm.2016.96051>
- Sabherwal, R., Jeyaraj, A., & Chowa, C. (2006). Information System Success: Individual and Organizational Determinants. *Management Science*, 52(12), 1849–1864.
<https://doi.org/10.1287/mnsc.1060.0583>
- Sambasivan, N., Kapania, S., Highfill, H., Akrong, D., Paritosh, P., & Aroyo, L. M. (2021). “Everyone wants to do the model work, not the data work”: Data Cascades in High-Stakes AI. *Proceedings of the 2021 CHI Conference on Human Factors in Computing Systems*, 1–15. <https://doi.org/10.1145/3411764.3445518>
- Saunders, M., Lewis, P., & Thornhill, A. (2023). *Research Methods for Business Students*.
<https://elibrary.pearson.de/book/99.150005/9781292402734>
- Sculley, D., Holt, G., Golovin, D., Davydov, E., Phillips, T., Ebner, D., Chaudhary, V., Young, M., Crespo, J.-F., & Dennison, D. (2015). Hidden Technical Debt in Machine Learning Systems. *Advances in Neural Information Processing Systems*, 28.
https://proceedings.neurips.cc/paper_files/paper/2015/hash/86df7dcfd896fcaf2674f757a2463eba-Abstract.html
- Serralvo, F. A., & Casas, A. L. L. (2024). The Role of Social Media Engagement in Customer Service: A Study on the Brazilian Financial Sector. *International Journal of Business and Management*, 19(6), Article 6.
<https://doi.org/10.5539/ijbm.v19n6p175>
- Shang, S. S. C., & Lin, S.-F. (2010). Barriers to Implementing ITIL-A Multi-Case Study on the Service-based Industry. *Contemporary Management Research*, 6(1), Article 1. <https://doi.org/10.7903/cmr.1131>
- Sharma, P. N., Liengaard, B. D., Hair, J. F., Sarstedt, M., & Ringle, C. M. (2022). Predictive model assessment and selection in composite-based modeling using

- PLS-SEM: Extensions and guidelines for using CVPAT. *European Journal of Marketing*, 57(6), 1662–1677. <https://doi.org/10.1108/EJM-08-2020-0636>
- Sheth, J. N., Jain, V., & Ambika, A. (2023). The growing importance of customer-centric support services for improving customer experience. *Journal of Business Research*, 164, 113943. <https://doi.org/10.1016/j.jbusres.2023.113943>
- Shin, H., & Dai, B. (2022). The efficacy of customer's voluntary use of self-service technology (SST): A dual-study approach. *Journal of Strategic Marketing*, 30(8), 723–745. <https://doi.org/10.1080/0965254X.2020.1841269>
- Shmueli, G., Sarstedt, M., Hair, J. F., Cheah, J.-H., Ting, H., Vaithilingam, S., & Ringle, C. M. (2019). Predictive model assessment in PLS-SEM: Guidelines for using PLSpredict. *European Journal of Marketing*, 53(11), 2322–2347. <https://doi.org/10.1108/EJM-02-2019-0189>
- Sidey-Gibbons, J. A. M., & Sidey-Gibbons, C. J. (2019). Machine learning in medicine: A practical introduction. *BMC Medical Research Methodology*, 19(1), 64. <https://doi.org/10.1186/s12874-019-0681-4>
- Soukayna, B., Ilias, C., & Mohamed, B. (2020). A FRAMEWORK FOR THE INTEGRATION OF LEAN TOOLKIT IN ITIL FOR MORE FLEXIBILITY. <https://www.semanticscholar.org/paper/A-FRAMEWORK-FOR-THE-INTEGRATION-OF-LEAN-TOOLKIT-IN-Soukayna-Ilias/18b6f3603b90462811008b9992bdb3f717b50eb2>
- Stefanović, M., Tadic, D., Arsovski, S., Pravdic, P., Abadić, N., & Stefanović, N. (2015). Determination of the effectiveness of the realization of enterprise business objectives and improvement strategies in an uncertain environment. *Expert Systems*, 32(4), 494–506. <https://doi.org/10.1111/exsy.12102>
- Steiber, A., Alänge, S., Ghosh, S., & Goncalves, D. (2020). Digital transformation of industrial firms: An innovation diffusion perspective. *European Journal of*

Innovation Management, 24(3), 799–819. <https://doi.org/10.1108/EJIM-01-2020-0018>

Sultan, S., Acharya, Y., Zayed, O., Elzomour, H., Parodi, J. C., Soliman, O., & Hynes, N. (2023). Is the Cardiovascular Specialist Ready For the Fifth Revolution? The Role of Artificial Intelligence, Machine Learning, Big Data Analysis, Intelligent Swarming, and Knowledge-Centered Service on the Future of Global Cardiovascular Healthcare Delivery. *Journal of Endovascular Therapy*, 30(6), 877–884. <https://doi.org/10.1177/15266028221102660>

Swain, A. K., & Garza, V. R. (2023a). Key Factors in Achieving Service Level Agreements (SLA) for Information Technology (IT) Incident Resolution. *Information Systems Frontiers*, 25(2), 819–834. <https://doi.org/10.1007/s10796-022-10266-5>

Swain, A. K., & Garza, V. R. (2023b). Key Factors in Achieving Service Level Agreements (SLA) for Information Technology (IT) Incident Resolution. *Information Systems Frontiers*, 25(2), 819–834. <https://doi.org/10.1007/s10796-022-10266-5>

Tomat, L., & Trkman, P. (2019). Digital Transformation – The Hype and Conceptual Changes. *Economic and Business Review*, 21(3). <https://doi.org/10.15458/ebr.90>

Tran, M. T. (2024). Unlocking the AI-powered customer experience: Personalized service, enhanced engagement, and data-driven strategies for e-commerce applications. *Journal of Infrastructure, Policy and Development*, 8(7), 4970. <https://doi.org/10.24294/jipd.v8i7.4970>

Trkman, P., Mertens, W., Viaene, S., & Gemmel, P. (2015). From business process management to customer process management. *Business Process Management Journal*, 21(2), 250–266. <https://doi.org/10.1108/BPMJ-02-2014-0010>

- Tucker, M., & Pitt, M. (2009). Customer performance measurement in facilities management. *International Journal of Productivity and Performance Management*, 58(5), 407–422. <https://doi.org/10.1108/17410400910965698>
- Udeh, E. O., Amajuoyi, P., Adeusi, K. B., & Scott, A. O. (2024). AI-Enhanced Fintech communication: Leveraging Chatbots and NLP for efficient banking support. *International Journal of Management & Entrepreneurship Research*, 6(6), Article 6. <https://doi.org/10.51594/ijmer.v6i6.1164>
- Uren, V., & Edwards, J. S. (2023). Technology readiness and the organizational journey towards AI adoption: An empirical study. *International Journal of Information Management*, 68, 102588. <https://doi.org/10.1016/j.ijinfomgt.2022.102588>
- Vafaei-Zadeh, A., Nikbin, D., Wong, S. L., & Hanifah, H. (2024). Investigating factors influencing AI customer service adoption: An integrated model of stimulus–organism–response (SOR) and task-technology fit (TTF) theory. *Asia Pacific Journal of Marketing and Logistics*, ahead-of-print(ahead-of-print). <https://doi.org/10.1108/APJML-05-2024-0570>
- Vaid, A., & Sharma, C. (2022). Leveraging SAP and Artificial Intelligence for optimized enterprise resource planning: Enhancing efficiency, automation, and decision-making. *World Journal of Advanced Research and Reviews*, 14(3), 762–769. <https://doi.org/10.30574/wjarr.2022.14.3.0276>
- van Laar, E., van Deursen, A. J. A. M., van Dijk, J. A. G. M., & de Haan, J. (2017). The relation between 21st-century skills and digital skills: A systematic literature review. *Computers in Human Behavior*, 72, 577–588. <https://doi.org/10.1016/j.chb.2017.03.010>
- Venkatesh, V., Morris, M. G., Davis, G. B., & Davis, F. D. (2003a). User Acceptance of Information Technology: Toward a Unified View. *MIS Quarterly*, 27(3), 425–478. <https://doi.org/10.2307/30036540>

- Venkatesh, V., Morris, M. G., Davis, G. B., & Davis, F. D. (2003b). User Acceptance of Information Technology: Toward a Unified View. *MIS Quarterly*, 27(3), 425–478. <https://doi.org/10.2307/30036540>
- Wamba-Taguimdje, S.-L., Wamba, S. F., Kamdjoug, J. R. K., & Wanko, C. E. T. (2020). Influence of artificial intelligence (AI) on firm performance: The business value of AI-based transformation projects. *Business Process Management Journal*, 26(7), 1893–1924. <https://doi.org/10.1108/BPMJ-10-2019-0411>
- Wang, A., Wang, D., Drozdal, J., Muller, M. J., Park, S., Weisz, J. D., Liu, X., Wu, L., & Dugan, C. (2021). Documentation Matters: Human-Centered AI System to Assist Data Science Code Documentation in Computational Notebooks. *ACM Transactions on Computer-Human Interaction*, 29, 1–33. <https://doi.org/10.1145/3489465>
- Wang, X., Zhou, K., Wen, J., & Zhao, W. X. (2022). Towards Unified Conversational Recommender Systems via Knowledge-Enhanced Prompt Learning. *Proceedings of the 28th ACM SIGKDD Conference on Knowledge Discovery and Data Mining*. <https://doi.org/10.1145/3534678.3539382>
- Wei, J., Kim, S., Jung, H., & Kim, Y.-H. (2024). Leveraging Large Language Models to Power Chatbots for Collecting User Self-Reported Data. *Proc. ACM Hum.-Comput. Interact.*, 8(CSCW1), 87:1-87:35. <https://doi.org/10.1145/3637364>
- Weiner, B. J. (2009). A theory of organizational readiness for change. *Implementation Science : IS*, 4, 67–67. <https://doi.org/10.1186/1748-5908-4-67>
- West, S., Gaiardelli, P., & Sacconi, N. (2022). Overcoming the Barriers to Service Excellence. S. West, P. Gaiardelli, & N. Sacconi (Sud.), *Modern Industrial Services: A Cookbook for Design, Delivery, and Management* (p. 19–174). Springer International Publishing. https://doi.org/10.1007/978-3-030-80511-1_2

- Westlund, A. H., Gustafsson, C., Lang, E., & Mattsson, B. (2005). On customer satisfaction and financial results in the Swedish real estate market. *Total Quality Management & Business Excellence*, 16(10), 1149–1159. <https://doi.org/10.1080/14783360500236197>
- Whang, S. E., Roh, Y., Song, H., & Lee, J.-G. (2023). Data collection and quality challenges in deep learning: A data-centric AI perspective. *The VLDB Journal*, 32(4), 791–813. <https://doi.org/10.1007/s00778-022-00775-9>
- Wirtz, B., & Daiser, P. (2018). Business Model Innovation Processes: A Systematic Literature Review. *Journal of Business Models*, 6(1), Article 1. <https://doi.org/10.5278/ojs.jbm.v6i1.2397>
- Wolf, L., & Steul-Fischer, M. (2023). Factors of customers' channel choice in an omnichannel environment: A systematic literature review. *Management Review Quarterly*, 73(4), 1579–1630. <https://doi.org/10.1007/s11301-022-00281-w>
- Wulf, J., & Meierhofer, J. (2024, gegužės 15). *Exploring the Potential of Large Language Models for Automation in Technical Customer Service*. <https://www.semanticscholar.org/paper/4971b33efce8be02c0d3a42d519b272937f0aa58>
- Xu, Y., Shieh, C.-H., van Esch, P., & Ling, I.-L. (2020a). AI customer service: Task complexity, problem-solving ability, and usage intention. *Australasian Marketing Journal (AMJ)*, 28(4), 189–199. <https://doi.org/10.1016/j.ausmj.2020.03.005>
- Xu, Y., Shieh, C.-H., van Esch, P., & Ling, I.-L. (2020b). AI Customer Service: Task Complexity, Problem-Solving Ability, and Usage Intention. *Australasian Marketing Journal*, 28(4), 189–199. <https://doi.org/10.1016/j.ausmj.2020.03.005>
- Zdravković, M., Panetto, H., & Weichhart, G. (2021). AI-enabled Enterprise Information Systems for Manufacturing. *Enterprise Information Systems*, 16, 668–720. <https://doi.org/10.1080/17517575.2021.1941275>

- Zerbino, P., Stefanini, A., & Aloini, D. (2021). Process Science in Action: A Literature Review on Process Mining in Business Management. *Technological Forecasting and Social Change*, 172, 121021. <https://doi.org/10.1016/j.techfore.2021.121021>
- Zha, D., Bhat, Z. P., Lai, K.-H., Yang, F., Jiang, Z., Zhong, S., & Hu, X. (2023). *Data-centric Artificial Intelligence: A Survey* (No. arXiv:2303.10158). arXiv. <https://doi.org/10.48550/arXiv.2303.10158>
- Zhou, M., Duan, N., Liu, S., & Shum, H.-Y. (2020). Progress in Neural NLP: Modeling, Learning, and Reasoning. *Engineering*, 6(3), 275–290. <https://doi.org/10.1016/j.eng.2019.12.014>
- Zhu, K., Kraemer, K. L., & Xu, S. (2006). The Process of Innovation Assimilation by Firms in Different Countries: A Technology Diffusion Perspective on E-Business. *Management Science*, 52(10), 1557–1576. <https://doi.org/10.1287/mnsc.1050.0487>
- Zigurs, I., & Buckland, B. K. (1998). A Theory of Task/Technology Fit and Group Support Systems Effectiveness. *MIS Quarterly*, 22(3), 313–334. <https://doi.org/10.2307/249668>
- Zirar, A., Ali, S. I., & Islam, N. (2023). Worker and workplace Artificial Intelligence (AI) coexistence: Emerging themes and research agenda. *Technovation*, 124, 102747. <https://doi.org/10.1016/j.technovation.2023.102747>

**SUCCESS FACTORS OF ARTIFICIAL INTELLIGENCE
INTEGRATION AND THEIR IMPACT ON TECHNICAL CUSTOMER
SUPPORT EFFICIENCY**

Master's thesis

Business process management master study program

Vilnius University, Faculty of Economics and Business Administration

Supervisor – dr. Erika Vaiginienė

Vilnius, 2025

SUMMARY

This master's thesis investigates the success factors of artificial intelligence (AI) integration and their impact on technical customer support process efficiency in Lithuanian companies operating in information technology, telecommunications, and high-tech manufacturing sectors. The study addresses the critical question of how AI implementation intensity, organizational readiness, and task-technology fit interact to influence technical customer support effectiveness.

The main objective is to quantitatively assess the influence of AI implementation intensity, organizational readiness, and task-technology fit on technical customer support process efficiency. The research includes conducting scientific literature analysis to identify technical customer support processes and AI application possibilities; developing an integrated theoretical model combining Technology-Organization-Environment (TOE) and Task-Technology Fit (TTF) theories; empirically testing the proposed model; and providing recommendations for successful AI integration in IT companies.

The study employs a quantitative research approach using Partial Least Squares Structural Equation Modeling (PLS-SEM) methodology. Data was collected through a structured questionnaire survey from 252 respondents working in Lithuanian companies that utilize AI solutions in their customer service processes. The research instrument consisted of 40 main statements measuring four higher-order constructs through their lower-order components, using a six-point Likert scale.

The empirical analysis revealed significant positive relationships between AI implementation intensity and organizational readiness ($\beta = 0.690$; $p < 0.001$), and between AI implementation intensity and customer service efficiency ($\beta = 0.319$; $p < 0.001$). Organizational readiness demonstrated an even stronger effect on service efficiency ($\beta =$

0.443; $p < 0.001$), highlighting its critical role. Unexpectedly, task-technology fit did not significantly moderate the relationship between AI implementation and service efficiency, challenging traditional TTF theory in the AI context.

The study demonstrates that organizational factors are equally important, if not more critical, than technological solutions for achieving improved technical customer support efficiency. Documentation quality and employee technical agility emerged as the most significant organizational readiness components, while technical infrastructure contribution was statistically insignificant. This challenges traditional IT investment priorities and suggests that "soft" organizational aspects may be more crucial for successful AI implementation than hardware capabilities.

The findings recommend prioritizing organizational preparation before technology acquisition, creating an experimental culture that encourages employee learning and adaptation, ensuring active management involvement in AI initiatives, and developing systematic approaches to knowledge management and documentation quality improvement. This research contributes to the understanding of AI implementation success factors by providing empirical evidence for the critical role of organizational readiness as a mediator in the AI-performance relationship. The study also raises important questions about the applicability of traditional task-technology fit theory in dynamic AI contexts, suggesting the need for new theoretical frameworks better suited to evaluating AI solutions.

The results have implications for companies seeking to implement AI solutions in technical customer support, emphasizing the need for a holistic approach that balances technological capabilities with organizational transformation and employee development.

Keywords: artificial intelligence, technical customer support, business process efficiency, AI implementation intensity, organizational readiness, task-technology fit, PLS-SEM

PRIEDAI

1 priedas – matavimo modelio Cross loadings vertės:

Q19	Q18	Q17	Q16	Q15	Q14	Q13	Q11	Q10	Teiginiai
0.344	0.434	0.441	0.181	0.202	0.449	0.520	0.130	0.227	DIDI_Diegimo_apimtis
0.283	0.222	0.223	0.975	0.965	0.174	0.147	0.371	0.371	DIDI_Diegimo_evoliucija
0.278	0.233	0.251	0.356	0.393	0.103	0.081	0.955	0.973	DIDI_Funkcinis sudėtingumas
0.312	0.276	0.312	0.154	0.168	0.973	0.969	0.054	0.122	DIDI_Integracijos_lygis
0.383	0.396	0.398	0.374	0.344	0.351	0.336	0.306	0.396	KAPE_Aptarnavimo kokybė
0.329	0.301	0.334	0.455	0.392	0.327	0.302	0.198	0.254	KAPE_Laiko efektyvumas
0.324	0.315	0.370	0.304	0.256	0.274	0.230	0.216	0.265	KAPE_Resursų naudojimas
0.400	0.339	0.342	0.390	0.340	0.401	0.367	0.246	0.259	KAPE_Žinių valdymo kokybė
0.179	0.531	0.519	0.329	0.301	0.326	0.343	0.296	0.312	OP_Dokumentacijos kokybė
0.957	0.288	0.357	0.316	0.311	0.316	0.311	0.302	0.317	OP_Techninis lankstumas
0.313	0.942	0.951	0.228	0.229	0.301	0.305	0.233	0.257	OP_Techninė infrastruktūra
0.450	0.464	0.475	0.301	0.269	0.343	0.349	0.269	0.302	OP_Vadovybės palaikymas
0.251	0.275	0.339	0.270	0.268	0.258	0.241	0.240	0.276	TTF_DI galimybių atitikimas
0.373	0.245	0.269	0.267	0.245	0.321	0.283	0.156	0.201	TTF_Funkcinis atitikimas
0.202	0.383	0.364	0.302	0.300	0.210	0.215	0.255	0.329	TTF_Procesų suderinamumas

Q34	Q33	Q32	Q31	Q30	Q29	Q28	Q27	Q26	Q25	Q23	Q21
0.227	0.304	0.269	0.259	0.299	0.336	0.365	0.290	0.423	0.367	0.352	0.390
0.253	0.281	0.210	0.297	0.239	0.234	0.296	0.275	0.334	0.287	0.318	0.326
0.170	0.217	0.141	0.259	0.240	0.254	0.301	0.274	0.302	0.302	0.324	0.320
0.265	0.330	0.299	0.187	0.264	0.278	0.352	0.337	0.363	0.292	0.294	0.320
0.202	0.237	0.180	0.265	0.277	0.296	0.355	0.337	0.381	0.347	0.418	0.395
0.346	0.318	0.250	0.432	0.346	0.405	0.433	0.380	0.470	0.437	0.357	0.378
0.436	0.419	0.360	0.302	0.230	0.299	0.457	0.444	0.399	0.395	0.354	0.373
0.309	0.317	0.246	0.300	0.270	0.310	0.400	0.359	0.404	0.393	0.433	0.436
0.268	0.265	0.242	0.297	0.311	0.341	0.344	0.298	0.959	0.951	0.196	0.194
0.400	0.413	0.341	0.257	0.279	0.288	0.495	0.475	0.210	0.166	0.956	0.961
0.245	0.268	0.267	0.263	0.316	0.340	0.500	0.459	0.524	0.535	0.348	0.321
0.370	0.402	0.344	0.255	0.259	0.302	0.972	0.965	0.329	0.305	0.484	0.503
0.221	0.244	0.196	0.937	0.920	0.945	0.316	0.244	0.378	0.263	0.291	0.297
0.955	0.964	0.930	0.217	0.203	0.234	0.401	0.359	0.291	0.228	0.388	0.412
0.162	0.203	0.174	0.466	0.458	0.518	0.281	0.189	0.338	0.290	0.240	0.271

Q45	Q44	Q43	Q42	Q41	Q39	Q38	Q38	Q37	Q37	Q36	Q35
0.346	0.426	0.429	0.293	0.292	0.340	0.345	0.345	0.344	0.344	0.327	0.293
0.358	0.381	0.342	0.296	0.270	0.372	0.418	0.418	0.448	0.448	0.316	0.276
0.243	0.377	0.343	0.253	0.240	0.192	0.240	0.240	0.237	0.237	0.303	0.291
0.378	0.350	0.340	0.254	0.255	0.281	0.317	0.317	0.316	0.316	0.221	0.199
0.303	0.979	0.974	0.196	0.167	0.429	0.473	0.473	0.489	0.489	0.374	0.302
0.461	0.507	0.453	0.465	0.428	0.929	0.953	0.953	0.947	0.947	0.279	0.176
0.515	0.218	0.142	0.980	0.975	0.401	0.467	0.467	0.424	0.424	0.305	0.248
0.969	0.338	0.271	0.520	0.485	0.399	0.465	0.465	0.458	0.458	0.328	0.240
0.410	0.387	0.357	0.429	0.381	0.423	0.455	0.455	0.464	0.464	0.345	0.280
0.442	0.419	0.393	0.366	0.350	0.338	0.343	0.343	0.370	0.370	0.271	0.199
0.359	0.425	0.393	0.357	0.351	0.346	0.303	0.303	0.307	0.307	0.399	0.355
0.395	0.373	0.322	0.462	0.447	0.397	0.400	0.400	0.395	0.395	0.266	0.195
0.302	0.292	0.291	0.291	0.296	0.408	0.412	0.412	0.386	0.386	0.533	0.448
0.300	0.226	0.202	0.431	0.412	0.309	0.327	0.327	0.289	0.289	0.214	0.135
0.300	0.346	0.350	0.292	0.277	0.226	0.260	0.260	0.208	0.208	0.980	0.952

Q8	Q7	Q46
0.971	0.968	0.342
0.179	0.203	0.374
0.180	0.191	0.266
0.476	0.490	0.390
0.423	0.426	0.305
0.364	0.340	0.447
0.295	0.285	0.482
0.349	0.339	0.968
0.390	0.414	0.398
0.369	0.366	0.415
0.449	0.447	0.337
0.336	0.324	0.365
0.316	0.299	0.309
0.276	0.264	0.301
0.321	0.307	0.286

2 priedas – Fornell-Larcker testo vertės:

KAPE_Lai ko efektyvum as	KAPE_Apt arnavimo kokybė	DIDL_Integ racijos_lygi s	DIDL_Fun kcinis sudėtingu mas	DIDL_Diegi mo_evoluc ija	DIDL_Diegi mo_apimti s	
0.363	0.438	0.497	0.191	0.197	0.970	DIDL_Diegi mo_apimtis
0.439	0.371	0.166	0.384	0.970		DIDL_Diegi mo_evolucija
0.238	0.370	0.095	0.964			DIDL_Funkcinis sudėtingumas
0.324	0.354	0.971				DIDL_Integracijos_lygis
0.493	0.976					KAPE_Aptarnavimo kokybė
0.943						KAPE_Laiko efektyvumas
						KAPE_Resursų naudojimas
						KAPE_Žinių valdymo kokybė
						OP_Dokumentacijos kokybė
						OP_Techninis_lankstumas
						OP_Techninė_infrastruktūr a
						OP_Vadovybės palaikymas
						TTF_DI galimybių atitikimas
						TTF_Funkcinis atitikimas
						TTF_Procesų suderinamumas

TTF_Procesų suderinamumas	TTF_Funkcinis atitikimas	TTF_DI galimybių atitikimas	OP_Vadovybės palaikymas	OP_Techninė infrastruktūra	OP_Techninis lankstumas	OP_Dokumentacijos kokybė	KAPE_Žinių valdymo kokybė	KAPE_Resursų naudojimas
0.324	0.279	0.318	0.341	0.462	0.379	0.414	0.355	0.299
0.310	0.265	0.277	0.295	0.235	0.324	0.326	0.378	0.290
0.308	0.188	0.270	0.298	0.256	0.322	0.316	0.263	0.253
0.219	0.312	0.257	0.356	0.312	0.323	0.344	0.396	0.260
0.356	0.220	0.299	0.358	0.420	0.416	0.382	0.314	0.186
0.246	0.327	0.426	0.421	0.336	0.372	0.475	0.469	0.458
0.292	0.431	0.300	0.466	0.363	0.367	0.416	0.515	0.978
0.303	0.311	0.315	0.393	0.360	0.443	0.417	0.968	
0.330	0.273	0.338	0.332	0.554	0.198	0.955		
0.250	0.409	0.293	0.501	0.342	0.958			
0.394	0.272	0.326	0.496	0.947				
0.246	0.393	0.291	0.969					
0.515	0.234	0.934						
0.189	0.950							
0.966								

3 priedas – HTMT testo vertės:

DIDL_Diegimo_apimtis
DIDL_Diegimo_evoliucija
DIDL_Funkcinis sudėtingumas
DIDL_Integracijos_lygis
KAPE_Aptarnavimo kokybė
KAPE_Laiko efektyvumas
KAPE_Resursų naudojimas
KAPE_Žinių valdymo kokybė
OP_Dokumentacijos kokybė
OP_Techninis_lankstumas
OP_Techninė_infrastruktūra
OP_Vadovybės palaikymas
TTF_DI galimybių atitikimas
TTF_Funkcinis atitikimas
TTF_Procesų suderinamumas

OP_Vadov ybės palaikymas	OP_Techni nė_infrastr uktūra	OP_Techni nis_lankstu mas	OP_Doku mentacijos kokybė	KAPE_Žin ių valdymo kokybė	KAPE_Res ursų naudojima s	KAPE_Lai ko efektyvum as	KAPE_Apt arnavimo kokybė	DIDI_Integ racijos_lygi s	DIDI_Fun kcinis sudėtingu mas	DIDI_Diegi mo_evoliuc ija	DIDI_Diegi mo_apimti s
0.361	0.508	0.400	0.450	0.380	0.317	0.388	0.464	0.532	0.199	0.211	
0.313	0.259	0.341	0.352	0.402	0.304	0.464	0.391	0.177	0.415		
0.318	0.281	0.341	0.345	0.282	0.265	0.250	0.387	0.097			
0.380	0.341	0.340	0.372	0.422	0.274	0.344	0.373				
0.377	0.456	0.436	0.410	0.331	0.193	0.519					
0.448	0.370	0.391	0.515	0.499	0.482						
0.492	0.393	0.382	0.446	0.544							
0.419	0.396	0.468	0.454								
0.360	0.620	0.212									
0.529	0.370										
0.544											

TTF_Proce su suderinam umas	TTF_Funk cinis atitikimas	TTF_DI galimybių atitikimas
0.343	0.298	0.342
0.328	0.276	0.295
0.326	0.195	0.288
0.232	0.332	0.279
0.371	0.228	0.318
0.251	0.341	0.453
0.303	0.448	0.316
0.315	0.325	0.337
0.351	0.292	0.367
0.256	0.424	0.311
0.430	0.299	0.361
0.252	0.414	0.310
0.544	0.247	
0.193		