



VILNIAUS GEDIMINO TECHNIKOS UNIVERSITETAS

MECHANIKOS FAKULTETAS

MECHANIKOS IR MEDŽIAGŲ INŽINERIJOS KATEDRA

Dovydas Alčauskas

**DIRBTINIO INTELEKTO (DI) TAIKYMAS INOVATYVIEMS
PRODUKTAMS KURTI
ARTIFICIAL INTELLIGENCE (AI) FOR INNOVATIVE PRODUCTS
DEVELOPMENT**

Baigiamasis magistro darbas

Pramonės inžinerijos ir inovacijų vadybos studijų programa, valstybinis kodas 6211EX056

Gamybos inžinerijos studijų kryptis

Vilnius, 2025

VILNIAUS GEDIMINO TECHNIKOS UNIVERSITETAS

MECHANIKOS FAKULTETAS

MECHANIKOS IR MEDŽIAGŲ INŽINERIJOS KATEDRA

Dovydas Alčauskas

**DIRBTINIO INTELEKTO (DI) TAIKYMAS INOVATYVIEMS
PRODUKTAMS KURTI
ARTIFICIAL INTELLIGENCE (AI) FOR INNOVATIVE PRODUCTS
DEVELOPMENT**

Baigiamasis magistro darbas

Pramonės inžinerijos ir inovacijų vadybos studijų programa, valstybinis kodas 6211EX056

Gamybos inžinerijos studijų kryptis

Vadovas

_____ doc. dr. Rūta Banelienė _____
(Moksl. laipsnis/pedag. vardas, vardas, pavardė)

Lietuvių kalbos konsultantė

_____ Angelika Petrėtienė _____
(Moksl. laipsnis/pedag. vardas, vardas, pavardė)

Vilnius, 2025

VILNIAUS GEDIMINO TECHNIKOS UNIVERSITETAS
MECHANIKOS FAKULTETAS
MECHANIKOS IR MEDŽIAGŲ INŽINERIJOS KATEDRA

Studijų kryptis: Gamybos inžinerija

Studijų programa: Pramonės inžinerija ir inovacijų vadyba , valstybinis kodas 6211EX056

Specializacija: Pramonės inžinerija ir inovacijų vadyba

TVIRTINU

Katedros vedėjas

Irmantas Gedzevičius

2025-05-18

MAGISTRO BAIGIAMOJO DARBO UŽDUOTIS

Nr. PIVfm-23-9724

Vilnius

Studentas (-ė): Dovydas Alčiauskas

Baigiamojo darbo tema: Dirbtinio intelekto (DI) taikymas inovatyviems produktams kurti

Baigiamojo darbo užbaigimo terminas pagal numatytą studijų kalendorinį grafiką.

BAIGIAMOJO DARBO UŽDUOTIS:

Uždaviniai tikslui pasiekti:

- Atlikti mokslinės literatūros, įvertinančios dirbtinio intelekto (DI) įtaką inovatyvių produktų kūrimui, analizę.
- Apžvelgti kitų tyrėjų taikytus empirinių tyrimų metodus tiriant DI panaudojimą inovatyvių produktų kūrimui ir pasirinkti metodą/-us savo empirinei tyrimo daliai.
- Atlikti empirinius tyrimus ir/ar simuliacinį modeliavimą.
- Parengti ir pasiūlyti struktūruotą modelį, įvertinantį dirbtinio intelekto įtaką inovatyvių produktų kūrimui.

Vadovas docentas Rūta Banelienė

<table><tr><td>Vilniaus Gedimino technikos universitetas</td></tr><tr><td>Mechanikos fakultetas</td></tr><tr><td>Mechanikos ir medžiagų inžinerijos katedra</td></tr></table>		Vilniaus Gedimino technikos universitetas	Mechanikos fakultetas	Mechanikos ir medžiagų inžinerijos katedra	<table><tr><td>ISBN</td><td>ISSN</td></tr><tr><td>Egz. sk.</td><td></td></tr><tr><td>Data-.....-.....</td><td></td></tr></table>	ISBN	ISSN	Egz. sk.		Data-.....-.....	
Vilniaus Gedimino technikos universitetas											
Mechanikos fakultetas											
Mechanikos ir medžiagų inžinerijos katedra											
ISBN	ISSN										
Egz. sk.											
Data-.....-.....											
Antrosios pakopos studijų Pramonės inžinerijos ir inovacijų vadybos programos magistro baigiamasis darbas 4											
Pavadinimas	Dirbtinio intelekto (DI) taikymas inovatyviems produktams kurti										
Autorius	Dovydas Alčauskas										
Vadovas	Rūta Banelienė										
<table><tr><td></td><td>Kalba: lietuvių</td></tr></table>			Kalba: lietuvių								
	Kalba: lietuvių										
Anotacija Baigiamajame magistro darbe nagrinėjamos dirbtinio intelekto (DI) integravimo galimybės inovatyvių produktų kūrimo procesuose, atsižvelgiant į sparčią technologinę pažangą ir būtinybę stiprinti įmonių konkurencinį pranašumą rinkoje. Atliekant mokslinės literatūros analizę, apžvelgti inovatyvių produktų kūrimo teoriniai aspektai bei išanalizuoti kitų autorių taikomi empiriniai metodai šioje srityje. Remiantis analize ir atliktais praktiniais tyrimais, parengtas struktūruotas DI integracijos modelis, pagrįstas „Stage-Gate“ inovacijų valdymo sistema. Empirinėje darbo dalyje atlikta simuliacija, įvertinanti DI taikymo poveikį įvairiuose produkto kūrimo etapuose – nuo idėjų generavimo iki verslo plano rengimo. Tyrimas atskleidė, kad DI technologijų diegimas leidžia pagerinti kūrimo procesą, trumpina produkto pateikimo į rinką laiką, didina sprendimų kokybę bei inovacijų efektyvumą gamybos sektoriuje, ypač Lietuvos pramonės kontekste. Darbą sudaro: įvadas, dirbtinio intelekto ir inovatyvių produktų sąsajos teoriniai aspektai, DI integracijos kuriant inovatyvius produktus metodologijų empiriniai tyrimai, dirbtinio intelekto integracijos kuriant inovatyvius produktus modelis, išvados ir pasiūlymai. Darbo apimtis – 86 p. teksto be priedų, 37 iliustr., 22 lent., 91 bibliografiniai šaltiniai. Atskirai pridedami darbo priedai											
Prasminiai žodžiai: dirbtinis intelektas, inovatyvus produktas, „Stage-Gate“ modelis, gamybos sektorius, simuliacija, inovacijų valdymas.											

<table><tr><td>Vilnius Gediminas Technical University</td></tr><tr><td>Faculty of Mechanics</td></tr><tr><td>Department of Mechanical and Material Engineering</td></tr></table>		Vilnius Gediminas Technical University	Faculty of Mechanics	Department of Mechanical and Material Engineering	<table><tr><td>ISBN</td><td>ISSN</td></tr><tr><td>Copies No.</td><td></td></tr><tr><td>Date-.....-.....</td><td></td></tr></table>	ISBN	ISSN	Copies No.		Date-.....-.....	
Vilnius Gediminas Technical University											
Faculty of Mechanics											
Department of Mechanical and Material Engineering											
ISBN	ISSN										
Copies No.											
Date-.....-.....											
Master Degree Studies Industrial Engineering and Innovation Management study programme Master Graduation Thesis 4											
Title	Artificial Intelligence (AI) for Innovative Products Development										
Author	Dovydas Alčauskas										
Academic supervisor	Rūta Banelienė										
<table><tr><td></td><td>Thesis language: Lithuanian</td></tr></table>			Thesis language: Lithuanian								
	Thesis language: Lithuanian										
Annotation This master's thesis explores the potential for integrating artificial intelligence (AI) into innovative product development processes, taking into account rapid technological advancement and the growing necessity for companies to strengthen their competitive advantage in the market. Through a comprehensive review of scholarly literature, the theoretical foundations of innovative product development are examined, alongside an analysis of empirical methodologies employed by other researchers in the field. Based on this analysis and the conducted empirical research, a structured AI integration model has been developed, grounded in the "Stage-Gate" innovation management framework. The empirical part of the study includes a simulation that evaluates the impact of AI application across various stages of product development - from idea generation to business plan formulation. The findings reveal that the implementation of AI technologies can improve the development process, reduce time-to-market, enhance decision-making quality, and improve innovation efficiency in the manufacturing sector, particularly within the context of Lithuanian industry. The thesis consists of: introduction, theoretical aspects of the interface between artificial intelligence and innovative products, empirical studies of methodologies of AI integration in innovative product development, a model of AI integration in innovative product development, conclusions and suggestions. The thesis consists of 86 pages of text without appendixes, 37 figures, 22 tables and 91 references. The appendixes are separately attached.											
Keywords: artificial intelligence, innovative product, Stage-Gate model, manufacturing sector, simulation, innovation management											

TURINYS

IVADAS	8
1. INOVATYVIŲ PRODUKTŲ KŪRIMAS, DIRBTINIS INTELEKTAS IR JO TAIKYMAS	11
1.1. Inovatyvių produktų kūrimas.....	11
1.1.1. Inovacijų samprata.....	11
1.1.2. Inovatyvus produktas.....	13
1.1.3. Proceso inovacija.....	16
1.1.4. Inovatyvaus produkto kūrimas	18
1.2. Dirbtinis intelektas.....	22
1.2.1. Dirbtinio intelekto samprata	22
1.2.2. Dirbtinio intelekto tipai ir technologijos	23
1.2.3. Dirbtinio intelekto taikymas praktikoje	31
2. DIRBTINIO INTELEKTO TAIKYMO METODOLOGINIAI ASPEKTAI	34
2.1. Dirbtinio intelekto sąsaja su inovatyviu produktu.....	34
2.1.1. Dirbtinio intelekto įtaka gamybos pramonėje	34
2.1.2. Dirbtinio intelekto įtaka inovatyvaus produkto kūrimo procese	37
2.1.3. Dirbtinio intelekto taikymo kliūtys pramonės įmonėse.....	42
2.1.4. Dirbtinio intelekto taikymas Lietuvos pramonėje	44
2.2. Dirbtinio intelekto taikymo tyrimo eiga inovatyvių produktų kūrimo procese.....	45
2.3. Tyrimo metodų pasirinkimo pagrindimas dirbtinio intelekto integracijai vertinti	47
2.4. Tyrime naudotos priemonės ir technologijos	48
3. DIRBTINIO INTELEKTO TAIKYMO INTEGRAVIMAS Į STAGE-GATE MODELĮ: SIMULIACIJA IR SIŪLOMAS MODELIS INOVATYVIŲ PRODUKTŲ KŪRIMUI	50
3.1. DI integravimas „Stage-Gate“ modelyje	50
3.1.1. I Etapas. Idėjų generavimas.....	50
3.1.2. II Etapas. Pirminė apžvalga	52
3.1.3. III Etapas. Verslo atvejo analizė.....	54
3.1.4. IV Etapas. Produkto kūrimas.....	55
3.1.5. V Etapas. Testavimas ir įgyvendinimas	58
3.1.6. VI Etapas. Produkto paleidimas	59
3.2. Inovatyvių produktų kūrimo modelis, pagrįstas dirbtinio intelekto taikymu	61

3.3. Inovatyvių produktų kūrimo proceso simuliacija taikant dirbtinį intelektą	63
3.3.1. I Etapas. Idėjų generavimas.....	63
3.3.2. I Etapas. Vartų sistema	71
3.3.3. II Etapas. Konceptijos detalizavimas.....	72
3.3.4. III Etapas. Verslo plano kūrimas	85
3.3.5. IV Etapas. Produkto dizainas ir projektavimas	92
3.3.6. Simuliacijos rezultatas	95
IŠVADOS IR REKOMENDACIJOS.....	97
LITERATŪROS SĄRAŠAS.....	100
PRIEDAS A. Lietuvos jaunųjų mokslininkų konferencijoje pristatyta prezentacija.....	108

LENTELIŲ SĄRAŠAS

1 lentelė. Inovacijos sąvokos apibrėžimai ir jų grupavimo būdai remiantis skirtingais autoriais	11
2 lentelė. Veiklos ir valdymo procesai pramonės įmonėse	17
3 lentelė. Tobulinimo ir inovacinio proceso skirtumai.....	17
4 lentelė. „Stage-Gate“ modelio etapų ir vartų apibūdinimas	19
5 lentelė. DI klasifikavimas paremtas technologijomis.....	29
6 lentelė. DI taikymas pagal industrijas	32
7 lentelė. DI įtaka inovacijų valdymo srityje.....	39
8 lentelė. Rudolfo Grunbichler’io penkių lygmenų dirbtinio intelekto taikymo kliūtis.....	43
9 lentelė. DI naudojimas gamybos procesams.....	45
10 lentelė. Technologinis pagrįstumas pasirinktoms idėjoms	66
11 lentelėje. Rinkos analizė.	68
12 lentelė. Vartų etapas	71
13 lentelė. Pasirinktos idėjos detalizavimas atsižvelgiant į techninius reikalavimus, ekonominius aspektus, vartotojų reikalavimus, pagrindines savybes, išūkius ir apribojimus .	72
14 lentelė. Drono pirkimo duomenys	74
15 lentelė. Tikslinės vartotojų grupės pasirinkimas	77
16 lentelė. Žemės ūkio drono vartotojų apklausa, sukurta su Chatgpt modeliu.....	78
17 lentelė. Rizikų identifikavimas su Chatgpt modeliu.....	83
18 lentelė. Verslo galimybių įvertinimas.....	84
19 lentelė. Pardavimų prognozės pagal kategorijas.....	88
20 lentelė. Žemės ūkio drono pardavimų prognozė 2024 - 2025 m.	88
21 lentelė. PESTEL analizė.	89
22 lentelė. Porterio penkių jėgų modelis	91

PAVEIKSLŲ SĄRAŠAS

1 pav. Igorio Ansoffo „Produkto-rinkos“ matrica.....	15
2 pav. Trijų šalių veikiamos jėgos inovatyviam produktui.	16
3 pav. „Stage-Gate“ modelis naujų produktų kūrimo.....	20
4 pav. Montagnos struktūrinė diagrama	21
5 pav. Dirbtinio intelekto klasifikavimas	23
6 pav. DI klasifikavimas paremtas intelektu	25
7 pav. Mašininio mokymosi tipai	26
8 pav. Giliojo mokymosi architektūra	28
9 pav. DI pritaikymas gamybos sektoriuje	36
10 pav. Naujos kartos išmanios gamybos modelis.....	37
11 pav. DI pritaikymas sėkminguose ir nesėkminguose projektuose.....	40
12 pav. Dirbtinio intelekto technologijų poveikis projekto sėkmės rodikliams.....	41
13 pav. DI vaidmuo inovatyvių produktų kūrimo procese.....	42
14 pav. Tyrimo metu analizuojami etapai remiantis „Stage-Gate“ modeliu.....	50
15 pav. DI integravimas inovatyvaus produkto kūrimo procesuose	61
16 pav. Užklausos formulavimas.....	63
17 pav. Idėjų generavimas skirtingomis užklausomis	64
18 pav. Idėjų vizualizacijos	65
19 pav. Sugeneruotų idėjų klasifikavimas	68
20 pav. Vartotojo atsiliepiamas ir <i>Google Cloud Natural Language</i> priemonė	69
21 pav. <i>Google Cloud</i> atsiliepimo analizė.....	70
22 pav. „Orange“ programos asociacijų taisyklių kūrimas	75
23 pav. „Orange“ programos asociacijų rezultatai	76
24 pav. „Orange“ programoje apskaičiuotos tikimybės	76
25 pav. „Garunda“ bepiločio orlaivio skirtos žemės ūkiui reklama.....	80
26 pav. Vaizdų atpažinimo metodas Python aplinkoje.....	80
27 pav. Duomenų klasterizavimo analizė naudojant K-means algoritmą	81
28 pav. Klasterifikavimo rezultatai. „Derlius vs Investicijos“ ir „Amžius vs Patirtis“	83
29 pav. Verslo modelio kūrimas su „Miro AI“ platforma.....	86
30 pav. Galutinis sugeneruotas verslo planas, naudojant „Miro AI“ programą.....	87
31 pav. SSGG analizė.....	91
32 pav. Modelio paruošimas generatyviniui dizainui Autodesk Fusion 360 aplinkoje.....	93
33 pav. Nustatytos apkrovos ir jėgos.....	94

34 pav. Sugeneruotas drono korpusas su generatyvinio dizaino algoritmais	95
35 pav. DI integracija inovatyvių produktų kūrimo „Stage-Gate“ modelyje po atliktos simuliacijos.....	96

IVADAS

Tyrimo aktualumas. Inovatyvaus produkto kūrimas laikomas vienu iš esminių procesų, užtikrinančių sėkmę sparčiai besivystančiose ir konkurencingose rinkose (Brown & Eisenhardt, 1995). Inovatyvaus produkto vertė išryškėja tik esant produkto sąveikai su kitais suinteresuotais produktais tam tikrame kontekste (Chesbrough, 2010). Dabartinėje ekonominėje aplinkoje, kurioje technologijų pažanga vyksta labai sparčiai, o produktų gyvavimo ciklas trumpėja, įmonėms reikia ne tik inovatyvios produktų kūrimo strategijos, bet ir žinoti veiksnius, lemiančius naujų produktų sėkmę rinkoje (Cooper & Kleinschmidt, 2007). Vienas iš sprendimo būdų – inovatyvaus produkto kūrimas pasitelkiant dirbtinį intelektą (DI). Remiantis naujausiais 2022 m. IMB duomenimis, 35 % pasaulinių įmonių naudojami dirbtiniai intelektu savo versle, o daugiau nei 50 % įmonių planuoja integruoti dirbtinio intelekto technologijas 2023 m., dėl tokio poreikio DI augimas tampa vis labiau institucionalizuotas visuomenėje (World Bank, 2019). Sparčiai kylant DI poreikiui, įmonės yra priverstos integruoti šią technologiją, suprasti kaip tinkamai panaudoti ją inovatyvaus produkto kūrimo procesuose ir veiksmuose (Ghosh, 2022). Toks sprendimo būdas gali sumažinti laiką, kuris daro įtaką produkto patekimui į rinką, pagerinti produkto kokybę, sumažinti išlaidas, sukurti naujų darbo vietų bei padidinti įmonės konkurencingumą rinkoje (Fujitsu, 2017; Bughin et al., 2018).

Lietuvoje vienas iš didžiausių ekonomikos sektorių – gamyba. Remiantis 2024 m. Eurostato duomenimis, gamybos sektorius sudaro apie 14 % Lietuvos bendrojo vidaus produkto (Eurostat, 2024). Lietuvos gamybos sektoriuje viena iš didžiausių problemų yra mažas darbo našumo lygis. Žvelgiant į 2019 m. „Our World in Data“ pasaulio šalių duomenis, Lietuva užima tik 38-tą vietą (34,45 US\$ PPP darbo našumas per darbo valandą) (OWID, 2019). Šią problemą galima spręsti pasitelkiant dirbtinį intelektą – automatizuojant įprastas įmonės veiklas bei kuriant inovatyvius sprendimus produkto kūrimo laikotarpiu (OECD, 2021). Remiantis Oficialios statistikos portalo 2021 m. duomenimis, Lietuvoje darbo procesams automatizuoti su DI naudojosi tik 2,3 % įmonių. Toks DI integravimas Lietuvos gamybos įmonėse paskatintų vietinės bei pasaulinės rinkos konkurencingumą, padidintų darbo našumą, pridėtinę vertę ir sukurtų naujų darbo vietų automatizacijos procesuose.

Tyrimo problema. Nepaisant didėjančio dirbtinio intelekto taikymo potencialo, inovatyvių produktų kūrimo kontekste vis dar stokojama sisteminių metodinių sprendimų, leidžiančių efektyviai integruoti DI technologijas į šį procesą. Tai apsunkina galimybę užtikrinti produktyvumo augimą, didesnę kuriamų produktų pridėtinę vertę bei įmonių konkurencinį pranašumą dinamiškoje rinkos aplinkoje.

Tyrimo objektas – inovatyvaus produkto kūrimas pasitelkiant dirbtinį intelektą.

Tyrimo tikslas – išanalizavus mokslinę literatūrą bei atlikus empirinius tyrimus parengti ir pasiūlyti struktūruotą modelį, įvertinantį dirbtinio intelekto įtaką inovatyvių produktų kūrimui.

Uždaviniai tikslui pasiekti:

1. Atlikti mokslinės literatūros, įvertinančios dirbtinio intelekto įtaką inovatyvių produktų kūrimui, analizę.
2. Apžvelgti kitų tyrėjų taikytus empirinių tyrimų metodus tiriant DI panaudojimą inovatyvių produktų kūrimui ir pasirinkti metodą (-us) empirinei tyrimo daliai.
3. Atlikti empirinius tyrimus ir / ar simuliacinį modeliavimą.
4. Parengti ir pasiūlyti struktūruotą modelį, įvertinantį dirbtinio intelekto įtaką inovatyvių produktų kūrimui.

Tyrimo metodai. Norint ištirti kaip dirbtinio intelekto integravimas veikia inovatyvaus produkto kūrimo procesą, naudojamas literatūros analizės metodas. Šis metodas leis susisteminti kitų mokslininkų išvalgas bei žinias, tarp inovatyvaus produkto kūrimo proceso ir dirbtinio intelekto sąsajos. Atsižvelgiant į tyrimo tikslą - parengti ir pasiūlyti struktūruotą modelį, įvertinantį dirbtinio intelekto įtaką inovatyvių produktų kūrimui, taikomas lyginamosios analizės metodas, kuriuo metu lyginami kitų tyrėjų empiriniai metodai. Toks lyginamasis tyrimas leidžia pasirinkti tinkamiausius empirinio tyrimo metodus tyrimo daliai. Taip pat šioje dalyje svarbu atsižvelgti į jau kitų mokslininkų sukurtus modelius įvertinančius DI įtaką inovatyvių produktų kūrimo procesuose, surasti jų silpnąsias vietas ir patobulinti. Empirinio tyrimo dalyje, atliekama teksto analize. Remiantis atlikta literatūros analize, pasirenkamas populiarus inovatyvių produktų kūrimo modelis. Į šį modelį integruojant dirbtinį intelektą, nagrinėjami įvairūs jo pritaikymo aspektai, tokie kaip procesų automatizavimas, duomenų analizės metodai ir sprendimų priėmimo tobulinimas. Randama sąsajų tarp pasirinkto modelio ir dirbtinio intelekto integravimo. Siekiant pasiūlyti struktūruotą modelį, įvertinantį dirbtinio intelekto įtaką inovatyvių produktų kūrimui, taikomas modeliavimo metodas. Šis metodas padeda suprasti empirinio tyrimo rezultatų ir elementų, ryšius bei sąsajas. Sukuriamas modelis. Siekiant tinkamai suprasti pasiūlytą struktūrizuotą modelį, taikomas simuliacijos metodas. Simuliacijos metodas leidžia atkartoti ar imituoti realią situaciją, išskiriant tik esmines realaus gyvenimo charakteristikas ir perkeltant procesus į nerizikingą aplinką.

Darbo pristatymas ir validavimas. Darbas pristatytas 28-oje Lietuvos jaunųjų mokslininkų konferencijoje „Mokslas – Lietuvos ateitis“ Mechanika, medžiagų inžinerija, pramonės inžinerija ir vadyba, vykusioje 2025 m. balandžio 25 d. Konferencijoje pristatymo darbo tema - dirbtinio intelekto taikymas inovatyvių produktų kūrimui. Pristatymo metu buvo aptarti darbo tikslai, metodologija, tyrimo eiga, rezultatai bei pateiktas struktūruotas modelis, įvertinantis dirbtinio intelekto įtaką inovatyvių produktų kūrimui. Dalyvavimas konferencijoje suteikė galimybę gauti konstruktyvų grįžtamąjį ryšį, o tai prisidėjo prie darbo turinio pagrįstumo ir mokslinio aktualumo.

1. INOVATYVIŲ PRODUKTŲ KŪRIMAS, DIRBTINIS INTELEKTAS IR JO TAIKYMAS

1.1. Inovatyvių produktų kūrimas

1.1.1. Inovacijų samprata

Šiuolaikinėje visuomenėje naujų produktų ar paslaugų kūrimas, jų taikymas ir tobulinimas įgauna vis spartesnį tempą. Dėl intensyvios pasaulinės konkurencijos ir technologijų plėtros inovacijos tapo konkurencinio pranašumo šaltiniu (Kleinschmidt, 2007). Organizacijos pateikdamos savo viziją, misiją ir objektyvius pareiškimus, dažnai vartoja terminą *inovacija* (Kahn, 2018). Užduodant bet kuriam įmonės vadovui klausimą „Ko reikia, kad Jūsų įmonė sėkmingai veiktų šiandienos dinamiškoje ekonomikoje?“, labiausiai tikėtinas atsakymas yra „inovacijos“ (Kuratko, 2009), todėl XXI a. verslo terpėje inovacijos sąvoka įgauna didelę reikšmę, kuri paliečia daugumą versle vykdomų etapų. Inovacijos turi platų poveikį įvairioms ekonomikos sritims, strateginiam inovacijų procesų valdymui ir veikimui bei viešajai politikai, orientuotai į inovacijas (Peters, 2009). Viename žurnalo „Wired“ straipsnyje inovacijos terminas buvo pavadintas svarbiausiu ir per daug vartojamu žodžiu Amerikoje (O’Byrne, 2013). Toks spartus termino vartojimas lėmė klaidingą supratimą visuomenėje. Atsirandant įvairioms termino interpretacijoms, įmonės priima neteisingus sprendimus galvodamos, kad naujovės yra sunkiai įgyvendinamos (Kuratko, 2014). Dėl šios priežasties įmonėms privaloma suprasti tinkamai inovacijos sąvokos prasmę. Egzistuoja daug inovacijų apibrėžimų, jų grupavimo būdų pagal įvairius požyrius (1 lentelė).

1 lentelė. Inovacijos sąvokos apibrėžimai ir jų grupavimo būdai remiantis skirtingais autoriais

Autorius	Apibūdinimas
Schumpeter (1930)	• Naujas produktas arba patobulinamas esamas produktas. • Naujas inovacijų procesas pramonėje. • Naujos rinkos atradimas. • Naujų žaliavų tiekimo šaltinių kūrimas. • Kiti pokyčiai organizacijoje.
Druker (1954)	Viena iš dviejų pagrindinių organizacijos funkcijų.
Howard and Sheth (1969)	Bet koks naujas elementas, pateiktas pirkėjui, nesvarbu, ar jis naujas organizacijai.
Mohr (1969)	Konkrečių naujų pokyčių įgyvendinamas organizacijoje.
Simmonds (1986)	Inovacijos – tai naujos idėjos, kurias sudaro: nauji produktai ir paslaugos, naujas esamų produktų panaudojimas, naujos esamų produktų rinkos arba nauji rinkodaros metodai.
Simmonds (1986)	Pagrindinis kūrybinis procesas
Damanpour (1991)	Naujų idėjų kūrimas ir priėmimas įmonėje.

Davenport (1991)	Produkto kūrimas radikaliai nauju būdu.
Evans (1991)	Gebėjimas atrasti naujus santykius, pamatyti dalykus iš naujų perspektyvų ir sudaryti naujus derinius iš esamų koncepcijų.
Slevin (1991), Lumpkin and Dess (1996), Knox (2002)	Inovacija gali būti apibrėžta kaip procesas, suteikiantis pridėtinę vertę ir tam tikrą naujumo laipsnį organizacijai, tiekėjams ir klientams, kuriant naujas procedūras, sprendimus, produktus ir paslaugas bei naujus rinkodaros būdus.
Rogers (1998)	Apima ir žinių kūrimą, ir esamų žinių sklaidą.
The European Commission (1999)	Sėkmingas naujovių kūrimas, įsisavinimas ir panaudojimas ekonominėje ar socialinėje aplinkoje.

Šaltinis: sudaryta autoriaus.

Pamatine prasme, žodis „inovacija“ kilęs iš lotyniško žodžio „innovare“, reiškiančio patobulinti arba sukurti naują. Vienas dažniausiai minimų moksliniuose darbuose inovacijos teorijos pradininkų yra Josephas Schumpeteris, kuris suformulavo šiandien žinomos inovacijų teorijos ištakas. Schumpeteris teigė, kad inovacijos yra esminė varomoji jėga, lemianti ekonomikos augimą, verslo pelningumą ir prisidedanti prie visuomenės gerovės kūrimo (Schumpeter, 1934). Visi novatoriški produktai išsiskiria tuo, kad jie tam tikra prasme yra nauji, tačiau vien naujumas inovacijas nepakankamai apibūdina (Tan, 2006). Inovacija labiau apibūdina produkto / paslaugos vertės kūrimą, lyginant su esamais sprendimais. Šį reiškinį labiau išplėtojo Adamas Smithas knygoje „Wealth of Nations“, kai tyrinėjo techninius pokyčius ir jų poveikį ekonomikos augimui (Smith, 1776). Technologijų tobulėjimas leido gaminti produktus su daug mažesne darbo jėga, taip padidinant įmonės pelną bei pridėtinę vertę.

Bene geriausiai atspindi šių dienų ekonomikos aktualijas ir sujungiantis kitų autorių inovacijų apibūdinimus OECD (angl. *The Organisation for Economic Co-operation and Development*) išleistas Oslo vadovo ketvirtasis leidimas, pasirodęs 2018 metais. Šiame leidinyje inovacija apibūdinama kaip naujas ar patobulintas produktas ar verslo procesas (arba jų derinys), kuris reikšmingai skiriasi nuo įmonės ankstesnių produktų ar verslo procesų ir kuris buvo pateiktas rinkai arba kurį įmonė pradėjo naudoti (OECD 2018).

Taip pat šiame vadove pateikiamos inovacijų rūšys, jas galima skaidyti į dvi atskiras kategorijas:

- 1) Produkto inovacijos:
 - 1) prekės (gaminio) inovacijos;
 - 2) paslaugų inovacijos.
- 2) Verslo procesų inovacijos:
 - 1) produktų ir procesų kūrimo inovacijos;
 - 2) administravimo / valdymo inovacijos;
 - 3) informacijos komunikacijos sistemų inovacijos;
 - 4) marketing / pardavimų inovacijos;

- 5) paskirstymo / logistikos inovacijos;
- 6) gamybos / atlikimo inovacijos.

Papildydamas inovacijos sritis, Kennethas Kahnas išskiria inovacijas platesne prasme, teigdamas, kad tai net nėra baigtinis kriterijų sąrašas (Kahn, 2018). Išskiriamos Kahno inovacijos sritis: produkto inovacijos, proceso inovacijos, marketingo inovacijos, verslo modelio inovacijos, tiekimo grandinės inovacijos, organizacijos inovacijos.

Inovacijos yra skirstomos ir pagal savo naujumo laipsnį bei būdą, kuriuo jos yra diegiamos, t.y. radikalių arba laipsniškų (Eiriz, Faria ir Barbosa, 2013).

Radikalios. Naujų technologijų ir naujos verslo strategijos derinys, visiškai pakeičiantis esamą rinką. Radikalioje naujovėje įmonė siekia novatoriškos ir transformuojančios naujovių formos, apimančios nuokrypį nuo laipsniškų patobulinimų ar nedidelių pakeitimų (Dieffenbacher, 2023).

Laipsniškos. Jos apibrėžiamos, priešingai nei racionalių, kaip palaipsniui, žingsnis po žingsnio plėtojimas arba pritaikymas, kuriuo siekiama optimizuoti ir suteikti papildomos kokybės jau egzistuojančiam produktui ar procesui (Varadarajan, 2009).

1.1.2. Inovatyvus produktas

Produkto inovacijos apibūdinimas atsiranda, kai rinkoje pristatomas naujas produktas arba nauja esamo produkto rūšis, siekiant patenkinti konkrečią rinkos dalį (Tavassoli, 2015). Tai apima reikšmingus techninių specifikacijų, komponentų ir medžiagų, integruotos programinės įrangos, patogumo vartotojui ar kitų funkcinių savybių patobulinius. Pagrindinis produktų inovacijų tikslas yra pristatyti naujus produktus, kurie leistų įmonei įgyti konkurencingą trumpalaikę arba ilgalaikę monopolinę padėtį, suteikiant laisvę nustatyti kainas, viršijančias ribinius rinkos kaštus (Gilbert, 1982). Robertas Cooperis 2001 m. mokslinėje darbe aiškina, kad inovatyvus produktas yra apibrėžiamas kaip inovatyvus, jei jis išbuvo rinkoje penkerius metus ir apima patobulinius. Norint nustatyti inovatyvaus objekto savybes, reikia suprasti, kuo naujas objektas skiriasi nuo anksčiau egzistavusių ir kokia terpėje jis gali pasireikšti (Tan, 2006). Naujumo lygis skirsis priklausomai ne tik nuo srities naujumo rinkoje bet ir nuo to, kaip naują jį suvoks produkto naudotojas.

Booz-Allen tyrimo metu nustatė ir išskyrė septynias inovatyvių produktų kurimo sferas (Booz-Allen, 2005):

- 1) *Produkto tobulinimas:* patobulinimai, kurie pagerina produkto formą arba funkciją. Dažniausiai tokie produkto patobulinimai išstumia iš rinkos originalų produktą, nes jie užtikrina didesnę našumą arba didesnę suvokiamą vertę, palyginti su senu produktu


(Crawford, 2003), todėl senasis produktas nebėra pasiekiamas klientams. Produkto patobulinimai taip pat gali apima pakuotės pakeitimus, darant prielaidą, kad pagrindinis produktas, kurį klientas perka, nesikeičia.

- 2) *Produkto plėtiniai*: naujos funkcijos / parinktys, pridėtos prie esamo pasiūlymo, suteikiančios unikalių pranašumų ir funkcijų, kurių neturi esamas produktas. Pagrindinis skirtumas tarp produkto tobulinimo ir plėtimo yra tas, kad pristačius produkto papildymą, klientas vis tiek gali įsigyti esamą originalų produktą.
- 3) *Naujos rinkos*: dabartiniai produkcijos pasiūlymai perkeliama į naujas rinkas su minimaliais produkto pakeitimais. Pavyzdžiui, 2005 m. pasaulinė farmacijos ir sveikatos produktų gamintoja Bristol-Myers Squibb paskelbė, kad Kinijoje pristato savo vaistą nuo hepatito B. Vaistas jau debiutavo ir pasirodė esąs veiksmingas JAV. Vaistas nepasikeitė, nors pakuotės kalba turėjo būti išversta į kinų kalbą ir pateikti reikiamą informaciją, kad atitiktų Kinijos vyriausybės reikalavimus (Bristol-Myers Squibb, 2017).
- 4) *Nauji panaudojimo būdai*: išlaikomi originalūs gaminiai, įterpti naujose rinkose, įgaunant naują panaudojimo funkcionalumą.
- 5) *Naujos kategorijos pasirinkimas*: produktai, kurie yra nauji įmonei, bet nėra nauji vartotojui kaip kategorija. Pavyzdžiui, Apple įmonės pagrindinė produkcija yra išmanieji telefonai, tačiau atsiradus naujam visuomenės poreikiui, įmonė pradėjo kurti išmaniuosius laikrodžius.
- 6) *Visiškai nauji produktai rinkoje*: technologinės naujovės, sukuriančios visiškai naują rinką, kurios anksčiau nebuvo. Pavyzdžiui, COVID-19 pandemijos laikotarpiu buvo sukurta nauja vakcina.
- 7) *Kainos sumažinimas*: šis produkto tipas labiau apibūdina kainos pokyčius, paprastai nedarantys įtakos produkto vizualinių savybių pokyčiui. Sąnaudų mažinimo tikslas – išlaikyti produkto konkurencingumą, mažinant produkto kainą.

Pasak Khanto, vienas iš būdų valdyti produktų inovacija yra susieti šiuos visus septyniuosius inovatyvių produktų tipus su organizacijos rinkodaros strategija (Kahn, 2018). Šiam procesui įgyvendinti Khantas, pasitelkia Igorio Ansoffo „Produkto-rinkos“ matrica (1 pav.). Apibrėžiant tiek rinką, kurioje plėtojamas produktas, tiek siūlomą produktą kaip esamą ar naują, pateikiamos keturių tipų strategijos: skverbimasis į rinką (esama rinką, esamas produktas), produkto kūrimas (esama rinką, naujas produktas), rinkos plėtra (nauja rinką, esamas produktas) ir diversifikaciją (nauja rinką, naujas produktas). Kiekvienas iš septynių skirtingų naujų produktų tipų gali būti susietas su šiomis strategijomis:

- 1) *Skverbimasis į rinką*. Šios strategijos tikslas padidinti tą pačią rinkos dalį ir tų pačių produktų naudojimą. Esamas klientų kiekis yra patenkinamas tuo pačiu produktu, nekeičiant dabartinio gaminio gamybos technologijos. Šiai strategijai galime priskirti *kainos sumažinimo* ir *produkto tobulinimo* tipus, kurių pagrindiniai kriterijai: mažesne kaina, daugiau patobulintų funkcijų.
- 2) *Produkto kūrimas*. Produkto kūrimo strategija kyla iš tikslo padidinti pardavimų apimtį, pasiūlant esamai rinkai naują produktą. Tokiu būdu įmonės, turi įvairesnį produktų asortimentą, gali pasiūlyti daugiau rinkai inovatyvių produktų, kurios didintų bendras įmonės pajamas. Šiai strategijai galima priskirti *produkto plėtinių* tipą.
- 3) *Rinkos plėtra*. Rinkos plėtros strategija siekiama išplėsti esamų produktų pardavimo apimtis naujose rinkose, išplėtojant tarptautinių rinkų ir naujų segmentų taikymo galimybes. Šiai strategijai būdingi *naujų rinkų* ir *naujų panaudojimo* inovatyvaus produkto tipai.
- 4) *Diversifikacija*. Diversifikacija vykdoma tada, kai įmonė nori pasiūlyti savo naują produkciją naujose rinkose. Šiai strategijai galima priskirti *naujos kategorijos pasirinkimo* ir *visiškai naujos produkcijos rinkoje* tipus.


Toks produktų ir rinkos palyginimas yra tiesiogiai susijęs su rizika. Kaip ir pavaizduota 1 pav., mažiausia rizika išlieka skverbimosi į rinką etape, ši strategija įmonei yra laikoma saugiausia. Produkto kūrimo ir rinkos plėtroje etapuose rizika išlieka vidutinė, o didžiausia rizika priskiriama diversifikacijos strategijos etape.



1 pav. Igorio Ansoffo „Produkto-rinkos“ matrica.

Šaltinis: sudaryta autoriaus remiantis Kahn (2018).

A. R. Tano moksliniame darbe teigiama, kad būtent trijų pagrindinių suinteresuotųjų šalių: įmonės, vartotojo ir socialinis – derinys lemia, ar produktas yra inovatyvus, ar ne. Kuriant inovatyvius produktus reikia atsižvelgti į visų trijų suinteresuotųjų šalių poreikius, vertybes ir tikslus. Tai veda prie visapusiškesnio supratimo apie tai, kas apibrėžia inovatyvų produktą (Tan, 2006). Svarbu paminėti, kad trys šios šalys turi bendrauti tarpusavyje, norint gauti inovatyvaus produkto rezultatą (2 pav.).



2 pav. Trijų šalių veikiamos jėgos inovatyviam produktui.

Šaltinis: sudarytas autoriaus remiantis Tan (2006).

- 1) *Įmonės elementas* apima visas organizacijas, grupes ar asmenis, kurie užsiima gaminio sumanymu, gamyba, pardavimu, pristatymu ir aptarnavimu.
- 2) *Vartotojo elementas* apima pirkėją, vartotoją ir klientus, kuriuos tiesiogiai veikia faktinis prekės pardavimas, pristatymas, naudojimas ir nuosavybės teisė.
- 3) *Socialinis elementas* apima visuomenę, vyriausybę, viešąsias nuomones. Visus, kurie netiesiogiai komunikuoja su produktu ir yra paveikti jo poveikio.

1.1.3. Proceso inovacija

Proceso inovacija – tai naujo ar žymiai patobulinto gamybos ar pristatymo būdo įdiegimas. Tai apima reikšmingus technikos, įrangos ir (arba) programinės įrangos pakeitimus (OECD 2005). Proceso inovacijos padeda sumažinti gamybos ir pristatymo sąnaudas, pagerina produkto kokybę, pateikiant patobulintą produktą rinkai. Proceso inovacijoms įmonėse dažniausiai priskiriami tokie valdymo metodai: viskas laiku (angl. *just-in-time*), bendro kokybės valdymo (angl. *Total Quality Management*), Lean sistema, aprūpinimo grandinės valdymas, išteklių valdymas.

Pagrindinis proceso inovacijų aspektas yra dėmesys į įmonės atliekamus procesus. 2 lentelėje pateikiami bei labiau detalizuojami du tipiniai procesai pramonės įmonėse: veikla ir valdymas (Davenport, 2011).

2 lentelė. Veiklos ir valdymo procesai pramonės įmonėse

Veikla	Valdymas
• Produkto kūrimas. • Marketingas. • Kliento poreikių identifikavimas. • Gamyba. • Integruota logistika. • Užsakymų valdymas.	• Veiklos stebėjimas. • Informacijos valdymas. • Turto valdymas. • Žmogiškųjų išteklių valdymas. • Planavimas ir išteklių paskirstymas.

Šaltinis: sudarytas autoriaus remiantis Davenport (2011).

Lyginant su prieš tai aptarta produkto inovacija, tai proceso inovacija labiau susijusi ne su fiziniu objektu ir jo suinteresuotų šalių sąsajoms, o su metodu taikymu ir tobulinimu tam produktui gaminant. Tačiau šių sąvokų sankirtoje atsiranda svarbus priešingantis ryšis. Proceso inovacija didžiausius prioritetus išskiria efektyvumo didinimui ir išlaidų mažinimui, tačiau produktų inovacijos labiau susijusios su veiksmingumu, siekiant sukurti inovatyvius pasiūlymus, o ne efektyvumą, taip pat inovatyviems produktams reikia papildomų kaštų, kurių reikalauja inovatyvių procesų diegimas. Organizacijos, per daug susitelkusios į procesų inovacijas, gali apriboti produktų inovacijų galimybes.

3 lentelė. Tobulinimo ir inovacinio proceso skirtumai

	Tobulinimas procesas	Inovacinis procesas
Pokyčio lygis	Laipsniškas	Radikalus
Pradžios taškas	Egzistuojantis procesas	Nuo pamatų
Keitimo dažnis	Vienkartinis/daugkartinis	Vienkartinis
Laiko poreikis	Trumpas	Ilgas
Dalyvavimas	Iš apačios į viršų	Iš viršaus į apačią
Tipinė taikymo sritis	Siaura, per funkcijas	Plati, daugiafunkcinis
Rizika	Valdoma	Aukšta
Pagrindinė įgalinimo priemonė	Statistinė kontrolė	Informacinės technologijos
Keitimosi tipas	Kultūrinis	Kultūrinis/struktūrinis

Šaltinis: sudarytas autoriaus remiantis Davenport (2011).

Proceso inovacijas taip pat galima atskirti ir nuo proceso tobulinimo. Jei proceso inovacijos reiškia darbo veiklos atlikimą radikaliai - nauju būdu, procesų tobulinimas apima tą patį verslo procesą, tik ne radikaliai, o laipsniškai didinant efektyvumą. Gali būti, kad procesų inovacijos gali duoti tik laipsnišką naudą, tokiu atveju tai klasifikuosime kaip patobulinimą (Davenport, 2011). Proceso inovacijos ir patobulinimo atskyrimui Davenportas sudarė skirtumų

lentelė, kurioje jas išskaido pagal pokyčio lygius, pradžios tašką, keitimo dažnį, laiko poreikį, dalyvavimą, taikymo sritį, riziką, įgaliniimo priemonę ir keitimosi tipą (žr. 3 lentelė).

1.1.4. Inovatyvaus produkto kūrimas

Produkto kūrimo procesas atlieka esminį vaidmenį pateikiant į rinką inovatyvius produktus, užtikrinant, kad jie būtų suprojektuoti, gaminami ir kuriami taip, kad atitiktų vartotojų reikalavimus ir pageidavimus, laikantis gamybos apribojimų, susijusių su sąnaudomis, laiku ir kokybe. Šis sudėtingas, daugialypis procesas apima daugybę disciplinų, įskaitant inžineriją, dizainą, rinkodarą ir valdymą (Montagna, 2023). Inovatyvaus produkto kūrimo procesas vadovaujasi nauja produkto strategija, kuria siekiama suderinti įmonės pastangas su jos strateginiais imperatyvais (Hargadons, 2003). Šis derinimas garantuoja, kad planuojami nauji produktai palaikys strateginius įmonės tikslus ir geriausiai išnaudos strategines kompetencijas. (Nikolaos, 2004).

Remiantis Montagnos sudarytą mokymosi vadovu, apie naujų produktų kūrimo procesus, visą procesą galima žiūrėti iš matematinės perspektyvos: produkto savybės (F), tikslinės rinkos segmentas (M), kaina (C), laikas iki rinkos pasiekimo (T) ir kokybė (Q). Tikslas yra rasti optimalų šių kintamųjų derinį, kad būtų maksimaliai padidintas rinkos potencialas ir pelningumas:

$$\text{Produkto kūrimo procesas } (F, M, C, T, Q) \rightarrow \text{Inovatyvus produktas}$$

Tam, kad šį procesą būtų galima suprasti ne tik matematiškais išraiškomis, naudojami įvairūs inovatyvaus produkto kūrimo proceso modeliai. Vienas iš labiausiai paplitusių pasaulyje modelių, užtikrinančių idėjos paleidimo sistemą, yra žinomas kaip „Stage-Gate“. Ši sistema atnešė sėkmę daugeliui įmonių visame pasaulyje. Ją naudoja tokios įmonės kaip „Procter & Gamble“, „Lego“, „ITT Industries“, ABB, „Emerson Electric“ ir daugelis kitų. „Amerikos produktyvumo ir kokybės asociacijos“ atlikti tyrimai rodo, kad daugiau nei 70 % savo pramonės srityse pirmaujančių įmonių naujų produktų kūrimui taiko būtent „Stage-Gate“ sistemą.

„Stage-Gate“ procesas yra koncepcinis veiklos planas, skirtas inovatyvių produktų projektams perkelti nuo idėjos iki galutinio produkto (Cooper, 2008). Pagrindinis „Stage-Gate“ principas susideda iš dviejų dalių (lentelė 4): inovacijų procesų suskirstymas į etapus (angl. *stages*) ir juos skiriantys vartai (angl. *gates*). Kiekviename etape įmonė turi atlikti suplanuotus veiksmus, o pasiekus vartus įmonė nusprendžia, ar praleisti projektą toliau, grąžinti tobulinimui, ar jo apskritai atsisakyti.


4 lentelė. „Stage-Gate“ modelio etapų ir vartų apibūdinimas

Etapai (stages)	„Vartai“ (gates)
• Kiekvienas etapas skirtas rinkti informaciją, siekiant sumažinti pagrindinio projekto neapibrėžtumą ir riziką; • Kiekvienas etapas kainuoja daugiau nei prieš tai buvęs. Tačiau su kiekvienu etapu, didėjant projekto sąnaudoms, neapibrėžtumas mažinamas taip, kad rizika būtų efektyviai valdoma.	• <i>Įeiga:</i> ką projekto vadovas ir komanda pateikia sprendimo etape (pvz., atliktų veiklų rezultatai). Šie rezultatai yra matomi, yra pagrįsti standartiniu kiekvieno vartų etapu ir sprendžiami ankstesnių vartų išvestyje. • <i>Kriterijai, pagal kuriuos vertinamas projektas:</i> Tai apima atitikties kriterijus arba atmetamuosius klausimus (kontrolinis sąrašas), skirtus greitai panaikinti netinkamus projektus. Taip pat turi atitikti kriterijus, kurie yra vertinami pagal taškų skaičiavimo sistema. <i>Rezultatai:</i> sprendimas (eiti toliau/atsakyti/susilaikyti/patobulinti) kartu su patvirtintu kito etapo veiksmų planu, darbo sąrašu ir data. • <i>Rezultatai:</i> sprendimas (eiti toliau / atsakyti / susilaikyti / patobulinti) kartu su patvirtintu kito etapo veiksmų planu, darbo sąrašu ir data.

Šaltinis: sudaryta autoriaus remiantas Cooper (2008).

„Stage-Gate“ metodas dažniausiai vykdomas tokia tvarka:

- 1) *Idėjų generavimas.* Išankstinis darbas, skirtas atrasti ir atskleisti verslo galimybes. Generuoti naujas idėjas.
- 2) *1 etapas. Apimties nustatymas.* Greitas, pigus, išankstinis projekto tyrimas ir apimties nustatymas.
- 3) *2 etapas. Verslo strategija.* Išsamus tyrimas, apimantis pirminius tyrimus (kliento, rinkos ir techninius), kurių rezultatas – verslo strategija, apimantis produkto ir projekto apibrėžimą, pagrindimą ir siūlomą plėtros planą.
- 4) *3 etapas. Kūrimas.* Detalus naujo produkto projektavimas ir kūrimas bei operacijų arba gamybos proceso, reikalingo masinei gamybai, planavimas.
- 5) *4 etapas. Testavimas.* Bandymai gamykloje ir rinkoje, siekiant patikrinti ir patvirtinti siūlomą naują produktą, jo gamybos ar veiklos planus.
- 6) *5 etapas. Paleidimas.* Komercializacija: plataus masto gamybos, rinkodaros ir pardavimo pradžia.



3 pav. „Stage-Gate“ modelis naujų produktų kūrime


Šaltinis: sudaryta autoriaus remiantis Cooper (2008).

Tačiau Kotleris ir Armstrongas, knygoje apie marketingo svarbą, mano, kad tam, kad bet kuri įmonė galėtų kurti inovatyvius produktus, ji turi suprasti savo vartotojus, rinkas ir teikti klientams kuo didesnę pridėtinę vertę (Kotler, 2010). Šiems veiksmai atlikti būtinas laipsniškas, išsamus planas. Anot jų, aštuoni pagrindiniai naujo produkto kūrimo etapai: idėjų generavimas, idėjų atranka, koncepcijos kūrimas ir testavimas, rinkodaros strategijos kūrimas, verslo analizė, produktų kūrimas, bandomoji rinkodara ir komercializacija:

- 1) *Idėjų generavimas*. Tai sisteminga inovatyvių produktų idėjų paieška. Įmonė paprastai turi generuoti daug idėjų, kad rastų keletą gerų ir naudingų. Produkto idėjos gali būti generuojamos iš vidaus (mokslinių tyrimų ir plėtros pastangos, vadovai, mokslininkai, inžinieriai, gamybos darbuotojai, pardavėjai) arba iš išorės (klientai, konkurentai, platintojai ir tiekėjai). Idėjų generavimas individualiu ar komandos lygiu išsilyka kaip esminė kūrybiškumo ir, atitinkamai, inovacijų proceso sudedamoji dalis. Idėjos kūrimo etapas (kūrybiškumas) paprastai kainuoja daug pigiau nei vėlesni naujo produkto kūrimo proceso kūrimo etapai. Todėl prasminga maksimaliai padidinti savo produkciją pateikiant daugybę idėjų, kurias organizacija galėtų toliau panaudoti. Kuo daugiau idėjų bus naujo produkto kūrimo proceso pradžioje, tuo didesnė tikimybė, kad gaminys bus sėkmingas.
- 2) *Idėjų atranka*. Tai inovatyvaus produkto sugeneruotų idėjų įvertinimas. Naujų idėjų patikrinimo pagrindinis tikslas – atrinkti geras idėjas nuo prastų. Šiame etape priimamos tik produktų idėjos, kurios potencialiai gali atnešti įmonei pelno.
- 3) *Koncepcijos kūrimas ir testavimas*. Produkto idėja suformuluojama žodine arba vaizdine forma, toliau paaiškinant koncepcijos pobūdį, pateikiant pradines idėjas apie galimus iššūkius, medžiagas ir technologijas. Be to, koncepcijos testavimo metu naujos

produktų koncepcijos išbandomos su tikslinių vartotojų grupe, siekiant išsiaiškinti, ar koncepcijos turi didelį patrauklumą vartotojui.

- 4) *Marketingo strategijos kūrimas*. Tai apima pradinės naujo produkto rinkodaros strategijos sukūrimą, pagrįstą produkto koncepcija. Marketingo strategijos teiginiai susideda iš trijų dalių: tikslinės rinkos aprašymas, planuojamas produkto pozicionavimas ir pardavimų (rinkos dalies ir pelno tikslai pirmaisiais keleriais metais).
- 5) *Verslo analizė*. Tai apima naujo produkto pardavimų, sąnaudų ir pelno prognozių peržiūrą, siekiant išsiaiškinti, ar šie veiksniai atitinka įmonės tikslus. Be to, šiame etape nagrinėjamas sprendimas išsiaiškinti produkto technines galimybes, produktų rinkos potencialą ir produktų galimas investicijas (Nikolaos, 2004).
- 6) *Produkto kūrimas*. Šiame etape produkto koncepcija paverčiama į prototipą, siekiant užtikrinti, kad produkto idėja gali būti įgyvendinama.
- 7) *Bandomoji rinkodara*. Tai inovatyvaus produkto kūrimo etapas, kurio metu produkto prototipas ir rinkodaros programa išbandomi tikroviškesnėmis rinkos sąlygomis.
- 8) *Komercializacija*. Šis etapas apima naujo produkto įvedimą į rinką naudojant pasirinktą rinkodaros reklaminę priemonę.



4 pav. Montagnos struktūrinė diagrama

Šaltinis: sudarytas autoriaus remiantis Montagno (2023).

Kitas naudingas įrankis yra grafiniai vaizdai, kuriuos galima naudoti iliustruojant ryšius ir priklausomybes tarp įvairių kūrimo proceso etapų ir veiklų. Vienas iš grafinio vaizdavimo principų yra struktūrinės diagramos (angl. Flowcharts) arba procesų žemėlapiai, kuriuos galima panaudoti vizualizuojant įvykių seką ir sprendimo taškus, siekiant nustatyti galimas kliūtis, perteklius ar neefektyvumą. Vienas iš pavyzdžių, Montagnos pateikta struktūrinė diagrama, kurioje detalai nurodomas inovatyvaus produkto kūrimo procesas (4 pav.).

1.2. Dirbtinis intelektas

1.2.1. Dirbtinio intelekto samprata


Apibrėžti dirbtinį intelektą nėra lengva, nes dėl sąvokų gausybės ir sudėtingos sistemos nėra vieno bendro visuotinio priimto sąvokos apibrėžimo (Russell, 2020). Plačiąja prasme DI apibrėžimas prilyginamas algoritmams. Tačiau tai nėra labai tikslus apibūdinimas. Algoritmai buvo sukurti anksčiau nei dirbtinis intelektas ir buvo plačiai naudojami kitose srityse. Terminas algoritmas yra kilęs iš IX a. persų matematiko vardo, o jo pagrindinis tikslas nurodyti konkrečią instrukciją, kaip išspręsti problemą arba atlikti skaičiavimą (Sheikh, 2023).

Dirbtinis intelektas kaip akademinė sritis atsirado šeštajame dešimtmetyje. Terminas DI pirmą kartą buvo įvestas per daugiadisciplininę programą, pristatytą Dartmute 1956 m (Benbya, 2020). Programa siekė ištirti galimybę, kad mašinų intelektas gali imituoti žmones, ir įtraukė įvairių sričių mokslininkus: matematikus ir filosofus. DI yra terminas, reiškiantis kompiuterines sistemas, kurios gali suvokti savo aplinką, mąstyti, mokytis ir išspręsti problemas, siekiant konkretaus tikslo (PwC, 2018). Ekonominio bendradarbiavimo ir plėtros organizacijos (2019 m.) teigimu, dirbtinio intelekto sistema apibrėžiama kaip mašininė sistema, kuri, siekdama tam tikro žmogaus nustatytų tikslų, gali pateikti prognozes, rekomendacijas ar sprendimus. Europos Parlamentas papildydamas teigia, kad dirbtinis intelektas „yra mašinos gebėjimas, kuris yra panašus į žmonių galimybes, tokias kaip argumentavimas, mokymasis, planavimas ir kūrybiškumas“. Kompiuterinė sistema priima duomenis (vaizdo kamera, jutikliai), juos apdoroja ir reaguoja. Nagrinėdamos ankstesnių veiksmų poveikį ir dirbdamos autonomiškai DI sistemos gali tam tikru laipsniu pritaikyti savo elgesį (Europos Parlamentas, 2020).

Nepaisant ankstyvų vilčių apie praktinį DI pritaikymą, septintajame ir aštuntajame dešimtmečiuose jis iš esmės nepasiteisino ir susidūrė su keliomis kliūtimis. Didžiausias iš jų buvo - skaičiavimo galios stoka. Mokslinių tyrimų finansavimas pamažu sustojo ir prarado pagreitį. Devintajame ir dešimtajame dešimtmečiuose vyriausybės ir įmonės daug investavo į ekspertinių sistemų tyrimus, o tai atgaivino susidomėjimą dirbtiniu intelektu (Benbya, 2020).

1.2.2. Dirbtinio intelekto tipai ir technologijos

DI apibendrintai gali būti apibūdinamas kaip intelekto operacijos, kurias atlieka tam tikros mašinos, sukurtos siekiant atkurti žmogaus smegenų galimybes per algoritmų derinius. Mokslinėje literatūroje yra išskiriama keletas DI tipų, vienas iš skirstymo pavyzdžių Hinda Benbya, kuris susideda iš trijų tipų: pagal intelektą, pagal į DI sistemą įterptos technologijos tipą ir pagal DI atliekamą funkciją (5 pav.).



5 pav. Dirbtinio intelekto klasifikavimas


Šaltinis: sudarytas autoriaus remiantis Benbya (2020).

Paremtas intelektu. Filosofiniuose debatuose apie dirbtinį intelektą daugiausia dėmesio skiriama protingų mašinų sąvokai, t. y. mašinos, kurios gali mokytis, prisitaikyti ir mąstyti kaip žmonės (Lake, 2016). Tokia samprata pagrįsti dirbtinio intelekto tipai patenka į tris kategorijas: dirbtinis siaurasis intelektas, dirbtinis bendrasis intelektas ir dirbtinis superintelektas (6 pav.).

- *Dirbtinis siaurasis intelektas (angl. Artificial Narrow Intelligence).* Ray Kurzweilas vartojo terminą „siaurasis dirbtinis intelektas“, kuris reiškia sistemų, atliekančių konkrečius „protingus“ veiksmus konkrečiomis aplinkybėmis, kūrimą (Kurzweil, 2005). Jei siauro dirbtinio intelekto sistema nors truputį pakeičia kontekstą ar elgesio specifikaciją, paprastai reikia tam tikro lygio žmogiškojo perprogramavimo ar

perkonfigūravimo, kad sistema išlaikytų savo intelekto lygį. Nors tokios sistemos gali atrodyti sudėtingos ir protingos, jos veikia pagal iš anksto nustatytus ir apibrėžtus parametrus, apribojimus ir kontekstus (Kanade, 2022). Jos leido „Facebook“ atpažinti veidus paveikslėliuose ir žymėti naudotojus, taip pat leido „Siri“ suprasti žmonių ir atitinkamai elgtis, o „Tesla“ - kurti savaeigius automobilius (Kaplan ir Haenlein, 2019). Visus šiandien įmanomus sprendimus galima priskirti siaurajam dirbtiniam intelektui (Buxmann ir Schmidt 2019).

- *Dirbtinis bendras intelektas (angl. Artificial General Intelligence)*. Bendrasis dirbtinis intelektas siekia žmogaus lygio įgūdžių rinkinio. Priešingai nei siaurasis intelektas, bendrai protinga sistema turėtų gebėti spręsti visai kitokias problemas ir spręsti kitokias situacijas, nei numatė jos kūrėjai (Goertzel, 2014). Iš pradžių dirbtinis bendrasis intelektas buvo pagrindinis dirbtinio intelekto srities objektas, tačiau dėl įrodyto problemos sudėtingumo juo tiesiogiai užsiima nedaug dirbtinio intelekto tyrėjų. Darbas su bendruoju intelektualu įgijo šiek tiek blogą reputaciją, tarsi skaitmeninio bendrojo intelekto kūrimas būtų analogiškas amžinojo variklio kūrimui. Tačiau, nors pastarasis fizikiniai dėsniai tvirtai rodo, kad jis neįmanomas, remiantis visais žinomais mokslo duomenimis, yra visiškai įmanomas.
- *Dirbtinis superintelektas (angl. Artificial Super Intelligence)*. Dirbtinis superintelektas - hipotetinė programine įranga pagrįsta dirbtinio intelekto sistema, kurios intelektinė apimtis pranoksta žmogaus intelektą. Pasak 2023 m. IBM tyrimu, pačiu fundamentaliausiu lygmeniu šis superintelektualusis dirbtinis intelektas pasižymi pažangiausiomis kognityvinėmis funkcijomis ir labai išvystytais mąstymo įgūdžiais, pažangesniais nei bet kurio žmogaus. Tokio tipo superintelektas gali atsirasti po evoliucijos ir sudėtingų adaptyvių sistemų principais (Engert, Hess, 2023). Argumentas teigia, kad jei žmonės galėtų sukurti dirbtinį intelektą maždaug žmogaus lygiu, tai šis intelektas savo ruožtu galėtų sukurti dar aukštesnį intelektą ir galiausiai evoliucionuoti toliau (BibBase, 2014). Nors futuristinėje literatūroje daroma prielaida, kad dirbtinis intelektas sistemos galės atlikti visas užduotis taip pat gerai kaip žmonės ar net geriau už juos, tokio tipo dirbtinis bendrasis intelektas dar neegzistuoja.




6 pav. DI klasifikavimas paremtas intelektu

Šaltinis: sudarytas autoriaus remiantis Benbya (2020).

Paremtas technologijomis. Pagal antrąją tipologiją Benbya išskiria dirbtinio intelekto sistemose įdiegtas technologijas, kurios apima mašininių mokymąsi, natūralios kalbos apdorojimą, robotus, įvairias automatizavimo technologijas ir taisyklėmis grindžiamas ekspertines sistemas. Vienos Deloitte neseniai atliktos apklausos duomenimis, visos šiuolaikinės dirbtinio intelekto technologijos šiuo metu naudojamos arba bus naudojamos per metus 95 % ar daugiau didelių dirbtinio intelekto diegėjų (Fulkerson, 1995).

- *Mašininis mokymasis (angl. Machine learning).* Pasak Michie, mašininis mokymasis paprastai apima loginėmis arba dvejetainėmis operacijomis pagrįstas automatinio skaičiavimo procedūras, kurios iš serijos pavyzdžių išmoka užduotį (Michie, 1994). Sudėtingesnę apibrėžimą pateikia Tomas Mitchellas, teigdamas, kad kompiuterio programa mokosi iš patirties *E (angl. experience)*, tam tikros užduočių klasės *T (angl. task)* ir našumo rodiklio *P (angl. performance measure)* atžvilgiu, jei jos našumas *T* užduotyje, matuojamas *P*, gerėja su patirtimi *E* (Mitchell, 1997). Mašininio mokymosi tikslas sukurti pakankamai paprastas klasifikavimo išraiškas, kad jas lengvai suprastų žmonės. Jie turi pakankamai imituoti žmogaus samprotavimus, kad būtų galima suprasti sprendimo priėmimo procesą. Paprastai mašininis mokymasis skaidomas į keturias atskiras kategorijas: pusiau prižiūrimas mokymas, prižiūrimas mokymasis, neprižiūrimas mokymasis ir sustiprintas mokymasis (7 pav.).




7 pav. Mašininio mokymosi tipai

Šaltinis: sudarytas autoriaus remiantis Saker (2021).

- *Neprižiūrimas mokymasis (angl. Unsupervised learning).* Neprižiūrimas mokymasis analizuoja nepažymėtus duomenų rinkinius be žmogaus įsikišimo, t. y. tai yra duomenų valdomas procesas (Data Mining: Concepts and Techniques, 2011). Tai plačiai naudojama generatyviniams požymiams išgauti, reikšmingoms tendencijoms ir struktūroms, rezultatų grupavimui ir tiriamiesiems tikslams nustatyti. Dažniausiai pasitaikantys nekontroliuojamo mokymosi uždaviniai yra klasterizavimas, tankio įvertinimas, požymių mokymasis, matmenų mažinimas, asociacijų taisyklių paieška, neatitikimų aptikimas ir kt. (Sarker, 2021).
- *Prižiūrimas mokymasis (angl. Supervised learning).* Prižiūrimas mokymasis - tai mašininio mokymosi metodas, skirtas funkcijai mokytis iš mokymo duomenų. Mokymo duomenis sudaro įvesties objektų (paprastai vektorių) ir pageidaujamų rezultatų poros. Funkcijos išvestis gali būti nepertraukiama reikšmė (vadinama regresija) arba gali numatyti įvesties objekto klasės etiketę (vadinama klasifikacija). Prižiūrimo besimokančiojo uždutis yra nuspėti funkcijos reikšmę bet kokiam galiojančiam įvesties objektui po to, kai jis matė tam tikrą skaičių mokymo pavyzdžių. Funkcijai išvesti naudojami paženklinėti mokymo duomenys ir mokymo pavyzdžių rinkinys. Prižiūrimasis mokymasis atliekamas, kai nustatomi tam tikri tikslai, kuriuos reikia pasiekti iš tam tikro įvesties rinkinio, t. y. taikomas į uždutį orientuotas metodas (Sarker, 2020). Dažniausiai pasitaikančios prižiūrimos uždutys yra „klasifikavimas“, kuris atskiria duomenis, ir „regresija“, kuri atitinka duomenis.

- *Pusiau prižiūrimas mokymasis (angl. Reinforcement learning)*. Pusiau prižiūrimas mokymasis gali būti apibrėžiamas kaip minėtų prižiūrimų ir neprižiūrimų metodų hibridas, nes jis veikia ir su pažymėtais, ir su nepažymėtais duomenimis (Sarker et al., 2020). Galutinis pusiau prižiūrimo mokymosi modelio tikslas - užtikrinti geresnį prognozavimo rezultatą nei tas, kuris gaunamas naudojant tik paženklintus modelio duomenis. Kai kurios taikymo sritys, kuriose naudojamas pusiau kontroliuojamas mokymasis, yra mašininis vertimas, sukčiavimo aptikimas, žymėtų duomenų ir teksto klasifikavimas.
- *Sustiprintas mokymasis (angl. Reinforcement)*. Tai mašininio mokymosi algoritmas, kuris leidžia programiniams agentams automatiškai įvertinti optimalų elgesį tam tikrame kontekste ar aplinkoje, siekiant pagerinti jų efektyvumą, t. y. į aplinką orientuotas metodus (Kaelbling, 1996). Šio tipo mokymasis grindžiamas atlygiu arba nuobauda, o jo galutinis tikslas - pasinaudoti iš aplinkos aktyvistų gautomis įžvalgomis ir imtis veiksmų atlygiui padidinti arba rizikai sumažinti (Mohammed, 2016). Tai galinga priemonė, skirta dirbtinio intelekto modeliams mokyti, galinti padėti padidinti automatizavimą arba optimizuoti sudėtingų sistemų, pavyzdžiui, robotikos, autonominio vairavimo užduočių, gamybos ir tiekimo grandinės logistikos, veiklos efektyvumą (Sarker, 2021).
- *Gilusis mokymasis (angl. Deep learning)*. Gilusis mokymasis - tai mašininio mokymosi pakraipa, kurioje bandoma išmokyti aukšto lygio duomenų abstrakcijų naudojant hierarchines architektūras. Tai naujas metodas, kuris plačiai taikomas tradicinėse dirbtinio intelekto srityse, tokiose kaip semantinė analizė, perkėlimo mokymasis, natūralios kalbos apdorojimas, kompiuterinė vizija ir daugelyje kitų (Guo, 2016). Giliojo mokymosi architektūra pateikiama 8 paveiksle. Tokia architektūra taikoma įvairiose srityse ir gali padėti spręsti daugelį problemų:



8 pav. Giliojo mokymosi architektūra

Šaltinis: sudarytas autoriaus remiantis Guo (2016).

- *Neuroniniai tinklai (angl. Neural Networks)*. Dirbtinis neuroninis tinklas - tai mašininio mokymosi algoritmas, sukurtas remiantis biologiniais neuroniniais tinklais. Kiekvieną neuroninį tinklą sudaro mazgai (analogiški ląstelių kūnams), kurie susisiečia su kitais mazgais jungtimis (analogiškais aksonams ir dendritams). Panašiai kaip sinapsės tarp neuronų stiprėja, kai jų neuronų išėjimai biologiniame neuronų tinkle yra susiję, taip ir dirbtinio neuronų mazgų jungtys vertinamos pagal jų gebėjimą užtikrinti norimą rezultatą (Choi, 2020).
- *Natūralios kalbos apdorojimas (angl. Natural Language Processing)*. Tai kompiuterinės sistemos, kurios analizuoja, bando suprasti ar sukurti vieną ar daugiau žmonių kalbų. Įvestis gali būti tekstas, šnekamoji kalba arba klaviatūros įvestis. Užduotis gali būti vertimas į kitą kalbą, teksto turinio supratimas ir atvaizdavimas, duomenų bazės kūrimas ar santraukų generavimas arba dialogo su naudotoju palaikymas kaip duomenų bazės ir (arba) informacijos paieškos sąsajos dalis (Ralston, 2003). Natūralios kalbos apdorojimo taikymai apima daugybę tyrimų sričių, pavyzdžiui, mašininį vertimą, natūralios kalbos tekstų apdorojimą ir apibendrinimą, naudotojų sąsajas, daugiakalbės informacijos paiešką, kalbos atpažinimą, dirbtinį intelektą ir ekspertines sistemas ir kt. (Chowdhury, 2003).
- *Taisyklėmis pagrįsta ekspertų sistema (angl. Rule-based expert systems)*. Taisyklėmis pagrįsta dirbtinio intelekto sistema pasirinkimus ar išvadas grindžia nustatytomis taisyklėmis. Šie dėsniai dažnai išreiškiami žmogui suprantama kalba, pavyzdžiui, „jei X yra tiesa, tai ir Y yra tiesa“, kad skaitytojams būtų lengviau juos suprasti (Shah, 2023). Literatūroje ekspertų sistemos dažniausiai suprantamos vienu iš dviejų būdų: kaip samprotavimo linija arba kaip problemų sprendimo veikla. Ekspertų sistemos

dažniausiai naudojamos ten, kur reikalingas žmogaus, kaip eksperto, gebėjimas priimti sprendimus.

- *Robotų procesų automatizavimas (angl. Robotic process automation)*. Robotų procesų automatizavimas yra paslaugų užduočių automatizavimas, atkuriantis žmonių atliekamą darbą (Van Der Aalst, 2018). Automatizavimas atliekamas naudojant programinės įrangos robotus arba DI, kurie gali tiksliai atlikti pasikartojančias užduotis. Užduočių instrukcijas nustato kūrėjas, naudodamas tam tikrą ekrano įrašymo formą ir apibrėždamas kintamuosius. Šios užduotys apima tokius veiksmus kaip prisijungimas prie programų, duomenų kopijavimas ir įklijavimas, el. laiškų atidarymas, formų pildymas ir kt. Sėkmingai įdiegusios RPA ir efektyvius verslo procesus organizacijos patyrė teigiamą poveikį jų strateginiams tikslams, darbuotojų produktyvumui ir klientų aptarnavimui (Lacity, 2015). RPA ypač domina pramonės šakas, kurios tradiciškai greitai įsisavino naujas technologijas, ypač procesus informuojančios informacinės sistemos (pvz., bankininkystė, draudimas).
- *Robotai (angl. Robots)*. Dirbtinio intelekto valdomi robotai papildyti įvairiais jutikliais (įskaitant regėjimo įrenginius, tokius kaip 2D/3D kameros, vibracijos jutikliai, artumo jutikliai, akcelerometrai ir kiti aplinkos jutikliai) gali analizuoti ir perteikti gautą informaciją gamybos procesuose. Gamyboje dirbtinio intelekto robotai naudojami gamybos linijų automatizavimui, gaminių surinkimui, kokybės kontrolei ir logistikai (Robotnik, 2023).

Dirbtinio intelekto klasifikavimą paremta technologijomis galima apibendrinti ir pateikti pagrindinius apibūdinimus bei pavyzdžius (žr. 5 lentelė).

5 lentelė. DI klasifikavimas paremtas technologijomis

Technologija	Glaustas apibūdinimas	Pritaikymo pavyzdys
Mašininis mokymasis: • Prižiūrimas mokymasis; • Neprižiūrimas mokymasis; • Pusiau prižiūrimas mokymasis; • Sustiprintas mokymasis	Moko iš patirties Mokosi iš treniruočių duomenų rinkinio Aptinka duomenų, kurie nėra pažymėti ir kurių rezultatas nežinomas, modelius	Labai detali didelių duomenų rinkodaros analizė
Gilusis mokymasis	Mašininio mokymosi klasė, kuri mokosi be žmogaus priežiūros, remdamasi duomenimis, kurie yra pažymėti arba nepaženklinti.	Vaizdų ir balso atpažinimo sistemos, automatinio valdymo automobiliai
Neuroniniai tinklai	Algoritmai, kuriais siekiama atpažinti pagrindinius ryšius duomenų rinkinyje, naudojant procesą, kuris imituoja žmogaus smegenų veiklą.	Kredito ir paskolos paraiškų vertinimas, orų prognozavimas

Natūralus kalbos apdorojimas	Kompiuterinė programa, galinti suprasti žmonių kalbą, kaip ji rašoma ar kalbama	Kalbos atpažinimas, teksto analizė, vertimas, generavimas
Taisyklėmis pagrįsta ekspertų sistema	Loginių taisyklių rinkinys paremtas iš žmonių ekspertų	Draudimo pasirašymas, kredito patvirtinimas
Robotų procesų automatizavimas	Sistemos, automatizuojančios struktūrizuotas skaitmenines užduotis ir sąsajas	Prisijungimas prie programų, duomenų kopijavimas ir įklijavimas, el. laiškų atidarymas, formų pildymas
Robotai	Automatiškai valdomos mašinos, kurios automatizuoja fizinę veiklą, manipuliuoja ir paima daiktus	Gamyklos ir sandėlio užduotys

Šaltinis: sudarytas autoriaus.

Paremta funkcija. Šis klasifikavimas išskiria keturis DI tipus: pokalbio, biometrinio, algoritminio ir robotinio.

- *Pokalbio DI (angl. Conversational AI).* reiškia bendrą gebėjimą kompiuterių suprasti ir reaguoti su natūralia žmogaus kalba. Tokios sistemos apima balso ir tekstinėmis technologijomis grindžiamas technologijas ir iš esmės skiriasi dėl jų pajėgumo ir įsikūrimo lygio. Paprastos DI pokalbio sistemos yra daugiausia naudojamas spręsti pasikartojančius klientų užklausas, tuo tarpu protingos pokalbių sistemos, pasitelkiant mašininį mokymą ir natūralių kalbų apdorojimą, gali imtis sudėtingesnių užduočių, kurios apima daugiau sąveikos, motyvavimo, prognozavimo, ir tikslumo (Benbya, 2020).
- *Biometrinis dirbtinis intelektas (angl. Biometric AI).* Biometrija remiasi metodais, kuriais matuojamas asmens fiziologinis (pirštų atspaudai, rankos geometrija, tinklainės, rainelė, veido vaizdas) arba elgsenos bruožai (parašas, balsas, klavišų paspaudimo ritmai). Dirbtinio intelekto pagrįsti biometriniai duomenys naudoja tokias programas kaip veido atpažinimas, kalbos atpažinimas ir kompiuterinė vizija, kad būtų galima nustatyti, autentifikuoti ir saugos tikslus kompiuterių įrenginiuose, darbo vietoje, namų saugoje ir kt.
- *Algoritminis dirbtinis intelektas (angl. Algorithmic AI).* Ši sritis siejama su mašininio mokymosi algoritmų naudojimu. Kai kurie mašininio mokymosi algoritmai gali būti mokomi remiantis struktūriniais duomenimis ir yra būdingi siauroms užduočių sritims, pvz., kalbos atpažinimui ir vaizdų klasifikavimui. Kiti algoritmai, ypač gilaus mokymosi neuroniniai tinklai, gali mokytis iš didelio kiekio žymėtų duomenų, tobulėti mokydami ir atlikti įvairias užduotis, tokias kaip klasifikavimas, numatymas ir atpažinimas.

- *Robotinis dirbtinis intelektas (angl. Robotic AI)*. Pastaruoju metu dirbtinis intelektas, įskaitant mašininį mokymąsi ir neuroninius tinklus, vis dažniau naudojamas robotų sprendimuose, leidžiančius robotams pereiti nuo automatizavimo ir spręsti sudėtingesnes bei aukšto lygio užduotis. DI palaikantys robotai turi galimybę jausti savo aplinką, suprasti, veikti ir mokytis. Tai padeda robotams atlikti daugybę užduočių, pradedant sėkmingai naršyti aplinką, identifikuoti aplink robotą esančius objektus ar padėti žmonėms atlikti įvairias užduotis, pavyzdžiui, operacijas su robotais.

1.2.3. Dirbtinio intelekto taikymas praktikoje

Dirbtinio intelekto naudojimas sistemingai didėja, o DI taikomosios programos atsiranda įvairiose srityse. DI pritaikymą palengvino perėjimas prie debesų kompiuterijos (angl. *Cloud computing*) ir didėjantis „*plug-and-play*“ (sistema leidžianti kitiems įrenginiams tiesiogiai prisijungti prie kitų įrenginių ir supaprastinti tinklo įdiegimą namuose) DI paslaugų prieinamumas bei augantis dirbtiniu intelektu grindžiamos programinės įrangos tiekėjų skaičius (MMC, 2019). Didėjantį dirbtinio intelekto pritaikymo svarbą galima vertinti ir tai, kad sparčiai auga naujų su DI susijusių patentų skaičius, o per pastarąjį dešimtmetį paskelbtų DI patentų paraiškų skaičius išaugo 400 % (Office, 2019). Pagal Patentinių bendradarbiavimo sutartį 1960–2018 m. JAV buvo pateikti 1 863, Kinijoje 1 085 ir ES 1 074 dokumentai, o JAV įmonės pirmavo teikiant patentus 12 iš 20 DI taikymo sričių, pvz. švietimas, kartografija, verslas ir žemės ūkis (Castro, 2021).

Dirbtinio intelekto ir mašininio mokymosi programinės įrangos bei platesnių pramonės 4.0 industrijos technologijų, pvz., automatizavimo programinės įrangos, sąnaudos laikui bėgant tapo pagrįstesnės, todėl tai galėtų paskatinti mažos ir vidutinės įmonės (MVĮ) naudoti dirbtinio intelekto technologijas, kurios anksčiau daugiausia buvo prieinamos didelėms įmonėms. Be to, MVĮ dabar gali gauti naudos iš pigesnių dirbtinio intelekto sprendimų, kurie yra pagrįsti debesimis ir kuriuos teikia vis daugiau paslaugų, todėl dirbtinis intelektas tampa prieinamesnis, o MVĮ gali gauti tam tikros naudos, kurią, iki šiol daugiausia mėgavosi didesnėmis organizacijoms.

Mokslininkai skirtingai išskiria DI pritaikymo sritis, pavyzdžiui, Rao ir Vereij išskiria aštuonias sferas, kuriose DI naudojamas plačiausiai ir atneša didžiausią vertę – tai sveikatos apsauga, automobilių pramonė, finansų sektorius, transportas ir logistika, technologijos ir komunikacija, mažmeninė prekyba, energetika ir gamyba (Rao & Verweij, 2017). H. Sarker išskiria dar platesnes DI panaudojimo sritis: medicina, agrokultūra, kompiuterinė vizija, daiktų internetas, edukacija, verslas ir finansai, socialinė medija, virtualioji realybė, robotika ir

automatizavimas, autonominės transporto priemonės, žaidimai, internetas, kelionės, kibernetinis saugumas, natūralios kalbos apdorojimas, priežiūra (Sarker, 2022).

Pasaulyje McKinsey apklausoje buvo apklausiami 2360 organizacijų atstovai (McKinsey Analytics, 2019). Apklausoje nustatyta, kuriose srityse ir kokios dirbtinio intelekto technologijos yra naudojamos. Rezultatai pateikiami 6 lentelėje.

6 lentelė. DI taikymas pagal industrijas

Industrija	Robotikos procesų automatizavimas	Kompiuterinis matymas	Mašininis mokymasis	Natūralios kalbos apdorojimas	Virtualūs agentai	Fiziniai robotai	Natūralios kalbos supratimas	Natūralios kalbos generavimas	Autonominės transporto priemonės
Aukštosios technologijos	35 %	33 %	54 %	38 %	35 %	9 %	24 %	22 %	4 %
Automobilių surinkimas	46 %	42 %	31 %	28 %	17 %	44 %	19 %	18 %	25 %
Telekomunikacijos	30 %	36 %	45 %	38 %	45 %	20 %	23 %	26 %	3 %
Transportavimas, kelionės, logistika	33 %	26 %	19 %	24 %	29 %	10 %	12 %	12 %	7 %
Finansinis aptarnavimas	36 %	24%	25 %	28 %	32 %	7 %	19 %	16 %	6 %
Mažmeninė prekyba	21 %	24 %	23 %	24 %	27 %	25 %	18 %	16 %	9%
Prekių pakavimas	17 %	14 %	12 %	13 %	11 %	47 %	7 %	7 %	15 %
Elektros energija ir gamtinės dujos	26 %	31 %	30 %	9 %	22 %	22 %	8 %	6 %	4 %
Medicinos sistemos	23 %	32 %	23 %	30 %	20 %	14 %	22 %	16 %	4 %
Farmacija ir medicinos produktai	21 %	19 %	15 %	10 %	6 %	31 %	7 %	8 %	5 %
Infrastruktūra	20 %	17 %	15 %	10 %	4 %	14 %	5 %	5 %	2 %
Profesionalios paslaugos	17 %	20 %	22 %	22 %	17 %	7 %	12 %	13%	6 %

Šaltinis: sudarytas autoriaus remiantis McKinsey Analytics (2019).

Iš 6 lentelės galima daryti išvadą, kad konkrečių dirbtinio intelekto technologijų diegimas skiriasi priklausomai nuo pramonės šakos. Pavyzdžiui, labiau tikėtina, kad automobilių pramonėje diegiamas dirbtinio intelekto technologijas sudaro fizinės robotikos taikomosios programos. Tuo tarpu telekomunikacijų atveju labiau tikėtina, kad naudojamos taikomosios programos yra virtualūs agentai, skirti bendravimui su klientais. Apskritai iš

lentelėje pateiktų duomenų matyti, kad autonominės transporto priemonės ir natūralios kalbos generavimas ir (arba) kalbos supratimas yra mažiausiai paplitusios pritaikytos dirbtinio intelekto formos.

Toje pačioje apklausoje nustatyta, kad 58 % respondentų nurodė 2019 m. įdiegę bent vieną iš šių AI taikomųjų programų, palyginti su 47 % ankstesniais metais, o tai dar labiau rodo AI augimą pramonėje. Be to, vis dažniau matyti, kad įmonės naudoja daugiau nei vieną AI technologiją; organizacijų, taikančių dvi ar daugiau technologijų, skaičius išaugo nuo 21 % 2018 m. apklausoje iki 30 % 2019 m. apklausoje.

2. DIRBTINIO INTELEKTO TAIKymo METODOLOGINIAI ASPEKTAI

2.1. Dirbtinio intelekto sąsaja su inovatyviu produktu

2.1.1. Dirbtinio intelekto įtaka gamybos pramonėje

Remiantis Pasaulio ekonomikos forumu, įdiegus dirbtinį intelektą gamybos procesuose, sąnaudos gali sumažėti iki 30 % (Advanced Manufacturing: A New Narrative, 2024), o „Accenture“ tarptautinė profesionalių paslaugų įmonė teigia, kad iki 2035 m. dirbtinis intelektas gamybos pramonėje padidins produktyvumą 40 % ar net daugiau. Dėl šių priežasčių gamybos pramonėje dirbtinį intelektą naudojančios robotai, prognozuojamos techninės priežiūros sistemos ir tiekimo grandinės optimizavimo algoritmai keičia tradicinius gamybos procesus ir logistikos operacijas (Plathottam, 2023).

Chandra atliktame tyrime 2019 m. buvo nagrinėjamas dirbtinio intelekto valdomų prognozuojamos techninės priežiūros sistemų naudojimas mažinant prastovas ir minimizuojant techninės priežiūros išlaidas gamybos įmonėse, pabrėžiant DI potencialą didinti veiklos efektyvumą ir našumą (Chandra, 2019). Be to, Ivanovo tyrime buvo nagrinėjamas AI pagrįstų paklausos prognozavimo modelių taikymas tiekimo grandinės valdyje, parodant, kad gerokai pagerėjo atsargų valdymas ir užsakymų įvykdymo rodikliai (Zamani, 2022).


Indianos universiteto Viešųjų ir aplinkosaugos reikalų mokyklos išleistame leidinyje (2019), kalbama kaip dirbtinis intelektas gali būti taikomas gamyboje (Belton, 2019). Šiame darbe išskiriamos septynios sritys: kokybės kontrolė, tiekimo grandinės optimizavimas, tiksli įrangos stebėseną ir numatoma techninė priežiūra, pažangi robotika, generatyvinis dizainas, žmogiškųjų gebėjimų didinimas, transportavimas.

- **Kokybės kontrolė.** Gamybos įmonės aplinkoje kompiuterinė vizija gali atlikti daugelį tikrinimo užduočių greičiau, tiksliau ir efektyviau nei žmogus. Pavyzdžiui, „Google cluod“ siūloma „Visual Inspection AI“ sistema, atlieka surinkimo ir kosmetinio paviršiaus patikrą, kuri įvairiuose surinkimo proceso etapuose aptinka net pačius subtiliausius neatitikimus. Automatizuotas tikrinimas taip pat gali gerokai padidinti vartojimo produktų gamybos efektyvumą, pavyzdžiui, aštraus padažo gamintojo pritaikyta automatizuota sistema tikrina etikečių išdėstymą daugiau nei 1000 etikečių per minutę (Carroll, 2013).
- **Tiekimo grandinės optimizavimas.** Dirbtinis intelektas gali būti naudojamas smulkiems duomenims rinkti ir stebėti visoje tiekimo grandinėje, valdyti atsargas,

prognozuoti būsimą paklausą, pastebėti neefektyvumą ir pan. Pavyzdžiui, „Walmart“ naudoja mašininį mokymąsi, kuris padeda produktų paklausai prognozuoti pagal vietos orus, taip pat atrado subtilių dėsningumų, kurie žmogui prognozuotojui galėjo būti nepastebėti (pavyzdžiui, kad tam tikri produktai geriau parduodami, kai debesuota ir vėjuota).

- **Tiksli įrangos stebėseną ir numatoma techninė priežiūra.** Dirbtinis intelektas naudodamasis šimtais jutiklių, sujungtų į neuroninį tinklą gali detalios stebėti gamybos įrangą, pastebėti subtilius pokyčius, pvz., didesnę nei įprasta vibraciją arba nedidelius mašinos triukšmo pokyčius, kurie gali reikšti artėjantį gedimą. Ši technologija gali padėti pereiti nuo prevencinės techninės priežiūros prie prognozuojamos techninės priežiūros ir išvengti mašinų prastovų tiek dėl mašinų gedimų, tiek dėl nereikalingos prevencinės techninės priežiūros.
- **Pažangi robotika.** Robotai jau seniai naudojami gamyboje, tačiau paprastai jie turi būti pritaikyti vienai konkrečiai užduočiai atlikti, jų negalima lengvai perkvalifikuoti ir jie paprastai nesuvokia supančios darbo aplinkos. Naujos technologijos pradeda leisti robotams suvokti žmonių veiklą ir saugiai su jais bendradarbiauti (Knight, 2020).
- **Generatyvinis dizainas.** Tai DI sistema, kuri gali generuoti naują turinį, kurio anksčiau nebuvo. Dirbtinis intelektas gali būti naudojamas modeliuoti, kaip dizainas veiktų realiame pasaulyje, jo fiziškai nekuriant, ir tada automatiškai tobulinti modifikacijas, kol bus pasiektas optimalus dizainas.
- **Žmogiškųjų gebėjimų didinimas.** Bendradarbiaudami žmonės ir dirbtinis intelektas gali dirbti geriau ir efektyviau nei kiekvienas iš jų atskirai. Pavyzdžiui, išplėstinė realybė (angl. *Augmented Reality*) gali padidinti efektyvumą rodydama darbuotojams svarbią informaciją, suteikdama galimybę matyti vaizdus, kurių kitaip nebūtų įmanoma pamatyti. Vieno tyrimo duomenimis, darbuotojo, atliekančio elektros instaliacijos užduotį, produktyvumas padidėjo 34 %, kai procesui vadovauti buvo naudojami išplėstinės realybės akiniai (Abraham, 2020).
- **Transportavimas.** Autonominės transporto priemonės ilgainiui gali sukelti revoliuciją pasaulio transporto sistemose, tačiau dar daug techninių, socialinių, teisinių ir etinių problemų kyla prieš pradedant jas plačiai naudoti vartotojams (Kalra, Paddock, 2016). Tačiau autonominės transporto priemonės labiau riboto naudojimo aplinkoje, pavyzdžiui, gamybos cechuose, jau diegiamos. Pavyzdžiui, „Amazon“ naudoja dešimtis tūkstančių robotų, kurie automatiškai perkelia produktus jos sandėliuose (Shead, 2017).

Plathottam moksliniame tyrime apie dirbtinio intelekto pritaikymą gamybos sektoriuje, pateikia detalesnę DI taikymo architektūrą (Plathottam, 2023) (9 pav.). Schemoje pateikiama, kad DI pritaikymas plačiąją prasme yra klasifikuojamas į dvi atskiras šakas: operacijos ir dizaino sferose.



9 pav. DI pritaikymas gamybos sektoriuje


Šaltinis: sudarytas autoriaus remiantis Plathottam (2023).

- **Operacijos.** Operacijos susijusi su faktiniu gamybos įrenginių ir išteklių naudojimu. Iš fizinės pusės tai yra pramoninės mašinos, jutikliai ir valdikliai, darbuotojai ir įrenginių infrastruktūra. Operacijos gali būti klasifikuojamos kaip ilgalaikiai įrenginių ir procesų planai (planavimas) arba realaus laiko veiksmai gamykloje („*Real time*“), priklausomai nuo atitinkamo laiko poreikio. Jos labai svarbios siekiant užtikrinti, kad pramonės įranga veiktų taip, kaip norima, ir būtų išlaikyta produkto kokybė.
- **Dizainas ir projektavimas.** Projektavimas apima naujų ar modifikuotų produktų ir procesų kūrimą, jų skaitmeninį ar fizinį modeliavimą ir bandymus, siekiant užtikrinti, kad jie būtų įgyvendinami ir atitiktų gamintojo tikslus. Įprastas gamybos projektavimo procesas yra kartotinis, todėl reikia atlikti kiekvieno naujo projekto bandymus, kad būtų nustatytas jo veiksmingumas, o tai sunaudojama daug laiko, darbo ir medžiagų siekiant idealaus rezultato. Nauji DI mašininio mokymosi metodai, padedantys projektuoti procesus arba gaminius, apima eksperimentinį modeliavimą, generatyvinį projektavimą ir sustiprintąjį mokymąsi.

Analizuojant mokslinę literatūrą apie DI pritaikymą gamyboje, dažnai paminama sąvoka – išmanioji gamyba (angl. *Intelligent manufacturing*). Šiuolaikinė gamyba yra neatsiejama nuo šios sąvokos taikymo, todėl šią temą būtina išnagrinėti detaliau.

Išmani gamyba tapo pagrindine aukštąja technologija, didinančia bendrą gamybos pramonės konkurencingumą. Išmanioji gamykla - tai lankstus ir efektyvus gamybos sprendimas, skirtas patenkinti šiuolaikinės rinkos poreikius. Jis susieja fizinius komponentus gamybos sistemos ir skaitmeninius, abstrakčius bei virtualius komponentus (Hozdić, 2015).

Mokslininkas Yanhong Zhou pateikia naujos kartos išmanios gamybos modelį, kuris pasak jo tai visa apimanti sistema, kurią sudaro dviejų pagrindinių pagalbinių sistemų (pramoninis intelekto internetas ir pažangioji gamybos debesija) ir trijų pagrindinių funkcinių sistemų (pažangieji produktai, pažangioji gamyba ir pažangiosios paslaugos) derinys (10 pav.) Išmanieji gaminiai ir išmanioji gamybos įranga yra pagrindiniai naujos kartos išmaniosios gamybos sistemos elementai. Pažangūs gaminiai yra pažangiosios gamybos ir paslaugų vertės nešėjai, o pažangioji gamybos įranga sudaro technologinę prielaidą ir materialinį pagrindą pažangiajai gamybai įgyvendinti. Naujos kartos pažangioji gamyba sukurs neribotą erdvę gaminių ir gamybos įrangos projektavimo naujovėms ir lems revoliucinius pokyčius šiais aspektais (Zhou, 2018).



10 pav. Naujos kartos išmanios gamybos modelis

Šaltinis: sudarytas autoriaus remiantis Zhou (2018).

Toks DI ir išmaniosios gamybos ryšis gali pagerinti efektyvumą, produktų kokybę ir padidinti gamybos proceso saugą. Taigi gamybos sektorius yra vienas iš pagrindinių veiksmų, skatinančių taikomųjų dirbtinio intelekto technologijų plėtrą (Kehayov, 2022).

2.1.2. Dirbtinio intelekto įtaka inovatyvaus produkto kūrimo procese

Atsižvelgiant į tai, kad dirbtinis intelektas gali perimti tradicines žmogiškąsias užduotis organizacijose, galima klausti, ar dirbtinio intelekto vaidmuo gali būti panaudotas siekiant

vieno iš svarbiausių procesų, turinčių įtakos ilgalaikiam įmonės išlikimui ir konkurenciniam pranašumui, - inovacijų (Lengnick-Hall, 1992; Porter ir Stern, 2001). Iš pirmo žvilgsnio idėja, kad įmonės galėtų ir turėtų naudoti dirbtinį intelektą ir mašininių mokymąsi inovacijų diegimo tikslais, gali atrodyti beveik iš piršto laužta. Juk inovacijos tradiciškai laikomos žmonių sritimi, atsižvelgiant į jų unikalų gebėjimą būti novatoriškais (Amabile, 2019).

Tarp inovacijų procesui nebūdingų veiksnių yra tai, kad inovacijų steigėjai vis dažniau susiduria su labai nepastovia ir kintančia aplinka, vis konkurencingesnėmis pasaulinėmis rinkomis, technologijomis ir dramatiškai besikeičiančiu politiniu kraštovaizdžiu (Jones ir kt., 2016), (O'Cass ir Wetzels, 2018). Tačiau tuo pat metu informacijos prieinamumas smarkiai padidėjo. Šios dvi sąlygos yra svarus įrodymas, kad konkurencingumo pagrindas stovi ant organizacijų informacinės prieigos ir greito problemų sprendimo gebėjimų (Hajli ir Featherman, 2018). Tai reiškia, kad dirbtinis intelektas yra neatsiejamas su inovacijomis, kuris dėl ekonominio pranašumo gali apdoroti didelį kiekį informacijos.

Haefner moksliniame darbe apie dirbtinio intelekto įtaką inovacijų valdymo sferoje, labiau plėtoja būtent šį inovatyvių organizacijų ir didelio kiekio informacijos apdorojimo ryšį (Haefner, 2021). Inovacijų steigėjai organizacijose bandydami atpažinti ar plėtoti naujas galimybes ir idėjas, susiduria su dviem konkrečiomis kliūtimis (Eggers ir Kaplan, 2009). Pirmą, įmonės turi įveikti informacijos apdorojimo apribojimus, kurie riboja informacijos apie naujas galimybes arba galimus sprendimus. Šiuos informacijos apdorojimo apribojimus dažnai lemia vadovų kognityviniai apribojimai, t. y. žmogaus protiniai gebėjimai priimti ar apdoroti informaciją yra biologiškai riboti.

Antroji kliūtis, su kuria susiduria inovatoriai, atsiranda dėl neefektyvių arba vidinės paieškos procedūrų. Šis barjeras nurodo, kad įmonės ieško sprendimų žinių srityse, kurios susijusios su įmonės ir jų pačių turima žinių baze, t. y. vadovaujasi uždarų inovacijų principu. Tačiau norėdami sukurti kūrybiškesnę ir inovatyvesnę idėją ar galimybę, įmonės privalo išplėsti paieškas už esamų žinių sričių ribų į naujas sritis, kurios yra labiau tiriamojo pobūdžio.

Haefner apibrėžia sritis, kuriose DI gali padėti ir potencialiai pakeisti žmogaus priimamus sprendimus inovacijų valdymo srityje. 7 Lentelėje pateikiami trys DI panaudojimo etapai sprendimų paieškos procese: panaudojimo, išplėtimo ir tyrinėjimo. Kiekviename etape apibrėžiami pagrindiniai paieškos metodai, charakteristikos, brandos ir autonomiškumo lygmenys.

7 lentelė. DI įtaka inovacijų valdymo srityje

	1 ETAPAS: panaudojimo	2 ETAPAS: išplėtimo	3 ETAPAS: tyrinėjimo
Paieškos metodas	Sėkmingai išnaudoti ir problemą, ir jos sprendimą	Galimybė ištirti ir iš naujo apibrėžti problemos arba sprendimo erdvę	Visapusiškai ištirti ir iš naujo apibrėžti tiek problemos, tiek sprendimo erdvę.
Charakteristikos	-Panaudota siekiant įveikti kognityvinius informacijos apdorojimo apribojimus. - gali apdoroti daugiau duomenų. - galima apdoroti daug skirtingų duomenų šaltinių.	- Gebėti atrasti naujų idėjų ir galimybių. - padeda žmonėms kurti novatoriškesnes idėjas ir sprendimus	-Naujų inovacijų proceso krypčių ieškojimas -generuoti ir kurti inovatyvias ir kūrybiškas naujas idėjas -išnagrinėti naujus problemų apibrėžimo būdus -ieškoti naujų problemų sprendimo būdų
Brandos lygmuo	Realizuojamas pritaikymas pradiniai įgyvendinimai Smėlio dėžės eksperimentai	Pradiniai įgyvendinimai	„Sandbox“ eksperimentai
Autonominis lygmuo	Žmogaus sukurtos DI sistemos → DI sistemos su didėjančiu mašinos savarankiškumu		


Šaltinis: sudarytas autoriaus remiantis Haefner (2021).

Išsiaiškinus inovacijos valdymo sritis, kuriose DI gali padėti ir potencialiai pakeisti žmogaus priimamus sprendimus, galima detaliau nagrinėti kaip DI integravimas paveikia inovatyvaus produkto kūrimo procesus.

Sėkmingas naujų produktų kūrimas gali užtikrinti geresnį organizacijos augimą ir veiklos rezultatus (Cooper ir Edgett 2003). Tačiau inovatyvių produktų kūrimo procesuose nesėkmių lygis vis dar aukštas (Cooper, Edgett ir Kleinschmidt 2004). Pasak Cooperio, maždaug 40 % projektų žlunga komercializavimo etape, ir tik 13 % inovatyvaus produkto kūrimo pastangų pasiekia pelno tikslus (Cooper, 2019). Siekdamas sumažinti nesėkmių skaičių, įmonės pradeda taikyti „duomenimis pagrįstą, sprendimų priėmimą, į inovatyvaus produkto kūrimo procesą įtraukdamos didžiulius duomenis (Wang, Zhang ir Song 2020).

Pagrindė didelio kiekio duomenų naudojimas naudą suteikia: proceso idėjų kūrimo, produkto projektavimo ir plėtros etapuose (Wang, Zhang ir Song 2020). Vis platesnis dirbtinio intelekto diegimas paskatino naujos vertės kūrimą, kuris iš esmės pakeitė inovacijų procesus (Nambisan, 2017; Davenport ir Ronanki 2018). Dirbtinio intelekto naudojimas inovatyvaus produkto kūrimo procese suteikia naujų galimybių geriau plėtoti produktų idėjas, atlikti geresnę verslo analizę, kurti inovatyvesnius produktus, greičiau juos komercializuoti, teikti kokybiškesnes paslaugas po komercializavimo ir efektyviau valdyti veiklą (Wang, Zhang ir Song 2020). Nors 59 %. 2018 m. „McKinsey“, pasaulinėje apklausoje apklaustų vadovų nurodė, kad jų įmonės pritaikė DI į inovatyvaus produkto kūrimo procesus, o tik 21 % įmonių įdiegė DI keliuose verslo padaliniuose ar procesuose.

Haili Zhang atliktame tyrime, buvo nagrinėjami 558 inovatyvių produktų kūrimo projektų, kurių iš jų buvo, 282 - sėkmingi, o 276 – nesėkmingi (Zhang, 2021). Pirmuoju atveju, Zhang tyrė, kokia įtaką daro dirbtinis intelektas sėkmingiems ir nesėkmingiems inovatyvaus produkto kūrimo procesams (11 pav.).




11 pav. DI pritaikymas sėkminguose ir nesėkminguose projektuose

Šaltinis: sudarytas autoriaus remiantis Zhang (2021).

Rezultatai parodo, kad DI naudojimo visuose septyniuose etapuose turi didelį poveikį projekto sėkmės rodikliams. Tačiau šis poveikis labai skiriasi visuose etapuose. Didžiausią naudą duoda dirbtinio intelekto naudojimo lygio padidėjimas operacijų valdyje (46,6 %), verslo analizėje (45,2 %) ir produkto projektavime (43,0 %). Mažiausia nauda didinant dirbtinio intelekto naudojimą yra produkto testavimo srityje.

Antruoju atveju Zhang nagrinėjo dirbtinio intelekto technologijų galimybių įtaką projekto sėkmės rodikliui. Rezultatai taip pat parodė, kad visų šešių konkrečių dirbtinio intelekto technologijų (analitinio, funkcinio, interaktyvaus, tekstinio, vizualinio ir robotinio dirbtinio intelekto) gebėjimai turi reikšmingą poveikį projekto sėkmės rodikliui (12 pav.).




12 pav. Dirbtinio intelekto technologijų poveikis projekto sėkmės rodikliams

Šaltinis: sudarytas autoriaus remiantis Zhang (2021).

Rezultatai rodo, kad robotų dirbtinio intelekto gebėjimai duoda didžiausią naudą didinant projektų sėkmės rodiklį (48,4 % skirtumas tarp didelio ir mažo robotų dirbtinio intelekto gebėjimų sėkmės rodiklio). Antrą didžiausią naudą duoda investicijos į interaktyviojo DI pajėgumus, nes skirtumas yra 45,5 %. Tekstinio DI pajėgumo pagerinimas nuo mažo iki aukšto sėkmės rodiklis buvo mažiausiai - 40,5 procento. Kitų trijų DI technologijų tobulinimo sėkmės rodiklio padidėjimas panašus: analitinio DI (45,2 %), funkcinio DI (44,1 %) ir vizualinio DI (44,1 %).

Kitas DI vaidmens suvokimo būdas inovatyvaus produkto kūrimo procese - būti *iniciatoriumi* ir *tarpininku*. Šį modelį pateikė Alexander Brem moksliniame darbe apie konceptualųjį dirbtinio intelekto modelį naujų produktų kūrimo srityje (Bream, 2023)

- *Iniciatoriaus* vaidmuo yra kūrybinė produkto kūrimo pusė - DI panaudojimas kaip kūrybinis modelis ir išradimo metodas.
- *Tarpininko* vaidmuo labiau susijęs su esamų procesų ir metodų tobulinimu, kad jie taptų veiksmingesni ir efektyvesni. Jame išnaudojamas dirbtinio intelekto gebėjimas naujoviškai integruoti duomenis ir jais manipuluoti.



13 pav. DI vaidmuo inovatyvių produktų kūrimo procese

Šaltinis: sudarytas autoriaus remiantis Cooper (2021).

13 paveiksle pavaizduota, kaip dirbtinis intelektas naudojamas įvairiuose naujų produktų kūrimo proceso etapuose – nuo idėjų generavimo iki produkto paleidimo į rinką. Diagrama parodo, kad ankstyvosiose stadijose, DI dažniausiai naudojamas kūrybiškoms ir analitinėms funkcijoms, įskaitant idėjų generavimą, technines idėjas ir rinkos vertinimą. Vidurinėse stadijose DI įgyja didesnę svarbą, atliekant sėkmės prognozavimą, prototipų kūrimą, rinkos duomenų analizę ir rizikos valdymo užduotis. Vėlyvosiose stadijose DI orientuojasi į procesų optimizavimą, pavyzdžiui, kainodaros nustatymą, gamybos optimizavimą ir klientų pasitenkinimo užtikrinimą. Bendrai DI reikšmė auga pereinant nuo pagalbinių užduočių prie strateginių ir kūrybinių funkcijų, kurios yra esminės produkto kūrimo sėkmei.

2.1.3. Dirbtinio intelekto taikymo kliūtys pramonės įmonėse

Nepaisant visų dirbtinio intelekto pasiekimų, akivaizdu, kad ši technologija dar nepasiekė daugelio įmonių. Remdamasis nacionaline statistika, Eurostatas (2022 m.) paskelbė tyrimą apie dirbtinio intelekto naudojimą įmonėse. Iš jo matyti, kad ES vidutiniškai tik 8 % apklaustų įmonių naudoja bent vieną dirbtinio intelekto technologiją. Nenuostabu ir tai, kad įmonės dydis ir DI naudojimas yra teigiamai susiję. Kuo didesnė įmonė, tuo didesnė tikimybė, kad ji naudos bent vieną DI technologiją. Austrijoje 92 % mažų įmonių, 85 % vidutinio dydžio įmonių ir 74 % didelių įmonių dar nesvarstė galimybės taikyti DI (Statistik Austria, 2021). Ypač mažosiose ir vidutinėse įmonėse akivaizdu, kad išvelgiami privalumai, tačiau kompetencija yra

labai menka, dažnai nežinomos galimos taikymo sritys, o naudos dažnai neįmanoma įvertinti (Bunte, Richter ir Diovisalvi, 2021).

Rudolf Grunbichler analizavo septynius skirtingus mokslinius darbus apie dirbtinio intelekto taikymo kliūtis (Grunbichler, 2023). Bendra dalyvių apimtis visuose darbuose buvo virš 9 tūkst. Iš visų mokslinių tyrimų Grunbichler'is išskyrė 41 kliūtis, kurios susijusios su DI diegimo problemomis įmonėse. Jas visas sugrupavo į 5 skirtingus lygmenius: valdymo, darbuotojų, organizacijos, duomenų, išorinių (detaliau žr. 8 lentelė).

8 lentelė. Rudolfo Grunbichler'io penkių lygmenų dirbtinio intelekto taikymo kliūtis

Lygmuo	Pagrindinės lygmens kliūtys
Valdymo lygmuo	• Aukščiausiosios vadovybės įsipareigojimo ir (arba) žinių trūkumas. • Reguliavimo kliūčių ir techninės rizikos valdymas. • Etiniai aspektai.
Darbuotojų lygmuo	• Kompetencijos stoka. • Verslo galimybių nebuvimas / verslo galimybių nenustatymas. • Neįžvelgiama papildoma nauda. • Trūksta įrodymų, kad dirbtinis intelektas turi pridėtinės vertės, palyginti su alternatyviais metodais; mažai tikimasi pridėtinės vertės. • Darbuotojų nepritarimas.
Organizacijos lygmuo	• Finansinės kliūtys ir didelės išlaidos. • IT infrastruktūros trūkumai / nesuderinamumas.
Duomenų lygmuo	• Duomenų problemos (kokybė), duomenų prieinamumas; • Su privatumu susijusios problemos. • Prieigos prie išorinių duomenų trūkumas.
Išorinis lygmuo	• Individualių (įmonei pritaikytų) dirbtinio intelekto sprendimų trūkumas; rinkos brandos stoka. • Išorinės paramos dirbtinio intelekto klausimais trūkumas. • Nenoras bendradarbiauti universitetų ar mokslinių tyrimų institucijų.

Šaltinis: sudarytas autoriaus remiantis Grunbichler (2023).

Šie duomenys leidžia identifikuoti dažniausiai pasitaikančias kliūtis, kurių būtina vengti, ir numatyti veiksmus, kaip spręsti potencialias problemas. Atsižvelgiant į šias kliūtis, galima suformuluoti konkrečias rekomendacijas, kurios užtikrins sėkmingą DI diegimą. Be to, ši analizė padės išsamiau atkreipti dėmesį į svarbiausius aspektus – nuo darbuotojų kompetencijų ir organizacinių išteklių iki išorinių veiksnių, tokių kaip rinkos brandumas ar bendradarbiavimo su tyrimų institucijomis svarba. Šie duomenys taps naudinga gairė kuriant darbo struktūrą ir formuluojant argumentus apie efektyvų DI panaudojimą.

2.1.4. Dirbtinio intelekto taikymas Lietuvos pramonėje

2018 metų rudenį Lietuvos Respublikos ekonomikos ir inovacijų ministerija kartu su ekspertų grupe pradėjo rengti susitikimus ir aktyvias diskusijas, skirtas aptarti DI technologijų įtaką bei jų reikšmę šaliai. Ši ekspertų grupė, suburta iš privataus ir viešojo sektoriaus atstovų bei mokslininkų, siekė nustatyti DI plėtros kryptis Lietuvoje ir pateikti konkrečias strategijas bei rekomendacijas. Šių susitikimų dėka buvo išleistas 2019 m. Lietuvos DI strategija, kurios tikslas yra „remiantis esamais ištekliais, patirtimi ir potencialu, tapti regiono lydere, padidinti Lietuvos konkurencingumą Europos Sąjungos šalių tarpe, bei sėkmingai įsijungti į pasaulinę DI ekosistemą“ (Čivilis ir kt., 2019). Lietuvos įmonės nėra išimtis, todėl taip pat, šiame leidinyje pabrėžiamos jau aptartos DI diegimo kliūtys: nepakankamai išvystyta infrastruktūra, netiksliai apskaičiuoti pradiniai kaštai, nepakankamai įvertintos dirbtinio intelekto galimybės, dėl ko dažnai pasirenkami netinkami jo diegimo sprendimai.

Lietuvos Respublikos ekonomikos ir inovacijų ministerija yra pateikusi DI technologijų plėtros 2023–2026 m. veiksmų planą, kuriame numatyta, kaip paskatinti proveržį Lietuvoje kuriant ir diegiant dirbtinio intelekto technologijas ir sprendimus. Svarbiausi uždaviniai: „sudaryti sąlygas aukšto technologinio lygio DI inovacijoms ir stiprinti DI technologijų ekosistemą, taip pat skatinti DI diegimą ir naudojimą visuose sektoriuose, tarp jų ir viešajame sektoriuje“. Taip pat parengtos DI ekosistemai augti reikalingas finansines priemones: 15 mln. eur. startuoliams, viešosioms paslaugoms 110 mln. Eur.

Remiantis 2024 m. Eurostato duomenimis, gamybos sektorius sudaro apie 14 % Lietuvos bendrojo vidaus produkto (Eurostat, 2024). Lietuvos gamybos sektorius kartu su išmaniosiomis robotikos sistemomis gali gauti didžiausią naudą iš DI pritaikymo. Šio sektoriaus didžiausias iššūkis – žemas darbo našumo lygis, kurį dirbtinis intelektas gali padėti spręsti automatizuodamas rutiniškas užduotis. Skatinant DI sistemų integraciją, galima užtikrinti Lietuvos gamybos sektoriaus konkurencingumą tiek regioninėse, tiek pasaulinėse rinkose. Oficialios statistikos portalas, teigia, kad 2023 m. DI Lietuvoje naudoja apie 4,9 % įmonių (Oficialios statistikos portalas, 2023). Europos Sąjungos vidurkis siekia daugiau nei 8 %, lyginant su Europos vidurkiu Lietuva gerokai atsilieka dirbtinio intelekto naudojime (Statista, 2023).

Remiantis oficialios statistikos portalo duomenimis, 9 lentelėje pateikti duomenys rodo, kad dirbtinio intelekto technologijų naudojimas gamybos procesuose Lietuvoje skiriasi priklausomai nuo įmonės dydžio. Iš viso pagal darbuotojų skaičių DI naudojimas sudarė 1,4 % 2021 m., sumažėjo iki 1 % 2023 m., tačiau 2024 m. pastebimas augimas iki 1,9 %. Mažos įmonės (10–49 darbuotojų) DI technologijas naudojo 0,9 % 2021 m., šis rodiklis nukrito iki 0,5

% 2023 m., o 2024 m. pastėbimas padidėjimas iki 1,2 %. Vidutinio dydžio įmonės (50–249 darbuotojų) 2021 m. rodė 2,8 % DI naudojimą, kuris sumažėjo iki 1,9 % 2023 m., tačiau matomas augimas iki 3,7 % 2024 m. Tuo tarpu didelėse įmonėse (250 ir daugiau darbuotojų) DI naudojimas buvo žymiai didesnis: 6,7 % 2021 m., išaugo iki 8,5 % 2023 m. ir 2024 m. 10,9 % (Oficialios statistikos portalas, 2024). Tai rodo, kad DI technologijų diegimas sparčiausiai plečiasi didelėse įmonėse, o mažesnėse – vyksta lėtesniu tempu. Tam įtakos gali turėti jau aptartos diegimo kliūtys įmonėse.

9 lentelė. DI naudojimas gamybos procesams

		Įmonės, naudojančios dirbtinio intelekto technologijas ir naudojimo tikslai, %		
		2021	2023	2024
Gamybos procesams	Iš viso pagal darbuotojų skaičių	1,4	1	1,9
	10–49 darbuotojai	0,9	0,5	1,2
	50–249 darbuotojai	2,8	1,9	3,7
	250 ir daugiau darbuotojų	6,7	8,5	10,9


Šaltinis: sudarytas autoriaus remiantis Statista (2023).

Apibendrinant, Lietuvoje dirbtinio intelekto plėtrai yra sukurtos perspektyvios sąlygos, tačiau vis dar susiduriama su reikšmingais iššūkiais. Nepaisant to, kad pradėtos strateginės iniciatyvos ir veiksmų planas skatina DI integraciją, DI naudojimas šalies įmonėse išlieka žemas. Gamybos sektorius, kuris yra svarbiausias Lietuvos ekonomikoje, gali daugiausiai laimėti pritaikydamas DI technologijas, tačiau mažos ir vidutinės įmonės susiduria su kliūtimis, o didelėse įmonėse DI diegimas vyksta sparčiau.

2.2. Dirbtinio intelekto taikymo tyrimo eiga inovatyvių produktų kūrimo procese

Tyrimo eiga struktūrizuota taip, kad būtų galima nuosekliai ištirti dirbtinio intelekto įtaką inovatyvių produktų kūrimo procesui (žr. 14 pav.). Pirmiausiai atliekama mokslinės literatūros šaltinių, susijusių su DI, jo taikymo sąsajų su inovatyvių produktų kuriančių įmonių veiklos rezultatais, analizė. Mokslinės literatūros analizė padeda geriau suprasti nagrinėjamą objektą, analizuoti inovatyvaus produkto kūrybos bei dirbtinio intelekto apibrėžimus, sampratas, sąsajas, klasifikavimą iš skirtingų autorių perspektyvos. Šio darbo metu mokslinės literatūros atlikimą galima skaidyti į tris nagrinėjamus etapus: inovatyvaus produkto kūrimo

samprata, dirbtinio intelekto samprata, inovatyvaus produkto ir dirbtinio intelekto sąsaja pramonės inžinerijoje. Visuose etapuose renkant informaciją yra naudojamos mokslinės literatūros duomenų bazės įskaitant mokslinius žurnalus, knygas, straipsnius ir kitus mokslinius veikalus.



14 pav. Tyrimo alikimo schema

Šaltinis: sudaryta autoriaus.

Inovatyvaus produkto kūrimo sampratoje pagrindinis tikslas išnagrinėti, kas yra inovatyvus produktas, kokie procesai jį daro inovatyviu, kokius metodus / modelius taiko įmonės kuriant šį produktą, kaip klasifikuojami, kaip tokie produktai kuriami Lietuvoje.

Dirbtinio intelekto sampratos etape pagrindinis tikslas išnagrinėti, kas yra dirbtinis intelektas, jo atsiradimo priežastys, kaip jis veikia, kaip klasifikuojamas, kokios taikymo sritys.

Trečiajame mokslinės literatūros analizės etape bus siekiama išsiaiškinti, kokiose inovatyvaus produkto kūrimo procesuose dirbtinis intelektas gali turėti įtakos, kokią suteikia naudą ir žalą, atsižvelgiama tiek į globalinį įmonių kontekstą, tiek Lietuvos pramonės įmonių veiklą. Įsivertinama, kokie įmonių rodikliai gali būti fiksuojami šio tyrimo metu. Taip pat šiame etape apžvelgiama kitų mokslininkų taikomi empirinio tyrimo metodai, išsirenkant labiausiai tinkamus metodus savo empiriniai daliai.

Toliau buvo išanalizuoti kitų tyrėjų empiriniai darbai – jų metu naudoti metodai, taikymo kontekstas bei surinkti duomenys. Ši analizė leido ne tik įvertinti taikomų metodų tinkamumą, bet ir pasirinkti tuos tyrimo metodus, kurie labiausiai atitinka šio darbo tikslus. Remiantis surinkta informacija, pasirenkamas plačiai naudojamas inovatyvių produktų kūrimo modelis, kuris tampa pagrindu tolimesniam tyrimui. Integruojant dirbtinį intelektą į pasirinktą modelį, analizuojami įvairūs jo taikymo aspektai. Sukuriamas teorinis integracijos modelis,

kuriame numatomos pagrindinės dirbtinio intelekto funkcijos ir jų sąveika su tradiciniais inovacijų kūrimo etapais.

Kitas tyrimo etapas – parengtas ir pasiūlytas struktūruotas modelis, įvertinantis dirbtinio intelekto įtaką inovatyvių produktų kūrimui. Struktūrizuotas modelis gautas susisteminus literatūros analizės ir empirinio tyrimo rezultatus.

Pasiūlyto modelio patikrinimui sukurama simuliacija, kuri leidžia atkartoti ar imituoti realią situaciją, išskiriant tik esmines realaus gyvenimo charakteristikas ir perkeliant procesus į nerizikingą aplinką. Šiam procesui atlikti pasirinktas realus inovatyvus produktas ir jo kūrimo eigai pritaikytas galutinis struktūrizuotas modelis. Gauti rezultatai įvertina, kokią naudą teikia sukurtas modelis.

2.3. Tyrimo metodų pasirinkimo pagrindimas dirbtinio intelekto integracijai vertinti

Norint ištirti kaip dirbtinio intelekto integravimas veikia inovatyvaus produkto kūrimo procesą, naudojamas literatūros analizės metodas. Šis metodas leis suprasti bei susisteminti kitų mokslininkų įžvalgas bei žinias, tarp inovatyvaus produkto kūrimo proceso ir dirbtinio intelekto sąsajos.

Atliekamas lyginamosios analizės metodas, kuriuo metu lyginami kitų tyrėjų empiriniai metodai. Toks lyginamasis tyrimas leido pasirinkti tinkamiausius empirinio tyrimo metodus savo tyrimo daliai. Mokslinėje literatūroje dažniausiai pasitelkiami kokybiniai ir kiekybiniai tyrimo metodai, tokie kaip atvejo analizė, modeliavimo ir simuliacijos metodai, tekstų analizė bei struktūriniai procesų vertinimo modeliai. Remiantis tyrėjų Cooper, Montagna, Ghosh, Bughin ir kt. darbais, vienas iš dažniausiai naudojamų inovacijų valdymo analizės metodų yra modeliavimo metodas, leidžiantis vizualizuoti ir struktūrizuoti procesų veikimą bei jų sąsajas su technologiniais sprendimais.

Empirinio tyrimo dalyje, atliekama teksto analizė. Šis metodas leidžia gilintis į turinio reikšmes, atskleisti paslėptus ryšius tarp DI sprendimų ir inovatyvaus produkto kūrimo etapų. Kitų metodų (pvz., apklausų) atsisakyta, nes tyrimas orientuotas į teorinių ir praktinių sprendimų kūrimą, o ne į nuomonės rinkimą. Remiantis atlikta literatūros analizė, šio tyrimo metu pasirinktas „Stage-Gate“ modelis, kuris yra vienas plačiausiai taikomų inovatyvių produktų kūrimo struktūrizavimo metodų pasaulyje. Šį modelį naudoja tokios įmonės kaip Procter & Gamble, Lego, ABB, Emerson Electric, o įvairūs moksliniai šaltiniai (pvz., Cooper, 2008). „Stage-Gate“ metodas pasirinktas dėl to, kad jis aiškiai leidžia suskaidyti inovatyvaus produkto kūrimo procesą į logiškas, nuoseklias fazes bei kiekviename etape galima integruoti

dirbtinio intelekto sprendimus, tokius kaip automatizuotas idėjų generavimas, rinkos analizė, koncepcijos vertinimas ar produkto projektavimas, testavimas ir validavimas.

Siekiant pasiūlyti struktūruotą modelį, įvertinantį dirbtinio intelekto įtaką inovatyvių produktų kūrimui, naudojamas modeliavimo metodas. Šis metodas padeda suprasti empirinio tyrimo rezultatų ir elementų, ryšius bei sąsajas. Sukuriamas modelis remiantis „Stage-Gate“ DI integravimo kontekste.

Tinkamai suprasti pasiūlytą struktūrizuotą modelį, kaip veikia DI pagrįstas produktų kūrimo procesas praktinėje aplinkoje atliekamas simuliacijos metodas. Simuliacijos metodas leidžia atkartoti ar imituoti realią situaciją, išskiriant tik esmines realaus gyvenimo charakteristikas ir perkeliant procesus į nerizikingą aplinką. Atlikus simuliaciją, pakoreguojamas ir pateikiamas galutinis sukurtas DI integracijos „Stage-Gate“ modelis.

2.4. Tyrime naudotos priemonės ir technologijos

Tyrimo metu buvo pasitelktos įvairios technologinės, analitinės ir vizualizavimo priemonės, kurios atliepė kiekvieno tyrimo etapo tikslus. Kiekvienoje tyrimo stadijoje buvo naudotos atskiros specializuotos technologijos, padėjusios surinkti, struktūruoti, modeliuoti ir simuliuoti duomenis.

Literatūros analizės etape naudotos kelios skaitmeninės šaltinių analizės ir informacijos valdymo priemonės. Pirmiausia, remtasi akademinėmis duomenų bazėmis, kurios leido surinkti aktualius šaltinius apie dirbtinio intelekto pritaikymą inovacijų procese, modelių kūrimą, DI taikymą įvairiuose verslo kontekstuose.

Modelio sudarymo etape buvo pasitelktas „Canva“ – vizualinio modeliavimo įrankis, leidžiantis kurti proceso struktūrines schemas ir „Stage-Gate“ modelio adaptaciją.

Simuliacijos sudarymo metu naudota Python programavimo kalba, kuria buvo kuriamos duomenų analizės, rinkos segmentavimo bei rezultatų vizualizavimo skriptų struktūros. Naudoti klasikiniai duomenų analizės algoritmai, tokie kaip „K-means“ klasterizavimas, buvo įgyvendinti naudojant Python bibliotekas – „scikit-learn“, „pandas“ ir „matplotlib“. Taip pat naudota „Autodesk Fusion 360“ su generatyvinio dizaino moduliu pasitelktas produkto prototipo formavimui – leidžiantis pavaizduoti, kaip DI gali kurti, optimizuoti ir testuoti konstrukcinius sprendimus. Simuliuojant rinkos analizę ir vartotojų poreikių vertinimą naudota „Google Cloud Natural Language API“ – leidusi analizuoti tekstinę informaciją ir įvertinti vartotojų atsiliepimus automatizuotu būdu. Simuliacijos duomenų apdorojimui ir rezultatų vertinimui naudoti „Microsoft Excel“ ir „Google Sheets“ įrankiai. Jie padėjo atlikti kiekybinių

rodiklių analizę, rezultatus sisteminti lentelėse, skaičiuoti santykinius pokyčius bei vizualizuoti rezultatus. Taip pat naudotos „Microsoft Word“ diagramų ir grafikų funkcijos, padėjusios aiškiai parodyti DI įtaką skirtingiems produkto kūrimo etapams.

3. DIRBTINIO INTELEKTO TAIKYMO INTEGRAVIMAS Į STAGE-GATE MODELĮ: SIMULIACIJA IR SIŪLOMAS MODELIS INOVATYVIŲ PRODUKTŲ KŪRIMUI

3.1. DI integravimas „Stage-Gate“ modelyje

Empirinio tyrimo dalyje pagrindinis tikslas ištirti dirbtinio intelekto integravimo galimybes inovatyvaus produkto kūrimo procese, pasitelkiant „Stage-Gate“ modelį. Pirmiausia analizuojamas šio modelio pritaikymas DI kontekste, tuomet formuojamas atitinkamas struktūrizuotas modelis, o galiausiai atliekama simuliacija. Tyrimo metu taikomas modeliavimo metodas, kuris leidžia sukurti struktūrinį požiūrį į DI integraciją įvairiuose produkto kūrimo etapuose (14 pav.).

I Etapas. Idėjų generavimas	II Etapas. Apžvalga	III Etapas. Verslo planas	IV Etapas. Kūrimas	V Etapas. Testavimas	VI Etapas. Paleidimas
- Idėjų generavimas; - Technologijų analizė; - Rinkos analizė. - Idėjų tyrinėjimas;	- Vartotojų poreikių analizė; - Rizikų identifikavimas; - Koncepcijos plėtojimas; - Verslo galimybių vertinimas.	- Verslo plano kūrimas; - Pardavimų prognozė; - Konkurentų analizė; - Technologijų tinkamumas.	- Produkto dizaino projektavimas; - Darbo automatizavimas; - Projektų valdymas. - Technologijų testavimas; - Prototipo vystymas;	- Našumo optimizavimas; - Rizikų valdymas; - Reglamentavimas. - Simuliaciniai modeliai;	- Gamybos optimizavimas. - Rinkodaros strategijos įgyvendinimas; - Klientų pasitenkinimas; - Kainodaros strategija;

14 pav. Tyrimo metu analizuojami etapai remiantis „Stage-Gate“ modeliu

Šaltinis: sudaryta autoriaus.

Simuliacijos metodas pasirinktas kaip priemonė atvaizduoti ir įvertinti modelio veikimą bei rezultatus virtualioje, nerizikingoje aplinkoje. Tokiu būdu siekiama ne tik pagrįsti modelio teorinį aktualumą, bet ir įvertinti jo praktinį taikymą.

3.1.1. I Etapas. Idėjų generavimas

Idėjų generavimas. Idėjų generavimas yra labai svarbi inovatyvių produktų kūrimo proceso dalis. Tam reikia kūrybiškumo, vaizduotės, grupinio darbo ir naujausių žinių, kad būtų sugalvotos naujos, originalios idėjos. Šiuo atveju, šiems veiksniams įgyvendinti galima pritaikyti dirbtinį intelektą. Natūralios kalbos apdorojimo metodai, leidžia efektyviai analizuoti didelius tekstinių duomenų kiekius, juos klasifikuoti, atrūšiuoti, bei sintezuoti į inovatyvias idėjas. Generatyviniai teksto modeliai, tokie kaip *ChatGPT* iš taisyklingai suformuluotos užklauso, gali pateikti per kelias sekundes gausybę naujų idėjų taikant minčių šturmo, minčių žemėlapių, SCAMPER bei kitus gerai žinomus naujų produktų kūrimo metodus. Vaizdiniai generatyviniai modeliai, tokie kaip *DALL-E*, leidžia vizualizuoti idėjas, kurios gali būti naudojamos kaip pagrindas tolesniuose produkto tobulinimo etapuose.

Technologijų analizė. Technologinė analizė - tai praeityje naudotų technologijų studijavimas ir vertinimas, pasitelkiant jų materialinę kultūrą, ypač daug dėmesio skiriant funkcionalumui ir jų gamybos procesams. Natūralios kalbos apdorojimo metodai suteikia galimybę automatizuotai analizuoti, klasifikuoti technologijų raidos kryptis, pasitelkiant mokslinių straipsnių, patentų duomenų bazes ir kitus informacijos šaltinius. Generatyviniai teksto modeliai, pavyzdžiui, *ChatGPT* kuria galimas naujų technologijų pritaikymo idėjas, paremtas analizuotais duomenimis ir rinkos poreikiais. Pasitelkiant prižiūrimo mokymosi, klasifikacijos metodą, galima prognozuoti ir sugrupuoti technologijų raidą pagal istorinius duomenis. Klasterizacija aptinka technologijų grupes pagal pritaikymo sritis, o regresija padeda įvertinti potencialų jų poveikį verslo sektoriui. Šioms mašininio mokymosi užduotims atlikti dažniausiai naudojamos atvirojo kodo mašininio mokymosi bibliotekos – *TensorFlow* ir *PyTorch*. Kompiuterinės regos biblioteka, pavyzdžiui, *OpenCV* tirdama technologijų schemų, grafikų, prototipų vizualinius duomenis gali palengvinti jų palyginimą ir įvertinimą.

Idėjų tyrinėjimas. Idėjų tyrinėjimo procesas susijęs su minčių, sąvokų ar vizualinių idėjų, analizavimu ir plėtojimu. Šiuo procesu metu siekiama geriau suprasti arba gauti naujų įžvalgų iš esamų jau sugeneruotų idėjų. Natūralios kalbos apdorojimo priemonės leidžia atlikti siūlomų idėjų analizavimą, bei suskirstymą. Pavyzdžiui, NLP teksto klasifikacijos priemonė, suskirsto idėjas pagal jų tematiką, svarbą, segmentus ir panašiai. Generatyvinio teksto priemonė gali esamas idėjas lyginti su mokslinių straipsnių, rinkos ataskaitų duomenimis, taip pergeneruojant idėjas į moksliskai pagrįstas koncepcijas. Šiems veiksmai atlikti tinka *ChatGPT*. Mokslinių straipsnių, rinkos ataskaitų ir patentų analizė, vykdoma naudojant regresijos metodą, suteikia galimybę prognozuoti idėjų sėkmės tikimybę, o neprižiūrimo mokymosi klasterizacijos metodas leidžia grupuoti idėjas pagal bendras savybes ir kompleksines struktūras. Šiems procesams atlikti naudojamos atvirojo kodo mašininio mokymosi bibliotekos: *TensorFlow* ir *PyTorch*. Taip pat idėjų tyrinėjimo metode galima integruoti sustiprintą mokymaisi, kurio metu sukuriamas modelis leidžiantis interaktyviai tobulinti idėjas, atsižvelgiant į rinkos duomenis ir vartotojų poreikius. Vaizdinių idėjų ar eskizų vertinimui galima panaudoti kompiuterinės regos priemonės, kurios leis vertinti tarpusavio ryšius, rasti problematiškas vietas, lyginti esamų rinkoje produktų vizualus, atsižvelgiant į jų formą, funkcionalumą, estetiką, dizainą ir kt.

Rinkos analizė. Kai pradedamos gryninti potencialios idėjos, reikėtų atsižvelgti ir į esamą rinką, kurioje parduodami panašūs produktai. Atliekant rinkos analizę nagrinėjami tokie veiksniai kaip rinkos dydis, konkurentai, kainos ir potencialūs klientai. Rinkos analizė apima tiek kiekybinius duomenis, pavyzdžiui, rinkos dydis ir kainas, kurias vartotojai pasirenge mokėti, tiek kokybinius duomenis, pavyzdžiui, vartotojų vertybes, norus ir pirkimo motyvus.

Šiems duomenims nagrinėti padeda natūralios kalbos apdorojimo priemonės, kurios gali atlikti sentimentų analizę, kiekybinių duomenų grupavimą, bei kategorijų nustatymą iš socialinės medijos, forumų ar apžvalgų. Pavyzdžiui, *Google Cloud Natural Language* priemonė leidžia tekstą (forumai, el. laiškai, socialinė medija, atsiliepimai, žiniasklaida ir kt.) sugrupuoti pagal jiems prisikariamą etiketę (kainą, numerius, adresus, vietoje, produktus ir kt.), priskirti sentimentams, nuomonėms (teigiama, neigiama, vidutinė), sugrupuoti į kategorijas (kompiuteriai ir elektronika, operacinės sistemos, telefonai ir elektronika ir kt.). Prižiūravimo mokymasis klasifikacijos metodas gali identifikuoti pagal rinkos duomenis produktu nišas arba atlikti klientų segmentavimą, o regresija kiekybiniais duomenimis prognozuoti pardavimų arba rinkos perspektyvas. Neprižiūravimo mokymosi klasterizavimo modeliai gali grupuoti vartotojus į segmentus pagal jų elgesį, poreikius ir kitus reikalingus parametrus, o rekomendacijų sistemos gali padėti nustatyti geriausiai tinkančius rinkos segmentus. Taip pat galima integruoti ir sustiprinta mokymąsi, kuris modeliuoja ir kuria įvairius rinkos scenarijus, ieškant optimaliausio veiksmų plano. Kompiuterinės regos priemonės, tokios kaip *Google Cloud Vision* arba *OpenCV*, gali atlikti vizualinių duomenų analizę, kuri vizualiai įvertina konkurentų produktus, reklamų dizainą.

3.1.2. II Etapas. Pirminė apžvalga

Koncepcijos detalizavimas. Koncepcijos detalizavimas yra esminis procesas, kuriame pagrindinė idėja išvystoma į išsamų planą. Tai apima techninių, ekonominių ir vartotojų poreikių aspektų detalizavimą, siekiant maksimaliai padidinti koncepcijos sėkmės galimybes. Kaip ir pirmame Stage-gate etape, šiame procese natūralios kalbos apdorojimo priemonės išsirinktoms idėjoms taip pat gali atlikti detalesnę informacijos ir vartotojų atsiliepimų analizę. Šiuo atveju automatinio teksto generacijos priemonės leidžia greitai ir detalai sukurti ataskaitas, aprašymus, bei klientų apklausas. Prižiūravimo mokymosi klasifikacija padeda nustatyti, kurios koncepcijos savybės geriausiai atitinka rinkos poreikius, remiantis istoriniais duomenimis, o regresija labiau prognozuoja techninių sprendimų išlaidas ir sėkmę. Neprižiūravimo mokymosi klasterizacija grupuoja panašias koncepcijos savybes ar idėjas pagal vartotojų poreikius ir rinkos segmentus. Taip pat šiame procese galima taikyti asociacijų modelį, kuris aptinka ryšius, kurie gali būti naudingi detalizuojant koncepciją, pavyzdžiui, jei vartotojas perka „iPhone“ išmanųjį telefoną, taip pat dažniausiai perka „Apple Watch“ arba „AirPods“ ir panašiai. Tokios funkcijos gali būti atliekamos Python programa su „Aprior“ algoritmu pagalba. Kompiuterinė rega gali analizuoti ir sukurti produkto vizualinius ar struktūrinius modelius, siekiant maksimaliai optimizuoti koncepciją prieš gamybos etapą.

Vartotojų poreikių analizė. Vartotojų poreikių analizė yra procesas, leidžiantis suprasti tikslinius klientus, jų elgesį, norus ir problemas. Šis etapas padeda užtikrinti, kad siūloma koncepcija atitiktų rinkos poreikius ir užtikrintų vartotojų pasitenkinimą. Pritaikius šiam procesui natūralios kalbos apdorojimo, semantinės analizės priemones, galima automatiškai analizuoti, klientų atsiliepimus, apžvalgas ir socialinės medijos įrašus, kurios nusako klientų emocijas. Kitas metodas – tekstų modeliavimas, kuris identifikuoja dažniausiai vartotojų minimas temas ar problemas iš tekstinių duomenų. Teksto generavimo priemonės leidžia greitai sudaryti vartotojų segmentaciją pagal esamos rinkos poreikius. Prižiūrimo mokymosi klasifikacija segmentuoja vartotojų poreikius pagal demografinius, elgesio, geografinius ir kitus kriterijus. Regresijos metu galima prognozuoti kaip konkretūs vartotojų poreikiai paveiks koncepcijos integravimąsi rinkoje. Neprižiūrimo mokymosi sistema gali aptikti netipinius vartotojų poreikius, kurie galėtų suteikti naujų rinkos galimybių. Kompiuterine rega analizuoja nuotraukas arba vaizdo įrašus iš socialinių tinklų, tinklaraščių, žiniasklaidos, siekiant suprasti vartotojų įpročius ir pageidavimus.

Rizikų identifikavimas. Rizikų identifikavimas leidžia nustatyti potencialias problemas, galinčias kilti įgyvendinant ar plėtojant projektą. Šis etapas apima vidinių ir išorinių grėsmių analizę, kurios gali turėti įtakos koncepcijos sėkmei. Natūralios kalbos apdorojimo priemonės gali automatiškai identifikuoti rizikas iš didelio kiekio ataskaitų, sutarčių ir kitų tekstinių duomenų. Sentimentų analizėje nagrinėjamos vartotojų ir partnerių reakcijos, kurios gali perspėti apie galimas rizikas ateityje. Mašininio mokymosi klasifikacija skirsto rizikas pagal jų pobūdį (finansinę, technologinę, teisinę ir kt.), o regresija prognozuoja tikimybę, kad konkreti rizika atsirad tam tikrame etape. Neprižiūrimo mokymo klasterizacija gali grupuoti rizikas pagal panašias savybes, padedant analizuoti poveikį ir kilmę. Šiame etape pritaikius sustiprintą mokymąsi galima sukurti simuliaciją, kuri modeliuoja įvairias strategijas siekiant sumažinti nustatytas rizikas.

Verslo galimybių vertinimas. Verslo galimybių vertinimas apima finansinių, rinkos, technologinių ir kitų svarbių aspektų analizę, siekiant nustatyti, ar koncepcija turi pakankamai potencialo būti sėkmingai įgyvendinta. Tai padeda priimti greitus sprendimus apie projekto tęstinumą. Būtent automatinė duomenų analizė gali greitai apdoroti didelius kiekius verslo planų, ataskaitų ir rinkos tyrimų, tam kad būtų išgryninta svarbiausia informacija apie verslo galimybes. Šiuo atveju gali būti atliekama ir sentimentų analizė, kuri iš didelių duomenų kiekio įvertina klientų ir investuotojų nuomones apie potencialų rinkos požiūrį į naują koncepciją. Prižiūrimo mokymosi regresija, remdamasi istorinių duomenų analize, gali prognozuoti verslo pajamų augimą ar kaštų struktūrą. Kita prižiūrimo mokymosi šaka – klasifikacija, nustato kurios rinkos yra potencialiai pelningiausios. Neprižiūrimo mokymosi asociacijų metodas gali

aptikti paslėptus ryšius tarp skirtingų rinkos ar verslo veiksmų. Taip pat anomalijų aptikimas gali identifikuoti neįprastas ar rizikingas galimybes, kurios galėtų būti nepelningos ar nestabilios. Pritaikius kompiuterinės regos programas, tokias kaip „Tableau“, galima analizuoti geografinius žemėlapius, pardavimų vizualizacijas, kurios identifikuoja pelningiausius rinkos regionus.

3.1.3. III Etapas. Verslo atvejo analizė

Verslo plano kūrimas. Verslo plano kūrimas apima strategijų, finansinių prognozių, rinkodaros planų ir operacijų modelių rengimą, siekiant pateikti išsamų planą, kaip idėja bus įgyvendinta ir išvystyta iki galutinio produkto ar paslaugos. Verslo plano kūrimą galima pradėti nuo natūralios kalbos apdorojimo naudojimo, pritaikant teksto generavimo metodą, tokius kaip *ChatGPT*. Šis metodas generuoja pagrindines verslo plano dalis, pavyzdžiui, klientų segmentai, santykiai su klientais, kanalai, vertės pasiūlymai, ištekliai, partneriai, sąnaudų struktūra rinkodaros strategijos ir konkurencinės analizės santraukos ir kt. Ši verslo planas gali būti sugeneruotas šabloniniame dokumente arba atskiromis dalimis. Teksto analizės metodas gali pateikti glaustas ir apibendrintas išvagas iš išsamių informacijos šaltinių (rinkos tyrimų ataskaitos, finansų dokumentai). Norint įvertinti kiekybinius duomenis, galima naudoti prižiūrimo mokymo regresiją, kuri iš istorinių duomenų prognozuoja finansinius rezultatus ir galima pelningumą, taip pat klasifikacijos metodas gali suskirstyti verslo modelius pagal jų specifines rinkas. Norint modeliuoti skirtingus verslo plėtros scenarijus, kurie automatiškai pasirinktu optimaliausius sprendimus galima integruoti sustiprinto mokymosi modelius. Kompiuterinė regos programos, tokios kaip *Tableau* ir *Power BI*, gali kurti vizualines verslo diagramas, planus ir modelius, jų pristatymus, kurie perteiktų pagrindines idėjas investuotojams ar partneriams.

Pardavimų prognozė. Pardavimų prognozė padeda numatyti būsimas inovatyvaus produkto pajamų srauto tendencijas, atsižvelgiant į rinkos, vartotojų elgsenos ir ankstesnių duomenų analizę. Tai svarbus žingsnis verslo planavime, kuris turi įtakos priimančioms strateginiams sprendimams gamybos, rinkodaros ir finansų procesuose. Šiame procese natūralios kalbos apdorojimo metodai glaudžiai susiję su jau aptarta socialinių medijų analize ir potencialių klientų segmentavimu, tačiau galima išskirti tekstinių atsiliepimų analizę, kuri identifikuoja vartotojų nuomonę apie produktus nuspėjant jų poveikį pardavimams. Taip pat galima integruoti regresijos modelius, kurie remdamiesi istorijos duomenimis, prognozuotų pardavimų apimtis, bei kitus finansinius rodiklius. Papildomai galima taikyti mašininio mokymo segmentą – laiko eilučių analizę, kuri modeliuoja pardavimų tendencijas per tam tikrą nurodytą laiką, atsižvelgiant į sezoniskumą ir kitus reikalingus veiksnus. Šioms analizėms atlikti galima naudoti

ARIMA modelius. Norinti atlikti sudėtingesnes pardavimų prognozes, galima pritaikyti sustiprinto mokymo modelius, kurie kuria ir testuoja įvairius kainodaros ar rinkodaros scenarijus, siekiant optimizuoti pardavimus.

Konkurencinė analizė. Konkurencinė analizė yra procesas, kurio metu nustatoma ir vertinama konkurentų strategija, veikla ir rinkos padėtis. Tai leidžia įmonėms kurti efektyvesnes verslo strategijas ir nustatyti savo konkurencinius pranašumus. Natūralios kalbos apdorojimo priemonės, tokios kaip teksto analizė, padeda iš didelių duomenų kiekio greitai analizuoti konkurentų naujienas ir strategijas, socialiniuose tinkluose nagrinėjama rinkodaros kampanijų tikslai, bei vartotojų reakcijos. Generatyviniai teksto modeliai, gali sukurti konkurencingumo analizei taikomus metodus gaminamam produktui, pavyzdžiui, PESTEL, Porterio penkių jėgų ir kitos panašios analizės. Prižiūrimo mokymosi modeliai, tokie kaip klasifikacija, identifikuoja konkurentų segmentus pagal jų veiklos sritis, produktų asortimentą ir rinkos dalį. Klasterizacija gali grupuoti konkurentus pagal jų strateginius pranašumus, kainodarą ar rinkos fokusą. Šiuo atveju galime taikyti ir anomalijų aptikimo metodą, kuris identifikuoja reikšmingus konkurentų veiklos pokyčius, pavyzdžiui, staigius rinkos strateginius pakeitimus ar naujų produktų įvedimą. Konkurencingumo analizėje kompiuterinė rega taip pat gali gerai pasitarnauti, ji automatiškai analizuoja konkurentų produktų vizualinius pateikimus, stebi ir analizuoja reklamines kampanijas įvairiose platformose.

Technologijų tinkamumas. Technologijų tinkamumo vertinimas leidžia įmonėms nustatyti, kurios technologijos geriausiai atitinka kuriamo produkto poreikius. Tai apima technologinių sprendimų galimybių, pritaikomumo, išlaidų ir rizikos vertinimą. Integruojant natūralios kalbos apdorojimo metodus į technologijų tinkamumo analizės procesą, galima detaliau atlikti technologinių apžvalgų analizę, nuskaityti ir sekti naujausių technologinių tendencijų pranešimus ir prognozes. Mašininis mokymas taip pat gali ženkliai prisidėti prie technologijų tinkamumo analizės, pavyzdžiui, regresijos metodas vertina technologijų našumą ir jų poveikį verslo rodikliams. Neprižiūrimo mokymo klasterizacijos metodas gali grupuoti technologijas pagal panašumą, kurios leidžia nustatyti alternatyvias galimybes. Technologijų tinkamumui nusakyti galima integruoti ir sustiprintą mokymąsi, kuris testuoja skirtingus technologijų naudojimo scenarijus taip randant optimaliausią sprendimą. Pradėjus kurti technologinius prototipus, kompiuterine rega vertina jų veikimą, identifikodama našumo trūkumus arba privalumus.

3.1.4. IV Etapas. Produkto kūrimas

Produkto dizainas ir projektavimas. Produkto dizainas ir projektavimas apima koncepcijos vizualizavimą, techninių brėžinių ir prototipų kūrimą bei estetinių, funkcinų ir

ergonominių sprendimų tobulinimą. Šis veiksnys yra svarbus, siekiant užtikrinti, kad produktas atitiktų vartotojų poreikius ir techninius reikalavimus. Produkto projektavimo procese, natūralios kalbos apdorojimo metodai, gali apdoroti dideles apimties techninius reikalavimus, bei standartus, taip kuriant optimaliausius produkto sprendimus. Integravus prižiūrimo mokymosi, regresijos metodą, galima prognozuoti dizaino komponentų poveikį vartotojų pasitenkinimui arba gamybos efektyvumui. Neprižiūrimo mokymosi klasterizacija grupuoja vartotojų poreikius ar funkcijas pagal prioretizuotus dizaino elementus. Kiek sudėtingesnis pritaikymo atvejis, tai sustiprinto mokymosi metodas, kuris galėtų optimizuoti dizaino sprendimus, pavyzdžiui, modeliuoja skirtingus dizaino variantus ir parenka geriausią sprendimą pagal gamybos reikalavimus bei vartotojų poreikius. Produkto projektavimo procese didžiausią DI įtaką turi generatyvinis dizainas. Generatyvinis projektavimas apibūdinamas kaip kompiuterinio projektavimo metodika, kurioje pasitelkiama mašininio mokymosi algoritmai, euristiniai paieškos metodai ir optimizavimo metodai, kad sukurtų, įvertintų ir patobulintų dizaino alternatyvas, leidžiančias savarankiškai kurti ir vertinti daugybę projektavimo alternatyvų, remiantis iš anksto nustatytais tikslais ir apribojimais, pvz., medžiagų efektyvumu, struktūriniu vientisumu ir gamybos galimybėmis ir kt. Šis metodas ypač naudingas gamyboje, nes leidžia kurti lengvus, bet tvirtus komponentus, mažina medžiagų švaistymą ir optimizuoja dizainą konkreitiems gamybos metodams. Generatyvinis projektavimas supaprastina projektavimo ir gamybos darbo eigą, gerokai pagerina gaminio našumą ir tvarumą, pranokdamas įprastų gaminių projektavimo metodikų galimybes. Generatyvinio dizaino algoritmus taiko tokios programos kaip „Autodesk Fusion 360“, „Rhino + Grasshopper“, „Siemens NX“ ir kt. Kompiuterinės regos integravimas galėtų vertinti gaminamo gaminio ar prototipo estetiką, ergonomiką, silpnąsias vietas, defektus ir kt.

Prototipo vystymas. Prototipo vystymas apima suprojektuoto modelio pavertimą realiai veikiančiu modeliu, kuris leidžia patikrinti produkto funkcionalumą, našumą ir techninius reikalavimus. Tai yra svarbus etapas siekiant nustatyti galimas klaidas ar tobulinimo galimybes prieš gamybą etapą. Prototipo vystymo etape taip pat galima integruoti generatyvinio dizaino projektavimo principus, tačiau labiausiai pritaikoma DI kategorija – kompiuterinė rega. Kompiuterinė rega gali padėti aptikti gamybos klaidas ar neatitikimus nuskaitant prototipo paviršių ar struktūrą, pavyzdžiui, automobilio dalių gamyboje kompiuterinė rega gali būti naudojama paviršiaus defektams aptikti. Kamera su aukštos raiškos jutikliu nuskaito detalės paviršių, o algoritmai palygina jį su idealios detalės modeliu, kad aptiktų nukrypimus. Taip pat kompiuterinė rega gali vertinti prototipo funkcionalumą realaus naudojimo scenarijuose, pavyzdžiui, stebint dūmų srauto judėjimą vėjo tuneliuose aplink automobilio paviršių, taip

įvertinant prototipo aerodinamiką. Vaizdo analizė padeda nustatyti vietas, kuriose dizainas turėtų būti optimizuotas.

Technologijos testavimas. Technologijos testavimas apima produkto veikimo patikrinimą pagal nustatytus kriterijus ir standartus. Tai padeda identifikuoti technines problemas, patvirtinti veikimo stabilumą ir įvertinti, ar technologija atitinka vartotojų ir rinkos poreikius. Integruojant natūralios kalbos apdorojimo modelius galima automatiškai analizuoti didelius kiekius testavimo duomenų ir sukurti santraukas apie technologijos našumą. Prižiūrimo mokymosi regresijos metodas gali prognozuoti technologijos veikimo rodiklius (tikslumas, efektyvumas, patikimumas, sparta, jautrumas ir kt.) remiantis ankstesniais testavimo duomenimis. Technologijų testavime pravartu integruoti anomalijų aptikimą, kuris identifikuoja retai pasitaikančias problemas ar netipinius veikimo nukrypimus. Ši integracija ženkliai sumažintų gamybinio broko riziką. Kompiuterine rega šiuo atveju gali rasti veikimo trūkumus arba sutrikimus tikrinant vizualines technologines dalis.

Darbo srautų automatizavimas. Darbo srautų automatizavimas fokusuojasi į pasikartojančių, rankinių užduočių pakeitimą automatizuotais procesais. Tai padeda sumažinti darbo laiko sąnaudas, klaidų tikimybę ir leidžia darbuotojams sutelkti dėmesį į strateginius tikslus. Darbo srautų automatizavime iš DI klasifikacijos labiausiai įtakos turi - RPA (robotizuota procesų automatizacija). RPA leidžia automatizuoti pasikartojančias ir taisyklėmis paremtas užduotis, kurias paprastai atlieka žmonės. Naudojant programinius agentus, RPA gali imituoti žmogaus veiksmus kompiuterio sąsajoje, tokius kaip: duomenų įvedimas, kopijavimas, failų perkėlimas, el. laiškų siuntimas ar sistemų sujungimas. Tai sumažina klaidų tikimybę, pagreitina procesus ir leidžia darbuotojams sutelkti dėmesį į sudėtingesnes užduotis, kurios reikalauja kūrybiškumo ar sprendimų priėmimo galimybių. RPA yra lengvai integruojamas į skirtingas sistemas ir programas. Populiariausios kompanijos siūlančios RPA paslaugas yra tokios kaip „UiPath“, „Automation Anywhere“

Projektų valdymas. Projektų valdymas - tai žinių, įgūdžių, priemonių ir metodų taikymas projekto veikloje, siekiant įgyvendinti projekto reikalavimus. Tai planavimo, organizavimo ir užduočių, reikalingų inovatyviai idėjai paversti apčiuopiamu produktu, vykdymo praktika. Natūralios kalbos apdorojimo priemonės, tokios kaip teksto analizavimas, gali automatiškai apdoroti projektu planus, užduočių aprašus, ataskaitas, jas susisteminti ir išanalizuoti. Generatyvinis teksto metodas, labiau integruojasi į komunikacijos valdymą, kuris automatiškai generuoja susitikimų protokolus, el. laiškus, pokalbius, iš jų sukuria išvalgas, bei išvadas. Todėl šiame etape taip pat daug įtakos turi ir ankščiau aprašyti RPA modeliai. Integruojant prižiūrimo mokymosi, regresijos metodą, galima prognozuoti projekto eigą remiantis istoriniais duomenimis. Neprižiūrimo mokymosi klasterizacija gali grupuoti projekto

užduotis pagal sudėtingumą arba tam tikras priklausomybes. Svarbu atsižvelgti ir į anomalijų aptikimo modelius, kurie gali nustatyti galimus resursų vėlavimus, trūkumus, perteklių. Kompleksiškesnis sprendimas būtų pritaikyti sustiprintą mokymąsi, kuris galėtų mokintis iš vykdomų projektų ir tobulinti jų spendimus.

3.1.5. V Etapas. Testavimas ir įgyvendinimas

Simuliaciniai modeliai. Simuliaciniai modeliai leidžia virtualiai modeliuoti produkto ar paslaugos veikimą realiomis sąlygomis, prieš pradedant gamybą. Tai padeda analizuoti, prognozuoti ir tobulinti dizaino, bei veikimo parametrus, sumažinant sąnaudas ir rizikas. Simuliacinio modelio kūrimo procese labiausiai įtakos turi DI generatyvinis projektavimas ir skaitmeninis dvynys. Generatyvinio dizaino simuliacija gali sukurti alternatyvius simuliacijos scenarijus ir modelio parametrų derinius, kurie gali būti testuojami virtualioje aplinkoje, leidžiant palyginti įvairias alternatyvas. Ji padeda rasti optimalų sprendimą pagal našumo, medžiagų sąnaudas ar kitus kriterijus. Generatyvinė simuliacija remiasi įvestais pradiniais reikalavimais (medžiagos, apkrovos, aplinkos sąlygos) ir algoritmais, tam kad generuotų alternatyvas, tačiau realūs duomenys gali būti naudojami tik pagrįsti sprendimus. Tokias simuliacijas galima atlikti su tokiomis programomis, kaip „OpenAI Codex“ arba „IBM Watson“. Skirtingai, nei generatyvinis simuliacijos projektavimas, skaitmeninis dvynys naudoja realius duomenis iš fizinių sistemų (pvz., jutiklių duomenis, IoT informaciją) tam, kad tiksliai atspindėtų objekto būseną. Skaitmeninis dvynys siekia tiksliai atkartoti realų objektą ir pagerinti jo efektyvumą. Pavyzdžiui, automobilio variklio skaitmeninis dvynys gali būti naudojamas siekiant įvertinti šilumos išsklaidymą ir mechaninį patvarumą. Taip pat skaitmeninis dvynys padeda iš anksto aptikti potencialius gedimus taip sumažinant priežiūros ir eksploatacijos išlaidas. Skaitmenio dvynio kūrimo priemonės dažniausiai atliekamos su „Siemens Mindsphere“, „Ansys Twin Builder“ programomis. Simuliacinio modeliavimo procesuose taip pat pravartu integruoti prižiūrimą ir neprižiūrimą mokymąsi, pavyzdžiui, regresija naudojama modeliuoti sistemos veikimo rodiklius: našumas, efektyvumas, energijos sąnaudos, produkcijos apimtis ir kt. Klasifikacija daugiau pritaikoma analizuojant įvairių modelio komponentų tinkamumą pagal nurodytas kategorijas, pavyzdžiui, „reikalinga korekcija“, „tinkamas gamybai“. Klasterizacija gali grupuoti modelio komponentus ar parametrus pagal jų veikimo savybes, pavyzdžiui panašios apkrovos ar gėdimai. Pravartu integruoti ir anomalijų aptikimo sistemas, kurios gali identifikuoti veikimo sutrikimus arba neįprastą sistemos elgesį. Galima integruoti į simuliacinio modeliavimo procesą ir kompiuterinę regą, kuri gali realiu laiku reaguoti į modeliuojamus pokyčius ir pateikti veikimo

analizės įžvalgas. Viena iš tokių paslaugų gali atlikti programinė įranga „OpenCV“ arba „Google Cloud Vision“.

Rizikų valdymas. Rizikų valdymas apima galimų grėsmių identifikavimą, jų poveikio įvertinimą ir sprendimų priėmimą. Šiame etape pasitelkiamos DI priemonės leidžia ne tik nustatyti rizikas, bet ir efektyviau jas valdyti, analizuojant sudėtingus duomenų rinkinius bei simuliuojant alternatyvius scenarijus. Mašininio mokymosi, klasifikacijos metodas, gali greitai ir efektyviai kategorizuoti rizikas pagal jų tipą ar poveikį, pavyzdžiui, didelė, vidutinė, maža ir panašiai. Regresija gali vertinti galimų rizikų tikimybę arba priešingai prognozuoti sėkmės rodiklį iš sekamų rodiklių, pavyzdžiui gamybos temperatūra, surinkimo greitis, naudojamų medžiagų kokybė, darbuotojų patirties lygis, drėgmės lygis gamybos ceche ir panašiai. Sustiprinto mokymosi modeliai remiantis istoriniais duomenimis gali sukurti strategiją kaip sumažinti riziką realiuoju laiku. Kompiuterinė rega taip pat gali prisidėti prie rizikos valdymo proceso, pavyzdžiui, identifikuojant defektus gamybos linijoje.

Našumo optimizavimas. Našumo optimizavimas orientuotas į veiklos procesų efektyvumo didinimą, siekiant sumažinti išlaidas, laiką ar išteklius, reikalingus tikslams pasiekti. Naudojant prižiūrimo mokymosi, regresijos metodą, galima prognozuoti našumo rodyklus, tokius kaip, energijos sąnaudos, ciklo laikas, prastovų dažnis, savikaina, išėigos rodiklis, darbo našumas ir panašiai. Papildomai klasifikacijos metodas, gali šiuos rodiklius kategorizuoti pagal našumo lygį, pavyzdžiui, „aukštas“, „žemas“, „vidutinis“. Dar vienas galimas integravimo metodas – anomalijų aptikimas, jos identifikuoja veiklos procesus, kurie nepasiekia numatytų našumo rodiklių. Norint stebėti gamybos arba darbo procesą realiuoju laiku ir automatiškai nustatyti našumo problemų šaltinius galima integruoti kompiuterinę regą.

Reglamentavimas. Reglamentavimo procesas skirtas produktų teisiniam, techniniam ir pramonės standartų užtikrinimui. DI intelekto integracija šiame procese labiausiai fokusuojasi į natūralios kalbos apdorojimo priemonės. Tekstų analizė iš didelio kiekio duomenų greitai analizuoja ir sistemina reglamentus, standartus ir specifikacijas. Automatinis dokumentų lyginimas gali tikrinti ar dokumentai atitinka reglamentų reikalavimus ir esant reikalui sugeneruoti reikiamą tekstą. Reglamentavimo procesui tinka ir neprižiūrimo mokymosi, klasterizacijos integravimas, kuris gali grupuoti reglamentų reikalavimus pagal jų sąsajas, taip sutaupant daug laiko.

3.1.6. VI Etapas. Produkto paleidimas

Klientų pasitenkinimas. Klientų pasitenkinimo veiksnys apibūdina duomenų rinkimą ir analizę apie vartotojų patirtį, norint suprasti jų poreikius, identifikuoti problemas ir optimizuoti produktą. Šiame etape, kaip ir pirminiame *Stage-Gate* idėjos procese, galima integruoti

natūralios kalbos apdorojimo priemonės, tačiau šiuo atveju sentimentų analizė labiau orientuota į duomenų stebėjimą jau paleidimo metu, analizuojama klientų atsiliepimai ir socialinių tinklų įrašai. Iš šių duomenų nustatoma vartotojų nuotaiką ir pasitenkinimas. Visą šią gautą informaciją galima automatiškai apibendrinti ir suskirstyti. Į paskirstymo procesus galima įterpti prižiūravimo mokymosi, klasifikacijos metodą, kuris klasifikuoja klientų atsiliepimus į kategorijas, tokias kaip „teigiami“, „neigiami“, „neutralūs“ ir panašiai. Regresija tuos duomenis prognozuoja į pasitenkinimo indeksus. Vizualinę medžiagą iš socialinių tinklų apie produktą gali stebėti kompiuterinė rega, kuri gali nustatyti iškilusias problemas arba vartotojų reakcijas.

Rinkodaros strategijos įgyvendinimas. Rinkodaros strategijos įgyvendinimas apibūdina veiksmų plano vykdymą norint pristatyti produktą rinkai. Tai apima tikslinės auditorijos segmentavimą, tinkamų rinkodaros kanalų pasirinkimą, kampanijų efektyvumo analizę ir jų optimizavimą. Natūralios kalbos apdorojimo priemonės, tokios kaip, automatinio turinio kūrimas, gali generuoti greitai ir efektyviai reklaminius tekstus, anketas, užklausas, internetinių svetainių turinį ir panašiai. Vaizdo generavimo priemonėmis galima kurti vizualinius socialinių tinklų įrašus, internetinių svetainių dizainą, reklamas ir kitą panašų turinį, atsižvelgiant į pasirinktą vartotojų segmentą, poreikius ir pageidavimus.


Kainodaros strategija. Kainodaros strategijos kūrimas susijęs optimalios kainos nustatymu produktui, atsižvelgiant į rinkos poreikius, konkurenciją, klientų elgseną ir finansinius rodiklius. Natūralios kalbos priemonės, tokios kaip teksto analizės metodas, gali analizuoti vartotojų nuomones apie konkurentų kainas socialiniuose tinkluose. Pasitelkusi šiuos duomenis, generatyvinė teksto priemonė, generuoja rekomendacijas dėl tolimesnių kainodaros strategijų. Pasitelkus regresiją galima prognozuoti kainos įtaką pardavimų apimčiai ir pelningumui, klasifikacija nustato, kurie klientų segmentai reaguoja į tam tikrus kainų lygius.

Gamybos optimizavimas. Gamybos optimizavimas apima procesų efektyvumo gerinimą, resursų naudojimo optimizavimą ir kaštų mažinimą, užtikrinant aukštą produktų kokybę. Kompiuterinė rega gamybos optimizavime suteikia galimybę automatizuoti kokybės kontrolės, defektų aptikimo ir gamybos procesų stebėjimo užduotis, taip padidinant tikslumą ir efektyvumą. Pavyzdžiui, naudojant dirbtinio intelekto algoritmais paremtas vaizdo analizės sistemas, galima realiu laiku identifikuoti gamybos linijoje atsirandančius neatitikimus (pvz. pažeisti ar netiksliai surinkti komponentai) ir automatiškai pranešti apie esamą problemą į sistemą arba sustabdyti gamybą. Toks sprendimas ne tik taupo laiką, bet ir mažina žmogaus klaidų riziką. Gamybos optimizavimo procese galima integruoti ir robotizuotas sistemas. Robotai gali atlikti monotoniškas, sudėtingas ar pavojingas užduotis greičiau ir tiksliau nei žmonės, tai lemia sumažintas prastovas ir gamybos kaštus. Be to, jų diegimas leidžia lanksčiau reaguoti į rinkos poreikius, didinant gamybos apimtį arba pritaikant procesus naujiems

produktams. Automatizavus dalinai arba visiškai produkto gamybą, galima pasitelkti ir RPA sistemomis, kurios automatizuoja pasikartojančias užduotis skaitmeninėje erdvėje, pavyzdžiui inventorizacija, tiekimo gardinės valdymas ir kiti panašūs procesai.

3.2. Inovatyvių produktų kūrimo modelis, pagrįstas dirbtinio intelekto taikymu

Šioje dalyje remiantis literatūros analize ir empiriniu tyrimu, sukurtas DI integracijos modelis inovatyvių produktų kūrimo procesuose (15 pav.).



15 pav. DI integravimas inovatyvaus produkto kūrimo procesuose

Šaltinis: sudaryta autoriaus.

Modelis sistemingai vaizduoja dirbtinio intelekto integraciją į inovacijų kūrimo procesą, remiantis „Stage-Gate“ modeliu. Šis modelis yra struktūruotas į šešis pagrindinius etapus – nuo idėjos formavimo iki galutinio produkto paleidimo. Modelis leidžia matyti, kaip kiekviename

iš šių etapų integruojamos specifinės DI technologijos, kategorijos ir praktiniai įrankiai, sustiprinant inovacijų proceso efektyvumą, greitį ir tikslumą.

Kiekvienas inovacijų kūrimo etapas yra susietas su konkrečiomis integravimo sritimis. Pradiniame „Idėjos“ etape DI padeda vykdyti idėjų generavimą, technologijų analizę, rinkos tyrimus bei idėjų tyrinėjimą. Tuo tarpu „Pirminės apžvalgos“ etape daugiausia dėmesio skiriama koncepcijos plėtojimui, vartotojų poreikių analizei ir rizikų identifikavimui. Vėlesniuose etapuose – verslo atvejo analizėje, kūrime ir testavime – DI pasitelkiamas verslo planų rengimui, prototipų testavimui, technologijų tinkamumo vertinimui, našumo optimizavimui, reglamentavimo atitikčiai ir rizikos valdymui. Galiausiai, paleidimo fazėje DI naudojamas klientų pasitenkinimo analizei, kainodaros strategijai kurti, gamybos optimizavimui bei rinkodaros sprendimų įgyvendinimui.

Modelyje išskirtos DI kategorijos parodo taikomų technologijų spektrą. Dominuoja natūralios kalbos apdorojimas, kuris taikomas teksto analizei ir automatinio turinio generavimui, dažniausiai naudojant tokias sistemas kaip ChatGPT. Prižiūromo mokymosi metodai, tokie kaip klasifikacija ir regresija, pasitelkiami prognozuoti rinkos elgseną, analizuoti vartotojų duomenis, vertinti verslo rizikas ar pardavimų dinamiką. Neprižiūromas mokymasis, apimantis klasterizaciją ir asociacijų analizę, naudojamas idėjų ar klientų segmentų grupavimui bei netipinių duomenų struktūrų atpažinimui. Kai kuriuose etapuose pasitelkiamas ir sustiprintas mokymasis, kuris leidžia sistemoms interaktyviai tobulėti priimant sprendimus realiuoju laiku. Kompiuterinė rega – dar viena svarbi DI kategorija – taikoma produktų dizaino, prototipų ar gamybos procesų vizualinei analizei bei kokybės kontrolei. Vėlesniuose kūrimo etapuose integruojami generatyvinio dizaino sprendimai (pvz., „Autodesk Fusion 360“) leidžia automatizuotai modeliuoti daugybę dizaino alternatyvų pagal nustatytus parametrus. Taip pat minima robotizuota procesų automatizacija, kuri automatizuoja pasikartojančias skaitmenines užduotis, ypač naudinga verslo ar gamybos procesuose.

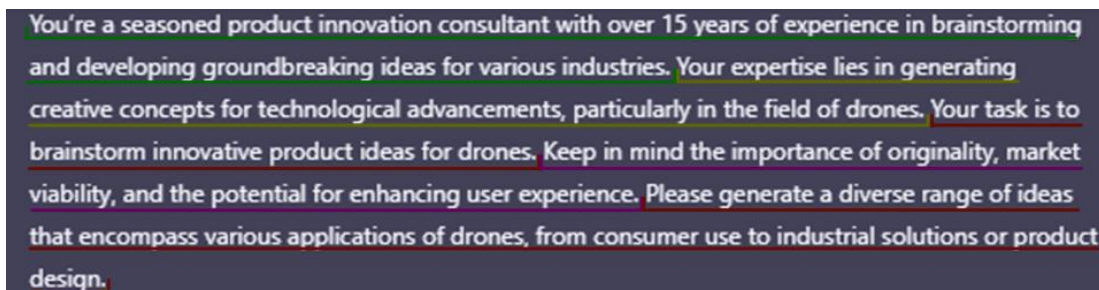
Apatinėje modelio dalyje pateiktos konkrečios technologinės priemonės, kurios yra taikomos skirtinguose etapuose. *ChatGPT* nurodomas kaip pagrindinis įrankis užduotims atlikti. Mašininio mokymosi algoritmams taikyti išskiriamos *TensorFlow* ir *PyTorch* bibliotekos. Kompiuterinės regos sprendimai dažniausiai grindžiami *OpenCV* įrankiais. RPA užduotims vykdyti pasitelkiamos platformos kaip *UiPath*, o generatyviniam dizainui – *Autodesk Fusion 360*. Šių technologijų įvairovė rodo ne tik platų DI taikymo spektrą, bet ir galimybę automatizuoti tiek analitines, tiek kūrybines ar operacines inovacijų proceso dalis.

3.3. Inovatyvių produktų kūrimo proceso simuliacija taikant dirbtinį intelektą

3.3.1. I Etapas. Idėjų generavimas

Pirmasis etapas pradėdamas nuo pirmųjų idėjų generavimo. Šiam veiksmui atlikti naudojamas natūralios kalbos generavimo modelis – *ChatGPT*. Generatyvinio teksto modeliuose svarbiausias kriterijus yra teisingas užklauso formulavimas. Kuo tiksliau ir detaliau yra suformuluojama užklausa tuo gaunamas efektyvesnis rezultatas.

Užklausa dažniausiai galima suskaidyti į atskiras formulavimo dalis (16 pav.). Paveiksle žalia spalva nurodo užklauso formulavimo pradžią, kurioje suteikiama dirbtinio intelekto algoritmams „pareigos“. Šiuo atveju nurodoma, kad DI yra patyręs inovatyvių produktų kūrimo konsultantas, turintis 15 metų patirties. Geltona spalva žymi papildomus kriterijus, kurių norime iš rezultato. Raudona spalva nurodo, kokia yra pagrindinė užduotis ir tikslas. Šiuo atveju pagrindinė užduotis – sugeneruoti inovatyvaus drono idėjas, pritaikant minčių šturmo metodą. Violetinė spalva nurodo gaires išsamesniam atsakymui šiuo atveju: originalumas, vartotojų potencialas, rinkos prieinamumas. Papildomai užklauso pabaigoje galima nurodyti norimo rezultato formatą, pvz., lentelė, tekstinis dokumentas, pastraipa ir panašiai.

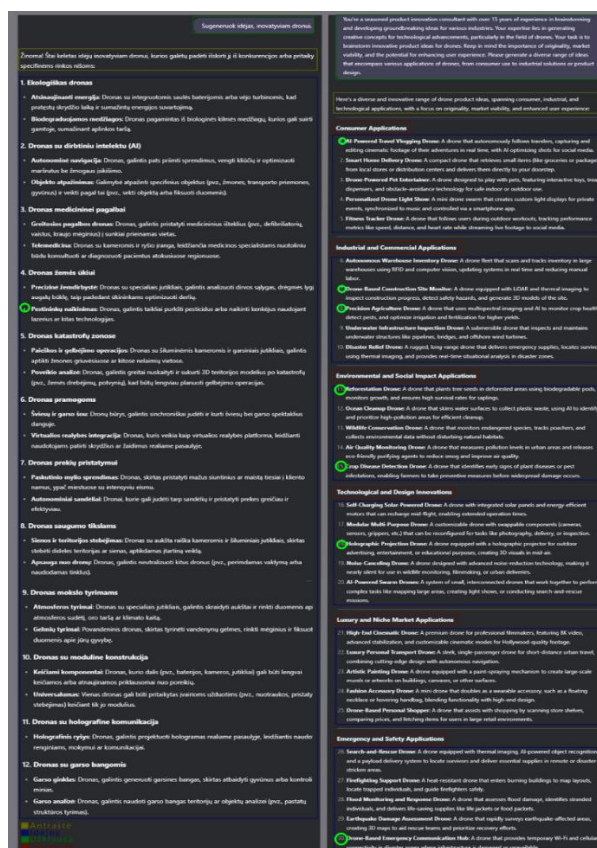
The image shows a text box with a dark background and light-colored text. The text is a prompt for a product innovation consultant. It is color-coded: green for the role and context, yellow for additional criteria, red for the main task, and purple for specific guidelines. The text reads: "You're a seasoned product innovation consultant with over 15 years of experience in brainstorming and developing groundbreaking ideas for various industries. Your expertise lies in generating creative concepts for technological advancements, particularly in the field of drones. Your task is to brainstorm innovative product ideas for drones. Keep in mind the importance of originality, market viability, and the potential for enhancing user experience. Please generate a diverse range of ideas that encompass various applications of drones, from consumer use to industrial solutions or product design."

16 pav. Užklauso formulavimas

Šaltinis: sudarytas autoriaus.

Simuliacijos metu buvo sugeneruotos dvi skirtingos užklauso (17 pav.). Kairėje pusėje užklausa sudaro vieną sakinį, dešinėje pusėje užklausa daugiau detalizuota (pritaikytos gairės užklauso formavimui) ir sudaryta iš daugiau sakinių. Tamsiai žalia spalva nurodo, kokios užklauso buvo panaudotos. Geltona spalva žymi sugeneruotas antraštes naujoms idėjoms. Raudona spalva nurodo idėjų temą, tačiau šis rezultatas gavosi tik su detalesne užklausa. Mėlyna spalva žymi sugeneruotas idėjas. Šiuo atveju daugiau potencialių idėjų buvo sugeneruota su detalesne užklausa. Iš viso tolesniam darbui pasirinktos 7 skirtingos inovatyvių dronų idėjos:

- 1) Dronas, skirtas kelionių vaizdo įrašams su DI integracija kurti. Dronas, kuris autonomiškai seka keliautojus, realiuoju laiku fiksuoja ir montuoja kinematografinius kadrus, o dirbtinis intelektas optimizuoja socialinei žiniasklaidai skirtas nuotraukas.
- 2) Dronas statybvietsės stebėjimui. Dronas su LiDAR ir termovizoriumi, kuriuo galima tikrinti statybų eigą, aptikti saugos pavojus ir kurti 3D statybvietsės modelius.
- 3) Agrokultūros stebėjimo dronas. Dronas, kuris naudoja daugiaspektrinius vaizdus ir dirbtinį intelektą pasėlių būklei stebėti, kenkėjams aptikti, drėkinimui ir tręšimui optimizuoti.
- 4) Dronas, skirtas miškams atkurti. Dronas, kuris, naudodamas biologiškai suyrančias ankštis, sodina medžių sėklas išskirstuose miško plotuose, stebi augimą ir užtikrina aukštą sodinukų išgyvenamumo lygį.
- 5) Dronas, naudojamas augalų ligoms aptikti. Dronas, kuris nustato ankstyvuosius augalų ligų ar kenkėjų antplūdžio požymius, todėl ūkininkai gali imtis prevencinių priemonių, kol dar nepadaryta didelė žala.
- 6) Holografinės projekcijos dronas. Dronas su holografiniu projektoriumi, skirtas lauko reklamai, pramogoms ar švietimui.
- 7) Dronas, skirtas agrokultūros kenkėjams naikinti lazeriu.




17 pav. Idėjų generavimas skirtingomis užklausomis

Šaltinis: sudarytas autoriaus.

Šiame etape taip pat buvo pasitelktas vaizdinis generatyvinis modelis DALL-E, kuris leido vizualizuoti pirmines idėjas. Šios vizualizacijos bus naudojamos tolimesniuose produkto vystymo etapuose.

Vaizdinių generavimo medeliuose taip pat naudojamos užklausoje, kurios yra itin svarbios galutiniam rezultatui. Pavyzdyje naudotoje užklausoje nurodoma, kad reikia sugeneruoti inovatyvių dronų vizualizacijas, naudojant techninio eskizo stilių, pritaikant detalias linijas, modernius dizaino elementus ir dinamiškus kampus. Taip pat dėl vienodos standartizuotos tvarkos nurodomas paveikslų formatas 1:1. Gautas rezultatas parodytas 18 paveiksle.

Dirbtiniu intelektu sugeneruoti dronų dizaino eskizai pateikia platų technologinių ir estetinių sprendimų spektrą, reprezentuojantį ankstyvasias inovatyvaus produkto kūrimo stadijas. Dronų modelių formos išlaiko aerodinamiškumą, o vizualiniuose sprendimuose atsispindi propelerių, kamerų laikiklių bei jutiklių variacijos. Šie dizaino sprendimai pateikia skirtingus dronų taikymo kontekstus – nuo filmavimo ar žvalgybos iki transportavimo ar mokslinių tyrimų.



18 pav. Idėjų vizualizacijos

Šaltinis: sudarytas autoriaus.

Toliau atliekama technologijų analizė. Šiame etape pasirinktom idėjoms generatyvinio teksto modelis *ChatGPT* gali sukurti galimas naujų technologijų pritaikymo idėjas, paremtas analizuotais duomenimis ir rinkos poreikiais. Suformulavus užklausą su jau aptartomis gairėmis gautas rezultatas pateikiamas 10 lentelėje. Lentelėje kiekvienai pasirinktai idėjai yra priskiriamos trys technologijų kategorijos: taikomos, tobulinamos ir naujos.

10 lentelė. Technologinis pagrindumas pasirinktoms idėjoms

Dronas, skirtas kelionių vaizdo įrašams kurti su DI integracija	
Kategorija	Technologijos
Taikomos technologijos	Mašininis mokymas, kompiuterinis regėjimas, 5G, stabilizavimas, balsinis valdymas.
Tobulinamos technologijos	Baterijos veikimo laikas, DI personalizavimas, triukšmo mažinimas.
Naujos technologinės idėjos	Išplėstinė realybė (angl. <i>augmented reality</i>), minios vengimas, keleto dronų bendradarbiavimas.
Dronas, skirtas statybvietei stebėti	
Kategorija	Technologijos
Taikomos technologijos	LIDAR, termografija, DI analitika, autonominė navigacija.
Tobulinamos technologijos	Realiojo laiko duomenų apdorojimas, patvarumas, integracija su BIM.
Naujos technologinės idėjos	Medžiagų atpažinimo DI, darbuotojų saugos stebėjimas, automatinis ataskaitų generavimas.
Žemės ūkio dronas	
Kategorija	Technologijos
Taikomos technologijos	Daugiaspektrė fotografija, mašininis mokymas, GPS, automatinis purškimo sistema.
Tobulinamos technologijos	Baterijos efektyvumas, duomenų integracija, kainų mažinimas.
Naujos technologinės idėjos	Dirvožemio analizės jutikliai, prognozuojamoji analitika, spiečiaus technologija.
Dronas naudojamas miškų atkūrimui	
Kategorija	Technologijos
Taikomos technologijos	Biodegraduojamos sėklų kapsulės, autonominė navigacija, augimo stebėjimo jutikliai.
Tobulinamos technologijos	Sėklų kapsulių dizainas, baterijos veikimo laikas, duomenų tikslumas.
Naujos technologinės idėjos	Laistymo dronai, kenkėjų kontrolės integravimas.
Dronas augalų ligų aptikimui	
Kategorija	Technologijos
Taikomos technologijos	Hiperspektrinė fotografija, mašininis mokymas, GPS žemėlapiai, realaus laiko įspėjimai.
Tobulinamos technologijos	Jutiklių jautrumas, kainų efektyvumas.
Naujos technologinės idėjos	Automatinis gydymas, orų prognozės integravimas.
Holografinės projekcijos dronas	
Kategorija	Technologijos

Taikomos technologijos	Holografinė projekcija, autonominė navigacija, 5G ryšys.
Tobulinamos technologijos	Ryškumas ir aiškumas, baterijos veikimo laikas, turinio kūrimo įrankiai.
Naujos technologinės idėjos	Kelių dronų sinchronizacija.
Dronas agrokultūros kenkėjų naikinimui lazeriu	
Kategorija	Technologijos
Taikomos technologijos	Lazerio technologija, kompiuterinė rega, autonominė navigacija, termografija;
Tobulinamos technologijos	Lazerio tikslumas, energijos vartojimo efektyvumas, saugos mechanizmai,
Naujos technologinės idėjos	kenkėjų duomenų bazės integracija, spiečiaus technologija.

Šaltinis: sudarytas autoriaus.

Kitas etapas – idėjų tyrinėjimas. Atliekant simuliaciją, idėjų tyrinėjimo etape buvo panaudota natūralios kalbos teksto klasifikacijos priemonė, kuri jau sugeneruotas idėjas suskirsto jas pagal jų tematiką, svarbą, segmentus ir panašiai. Šiam procesui atlikti naudojama „SpaCy“ biblioteką ir „Python“ programavimo kalba (pav. 19).

Pirmas žingsnis – modelio paruošimas. Kodo pradžioje importuojamos reikalingos bibliotekos, šiuo atveju „Spacy“ biblioteka, panaudojant *import* funkciją. Toliau sukuriamas „SpaCy“ NLP objektas anglų kalbai: *nlp = spacy.blank("en")*. Prie šio objekto pridedamas *textcat* komponentas – teksto kategorijų klasifikatorius. Tuomet pridedamos penkios skirtingos kategorijos (etiketės), kurios atitinka dronų taikymo sritis: video kūrimo, statybos, agrokultūra, gamta ir technologijos.

Po modelio paruošimo atliekamas atras etapas – mokymo duomenų paruošimas ir modelio mokymas. Sukurtas *train_data* sąrašas, kuriame pateikti sakiniai apie dronus ir kiekvienam jų priskirtos kategorijos (1 reiškia, kad sakinyje aptariama konkreiti sritis; 0 reiškia, kad ta sritis netaikoma). Toliau modelis treniruojamas 10 iteracijų, kiekvieną kartą atsitiktinai maišant treniravimo duomenis. Po treniravimo modelis išsaugomas faile.

Paskutinis etapas – modelio testavimas. Šiuo atveju buvo testuojami du pavyzdžiai. Pirmo testo įvestis: dronas su dirbtiniu intelektu vaizdo įrašams redaguoti. Anksčiau sukurtas modelis aukščiausiai įvertino *Filmmaking* kategoriją (tikimybė ~0,86). Antro testo įvestis: dronas skirtas žemės ūkiui, juo galima stebėti pasėlius ir vertinti jų būklę. Modelis teisingai identifikavo *Agriculture* kaip tinkamiausią kategoriją (tikimybė ~0,38). Abu testavimai pasiteisino ir šio etapo simuliacija atlikta sėkmingai.

```

1 import spacy
2 from spacy.pipeline.textcat import TextCategorizer
3 import random
4 nlp = spacy.blank("en")
5
6 textcat = nlp.add_pipe("textcat", last=True)
7
8 textcat.add_label("Filmmaking")
9 textcat.add_label("Construction")
10 textcat.add_label("Agriculture")
11 textcat.add_label("Environment")
12 textcat.add_label("Technology")
13
14 train_data = [
15     ("Drone for travel video creation with AI integration.", {"cats": {"Filmmaking": 1, "Construction": 0, "Agriculture": 0, "Environment": 0, "Technology": 0}}),
16     ("Drone for construction site monitoring.", {"cats": {"Filmmaking": 0, "Construction": 1, "Agriculture": 0, "Environment": 0, "Technology": 0}}),
17     ("Agricultural drone for crop monitoring.", {"cats": {"Filmmaking": 0, "Construction": 0, "Agriculture": 1, "Environment": 0, "Technology": 0}}),
18     ("Drone for reforesting and planting trees.", {"cats": {"Filmmaking": 0, "Construction": 0, "Agriculture": 0, "Environment": 1, "Technology": 0}}),
19     ("Drone for detecting plant diseases.", {"cats": {"Filmmaking": 0, "Construction": 0, "Agriculture": 1, "Environment": 0, "Technology": 0}}),
20     ("Holographic projection drone.", {"cats": {"Filmmaking": 0, "Construction": 0, "Agriculture": 0, "Environment": 0, "Technology": 1}}),
21     ("Laser drone for pest control.", {"cats": {"Filmmaking": 0, "Construction": 0, "Agriculture": 0, "Environment": 1, "Technology": 0}}),
22 ]
23
24 optimizer = nlp.begin_training()
25 for epoch in range(10):
26     random.shuffle(train_data)
27     for text, annotations in train_data:
28         doc = nlp.make_doc(text)
29         example = spacy.training.Example.from_dict(doc, annotations)
30         nlp.update([example], sgd=optimizer)
31 nlp.to_disk("drone_text_classification_model")
32
33 print("Modelis sėkmingai išsaugotas kaip 'drone_text_classification_model'")

```

```

1 import spacy
2
3 nlp = spacy.load("drone_text_classification_model")
4
5 text = "Drone equipped with AI for video editing"
6
7 doc = nlp(text)
8
9 print(f" Kategorijos {vertinimas: {doc.cats}}")
10
11 best_category = max(doc.cats, key=doc.cats.get)
12 print(f" Geriausia kategorija: {best_category}")

```

```

1 import spacy
2
3 nlp = spacy.load("drone_text_classification_model")
4
5 text = "The drone is designed for agriculture, it can monitor crops and assess their condition"
6
7 doc = nlp(text)
8
9 print(f" Kategorijos {vertinimas: {doc.cats}}")
10
11 best_category = max(doc.cats, key=doc.cats.get)
12 print(f" Geriausia kategorija: {best_category}")

```

Kategorijos {vertinimas: {'Filmmaking': 0.8508368270527344, 'Construction': 0.834654960803627777, 'Agriculture': 0.052228656538388249, 'Environment': 0.016243222382555, 'Technology': 0.035979196429252625}}

Kategorijos {vertinimas: {'Filmmaking': 0.16272546350955963, 'Construction': 0.13206258416175842, 'Agriculture': 0.30748116970062256, 'Environment': 0.28670104026794434, 'Technology': 0.19102977216243}}

Geriausia kategorija: Filmmaking

Geriausia kategorija: Agriculture

19 pav. Sugeneruotų idėjų klasifikavimas

Šaltinis: sudaryta autoriaus.

Toliau atliekama rinkos analizė. Išskyrus potencialias idėjas, simuliacijoje buvo atsižvelgta ir į esamą rinką, kurioje parduodami panašūs produktai. Šiam procesui atlikti simuliacijos metu buvo panaudota natūralios kalbos apdorojimo priemonė – *Chatgpt*. 11 lentelėje pasirinktos idėjos yra įvertinamos pagal rinkos dydį, konkurentus esančius rinkoje, kainą ir galimus iššūkius.

11 lentelėje. Rinkos analizė.

Idėjos	Rinkos dydis	Konkurentai	Kaina (Eur)	Iššūkiai
Kelionių vaizdo įrašų kūrimo dronas su DI	Didelė ir auganti, prognozuojama 29,06 mlrd. USD iki 2030 m.	DJI (Mavic serija), Skydio, Autel Robotics	1 000–3 000	Didelė konkurencija, nuolatinis DI atnaujinimo poreikis
Statybvietės stebėjimo dronas	Reikšminga, 15,2 % CAGR nuo 2023 iki 2030 m.	DJI (Matrice serija), Parrot, senseFly	2 000–10 000	Reikalavimai reguliavimui, integracija su statybų valdymo sistemomis
Žemės ūkio dronas	Sparčiai auganti, prognozuojama 9,45 mlrd. USD iki 2030 m.	DJI (Agras serija), PrecisionHaw, Sentera	1 500–5 000	Ūkininkų švietimo ir mokymo poreikis

Miškų atsodinimo dronas	Nišinė, bet auganti, didėjantis dėmesys tvarumui	Dendra Systems, Flash Forest, BioCarbon Engineering	10 000+	Didelės investicijos, bendradarbiauti su pradinės būtinybė ekologinėmis grupėmis
Augalų ligų aptikimo dronas	Auganti, reikšmė didelė ūkyje žemės	DJI, Parrot, Sentera	2 000–6 000	Tikslūs DI algoritmai, integracija į žemės ūkio praktiką
Holografinės projekcijos dronas	Kylanti rinka, prognozuojama 11,65 mlrd. USD iki 2030 m.	ARHT Media, Light Field Lab	5 000–20 000+	Didelės kūrimo išlaidos, ribotas rinkos žinomumas
Dronas skirtas pasėlių kenkėjų naikinimui lazeriu	Nišinė, bet perspektyvi, ekologiškas sprendimas	DJI, AgEagle	10 000+	Reguliavimo kliūtys, būtinybė tiksliai taikyti lazerį

Šaltinis: sudaryta autoriaus.

Taip pat šiame etape galima naudoti teksto analizės sistemą, taikomą vartotojo atsiliepimui arba pasakojimui analizuoti. Ši analizė vykdoma naudojant natūralios kalbos apdorojimo priemonę *Google Cloud Natural Language*.

Pirmiausiai pasirenkama, koks tekstas bus analizuojamas. Šiuo atveju analizuojamas tekstas yra vartotojo pasidalintas pasakojimas internetiniame „*Commercialdronepilots*“ forume, kuriame jis aprašo savo patirtį apie droną ir taikomas purškimo sistemas žemės ūkyje (20 pav.). Pasirinktas atsiliepimas perkeliamas į *Google Cloud* darbalaukį.

The image shows a forum post on the left and its analysis in the Google Cloud Natural Language API on the right. The forum post is from a user named 'CaptainRisky' and discusses their experience with drone spraying. The API interface shows the text being analyzed with various entity and sentiment tags.

20 pav. Vartotojo atsiliepimas ir *Google Cloud Natural Language* priemonė

Šaltinis: sudaryta autoriaus.

Iš pateikto atsiliepimo *Google Cloud* pateikia tris skirtingus rezultatus: emocijų analizę, esamų objektų kategorizavimą ir tematinį klasifikavimą (21 pav.).

Score	Magnitude		
0.067	17,516	39. frustration	OTHER
-0.234	0.904	40. generator	OTHER
0.464	0.924	41. generator	OTHER
-0.765	0.912	42. hell	LOCATION
0.035	0.093	43. job	OTHER
0.929	0.985	44. land	LOCATION
-0.595	0.579	45. manner	OTHER
-0.273	0.328	46. mission	OTHER
-0.933	0.918	47. obstacle avoidance	OTHER
0.949	0.985	48. obstacles	OTHER
0.021	0.07	49. one	PERSON
0.255	0.451	50. operators	PERSON
-0.088	0.099	51. paddock	LOCATION
0.138	0.197	52. pasture	LOCATION
0.966	0.985	53. pastures	LOCATION
0.633	0.098	54. phone	CONSUMER GOOD
-0.267	0.325	55. pics	WORK OF ART
0.034	0.415	56. pictures	WORK OF ART
-0.461	0.599	57. pilot	PERSON
-0.004	0.076	58. point	OTHER
-0.963	0.934	59. power	OTHER
0.912	0.949	60. power	OTHER
0.903	0.935	61. price	OTHER
-0.748	0.818	62. seed spreader	OTHER
0.473	0.549	63. sort	LOCATION
-0.859	0.934	64. surprise	OTHER
0.949	0.987	65. thing	OTHER
0.023	0.292	66. things	OTHER
0.049	0.085	67. tractor	CONSUMER GOOD
0.019	0.069	68. trailer	OTHER
Score Range: 0.25 - 1.0, -0.25 - 0.25, -1.0 - -0.25			
/Computers & Electronics/Consumer Electronics/Drones & RC Aircraft Confidence: 0.69191694		/Business & Industrial/Agriculture & Forestry/Agricultural Equipment Confidence: 0.37155488	
		/Home & Garden/Patio, Lawn & Garden/Yard Maintenance/Other Confidence: 0.19438967	
		/Business & Industrial/Agriculture & Forestry/Other Confidence: 0.18622553	

21 pav. Google Cloud atsiliepimo analizė

Šaltinis: sudaryta autoriaus.

Pirmoje nuotraukoje, kairėje pusėje, pateikiami kiekvieno sakinio sentimentų rezultatai, pagrįsti įvertinimu (nuo -1 iki -2,5; nuo -0,25 iki 0,25; nuo 0,25 iki 1), žymi emocinį nusiteikimą (nuo neigiamo iki teigiamo). Dydis, melsva spalva, žymi emocinės išraiškos stiprumą, nepriklausomai nuo teigiamos ar neigiamos krypties. Pavyzdžiui, sakiny „In frustration I contacted a couple of drone spray contractors...“ turi labai aukštą dydžio skalę (17,516), rodančią stiprią emocinę įtampą ar susierzinimą, įvertinimas yra neigiamas (-0,067), nurodantis neigiamą emociją.

Dešinėje nuotraukoje matoma sistema automatiškai atpažįsta ir kategorizuoja tam tikrus žodžius ar frazes (vadinamus entities), priskirdama juos kategorijoms, tokioms kaip:

- PERSON – asmenys (pvz., „pilot“),
- LOCATION – vietovės (pvz., „paddock“, „Australia“),
- CONSUMER GOOD – vartojimo prekės (pvz., „phone“, „tractor“),
- OTHER – kitos kategorijos.

Tai leidžia struktūrizuoti tekstą bei identifikuoti svarbiausias sąvokas. Šis procesas yra ypač naudingas teminei analizei, paieškai bei duomenų klasifikacijai.

Apatinėje nuotraukoje, pateikiami teksto klasifikavimo rezultatai pagal skirtingas pramonės šakas ar temas. Sistemos modelis klasifikuoja tekstą kaip priklausančią kelioms kategorijoms, nurodant pasitikėjimo koeficientus:

- Computers & Electronics / Consumer Electronics / Drones & RC Aircraft – 0.6919
- Business & Industrial / Agriculture & Forestry / Agricultural Equipment – 0.3715
- Home & Garden / Lawn & Garden / Yard Maintenance – 0.1943 ir kt.

Tai rodo, kad tekstas yra stipriausiai susijęs su elektronika bei dronais, bet taip pat yra aktualus žemės ūkio technikai ir aplinkos priežiūrai.

3.3.2. I Etapas. Vartų sistema

Šiame simuliacijos etape atliekama *Stage-Gate* modelio vartų sistema, t.y. atrenkamos, kurios potencialios idėjos keliauja į kitą etapą. Šiam procesui atlikti buvo pasitelktas *Chatgpt* modelis.

Užklausoje nurodama, kad dirbtinis intelektas yra „Stage-gate“ modelio ekspertas. Taip pat nurodoma, kad iš pasirinktų idėjų pirmajame etape sukurtu vartų sistemą (GO, HOLD, KILL, RECYCLE) bei užtikrintų šių veiksmų vykdymo kokybę, įvertintu verslo pagrindimu ir išteklius. Gautas rezultatas pateikiamas 12 lentelėje.

12 lentelė. Vartų etapas

Idėja	Verslo atvejo pagrindimas	Įgyvendinamumas	Rinkos potencialas	Derinimas su strateginiais tikslais	Resursų poreikiai	Vartų sprendimas
Dronas kelionių video kūrimui su AI integracija	Didelis potencialas vartotojų ir turinio kūrėjų rinkose	Techniškai įmanoma, bet reikalingas pažangus DI ir autonominis skrydis	Didelis	Gera dera su vartotojų technologijomis ir DI sprendimais	Didelės investicijos į DI ir dronų technologijas	GO
Dronas statybietės stebėjimui	Stipri vertė statybų sektoriui, gerina saugą ir efektyvumą	Techniškai įmanoma su esamomis technologijomis	Didelis	Gera dera su B2B ir pramoninėmis aplikacijomis	Vidutinės investicijos	GO
Žemės ūkio dronas derlių stebėjimui	Didelis potencialas tiksliai žemdirbystei	Techniškai įmanoma su DI ir daugiaspektrinėmis technologijomis	Didelis	Gera dera su agrotech ir tvarumo strategijomis	Vidutinės investicijos	GO
Dronas miškų atkūrimui	Stiprus aplinkosaugos ir socialinis poveikis, bet neaiškūs pelningumas	Techniškai įmanoma, bet yra sėklų kapsulių dizaino ir patvarumo iššūkių	Vidutinis	Gera dera su tvarumo ir socialinės atsakomybės strategijomis	Didelės investicijos	HOLD
Dronas augalų ligų aptikimui	Didelis potencialas siekiant	Techniškai įmanoma su DI ir vaizdų analize	Didelis	Gera dera su agrokultūros ir DI sprendimais	Vidutinės investicijos	GO

	ankstyvo ligų nustatymo					
Holografinės projekcijos dronas	Inovatyvus, bet rinkos potencialas nišinis	Techniškai sudėtinga, nes holografija vis dar vystosi	Vidutinis	Derėtų su inovacijų ir pažangių technologijų strategijomis	Didelės investicijos	RECYCLE
Dronas skirtas pasėlių kenkėjų naikinimui lazeriu	Didelis potencialas tvariam kenkėjų valdymui	Techniškai sudėtinga, reikalingas didelis tikslumas ir saugumas	Didelis	Gera dera su agrokultūros ir tvarumo strategijomis	Didelės investicijos	HOLD

Šaltinis: sudaryta autoriaus.

Po atliktos analizės DI modelio algoritmai atrinko keturias potencialas idėjas, kurios gali keliauti į antrą etapą, tačiau dėl galimos didelės darbo apimties buvo pasirinkta tik viena idėja - žemės ūkio dronas skirtas pasėlių stebėjimui. Todėl ši idėja detaliau bus nagrinėjama kituose simuliacijos etapuose.

3.3.3. II Etapas. Konceptijos detalizavimas

Šiame etape koncepcijos detalizavimas yra esminis procesas, kuriame pagrindinė idėja išvystoma į išsamų planą. Tam atlikti tinka natūralios kalbos apdorojimo *Chatgpt* algoritmai. Užklausoje nurodama informacija jau anksčiau sugeneruota, bei iškeliamas pagrindinis tikslas – detaliai išvystyti pasirinktą idėją. Sugeneruotojo lentelėje nr. 13 pateikiami pasirinktos idėjos techniniai reikalavimai, ekonominiai aspektai, vartotojų reikalavimai, pagrindinės savybės, vartotojų privalumai bei iššūkiai ir apribojimai.

13 lentelė. Pasirinktos idėjos detalizavimas atsižvelgiant į techninius reikalavimus, ekonominius aspektus, vartotojų reikalavimus, pagrindines savybes, išūkius ir apribojimus

Techniniai reikalavimai	
<i>Daugiaspektrė vaizdo gavimo sistema</i>	Dronas turi būti aprūpintas aukštos raiškos daugiaspektrinėmis kameromis, kurios gali fiksuoti duomenis įvairiose bangų srityse (matoma šviesa, artimoji infraraudonoji spinduliuotė ir šiluminė spinduliuotė). Tai leidžia atlikti išsamią augalų sveikatos, dirvožemio būklės ir vandens analizę.
<i>Dirbtinio intelekto analizė</i>	Dronas turėtų naudoti pažangius DI algoritmus realaus laiko duomenų apdorojimui. Šie algoritmai analizuos daugiaspektrinius vaizdus ir aptiks tokias problemas kaip maistinių medžiagų trūkumai, kenkėjų invazijos ir ligų protrūkiai.
<i>GPS ir autonominė navigacija</i>	Dronas turi turėti tikslią GPS sistemą ir autonominio skrydžio planavimo galimybes, kad būtų užtikrintas tikslus duomenų rinkimas ir efektyvus didelių plotų stebėjimas.
<i>Duomenų saugojimas ir perdavimas</i>	Dronas turėtų turėti pakankamai vidinės atminties aukštos raiškos vaizdams saugoti ir galimybę perduoti duomenis į debesų kompiuterijos platformas tolesnei analizei ir ilgalaikiam saugojimui.
<i>Patvarumas ir atsparumas aplinkos poveikiui</i>	Dronas turi būti sukurtas taip, kad atlaikytų sudėtingas žemės ūkio aplinkos sąlygas, įskaitant dulkes, drėgmę ir temperatūros svyravimus.
<i>Baterijos veikimo laikas ir įkrovimas</i>	Dronas turėtų turėti ilgą baterijos veikimo laiką (ne mažiau kaip 30 minučių skrydžio) ir palaikyti greitą įkrovimą arba keičiamas baterijas, kad sumažintų prastovos laiką.
Ekonominiai aspektai	

<i>Pradinė investicija</i>	Drono kaina, įskaitant daugiaspektrinę kamerą ir DI programinę įrangą, bus didelė pradinė investicija. Tačiau ilgalaikė nauda, tokia kaip didesnis derlius ir mažesnės sąnaudos, gali pateisinti išlaidas.
<i>Eksplotacijos išlaidos</i>	Ūkininkai turės atsizvelgti į drono priežiūros išlaidas, įskaitant baterijų keitimą, programinės įrangos atnaujinimus ir galimus remontus.
<i>Mastelio keitimas</i>	Dronas turėtų būti pritaikomas skirtingo dydžio ūkiams. Mažesni ūkiai galėtų dalintis išlaidomis per kooperatyvus arba nuomos galimybes.
<i>Investicijų grąža (ROI)</i>	Investicijų grąža turėtų būti aiškiai parodyta per atvejų analizes ir bandomuosius projektus, pabrėžiant, kaip dronas gali padidinti derlių, sumažinti pesticidų naudojimą ir pagerinti išteklių valdymą.
Vartotojo reikalavimai	
<i>Naudojimo paprastumas</i>	Dronas turėtų būti patogus naudoti, su intuityvia sąsaja skrydžio planavimui, duomenų rinkimui ir analizei. Turėtų būti teikiami mokymai ir palaikymas, kad ūkininkai galėtų efektyviai naudotis dronu.
<i>Pritaikomos ataskaitos</i>	Ūkininkai turėtų turėti galimybę generuoti pritaikomas ataskaitas pagal surinktus duomenis, pritaikytas konkrečioms kultūroms ir ūkininkavimo praktikoms.
<i>Integracija su esamomis sistemomis</i>	Drono surinkti duomenys turėtų būti suderinami su esama ūkininkavimo valdymo programine įranga, leidžiančia sklandžiai integruoti į ūkio darbų eigą.
<i>Mokymai ir palaikymas</i>	Turėtų būti teikiamos išsamios mokymo programos ir nuolatinė techninė pagalba, siekiant padėti ūkininkams maksimaliai išnaudoti drono galimybes.
Pagrindinės savybės	
<i>Realaus laiko stebėjimas</i>	Dronas suteikia realaus laiko įžvalgas apie augalų būklę, leidžiant nedelsiant imtis veiksmų, kad būtų išspręstos problemos.
<i>Tikslus žemės ūkis</i>	Nustatydamas konkrečias problemines zonas, dronas leidžia taikliai naudoti trąšas, pesticidus ir vandenį, sumažinant atliekas ir poveikį aplinkai.
<i>Istorinių duomenų analizė</i>	Dronas gali saugoti ir analizuoti istorinius duomenis, padedant ūkininkams sekti pokyčius laikui bėgant ir priimti informuotus sprendimus ateities sezonams.
<i>Ankstyva ligų ir kenkėjų aptikimas</i>	Dirbtinio intelekto algoritmai gali aptikti ligų ar kenkėjų užkrėtimo ankstyvus požymius, leidžiant anksti įsikišti ir sumažinti derliaus nuostolius.
<i>Derliaus prognozė</i>	Dronas gali pateikti derliaus prognozes, remdamasis dabartine augalų būkle ir aplinkos sąlygomis, padedant ūkininkams planuoti derliaus nuėmimą ir efektyviau parduoti produkciją.
Privalumai ūkininkams	
<i>Padidintas derlingumas</i>	Anksti nustatant ir sprendžiant problemas, ūkininkai gali žymiai padidinti savo derlių.
<i>Išlaidų taupymas</i>	Tikslus žemės ūkis sumažina trąšų, pesticidų ir vandens naudojimą, taupant lėšas.
<i>Aplinkosaugos tvarumas</i>	Taiklus išteklių naudojimas sumažina poveikį aplinkai, skatindamas tvarų žemės ūkį.
<i>Laiko taupymas</i>	Dronas gali greitai apimti didelius plotus, sumažinant laiką ir darbo jėgą, reikalingą rankiniam laukų stebėjimui.
<i>Duomenimis pagrįsti sprendimai</i>	Ūkininkai gali priimti geresnius sprendimus, remdamiesi tiksliais realaus laiko duomenimis, o tai pagerina bendrą ūkio valdymą.
Iššūkiai ir apribojimai	
<i>Didelės pradinės išlaidos</i>	Pradinė drono ir susijusios technologijos kaina gali būti per didelė mažų ūkių ūkininkams. Sprendimas: Siūlyti finansavimo galimybes, nuomos programas ar bendrą nuosavybę, kad technologija būtų prieinamesnė.
<i>Techninis sudėtingumas</i>	Kai kurie ūkininkai gali manyti, kad technologija yra sudėtinga ir bauginanti. Sprendimas: Teikti išsamų mokymą ir nuolatinę techninę pagalbą, kad ūkininkai galėtų jaunkiai naudotis dronu.
<i>Duomenų privatumas ir saugumas</i>	Ūkininkai gali nerimauti dėl savo duomenų saugumo. Sprendimas: Įdiegti patikimus duomenų šifravimo ir privatumo politikos mechanizmus, kad būtų apsaugota ūkininkų informacija.
<i>Reguliavimo atitiktis</i>	Dronų naudojimas gali būti susijęs su vietiniais reglamentais ir apribojimais.

	Sprendimas: Bendradarbiauti su reguliavimo institucijomis, kad būtų užtikrinta atitiktis, ir padėti ūkininkams gauti leidimus.
<i>Ribotas baterijos veikimo laikas</i>	Drono baterijos veikimo laikas gali riboti plotą, kurį jis gali apimti vieno skrydžio metu. Sprendimas: Sukurti keičiamų baterijų sistemas arba saulės energija varomus dronus, kad būtų pratęstas veikimo laikas.

Šaltinis: sudarytas autoriaus.

Taip pat šiame etape galima taikyti asociacijų modelį, kuris aptinka ryšius, kurie gali būti naudingi detalizuojant pasirinktą idėją. Simuliacijos metu šiam procesui atlikti naudojama programa „Orange“.

Turint didelę pirkimų/pardavimų duomenų bazę galima atlikti tikslias analizes apie vystomą produktą, tačiau tokie duomenys nėra viešai prieinami. Šiuo darbo metu bus sukurti atsitiktiniai duomenys, testuojant ar sistema tinkamai veikia ir yra efektyvi.


Pirmas žingsnis yra duomenų rinkimas ir jų apdorojimas. Šioje simuliacijoje sukuriame duomenys apie drono pirkimo istoriją ir papildomų produktų/paslaugų ryšius, pavyzdžiui, jei vartotojas perka žemės ūkiui skirtą droną, tai dažniausiai perka papildomą jutiklių komplektaciją, bateriją, dėklą arba integruota DI sistemą. Tokie duomenys pateikiami 14 lentelėje. Lentelėje simbolis – 1, reiškia įvykdytą pirkimą, o simbolis - ? neįvykdytą pirkimą. Kiekviena eilutė simbolizuoja kliento apsipirkimą vieno pirkimo metu.

14 lentelė. Drono pirkimo duomenys

Jutiklis	Baterija	Dėklas	DI integracijos programa	Dronas
1	1	?	?	1
?	1	1	?	1
1	?	?	1	1
1	?	1	?	1
1	1	1	1	1
?	1	?	1	1
?	?	?	1	1
1	?	?	?	1
1	?	?	?	1
1	1	?	1	1

Šaltinis: sudaryta autoriaus.

Antras žingsnis yra duomenų įkėlimas į „Orange“ programą (22 pav.). Šioje programoje visi procesai yra dėliojami ryšiais. Šiuo atveju *File* žymi bendrą informacijos lokaciją, funkcija *Data table* yra įkelti duomenys iš 14 lentelės, ir tada priskiriamos asociacijų taisyklės.



22 pav. „Orange“ programos asociacijų taisyklių kūrimas

Šaltinis: sudaryta autoriaus.

Gauti rezultatai pavaizduoti 23 ir 24 pav. 23 pav. duomenys išreikšti šešiais skirtingais parametrais:

- Pasikartojimo (*support*): Taisyklės pasikartojimo dažnis duomenų rinkinyje (dalinė dažnio reikšmė nuo 0 iki 1).
- Tikimybės (*confidence*): Parodo, kokia tikimybė, kad įvykus pirmam reiškiniui (priežasčiai), įvyks ir antras (pasekmė).
- Įsitikinimo (*conviction*): Parodo, kiek kartų taisyklė yra teisinga, palyginti su tuo, kiek kartų ji būtų klaidinga. Tai padeda įvertinti taisyklės patikimumą.
- Stiprumo (*strength*): Tai apibendrinta taisyklės svarbos vertė, parodanti jos bendrą stiprumą visame duomenų rinkinyje.
- Ryšio stiprumo (*lift*): Nurodo, kiek kartų dažniau abu reiškiniai įvyksta kartu, nei būtų tikėtina atsitiktinai. Jei reikšmė didesnė nei 1 – tai stiprus ryšys tarp reiškinių.
- Perteklius (*leverage*): Parodo, kiek daugiau duomenų įrašų atitinka taisyklę nei būtų galima tikėtis, jei abu reiškiniai būtų visiškai nepriklausomi vienas nuo kito.

Supp	Conf	Covr	Strg	Lift	Levr	Antecedent	Consequent
0.300	0.600	0.500	1.400	0.857	-0.050	Baterija=1	→ Sensorius=1
0.300	0.429	0.700	0.714	0.857	-0.050	Sensorius=1	→ Baterija=1
0.200	0.667	0.300	2.333	0.952	-0.010	D?klas=1	→ Sensorius=1
0.200	0.286	0.700	0.429	0.952	-0.010	Sensorius=1	→ D?klas=1
0.200	0.667	0.300	1.667	1.333	0.050	D?klas=1	→ Baterija=1
0.200	0.400	0.500	0.600	1.333	0.050	Baterija=1	→ D?klas=1
0.100	0.500	0.200	3.500	0.714	-0.040	Baterija=1, D?klas=1	→ Sensorius=1
0.100	0.500	0.200	2.500	1.000	0.000	Sensorius=1, D?klas=1	→ Baterija=1
0.100	0.333	0.300	1.000	1.111	0.010	D?klas=1	→ Sensorius=1, Baterija=1
0.100	0.333	0.300	1.000	1.111	0.010	Sensorius=1, Baterija=1	→ D?klas=1
0.100	0.200	0.500	0.400	1.000	0.000	Baterija=1	→ Sensorius=1, D?klas=1
0.300	0.600	0.500	1.400	0.857	-0.050	DI integracijos programa=1	→ Sensorius=1
0.300	0.429	0.700	0.714	0.857	-0.050	Sensorius=1	→ DI integracijos programa=1
0.300	0.600	0.500	1.000	1.200	0.050	DI integracijos programa=1	→ Baterija=1
0.300	0.600	0.500	1.000	1.200	0.050	Baterija=1	→ DI integracijos programa=1

23 pav. „Orange“ programos asociacijų rezultatai

Šaltinis: sudaryta autoriaus.

Šiam tyrimui svarbiausias tikimybės (*confidence*) koeficiento rezultatas, kuris nurodo, jog klientas pirkdamas droną, dažniausiai perka integruotas jutiklių sistemas ir dėklo kompleksą (0.667) arba su panašiu rezultatu – dėklas ir baterija (0.667).

24 paveiksle asociacijų taisyklės išreikštos procentais. Didžiausia tikimybė (70 %), jog perkant droną bus kartu įsigyta ir integruota jutiklių sistema, mažiausia tikimybė (30 %) – drono dėklas.

Itemsets	Support	%
✓ Sensorius=1	7	70
✓ Baterija=1	3	30
✓ DI integracijos programa=1	2	20
Dronas=1	2	20
Dronas=1	3	30
✓ D?klas=1	2	20
Dronas=1	2	20
✓ DI integracijos programa=1	3	30
Dronas=1	3	30
Dronas=1	7	70
✓ Baterija=1	5	50
✓ D?klas=1	2	20
Dronas=1	2	20
✓ DI integracijos programa=1	3	30
Dronas=1	3	30
Dronas=1	5	50
✓ D?klas=1	3	30
Dronas=1	3	30
✓ DI integracijos programa=1	5	50
Dronas=1	5	50
Dronas=1	10	100

24 pav. „Orange“ programoje apskaičiuotos tikimybės

Šaltinis: sudaryta autoriaus.

Ši analizė naudinga verslo sprendimų priėmimui, rekomendacinių sistemų kūrimui, procesų optimizavimui, siekiant suprasti, kurie požymiai dažnai pasireiškia kartu. Šiuo atveju daugiau dėmesio galima skirti pažangesnėms jutiklių sistemoms, jų dizainui ir panašiai.

Kitas etapas vartotojų poreikių analizė. Pirmiausiai šiame etape atliekama potencialių vartotojų segmentacija. Ši analizė atliekama pasitelkiant *Chatgpt* sistema. Užklausoje nurodomas anksčiau aprašytas produkto konceptas ir pateikiama pagrindinis tikslas sudaryti drono vartotojų segmentaciją vidutinio ir didelio dydžio žemės ūkio plotams. Gautas rezultatas pateikiamas 15 lentelėje.

15 lentelė. Tikslinės vartotojų grupės pasirinkimas

Kategorija	Aprašymas
Demografinės	Ūko dydis: 100–2000 arų
	Nuosavybės struktūra: Šeimos ūkiai arba kooperatyvai
	Pasėlių įvairovė: Mišrūs pasėliai (kukurūzai, soja, kviečiai, vaisiai, daržovės) arba specializuoti ūkiai
	Darbo jėga: Šeimos nariai, sezoniniai darbininkai, ribotas nuolatinių darbuotojų skaičius
Geografinės	Šiaurės Amerika: JAV Vidurio Vakarai, Kalifornija, Kanada
	Europa: Prancūzija, Vokietija, Ispanija, Italija, Baltijos šalys
	Azija: Indija, Pietryčių Azija, Kinija
	Lotynų Amerika: Brazilija, Argentina, Meksika
	Afrika: Kenija, Pietų Afrika, Nigerija
Psichografinės	Mąstysena: Praktiški, taupūs, atviri inovacijoms su aiškia grąža
	Vertybės: Tvarumas, efektyvumas, ilgalaikis pelningumas
	Iššūkiai: Riboti biudžetai ir techninės žinios
	Tikslai: Derliaus didinimas, išlaidų mažinimas, rizikos valdymas
Elgsenos	Technologijų naudojimas: Vidutinis, jau naudoja GPS traktorius, dirvožemio jutiklius
	Dronų naudojimas: Pasėlių stebėjimui, išteklių optimizavimui, derliaus prognozavimui
	Bendradarbiavimas: Kooperatyvai gali dalintis technologijomis per bendrą nuosavybę ar nuomą
Finansinės galimybės	Biudžto ribotumas: Riboti ištekliai, bet investuoja į ilgalaikę naudą
	Finansavimo pasirinkimai: Subsidijos, lizingas.
	ROI lūkesčiai: Aiški investicijų grąža per 2–3 metus

Šaltinis: sudaryta autoriaus.

Taip pat vartotojų poreikius galima nagrinėti renkant duomenis iš apklausų. Tokioms apklausoms generuoti puikiai tinka *Chatgpt* priemonė, kuri per kelias sekundes sugeneruoja apklausą remiantis kuriamu produktu. Dėl didelio kiekio informacijos pateikiu sutrumpintą apklausos rezultatą 16 lentelėje.

16 lentelė. Žemės ūkio drono vartotojų apklausa, sukurta su Chatgpt modeliu

1. Demografinė informacija	
Vaidmuo ūkyje	☐ Savininkas ☐ Vadovas ☐ Kooperatyvo narys ☐ Kita: _____
Ūkio dydis	☐ <100 a ☐ 100–500 a ☐ 500–2000 a ☐ >2000 a
Auginami augalai	☐ Grūdai ☐ Vaisiai ☐ Daržovės ☐ Specialieji ☐ Kita: _____
Ūkio vieta	Šalis: _____ Regionas: _____
Metinės pajamos	☐ <50 000 € ☐ 50–200 tūkst. € ☐ 200 tūkst.–1 mln. € ☐ >1 mln. €
2. Dabartinė ūkio praktika	
Naudojamos technologijos	☐ GPS traktoriai ☐ Jutikliai ☐ Palydovai ☐ Rankinis ☐ Kita: _____
Pasėlių stebėjimas	☐ Vizualiai ☐ Tyrimai ☐ Nuotoliniai įrankiai ☐ Kita: _____
Didžiausi iššūkiai (iki 3)	☐ Sąnaudos ☐ Ligų atpažinimas ☐ Išteklių valdymas ☐ Prognozės ☐ Darbo trūkumas ☐ Kita: _____
3. Požiūris į dronus	
Pažintis su dronais	☐ Naudoju ☐ Girdėjau ☐ Negirdėjau ☐ Nenaudojau
Matomos naudos (iki 3)	☐ Stebėjimas

	☐ Ankstyvas nustatymas ☐ Tikslus naudojimas ☐ Prognozės ☐ Mažiau darbo ☐ Kita: _____
Nuogastavimai (iki 3)	☐ Kaina ☐ Sudėtingumas ☐ Baterija ☐ Palaikymo trūkumas ☐ Privatumas ☐ Kita: _____
4. Investavimo pasirengimas	
Investicija į droną	☐ <5 000 \$ ☐ 5–10 tūkst. \$ ☐ 10–20 tūkst. \$ ☐ >20 tūkst. \$
Įsigijimo būdas	☐ Pirkti ☐ Nuomotis ☐ Paslauga ☐ Kita: _____
Finansavimas	☐ Subsidijos ☐ Paskola ☐ Gamintojas ☐ Kooperatyvas ☐ Kita: _____

Šaltinis: sudaryta autoriaus.

Tokio tipo apklausas galima automatizuoti, pritaikant jau nagrinėta klasifikavimo algoritmą, kuris suskirsto apklausos rezultatus į tam tikras paskirtas kategorijas. Taip pat galima naudoti *Google Cloud Natural Language* algoritmus, kurie nusakytų apklausos rezultatų emociją ir papildomus veiksnius.

Vartotojų poreikių analizę galima atlikti ir su kompiuterinės regos priemonėmis. Šiam procesui atlikti simuliacijoje naudota „Deepface“ biblioteka, aprašyta „Python“ programavimo kalba. Tokios priemonės leidžia analizuoti nuotraukas arba vaizdo įrašus iš socialinių tinklų, tinklaraščių, žiniasklaidos, siekiant suprasti vartotojų įpročius ir pageidavimus.

Darbo metu buvo pasirinkta atsitiktinė nuotrauka iš interneto, kurioje vaizduojamos asmuo (klientas) su tam tikra išreikšta emocija, o šalia jo esantis konkurentų produktas – dronas skirtas pasėlių stebėjimui (25 pav.).



25 pav. „Garunda“ bepiločio orlaivio skirta žemės ūkiui reklama.

Šaltinis: sudaryta autoriaus.

Python kodas pradedamas programuoti su funkcija *import*, kuri įkelia veido atpažinimo „DeepFace“ biblioteka. Toliau šiai bibliotekai nurodoma nuotraukos lokacija. Po šios operacijos nurodoma, kokio rezultato siekiame sužinoti iš šios nuotraukos. Pasirinktos pagrindinės vartotojų poreikių analizei reikalingos kategorijos: emocija, amžius, lytis ir rasė. Gautas rezultatas pateiktas 26 pav.

```

C:\Users\dovydas\Desktop> Test > python DeepFace.py ...
1 from DeepFace import DeepFace
2
3 # Nuotrauka
4 img_path = r"C:\Users\dovydas\Desktop\Test\DroneEmocijas.png"
5
6 # Atlikta analize
7 result = DeepFace.analyze(img_path=img_path, actions=['emotion', 'age', 'gender', 'race'])
8
9 # Rezultatas
10 print(result)

```

```

PROBLEMS OUTPUT DEBUG CONSOLE TERMINAL PORTS
To enable the following instructions: AVX2 AVX512F AVX512_VNNI AVX512_BF16 FMA, in other operations, rebuild TensorFlow with the appropriate compiler flags.
25-01-31 10:58:58 - facial_expression_model_weights.h5 will be downloaded...
Downloading...
From: https://github.com/serengil/deepface_models/releases/download/v1.0/facial_expression_model_weights.h5
To: C:\Users\dovydas\deepface\weights\facial_expression_model_weights.h5
100% | 5.98M/5.98M [00:05<00:00, 1.02MB/s]
Action: age: 25% | 1/4 [00:07<00:22, 7.47s/it]2
25-01-31 10:58:58 - age_model_weights.h5 will be downloaded...
Downloading...
From: https://github.com/serengil/deepface_models/releases/download/v1.0/age_model_weights.h5
To: C:\Users\dovydas\deepface\weights\age_model_weights.h5
100% | 539M/539M [12:40<00:00, 709kB/s]
Action: gender: 50% | 2/4 [12:51<15:04, 452.46s/it]2
25-01-31 11:03:50 - gender_model_weights.h5 will be downloaded...
Downloading...
From: https://github.com/serengil/deepface_models/releases/download/v1.0/gender_model_weights.h5
To: C:\Users\dovydas\deepface\weights\gender_model_weights.h5
100% | 537M/537M [11:21<00:00, 789kB/s]
Action: race: 75% | 3/4 [24:15<09:18, 558.11s/it]2
25-01-31 11:15:14 - race_model_single_batch.h5 will be downloaded...
Downloading...
From: https://github.com/serengil/deepface_models/releases/download/v1.0/race_model_single_batch.h5
To: C:\Users\dovydas\deepface\weights\race_model_single_batch.h5
100% | 537M/537M [16:56<00:00, 529kB/s]
Action: race: 100% | 4/4 [41:14<00:00, 618.66s/it]2
[{'emotion': {'angry': np.float32(1.1788861e-07), 'disgust': np.float32(5.275428e-14), 'fear': np.float32(2.5381544e-07), 'happy': np.float32(0.941514), 'sad': np.float32(3.8137763e-05), 'surprise': np.float32(0.0072580314), 'neutral': np.float32(0.5775478)}, 'dominant_emotion': 'happy', 'region': {'x': 60, 'y': 435, 'w': 196, 'h': 196, 'left_eye': (187, 511), 'right_eye': (120, 517)}, 'face_confidence': np.float64(0.89), 'age': 29, 'gender': {'Woman': np.float32(1.8177807e-05), 'Man': np.float32(99.99998)}, 'dominant_gender': 'Man', 'race': {'asian': np.float32(4.778578), 'indian': np.float32(54.245712), 'black': np.float32(5.418857), 'white': np.float32(2.7892244), 'middle_eastern': np.float32(2.579905), 'latino_hispanic': np.float32(30.187729)}, 'dominant_race': 'indian'}}]
PS C:\Users\dovydas>

```

26 pav. Vaizdų atpažinimo metodas Python aplinkoje

Šaltinis: sudaryta autoriaus.

Iš nuotraukos nustatyta, kad asmens emocija – linksma/pozityvi (atitikmuo 99.41), amžius – apie 29 metai, lytis – vyras (atitikmuo 99.99), rasė – indų tautybė (atitikmuo 54.24). Šios priemonės leidžia greičiau ir efektyviau rinkti potencialius klientus ir bendrai įvertinti vartotojų rinką iš vaizdinių objektų.

Šiame etape taip pat buvo atlikta duomenų klasterizavimo analizė naudojant *K-means* algoritmą, siekiant suskirstyti ūkininkų duomenis į skirtingus klasterius pagal įvairius kiekybinius rodiklius (27 pav.). Analizė vykdyta naudojant *Python* programavimo kalbą su bibliotekomis: *pandas*, *numpy*, *scikit-learn* ir *matplotlib*.

```
C:\Users\dovyd\Desktop>Test > klasterizavimas.py > ...
1 import pandas as pd
2 import numpy as np
3 from sklearn.cluster import KMeans
4 from sklearn.preprocessing import StandardScaler
5 import matplotlib.pyplot as plt
6
7 data = {
8     'Plotas_ha': [10, 20, 30, 40, 50, 60, 70, 80, 90, 100], # ūkio plotas hektarais
9     'Kvieciu_plotas_ha': [5, 10, 15, 20, 25, 30, 35, 40, 45, 50], # kviečių plotas hektarais
10    'Mieziu_plotas_ha': [3, 6, 9, 12, 15, 18, 21, 24, 27, 30], # miežių plotas hektarais
11    'Naudoja_dronus': [1, 0, 1, 0, 1, 0, 1, 0, 1, 0], # 1 - naudoja dronus, 0 - nenaudoja
12    'Vidutinis_derlius': [3.5, 4.0, 3.8, 4.2, 4.5, 3.7, 4.1, 4.3, 4.0, 4.4], # vidutinis derlius (t/ha)
13    'Investicijos_eurais': [1000, 2000, 1500, 3000, 2500, 4000, 3500, 5000, 4500, 6000], # investicijos į technologijas
14    'Amzius': [30, 40, 50, 60, 35, 45, 55, 65, 70, 75], # ūkininko amžius
15    'Patirtis_metai': [5, 10, 15, 20, 7, 12, 18, 22, 25, 30] # patirtis ūkininkauti metais
16 }
17
18 #Konvertuojame duomenis į pandas DataFrame
19 df = pd.DataFrame(data)
20
21 #Atrinkame tik skaitinius duomenis
22 X = df.values
23
24 # 4. Normalizuojame duomenis (kad visi stulpeliai būtų vienodo svorio)
25 scaler = StandardScaler()
26 X_scaled = scaler.fit_transform(X)
27
28 #Atliekame klasterizaciją naudodami K-means
29 kmeans = KMeans(n_clusters=3) # nustatome klasterių skaičių
30 kmeans.fit(X_scaled)
31
32 #Pridedame klasterio etiketes prie duomenų
33 df['Klasteris'] = kmeans.labels_
34
35 #Atvaizduojame rezultatus grafiškai
36 plt.figure(figsize=(12, 6))
37
38 # Scatter plot pagal vidutinį derlių ir investicijas
39 plt.subplot(1, 2, 1) # Pirmas grafikas
40 plt.scatter(df['Vidutinis_derlius'], df['Investicijos_eurais'], c=df['Klasteris'], cmap='viridis', s=100)
41 plt.xlabel('Vidutinis derlius (t/ha)')
42 plt.ylabel('Investicijos į technologijas (eurais)')
43 plt.title('Derlius vs Investicijos')
44 plt.colorbar(label='Klasteris')
45 plt.grid(True)
46
47 # Scatter plot pagal amžių ir patirtį
48 plt.subplot(1, 2, 2) # Antras grafikas
49 plt.scatter(df['Amzius'], df['Patirtis_metai'], c=df['Klasteris'], cmap='plasma', s=100)
50 plt.xlabel('Amžius')
51 plt.ylabel('Patirtis ūkininkauti (metai)')
52 plt.title('Amžius vs Patirtis')
53 plt.colorbar(label='Klasteris')
54 plt.grid(True)
55
56 plt.tight_layout()
57 plt.show()
58
59 # Rezultatas
60 print("Sugrupuoti duomenys:")
61 print(df)
62
```

27 pav. Duomenų klasterizavimo analizė naudojant K-means algoritmą

Šaltinis: sudaryta autoriaus.

Duomenys buvo pateikti kaip žodynas, kuriame kiekviena kategorija atitiko konkretų rodiklį:

- Ūkio plotas (ha),

- Kviečių ir miežių plotas (ha),
- Ar naudojami dronai (1 – taip, 0 – ne),
- Vidutinis derlius (t/ha),
- Investicijos į technologijas (eurais),
- Ūkininko amžius (metais),
- Ūkininkavimo patirtis (metais).


Svarbu paminėti, kad duomenys buvo sukurti atsitiktinai simuliacijos metu, tačiau įmonės renkančios duomenis arba turinčios prieigą prie duomenų bazės gali naudotis šiuo metodu. Duomenys buvo konvertuoti į *pandas DataFrame* formatą, kad būtų galima patogiai atlikti analizę. Kadangi *K-means* algoritmas yra jautrus skirtingiems kintamųjų masteliams, buvo atlikta standartizacija naudojant *StandardScaler*, kuris visus kintamuosius transformuoja taip, kad jų vidurkis būtų - 0, o standartinis nuokrypis – 1.

Toliau buvo pasirinktas 3 klasterių skaičius, kuris nurodytas kaip *n_clusters=3*. Pasinaudojus standartizuotais duomenimis, buvo pritaikytas *K-means* algoritmas. Po klasterizacijos kiekvienam stebėjimui buvo priskirtas klasterio numeris (0, 1 arba 2), taip įrašant į naują *DataFrame* stulpelį „Klasteris“.

Rezultatai, pateikti 28 paveiksle, dviem sklaidos diagramomis. Pirmojo grafiko „Derlius vs Investicijos“, X ašis vaizduoja vidutinį derlių (t/ha), Y ašis – investicijos į technologijas (eurais), o taškų spalva nurodo, kuriam klasteriui priklauso duomenų taškas. Ši diagrama leidžia įvertinti, kaip investicijos koreliuoja su derlingumu ir ar tarp šių požymių yra ryškūs skirtumai. Šioje simuliacijoje galima pastebėti, kad vienas iš klasterių (žr. šviesiai mėlyną spalvą) pasižymi didesnėmis investicijomis ir derlingumu, o kitas – mažesniais rodikliais.

Antrojo grafiko „Amžius vs Patirtis“ X ašis vaizduoja ūkininkų amžių, Y ašis – ūkininkavimo patirtis (metais). Ši diagrama leidžia analizuoti, ar amžius ir ūkininkavimo patirtis turi ryšį su klasterizacija. Šioje simuliacijoje pastebima, jog jaunesni ar mažiau patyrę ūkininkai dažnai sudaro atskirą klasterį, o vyresni su didesne patirtimi – kitą. Ganėtinais tiesus klasterių išsidėstymas rodo tolygų amžiaus ir patirties priklausomybę viena nuo kitos.

Tokios analizės leidžia priimti labiau pagrįstus sprendimus produkto vystymo stadijoje, atsižvelgiant skirtingų profilių ūkininkų grupes ir jų poreikius.



28 pav. Klasterifikavimo rezultatai. „Derlius vs Investicijos“ ir „Amžius vs Patirtis“

Šaltinis: sudaryta autoriaus.

Kitas etapas – rizikų identifikavimas. Rizikų identifikavimas padeda nustatyti galimas problemas, galinčias kilti įgyvendinant ar plėtojant produktą. Šiam procesui atlikti naudojamas *Chatgpt* modelis. Pateikus užklausą, gautas rezultatas vaizduojamas 17 lentelėje. Lentelėje išskiriamos septynios skirtingos rizikų kategorijos: finansinės, technologinės, teisinės, operacinės, rinkos, reputacinės ir aplinkosauginės. Kiekvienai kategorijai priskiriami rizikos veiksniai ir pateikiamas aprašymas.

17 lentelė. Rizikų identifikavimas su *Chatgpt* modeliu

Rizikų kategorija	Rizikos veiksnys	Aprašymas
Finansinės	<i>Finansavimo iššūkiai</i>	Gali būti sunku pritraukti pakankamą finansavimą MTEP, gamybai ir rinkos įėjimui dėl didelių pradinių išlaidų ir neaiškos investicijų grąžos (ROI).
	<i>Sąnaudų viršijimas</i>	Sudėtingų DI algoritmų kūrimas ir multispektrinio vaizdavimo integracija gali pareikalausiti nenumatytų išlaidų.
	<i>Rinkos įsisavinimas</i>	Ūkininkai gali nenoriai įsigyti naujas technologijas dėl didelių kainų ar sudėtingumo suvokimo.
	<i>Pajamų neapibrėžtumas</i>	Konkurencinga kainodara gali būti sudėtinga, ypač jei rinkoje atsiranda pigesnių alternatyvų.
Technologinės	<i>DI algoritmų patikimumas</i>	Jei DI nesuteiks tikslų ir nuoseklių duomenų analizių, gali sumažėti vartotojų pasitikėjimas.
	<i>Integracijos problemos</i>	Dronas turi sklandžiai veikti su esamomis ūkio valdymo sistemomis, o suderinamumo problemos gali padidinti kaštus.
	<i>Duomenų tikslumas ir interpretacija</i>	Aplinkos veiksniai, pvz., oras ir apšvietimas, gali paveikti multispektrinio vaizdų kokybę.
	<i>Aparatūros gedimai</i>	Mechaninės ar programinės įrangos klaidos gali sutrikdyti veiklą ir pakenkti reputacijai.
	<i>Mastelio keitimas</i>	Skirtingoms žemės ūkio sąlygoms pritaikyti technologiją gali būti sudėtinga.

Teisinės	<i>Reguliavimo atitikimas</i>	Dronai priklauso aviacijos reguliavimui, kuris skiriasi pagal šalis ir gali sukelti diegimo vėlavimus.
	<i>Duomenų privatumas ir saugumas</i>	Netinkamas ūkio duomenų apsaugojimas gali sukelti teisinių pasekmių, pvz., GDPR pažeidimus.
	<i>Atsakomybės klausimai</i>	Drono gedimas gali sukelti žalą pasėliams ar turtui, dėl ko gali kilti teisinių ginčų.
	<i>Intelektinės nuosavybės (IP) rizikos</i>	Konkurentai gali mėginti kopijuoti technologiją, todėl svarbu užtikrinti patentinę apsaugą.
Operacinės	<i>Tiekimo grandinės sutrikimai</i>	Specializuotų komponentų trūkumas ar geopolitiniai veiksniai gali sukelti gamybos vėlavimus.
	<i>Mokymai ir palaikymas</i>	Ūkininkams gali prireikti išsamių mokymų, o prastas klientų aptarnavimas gali mažinti priimtinumą.
	<i>Aplinkos veiksniai</i>	Ekstremalios oro sąlygos, pvz., vėjas ar lietus, gali apriboti drono funkcionalumą.
Rinkos	<i>Konkurencija</i>	Didelės agrotech kompanijos ar nauji rinkos dalyviai gali sukurti konkurencingus produktus.
	<i>Kintantys klientų poreikiai</i>	Ūkininkų lūkesčiai gali keistis, todėl reikės nuolat tobulinti drono funkcijas.
	<i>Ekonomikos nuosmukiai</i>	Sumažėjusi žemės ūkio sektoriaus perkamąji galia gali neigiamai paveikti pardavimus.
Reputacinės	<i>Produktų gedimai</i>	Technologijos gedimai ar netikslūs rezultatai gali pakenkti prekės ženklo reputacijai.
	<i>Etiniai klausimai</i>	AI naudojimas žemės ūkyje gali sukelti diskusijas apie darbo vietų mažėjimą ar pernelyg didelį priklausomumą nuo technologijų.
Aplikosauuginės	<i>Tvarumo klausimai</i>	Dronų gamyba ir utilizavimas gali turėti neigiamą poveikį aplinkai.
	<i>Socialinis priimtumas</i>	Kai kurie ūkininkai gali nesinaudoti AI technologijomis dėl kultūrinių ar tradicinių priežasčių.

Šaltinis: sudaryta autoriaus.

Kita estapas – verslo galimybių vertinimas. Šiame etape buvo naudojamas natūralios kalbos apdorojimo modelis – *Chatgpt*. Po tinkamos užklauso suformulavimo, pateikiamas rezultatas 18 lentelėje. Lentelėje išskiriamos aštuonios verslo galimybių kategorijos ir jų aprašymas.

18 lentelė. Verslo galimybių įvertinimas

Kategorija	Aprašymas
Tikslinės rinkos dydis	Pasaulinė žemės ūkio dronų rinka 2022 m. buvo vertinama apie 1,2 mlrd. JAV dolerių ir prognozuojama, kad nuo 2023 iki 2030 m. augs 22,5 % CAGR tempu dėl didėjančio precizinės žemdirbystės technologijų taikymo.
Pagrindiniai konkurentai ir jų pasiūlymai	„DJI“. Agras serija – purškimo ir trėšimo funkcijos su ribotomis vaizdavimo galimybėmis. „PrecisionHawk“. Dronai su daugiaspektriniu vaizdavimu ir duomenų analize pasėlių stebėsenai. „Parrot Bluegrass“ serija – daugiaspektriniai jutikliai ir analizės programinė įranga. „Sentra“. Aukšto tikslumo jutikliai ir analizė pasėlių būklės stebėsenai.


Unikalūs pardavimo pasiūlymai	Pažangi DI integracija: Drono DI gali realiuoju laiku analizuoti duomenis ir teikti prognozes, skirtingai nei konkurentai, kurie dažniausiai siūlo tik duomenų rinkimą. Kompleksinis sprendimas: Apjungia daugiaspektrinį vaizdavimą, kenkėjų aptikimą ir drėkinimo bei tręšimo optimizavimą vienoje platformoje. Patogi sąsaja: Lengvai naudojama net ir minimalias technines žinias turintiems ūkininkams, kas mažina mokymosi barjerą ir skatina priėmimą.
Pajamų modelis ir kainodaros strategijos	Pajamų modelis: Tiesioginiai pardavimai. Dronų ir programinės įrangos licencijų pardavimas tiesiogiai ūkininkams ir žemės ūkio įmonėms. Prenumeratos modelis. Duomenų analizės ir stebėsenos paslaugų teikimas prenumeratos pagrindu. Nuomos galimybės. Galimybė išsinuomoti dronus mažinant pradinės investicijas. Kainodaros strategijos: Diferencijuota kainodara. Skirtingos kainų kategorijos pagal funkcionalumą ir palaikymo lygį. Nemokamos dalies modelis. Pagrindinės paslaugos nemokamos, o pažangios funkcijos prieinamos už mokestį.
Reguliaciniai ir aplinkosaugos aspektai	Reguliaciniai: Būtina laikytis vietinių aviacijos taisyklių (pvz., FAA JAV, EASA Europoje) dėl dronų naudojimo. Taip pat reikia atitikti duomenų apsaugos reglamentus (pvz., GDPR Europoje). Aplinkosauga: Skatinti tvarią žemdirbystę optimizuojant resursų naudojimą (vanduo, trąšos), taip mažinant poveikį aplinkai.
Rinkos tendencijų analizė	Precizinė žemdirbystė: Didėjantis tikslinės stebėsenos ir valdymo technologijų taikymas žemės ūkyje. Tvarumas: Vis daugiau dėmesio skiriama aplinkai draugiškiems ūkininkavimo metodams. Automatizavimas: Augantis susidomėjimas automatizuotais sprendimais darbo jėgos trūkumui kompensuoti.
Galimos partnerystės ar bendradarbiavimas	Žemės ūkio kooperatyvai: Partnerystės gali palengvinti didmeninius pirkimus ir suteikti prieigą prie didelio klientų tinklo. Mokslinių tyrimų institucijos: Bendradarbiavimas su žemės ūkio tyrimų centrais gali padidinti produkto patikimumą ir suteikti naujausių tyrimų pagrįstą informaciją. Technologijų tiekėjai: Partnerystė su DI ir duomenų analizės įmonėmis gali sustiprinti drono galimybes ir pasiūlyti išsamesnius sprendimus.

Šaltinis: sudaryta autoriaus.

3.3.4. III Etapas. Verslo plano kūrimas

Šiame etape naudojama „Miro“ interaktyvi platforma. Ši sistema leidžia kurti vizualinius verslo modelius pasitelkiant „Business Model Canvas“ metodiką ir dirbtinį intelektą idėjų generavimui.

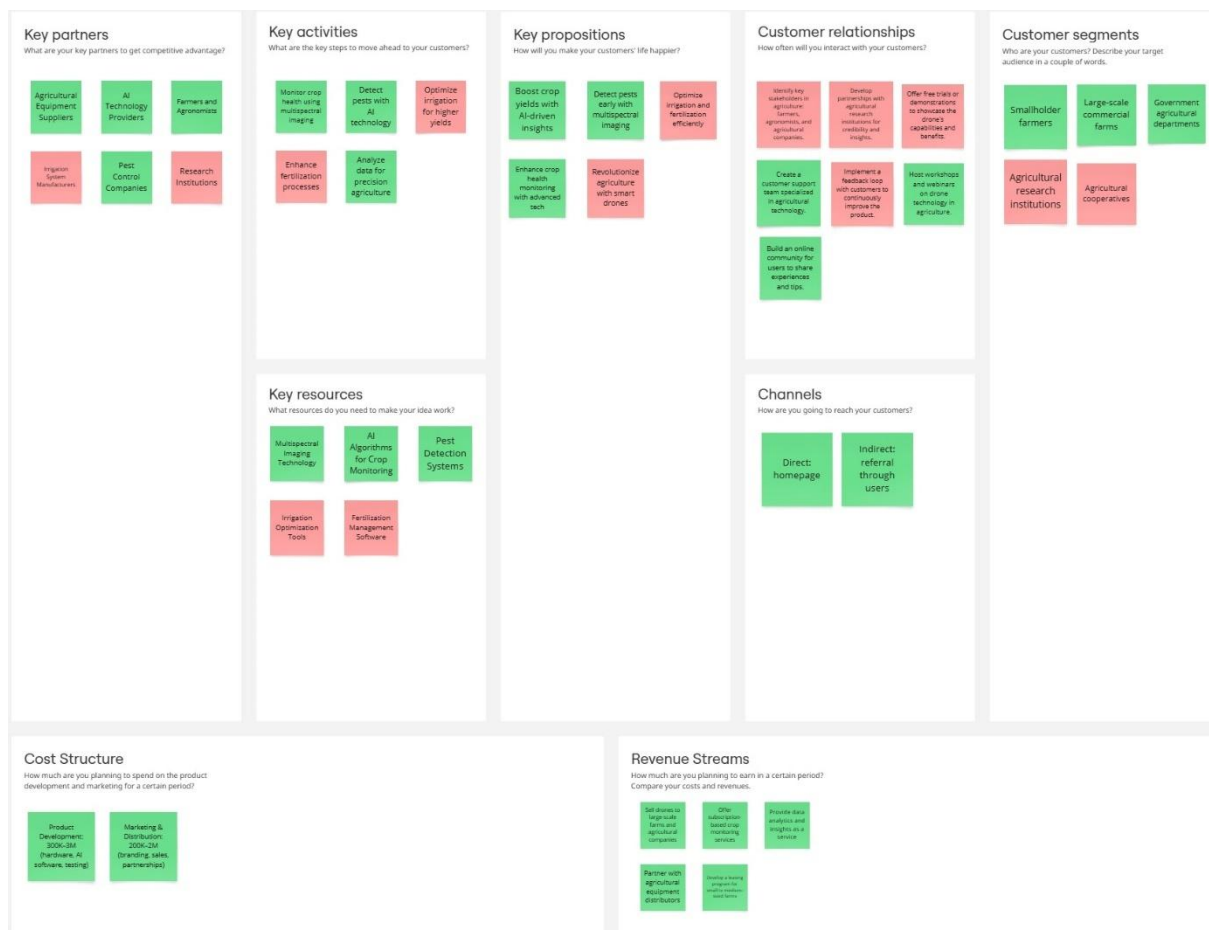
Dirbtinio intelekto integracija, kaip matyti iš 29 paveikslo, naudojama „Miro AI“ funkcija padeda generuoti lipnius lapelius remiantis pateiktu produkto aprašymu. Kaip pateikta pavyzdyje, užklausoje buvo prašoma sukurti trumpus, pagrindinius išteklius šiam produktui - žemės ūkio dronas, kuris naudoja daugiaspektrinius vaizdus ir dirbtinį intelektą pasėlių būklei stebėti, kenkėjams aptikti, drėkinimui ir tręšimui optimizuoti. Įvykdžius užklausą, buvo sugeneruoti šeši skirtingi lapukai.



29 pav. Verslo modelio kūrimas su „Miro AI“ platforma

Šaltinis: sudaryta autoriaus.

Toliau kartojant procesą buvo sugeneruotas verslo planas iš devynių pagrindinių blokelių: pagrindiniai tiekėjai, pagrindinės veiklos, vertės pasiūlymas, santykiai su klientais, klientų segmentai, kanalai, pagrindiniai ištekliai, sąnaudų struktūra ir pajamų srautai. Bendras gautas rezultatas pateikiamas 30 paveiksle. Peržiūrėjus visus rezultatus ir pritaikant jau anksčiau surinktus duomenis spalvomis buvo pasirenkami tinkami (žalia spalva) ir netinkami (raudona spalva) rezultatai.



30 pav. Galutinis sugeneruotas verslo planas, naudojant „Miro AI“ programą

Šaltinis: sudaryta autoriaus.

Naudojant „Miro“ platformą kartu su „Business Model Canvas“ metodika bei dirbtinio intelekto generuojamais siūlymais, galima ne tik efektyviai planuoti sudėtingus technologinius sprendimus, bet ir juos vizualizuoti bei adaptuoti verslo plano kūrimo kontekste. Simuliuojamas pasirinktas produktas parodo, kaip tarpdalykinės inovacijos (DI, nuotolinis stebėjimas, agrokultūra) gali būti sistemingai modeliuojamos, vertinamos ir pateikiamos interaktyviai.

Kitas etapas – pardavimų prognozė. Pardavimų prognozės etape labiausiai pritaikomas yra generatyvinio teksto modelis – *Chatgpt*, kuris per kelias minutes iš tinkamai suformuotos užklauskos gali pateikti išsamias pasirinkto produkto pardavimo prognozes. Šiame simuliacijos etape buvo sugeneruotos dvi lentelės.

19 Lentelėje pateikiamos septynios skirtingos kategorijos: sezoniškumas, klimato poveikis, kainodara, rinkos dydis, tikslinė rinka, augimo tempas ir sezoninių pardavimų paskirstymas. Kiekviena kategorija yra išnagrinėjama ir pateikiama bendra informacija apie galimas pardavimų prognozes.

19 lentelė. Pardavimų prognozės pagal kategorijas

Kategorija	Informacija
Sezoniškumas	Pardavimai didės per pasiruošimo sėjai ir augimo sezonus (I ir II ketvirtis).
Klimato poveikis	Dėl klimato kaitos (sausros, potvynių) didės poreikis technologijoms, kurios padeda valdyti rizikas ir gerinti derliaus atsparumą.
Kainodara	Drono kaina bus 10 000 Eur. už vieną, o per 5 metus palaipsniui mažės iki 8 000 Eur. dėl masto ekonomijos ir konkurencijos.
Rinkos skverbtis	Pirmaisiais metais bus pasiekta 1 % tikslinės rinkos (dideli ūkiai), o per 5 metus skverbtis pasieks 10 %.
Tikslinė rinka	Dideli ūkiai (>250 ha) – pagrindinė rinka. Maži ir vidutiniai ūkiai taps antrine rinka, kai kainos sumažės ir technologija taps prieinamesnė.
Augimo tempų analizė	1–2 metai (100% augimas): Spartus augimas dėl ankstyvųjų naudotojų ir susikaupusios paklausos. 2–3 metai (44 % augimas): Augimas lėtėja, nes pradeda sotintis ankstyvųjų naudotojų rinka. 3–4 metai (33 % augimas): Augimas stabilizuojasi, produktas tampa prieinamesnis platesnei auditorijai. 4–5 metai (50 % augimas): Pagreitėjęs augimas dėl kainų mažinimo ir plėtos besivystančiose rinkose.
Sezoninių pardavimų pasiskirstymas	I ketvirtis (sausis–kovas): 40 % metinių pardavimų (pasiruošimo sėjai sezonas). II ketvirtis (balandis–birželis): 30 % metinių pardavimų (ankstyvasis augimo sezonas). III ketvirtis (liepa–rugsėjis): 20 % metinių pardavimų (vidutinis augimo sezonas). IV ketvirtis (spalis–gruodis): 10 % metinių pardavimų (po derliaus nuėmimo, maža paklausa).

Šaltinis: sudaryta autoriaus.

20 lentelėje daugiau buvo naudojama kiekybinės informacijos. Finansinė pardavimų prognozė buvo sugeneruota nuo 2024 m. iki 2028 m. Kiekvienais metais įvertinamas parduotų produktų vienetų skaičius, pajamos, augimo tempas ir pagrindiniai veiksniai.

20 lentelė. Žemės ūkio drono pardavimų prognozė 2024 - 2025 m.

Metai	Parduotų vienetų skaičius	Pajamos (Eur.)	Augimo tempas	Pagrindiniai veiksniai
2024	2 500	25 000 000	–	Ankstyvieji naudotojai, paklausa prieš sodinimą
2025	5 000	50 000 000	100 %	Didėjantis žinomumas, plėtra į Europą ir Aziją
2026	8 000	72 000 000	44 %	Kainos sumažinimas iki 9 000 Eur., vidutinių ūkių įsisavinimas
2027	12 000	96 000 000	33 %	Su klimatu susijusi paklausa, plėtra į JAV
2028	18 000	144 000 000	50 %	Kainos sumažinimas iki 8 000 Eur., plačiai paplitęs naudojimas

Šaltinis: sudaryta autoriaus.

Toliau atliekama kokurencinė analizė. Šiame etape buvo siekiama nustatyti ir įvertinti konkurentų strategiją, veiklą ir rinkos padėtį. Generatyvinio teksto modelis Chatgpt per kelias minutes sugeneravo PESTEL,SSGG ir Porterio penkių jėgų analizes aprašytam produktui.

PESTEL analizė padeda įvertinti makroaplinkos veiksnius, kurie gali turėti įtakos produkto kūrimui ir komercializacijai. 21 Lentelėje Išskiriami tokie veiksniai:

- **Politiniai veiksniai:** žemės ūkio subsidijos, parama inovacijoms, ES žemės ūkio politika.
- Ekonominiai:** ūkininkų perkamoji galia, investicijų grąžos lūkesčiai, technologijų kainų kritimas.
- **Socialiniai:** požiūris į tvarumą, ūkininkų pasirengimas naudoti technologijas.
- **Technologiniai:** DI, jutiklių, dronų pažanga.
- **Ekologiniai:** klimato kaita, dirvožemio kokybė, tvari žemdirbystė.
- **Teisiniai:** dronų naudojimo reguliavimas, duomenų apsauga.


21 lentelė. PESTEL analizė.

Veiksniai	Analizė
Politiniai	- Vyriausybės subsidijos ir paskatos: Daugelis vyriausybės siūlo subsidijas precizinės žemdirbystės technologijų diegimui, taip sumažinant išlaidas ūkininkams. - Dronų naudojimo reglamentavimas: Griežtos aviacijos taisyklės (pvz., FAA JAV, EASA Europoje) reguliuoja dronų eksploatavimą, įskaitant aukščio ribojimus, draudžiamas skrydžių zonas ir licencijavimo reikalavimus. - Prekybos politika: Importuojamų dronų komponentų muitai ar eksporto apribojimai gali turėti įtakos gamybos sąnaudoms ir rinkos prieinamumui. - Duomenų suvereniteto įstatymai: Vyriausybės gali taikyti apribojimus, kur gali būti saugomi ar apdorojami dronų surinkti žemės ūkio duomenys.
Ekonominiai	- Įdiegimo išlaidos: Didelės pradinės dronų ir dirbtinio intelekto sistemų sąnaudos gali riboti jų naudojimą smulkiuose ūkiuose, tačiau nuomos modeliai gali padėti sumažinti šią kliūtį. - Rinkos paklausa: Didėjanti precizinės žemdirbystės įrankių paklausa dėl augančios pasaulinės maisto paklausos ir darbo jėgos trūkumo. - Ekonominės sąlygos: Besivystančių šalių ūkininkai gali susidurti su finansiniais apribojimais, o išsivysčiusiose šalyse labiau investuojama į pažangias technologijas. - Investicijų grąža (ROI): Dronai gali sumažinti išlaidas ilgalaikėje perspektyvoje, optimizuodami išteklių naudojimą (vandens, trąšų) ir didindami derliaus našumą.
Socialiniai	- Technologijų priėmimas: Jaunesni, technologijomis besidomintys ūkininkai labiau linkę naudoti dronus, o vyresnė karta gali priešintis dėl nežinojimo ar nepasitikėjimo technologijomis. - Viešoji nuomonė: Gali kilti susirūpinimas dėl darbo vietų mažėjimo tradicinėje žemdirbystėje, nors dronai greičiau papildys nei pakeis žmogaus darbą. - Švietimas ir mokymai: Ūkininkams gali reikėti mokymų, kad jie galėtų valdyti dronus ir interpretuoti dirbtinio intelekto pateikiamus duomenis, sukuriant galimybes bendradarbiauti su žemės ūkio konsultacinėmis tarnybomis. - Kultūriniai veiksniai: Kai kuriuose regionuose tradiciniai žemės ūkio metodai gali trukdyti įdiegti aukštąsias technologijas.
Technologiniai	- DI ir vaizdavimo pažanga: Tobulėjantys dirbtinio intelekto algoritmai ir multispektrinio vaizdavimo technologijos didina pasėlių būklės stebėjimo ir kenkėjų aptikimo tikslumą. - Baterijos ir skrydžio laikas: Baterijų technologijų inovacijos gali prailginti dronų skrydžio laiką, didinant jų efektyvumą.

	- Duomenų apdorojimas: Kraštinis kompiuterinis skaičiavimas leidžia realiu laiku analizuoti duomenis laukuose, sumažinant priklausomybę nuo debesų infrastruktūros. - Integracija su daiktų internetu (IoT): Dronai gali integruotis su kitais IoT įrenginiais (pvz., dirvožemio jutikliais, meteorologinėmis stotimis) siekiant sukurti išsamias ūkio valdymo sistemas. - Autonomija: Pilnai autonominių dronų kūrimas gali sumažinti kvalifikuotų operatorių poreikį.
Aplinkosauginiai	- Tvarumas: Dronai optimizuoja išteklių naudojimą, mažindami vandens ir trąšų švaistymą, taip prisidedant prie tvarios žemdirbystės praktikos. - Anglies dioksido pėdsakas: Elektriniai dronai turi mažesnę anglies pėdsaką nei tradicinė žemės ūkio technika. - Ekologinis poveikis: Dronai mažiau veikia dirvožemį nei sunkioji technika, išsaugodami dirvos sveikatą. - Atsparumas klimatui: Dronai gali padėti ūkininkams prisitaikyti prie klimato kaitos, suteikdami ankstyvus įspėjimus apie sausras, potvynius ar kenkėjų protrūkius. - Biologinė įvairovė: Pernelyg dažnas dronų naudojimas jautriose ekosistemose gali trikdyti laukinę gamtą, todėl reikalingas atsargus planavimas.
Teisiniai	- Intelektinė nuosavybė (IP): Dronų technologijos, dirbtinio intelekto algoritmų ir vaizdavimo technikų patentai yra svarbūs inovacijų apsaugai ir konkurenciniam pranašumui išlaikyti.- Duomenų privatumas: Ūkininkų duomenys, surinkti dronų, turi atitikti duomenų apsaugos įstatymus (pvz., BDAR Europoje). - Aviacijos taisyklės: Vietinių ir tarptautinių dronų eksploatavimo įstatymų laikymasis yra būtinas, siekiant išvengti teisinių sankcijų. - Atsakomybės klausimai: Reikalingos aiškios gairės dėl atsakomybės dronų gedimų ar avarijų atvejais. - Eksporto kontrolė: Pažangių dronų technologijų eksporto apribojimai į tam tikras šalis gali riboti rinkos plėtrą.

Šaltinis: sudaryta autoriaus.

SSGG (Stiprybių – Silpnybių – Galimybių ir Grėsmių) analizė leidžia įvertinti vidinius ir išorinius produkto ar organizacijos aspektus. Ji padeda nustatyti, ką reikia tobulinti, ko vengti ir kur koncentruoti pastangas. Šiam procesui atlikti panaudojamas teksto generavimo modelis *Chatgpt* ir *Microsoft Word* diagramų vizualizavimo priemonė. Rezultatas pavaizduotas 31 paveiksle.



31 pav. SSGG analizė

Šaltinis: sudaryta autoriaus.

22 lentelė. Porterio penkių jėgų modelis

Jėga	Aprašymas	Poveikis	Strateginės pasekmės
Naujų dalyvių grėsmė	Žemės ūkio dronų rinka reikalauja didelių investicijų į mokslinius tyrimus, dirbtinį intelektą ir daugiaspektrio vaizdavimo technologijas. Teisiniai reikalavimai ir masto ekonomija veikia kaip barjerai, tačiau technologinė pažanga ilgainiui mažina įėjimo kliūtis.	Vidutinis	Nuolatinės inovacijos, prekės ženklo lojalumo kūrimas ir masto ekonomijos išnaudojimas siekiant atgrasyti naujus konkurentus. Stiprūs santykiai su ūkininkais ir įmonėmis didina perjungimo kaštus.
Tiekėjų derybinė galia	Pagrindines komponentus (pvz., jutiklius, kameras) tiekia specializuoti gamintojai. Ribotas tiekėjų skaičius pažangioms daugiaspektrio vaizdavimo ir DI technologijoms suteikia jiems didelę galią.	Aukštas	Diversifikuoti tiekėjų bazę, kad sumažintumėte priklausomybę. Investuoti į vertikalią integraciją arba savo mokslinius tyrimus kritiniams komponentams. Kurti strategines partnerystes su tiekėjais palankioms sąlygoms užtikrinti.
Pirkėjų derybinė galia	Pirkėjai svyruoja nuo pavienių ūkininkų iki didelių žemės ūkio įmonių. Didelės įmonės turi didesnę derybinę galią dėl didelių pirkimų apimčių, o pavieniai ūkininkai daro mažesnę įtaką. Kainų jautrumas yra vidutinis arba aukštas.	Vidutinis–aukštas	Siūlyti išskirtines vertės savybes (pvz., duomenų analitiką, aptarnavimą po pardavimo). Taikyti diferencijuotą kainodarą, kad būtų patenkinti tiek smulkūs, tiek dideli pirkėjai. Siekti ilgalaikių sutarčių su didelėmis įmonėmis stabilumui užtikrinti.
Pakaitalų grėsmė	Alternatyvos apima tradicinius pasėlių stebėjimo metodus, palydovinį vaizdavimą ir rankinį pasėlių tikrinimą. Tačiau dronai suteikia	Žemas–vidutinis	Akcentuoti dronų unikalius pranašumus (pvz., realaus laiko stebėjimą, DI pagrįstas įžvalgas). Šviesti ūkininkus apie

	didesnį tikslumą, realaus laiko duomenis ir ilgalaikį ekonomiškumą.		investicijų grąžą ir ilgalaikes sąnaudų taupymo galimybes. Nuolat tobulinti produktų savybes, kad liktų pranašesni už pakaitalus.
Konkurencinė kova	Rinka sparčiai auga, joje veikia tiek žinomi žaidėjai (pvz., DJI, PrecisionHawk), tiek startuoliai. Konkurencija yra intensyvi, pagrįsta technologine pažanga, kainodara ir paslaugų diferenciacija.	Aukštas	Skirtis nuo konkurentų per pažangesnius DI sprendimus, patogumą naudoti ir klientų aptarnavimą. Investuoti į mokslinius tyrimus, išlaikant konkurencingumą. Ieškoti nišinių rinkų (pvz., ekologinis ūkininkavimas), kad išvengtumėte tiesioginės konkurencijos.

Šaltinis: sudaryta autoriaus.


Toliau atliekama Porterio 5 jėgų analizė (22 lentelė). Michael Porter modelis padeda įvertinti rinkos konkurencingumą ir suprasti, kur slypi grėsmės ar galimybės pelningumui. Šiuo atveju išskiriamos penkios jėgos:

- Esamų konkurentų grėsmė: kiek yra analogiškų dronų rinkoje?
- Naujų konkurentų įėjimo grėsmė: ar lengva patekti į rinką naujiems žaidėjams?
- Pakaitalų grėsmė: ar kiti gaminiai gali pakeisti dronus?
- Tiekėjų derybinė galia: ar sunku gauti multispektrinius jutiklių ar DI modulius?
- Pirkėjų derybinė galia: ar klientai turi didelę pasirinkimo laisvę ir gali daryti spaudimą kainai?

3.3.5. IV Etapas. Produkto dizainas ir projektavimas

Šioje simuliacijoje – produkto dizainas ir projektavimas. Šioje analizėje yra pateikti trys žingsniai, vaizduojantys generatyvinio dizaino proceso eigą, kuri buvo atlikta „Autodesk Fusion“ programa, kuriant inovatyvų drono rėmą, skirtą žemės ūkio laukų ir pasėlių stebėjimui, integruojant dirbtinio intelekto technologijas.

32 paveiksle vaizduojamas pirminis drono konstrukcijos konceptualus modelis, paruoštas statinei analizei ir generatyvinio dizaino procesui. Modelis yra sudarytas iš kryžminės formos rėmo, propelerių, elektroninių komponentų lokacijų.



32 pav. Modelio paruošimas generatyviniui dizainui Autodesk Fusion 360 aplinkoje.

Šaltinis: sudaryta autoriaus.

Kaip ir kiekvienam DI algoritmui reikia suteikti kuo daugiau informacijos tam, kad būtų gautas geriausias rezultatas. Skirtingai nei praeituose simuliacijos etapuose, informacija perteikiama ne per žodinę užklausą, o per 3D modelio kūrimo procesus. Geltona spalva nurodo, kas modelyje turi būti generuojama, šiuo atveju kryžminės formos rėmas. Raudona spalva nurodo apibrėžti kur generatyvinio dizaino modelis negali pakeisti modelio konstrukcijos. Šiame pavyzdyje negalima generuoti formos propelerių lokacijoje, pagrindinio korpuso elektronikos pozicijose ir korpuso apatinėje dalyje ant kurio stovės dronas. Žalia spalva nurodo, kurie komponentai gali minimaliai keistis išlaikant pagrindinę formą. Šiuo atveju yra propelerių ir baterijos laikikliai.

Kitas modeliavimo etapas – apkrovų ir ribinių sąlygų nurodymas. 33 paveiksle pateikiami skaitinio modeliavimo parametrai, naudojami atliekant generatyvinio dizaino skaičiavimus.

Pirminė nurodomo apkrova yra gravitacijos jėga $9,807 \text{ m/s}^2$, veikianti per masės centrą – simuliuoja Žemės trauką. Antroji jėga lygi $30,00 \text{ N}$, taikoma tiesiai į konstrukciją, imituojanti aerodinaminę apkrovą. Toliau priskiriami du sukimo momentai po $5,00 \text{ N mm}$ – šie momentai modeliuoja variklių sukimosi poveikį struktūrai. Ir galiausiai nurodomos ribinės sąlygos. Fiksuota atrama – ribojamas poslinkis visomis kryptimis (U_x , U_y , U_z), t. y. struktūra negali judėti jokia kryptimi – modeliuojama kaip pritvirtinta prie bazės.

Loads				
	Type	Name	Magnitude	Status
✓	Gravity	Gravity	9.807 m / s ²	In Center of Gravity
✓	Force	Force1	30.00 N	Attached
✓	Moment	Moment1	5.00 N mm	Attached
✓	Moment	Moment2	5.00 N mm	Attached
Constraints				
	Type	Name	Magnitude	Status
✓	Fixed	Fixed1	Ux; Uy; Uz;	Attached

33 pav. Nustatytos apkrovos ir jėgos

Šaltinis: sudaryta autoriaus.

Nurodžius visą reikiama informaciją yra atliekamas generatyvinis dizainas. Programa pateikia šešis skirtingus rezultatus, kurių parametrai skiriasi pagal produkto svorį, patvarumą, apkrovas. 34 paveiksle pavaizduotas galutinis generatyvinio dizaino etapo pasirinktas rezultatas. Modelio struktūra yra optimizuota atsižvelgiant į apkrovas, medžiagos panaudojimo efektyvumą ir mechaninį atsparumą. Gauta organinės formos konstrukcija, kuri būdinga generatyvinio dizaino rezultatui, dizainas siekia maksimalų efektyvumą su minimaliomis medžiagos sąnaudomis. Variklių laikikliai ir rėmo dalys yra išlaikytos ten, kur būtina perduoti apkrovas, o perteklinės zonos pašalintos, taip sumažinant bendrą svorį ir padidinant efektyvumą.




34 pav. Sugeneruotas drono korpusas su generatyvinio dizaino algoritmais

Šaltinis: sudaryta autoriaus.

Ši analizė įrodo, kaip pažangios skaitmeninės inžinerijos priemonės – generatyvinis dizainas – gali būti taikomos kuriant inovatyvų, lengvą ir tvirtą drono rėmą, skirtą tikslingam žemės ūkio sektoriaus taikymui.

3.3.6. Simuliacijos rezultatas

Dėl didelės darbo apimtys simuliacija buvo atliekama iki testavimo etapo. Tačiau šios dalies simuliacijos pakako atskleisti, kaip dirbtinis intelektas gali būti pritaikytas inovatyvių sprendimų generavimui, vertinimui ir vystymui – nuo idėjos iki pardavimų prognozių. Simuliacija pagrindžia DI modelių integracijos reikšmę sprendimų priėmimo procesuose. Tačiau buvo pastebėta skirtinga dirbtinio intelekto reikšmė kiekvienam etapui.



35 pav. DI integracija inovatyvių produktų kūrimo „Stage-Gate“ modelyje po atliktos simuliacijos.
Šaltinis: Sudarytas autoriaus.

Dėl šių priežasčių, remiantis simuliacijos rezultatais, pirminis modelis buvo pakoreguotas, o 35 paveiksle pateikiamas galutinis modelio variantas. Modelio pokytis matomas integravimo srityje, kurioje papildomai nurodoma (aukšta, vidutinė, žema) DI reikšmė inovatyvių produktų kūrimo procesuose. Didžiausias teigiamas poveikis buvo pastebėtas idėjų generavime, koncepcijos plėtojime, vartotojų poreikių analizėje, operacijų valdyme, verslo analizėje ir produkto projektavime, tuo tarpu mažesnis efektas užfiksuotas produkto testavimo, idėjų tyrinėjimo, technologijų, prototipo vystymo, kainodaros strategijos etapuose.

IŠVADOS IR REKOMENDACIJOS

Šio magistro darbo tikslas buvo išanalizuoti dirbtinio intelekto poveikį inovatyvių produktų kūrimo procesams, pasitelkiant mokslinės literatūros analizę, empirinius tyrimo metodus bei simuliacinį modeliavimą, ir galiausiai suformuoti struktūruotą DI integracijos modelį, taikomą produktų inovacijų kūrimo kontekste. Tyrimas sprendžia aiškios metodinės sistemos trūkumą, siekiant sistemingai įvertinti DI įtaką produktų kūrimui gamybos sektoriuje.

1. Pirmiausia buvo atlikta mokslinės literatūros analizė, kurios metu išnagrinėta inovatyvaus produkto, dirbtinio intelekto samprata ir jų tarpusavio sąsajos. Pirmajame etape išsiaiškinta, kas yra inovatyvus produktas, kokie metodai taikomi jam kurti. Antrajame etape išnagrinėta DI esmė, atsiradimo priežastys, veikimo principai, klasifikavimas ir taikymo sritys. Trečiajame etape nustatyta, kaip DI veikia inovatyvaus produkto kūrimo procesus, kokią naudą ar žalą gali sukelti bei įvertinami įmonių veiklos rodikliai. Paaiškėjo, kad dirbtinio intelekto technologijos tampa vis svarbesniu veiksnium valdant inovacijas ir naujų produktų kūrimo procese. Nustatyta, kad DI prisideda ne tik prie proceso efektyvumo, bet ir skatina kūrybiškumą, sisteminį mąstymą bei greitesnį sprendimų priėmimą. DI gali būti taikomas įvairiuose produkto kūrimo etapuose – nuo idėjų generavimo, rinkos analizės, techninių sprendimų formavimo iki produkto paleidimo. Literatūra atskleidžia, kad DI potencialas dažnai lieka neišnaudotas dėl organizacinės inercijos, kompetencijų stokos ir metodologinio neapibrėžtumo. Todėl tampa aktualu ne tik apibendrinti DI taikymo praktikas, bet ir sukurti teorinį pagrindą jų sistemingam vertinimui.
2. Analizuojant kitų autorių taikytus empirinius tyrimus ir metodikas, nustatyta, kad dominuoja kokybiniai tyrimo modeliai – atvejo analizės, apklausų, interviu bei modeliavimu grįsti tyrimo metodai. Šios metodikos leidžia įvertinti tiek kiekybinius, tiek kokybinius DI įtakos aspektus. Šiame darbe pasirinktas „Stage-Gate“ modelis pasirodė tinkamas kaip conceptualus pagrindas, integruojantis inovacijų valdymo principus su praktiniais DI taikymo aspektais. Modelio pritaikomumas įvairioms pramonės šakoms, jo struktūriškumas bei galimybė vertinti kiekvieną kūrimo etapą atskirai sudarė prielaidas atlikti sisteminę analizę bei simuliaciją, kuri remiasi realiais duomenimis ir loginiais ryšiais tarp produkto kūrimo etapų.
3. Empirinio tyrimo ir simuliacijos rezultatai parodė, kad DI taikymas inovatyviems produktams kurti gali labiau padidinti proceso efektyvumą, ypač ankstyvuosiuose etapuose – generuojant idėjas, vartotojų poreikių analizėje. Simuliacinio modeliavimo

metu įvertinta, kad DI sprendimai, tokie kaip natūralios kalbos apdorojimas, automatizuota duomenų analizė ir prognozavimo modeliai, padeda sumažinti kūrimo laiką, rizikas ir resursų sąnaudas. O vėlesniuose etapuose – testavimo, prototipavimo ir paleidimo – DI nauda yra labiau priklausoma nuo specifinių įmonės technologinių galimybių ir žmogiškųjų išteklių pasirengimo. Tai leidžia teigti, kad DI nauda inovacijų procese nėra vienalytė ir reikalauja diferencijuoto vertinimo.

4. Parengtas struktūruotas DI integracijos modelis pateikia sisteminę DI taikymo schemą inovatyvių produktų kūrimo procese, remiantis „Stage-Gate“ metodologija. Modelis vizualizuoja, kuriuose etapuose DI daro stipriausią poveikį (aukštas pritaikomumas), kur galimas vidutinis poveikis, o kur – ribotas taikymas. Tokia struktūra leidžia įmonėms įsivertinti savo brandą, pasirinkti prioritetinius DI diegimo taškus ir prognozuoti technologijų integracijos naudą. Modelio vertė grindžiama jo gebėjimu ne tik susieti teorinius principus su praktiniu pritaikymu, bet ir siūlyti realius sprendimus, kaip optimizuoti inovacijų procesą, pasitelkiant DI priemones.

Apibendrinant galima teigti, kad dirbtinio intelekto taikymas kuriant inovatyvių produktų gali gerokai prisidėti prie organizacijų konkurencingumo, darbo našumo ir inovatyvumo didinimo, tačiau tam būtina tikslinga, etapais grįsta integracijos strategija. DI diegimas neturėtų būti traktuojamas kaip pavienis technologinis sprendimas – veikiau kaip kompleksinė inovacijų valdymo priemonė, reikalaujanti metodinio pagrindimo ir aiškių taikymo ribų kiekviename produkto kūrimo etape.

Remiantis atliktu magistro darbo tyrimu apie dirbtinio intelekto integravimą inovatyvių produktų kūrimo procese, siūlomos rekomendacijos:

- 1) Atsižvelgiant į tai, kad DI integracija ne visais produkto kūrimo etapais yra vienodai naudinga, rekomenduojama įmonėms kurti adaptuotus technologijų integracijos planus, kurie diferencijuotai vertintų DI taikymo efektyvumą pagal produkto vystymo specifiką ir įmonės technologines galimybes. Tai užtikrintų efektyvesnę investicijų panaudojimą bei geresnę organizacijos pasirengimą integruoti pažangias technologijas ilgalaikėje perspektyvoje.
- 2) Siekiant nuolatinio DI integracijos modelio tobulinimo, rekomenduojama moksliniams tyrimams sutelkti dėmesį į kiekybinius tyrimus ir išsamesnes atvejų analizes įvairiose pramonės šakose. Tyrimai galėtų dar labiau išgryninti modelio praktinį pritaikomumą, pateikti papildomų įžvalgų apie DI integracijos proceso dinamiką ir efektyvumą, bei suteikti pagrindą platesnei teorinei diskusijai apie DI taikymą produktų inovacijų kontekste.

- 3) Taikant modelį rekomenduojama pradėti DI diegimą palaipsniui – nuo paprastesnių sprendimų, tokių kaip natūralios kalbos apdorojimas ar prognozavimo modeliai, pereinant prie kompleksinių sistemų, integruojamų į produktų projektavimą ar verslo strategijų formavimą.

LITERATŪROS SĄRAŠAS

- Abraham, M., & Annunziata, M. (2017). Augmented reality is already improving worker performance. *Harvard Business Review*. <https://hbr.org/2017/03/augmented-reality-is-already-improving-worker-performance>
- Amabile, T. (2019). GUIDEPOST: creativity, artificial intelligence, and a world of surprises guidepost letter for academy of management discoveries. *Academy of Management Discoveries*. <https://doi.org/10.5465/amd.2019.0075>
- Deloitte AI Institute, Deloitte Center for Integrated Research, & Girzadas, J. (2021). Becoming an AI-fueled organization. In *Deloitte's State of AI in the Enterprise, 4th Edition*. https://www2.deloitte.com/content/dam/insights/articles/US144384_CIR-State-of-AI-4th-edition/DI_CIR_State-of-AI-4th-edition.pdf
- Belton, K. B., Olson, R., David J. Crandall, Angus Low, Scott J. Shackelford, & Susan Ariel Aaronson. (2019). Smart Factories: Issues of information governance. In Manufacturing Policy Initiative. <https://policyinstitute.iu.edu/doc/mpii/smart-factories.pdf#page=12>
- Benbya, H., Davenport, T. H., & Pachidi, S. (2020). Artificial intelligence in Organizations: current state and future opportunities. *SSRN Electronic Journal*. <https://doi.org/10.2139/ssrn.3741983>
- BibBase. (n.d.). *Stephen Hawking: "Transcendence looks at the implications of artificial intelligence - but are we taking AI seriously enough?"* <https://bibbase.org/network/publication/hawking-russell-tegmark-wilczek-stephenhawkingtranscendencelooksattheimplicationsofartificialintelligencebutarewetakingaiseriouslyenough>
- Brewka, G. (1996). Artificial intelligence—a modern approach by Stuart Russell and Peter Norvig, Prentice Hall. Series in Artificial Intelligence, Englewood Cliffs, NJ. *The Knowledge Engineering Review*, 11(1), 78–79. <https://doi.org/10.1017/s0269888900007724>
- Bryan M. (2013). Innovation: the most important and overused word in America. <https://www.wired.com/insights/2013/11/innovation-the-most-important-and-overused-word-in-america/>
- Brown, S. L., & Eisenhardt, K. M. (1995). Product development: past research, present findings, and future directions. *Academy of Management Review*, 20(2), 343–378.
- Bughin, J., Seong, J., Manyika, J., Chui, M., & Joshi, R. (2018). *Notes from the AI frontier:*

- Modeling the impact of AI on the world economy.* McKinsey & Company. <https://www.mckinsey.com/featured-insights/artificial-intelligence/notes-from-the-ai-frontier-modeling-the-impact-of-ai-on-the-world-economy>
- Carroll, J. (2013). Machine vision system inspects tabasco hot sauce products. *Vision Systems Design*. <https://www.vision-systems.com/cameras-accessories/article/16743645/machine-vision-system-inspects-tabasco-hot-sauce-products>
- Chandy, R. K., & Tellis, G. J. (1998). Organizing for radical product innovation: the overlooked role of willingness to cannibalize. *Journal of Marketing Research*, 35, 474-487. <https://doi.org/10.1177/002224379803500406>
- Chandra, D. (2019). Role of artificial intelligence in strengthening democratic institution in India. *SSRN Electronic Journal*. https://papers.ssrn.com/sol3/papers.cfm?abstract_id=3508720
- Chesbrough, H. (2009). Business model Innovation: opportunities and barriers. *Long Range Planning*, 43(2–3), 354–363. <https://doi.org/10.1016/j.lrp.2009.07.010>
- Choi, R. Y., Coyner, A. S., Kalpathy-Cramer, J., Chiang, M. F., & Campbell, J. P. (2020). Introduction to machine learning, neural networks, and deep learning. *Translational Vision Science & Technology*, 9(2), 14. <https://doi.org/10.1167/tvst.9.2.14>
- Chowdhury, G. G. (2003). Natural language processing. *Annual Review of Information Science and Technology*, 37(1), 51–89. <https://doi.org/10.1002/aris.1440370103>
- Cooper, R. G. (2001). Winning at new products: Accelerating the process from idea to launch (3rd ed.). Perseus Books
- Cooper, R. G. (2008). Perspective: the Stage-Gate idea-to-launch process—update, what’s new, and nexgen Systems. *Journal of Product Innovation Management*, 25(3), 213–232. <https://doi.org/10.1111/j.1540-5885.2008.00296.x>
- Cooper, R. G. (2019). The drivers of success in new-product development. *Industrial Marketing Management*, 76, 36–47. <https://doi.org/10.1016/j.indmarman.2018.07.005>
- Cooper, R. G., & Kleinschmidt, E. J. (2007). Winning businesses in product development: the critical success Factors. *Research-Technology Management*, 50(3), 52–66. <https://doi.org/10.1080/08956308.2007.11657441>
- Cooper, R. G., Edgett, S. J., & Kleinschmidt, E. J. (2004). Benchmarking best NPD practices—I. *Research-Technology Management*, 47(1), 31–43.

<https://doi.org/10.1080/08956308.2004.11671606>

- Crawford, C. (2003). *Chris Crawford on Game Design*. <http://ci.nii.ac.jp/ncid/BA88565470>
- Castro, D., McLaughlin, M., & Center for data innovation. (2021). *Who is winning the AI race: China, the EU, or the United States? — 2021 Update*. <https://www2.datainnovation.org/2021-china-eu-us-ai.pdf>
- Han, J., Kamber, M., & Pei, J. (2011). Data mining: concepts and techniques (3rd ed.). *Morgan Kaufmann Publishers*
- Dieffenbacher S. F. (2023). Radical innovation meaning, examples and characteristics. <https://digitalleadership.com/blog/radical-innovation/>
- Eggers, J. P., & Kaplan, S. (2009). Cognition and renewal: comparing ceo and organizational effects on incumbent adaptation to technical change. *Organization Science*, 20(2), 461–477. <https://doi.org/10.1287/orsc.1080.0401>
- Eiriz, V., Faria, A., & Barbosa, N. (2013). Firm growth and innovation: towards a typology of innovation strategy. *Innovation: Management, Policy and Practice*, 15(1), 97–111. <https://doi.org/10.5172/impp.2013.15.1.97>
- Hozdić, E. (2015). Smart factory for Industry 4.0: a review. *International Journal of Modern Manufacturing Technologies*, 7(1), 28–35. https://www.researchgate.net/publication/282791888_Smart_factory_for_industry_40_A_review
- Engert, S., & Hess, T. (2023). Logic multiplicity in digital business models – an institutional logics perspective. *Proceedings of the Annual Hawaii International Conference on System Sciences/Proceedings of the Annual Hawaii International Conference on System Sciences*. <https://doi.org/10.24251/hicss.2023.756>
- Eurostat. (2024). Manufacturing sector share in GDP. Retrieved from <https://ec.europa.eu/eurostat>.
- Fujitsu. (2017). AI-powered design innovation. *Fujitsu scientific & technical journal*, 53(4), 56–63.
- Fulkerson, B., Michie, D., Spiegelhalter, D. J., & Taylor, C. C. (1995). Machine learning, neural and statistical classification. *Technometrics*, 37(4), 459. <https://doi.org/10.2307/1269742>
- Gilbert, R., & Newbery, D. M. (1982). *Preemptive patenting and the persistence of monopoly*. https://econpapers.repec.org/article/aeaaecrev/v_3a72_3ay_3a1982_3ai_3a3_3ap_3a514-26.htm

- Gyngell, P. (1994). Process innovation: reengineering work through information technology. *European Journal of Information Systems*, 3(3), 244–246. <https://doi.org/10.1057/ejis.1994.28>
- Cam, A., Chui, M., & Hall, B. (2019). Global AI survey: AI proves its worth, but few scale impact. *McKinsey & Company*. <https://www.mckinsey.com/featured-insights/artificial-intelligence/global-ai-survey-ai-proves-its-worth-but-few-scale-impact>
- Goertzel, B. (2014). Artificial general intelligence: concept, state of the art, and future prospects. *Journal of Artificial General Intelligence*, 5(1), 1–48. <https://doi.org/10.2478/jagi-2014-0001>
- Buxmann, P., & Schmidt, H. (2018). Grundlagen der Künstlichen Intelligenz und des Maschinellen Lernens. In *Künstliche Intelligenz*. https://doi.org/10.1007/978-3-662-57568-0_1
- Guo, Y., Liu, Y., Oerlemans, A., Lao, S., Wu, S., & Lew, M. S. (2016). Deep learning for visual understanding: A review. *Neurocomputing*, 187, 27–48. <https://doi.org/10.1016/j.neucom.2015.09.116>
- Ghosh, S. (2022). How AI capabilities influence data-driven business model innovation. *Presented at the World Open Innovation Conference, Eindhoven, The Netherlands*.
- Haefner, N., Wincent, J., Parida, V., & Gassmann, O. (2021). Artificial intelligence and innovation management: A review, framework, and research agenda. *Technological Forecasting & Social Change*, 162, 120392. <https://doi.org/10.1016/j.techfore.2020.120392>
- Hajli, N., & Featherman, M. S. (2018). The impact of new ICT technologies and its applications on health service development and management. *Technological Forecasting & Social Change/Technological Forecasting and Social Change*, 126, 1–2. <https://doi.org/10.1016/j.techfore.2017.09.015>
- Hargadon A. (2004). How breakthroughs happen: the surprising truth about how companies innovate. *Choice Reviews Online*, 41(10), 41-6004-41–6004. <https://doi.org/10.5860/choice.41-6004>
- Porter, M. E., & Stern, S. (2001). Innovation: location matters. *MIT Sloan Management Review*, 42(4), 28–36. <https://www.hbs.edu/faculty/Pages/item.aspx?num=10690>Jones,
- J. N., Cope, J., & Kintz, A. (2016). Peering into the future of innovation management. *Research Technology Management*, 59(4), 49–58. <https://doi.org/10.1080/08956308.2016.1185344>

- Kaelbling, L. P., Littman, M. L., & Moore, A. W. (1996). Reinforcement learning: a survey. *Journal of Artificial Intelligence Research*, 4, 237–285. <https://doi.org/10.1613/jair.301>
- Kahn, K. B. (2018). Understanding innovation. *Business Horizons*, 61(3), 453–460. <https://doi.org/10.1016/j.bushor.2018.01.011>
- Kalra, N., & Paddock, S. M. (2016). Driving to safety: how many miles of driving would it take to demonstrate autonomous vehicle reliability? *Transportation Research. Part a, Policy and Practice*, 94, 182–193. <https://doi.org/10.1016/j.tra.2016.09.010>
- Kanade, V. (2022). Narrow artificial intelligence definition, challenges, best practices - spiceworks Inc. Spiceworks Inc. <https://www.spiceworks.com/tech/artificial-intelligence/articles/what-is-narrow-ai/>
- Kaplan, A., & Haenlein, M. (2019). Siri, siri, in my hand: who's the fairest in the land? On the interpretations, illustrations, and implications of artificial intelligence. *Business Horizons*, 62(1), 15–25. <https://doi.org/10.1016/j.bushor.2018.08.004>
- Kehayov, M., Holder, L., & Koch, V. (2022). Application of artificial intelligence technology in the manufacturing process and purchasing and supply management. *Procedia Computer Science*, 200, 1209–1217. <https://doi.org/10.1016/j.procs.2022.01.321>
- Kleinschmidt, E. J., De Brentani, U., & Salomo, S. (2007). Performance of global new product development programs: a resource-based view. *Journal of Product Innovation Management*, 24(5), 419–441. <https://doi.org/10.1111/j.1540-5885.2007.00261.x>Salimon
- Knight, W. (2018). This company tames killer robots. *MIT Technology Review*. <https://www.technologyreview.com/2018/06/15/2647/this-company-tames-killer-robots/>
- Kotler, P., Armstrong, G., & Opresnik, M. O. (2012). *Principles of Marketing Global Edition*. https://openlibrary.org/books/OL29060739M/Principles_of_Marketing
- Kuratko, D. F., & Audretsch, D. B. (2009). Strategic entrepreneurship: exploring different perspectives of an emerging concept. *Entrepreneurship: Theory and Practice*. <https://doi.org/10.1111/j.1540-6520.2008.00278.x>
- Kuratko, D. F., Covin, J. G., & Hornsby, J. S. (2014). Why implementing corporate innovation is so difficult. *Business Horizons*, 57(5), 647–655. <https://doi.org/10.1016/j.bushor.2014.05.007>
- Lacity, M., Willcocks, L. P., & Craig, A. (2015). Robotic process automation at Telefónica O2. *LSE Research Online Documents on Economics*. <https://eprints.lse.ac.uk/64516/>
- Lake, B. M., Ullman, T. D., Tenenbaum, J. B., & Gershman, S. J. (2016). Building machines

- that learn and think like people. *Behavioral and Brain Sciences*, 40. <https://doi.org/10.1017/s0140525x16001837>
- Lengnick-Hall, C. A. (1992). Innovation and competitive advantage: what we know and what we need to learn. *Journal of Management*, 18(2), 399–429. <https://doi.org/10.1177/014920639201800209>
- Mitchell, T. M. (1997). Machine learning. *McGraw-Hill Science/Engineering/Math*.
- MMC (2019). *The state of AI: divergence*. <https://mmc.vc/wp-content/uploads/2024/01/The-MMC-State-of-AI-2019-Report.pdf>
- Mohammed, M., Khan, M. B., & Bashier, E. B. M. (2016). Machine learning. In *CRC Press eBooks*. <https://doi.org/10.1201/9781315371658>
- Pattnaik, A., & Mohanty, M. (2024, December 19). *Revolutionizing aerospace with artificial intelligence: A Review*. <https://ijcres.in/index.php/ijcr/article/view/8>
- Montagna F. (2023). Optimizing product development and innovation processes with artificial intelligence. *Master Degree Course Data Science and Engineering*
- Mou, X. & IFC. (2019). Artificial intelligence: investment trends and selected industry uses. In *IFC* . <https://www.ifc.org/thoughtleadership>
- Mucci, T., & Stryker, C. (2025, April 16). *Artificial Superintelligence. What is artificial superintelligence?* <https://www.ibm.com/topics/artificial-superintelligence>
- O’Cass, A., & Wetzels, M. (2018). Contemporary issues and critical challenges on innovation in services. *The Journal of Product Innovation Management*, 35(5), 674–681. <https://doi.org/10.1111/jpim.12464>
- Office, I. P. (2019, June 18). *Artificial intelligence - a worldwide overview of AI patents*. <https://www.gov.uk/government/publications/artificial-intelligence-a-worldwide-overview-of-ai-patents>
- Oslo Manual. (2005). In *The measurement of scientific and technological activities*. <https://doi.org/10.1787/9789264013100-en>
- PwC. (2018). Harnessing Artificial intelligence for the earth. *PricewaterhouseCoopers*.
- Peters, B. (2007). Persistence of innovation: stylised facts and panel data evidence. *The Journal of Technology Transfer*, 34(2), 226–243. <https://doi.org/10.1007/s10961-007-9072-9>
- Plathottam, S. J., Rzonca, A., Lakhnori, R., & Iloeje, C. O. (2023). A review of artificial intelligence applications in manufacturing operations. *Journal of Advanced*

Manufacturing and Processing, 5(3). <https://doi.org/10.1002/amp2.10159>

- Plathottam, S. J., Rzonca, A., Lakhnori, R., & Iloeje, C. O. (2023). A review of artificial intelligence applications in manufacturing operations. *Journal of Advanced Manufacturing and Processing*, 5(3). <https://doi.org/10.1002/amp2.10159>
- Popescu, A.-D. & SCX Holdings Pte. Ltd. (2019). The value of data from an artificial intelligence perspective. In *Annals of the University of Craiova for Journalism, Communication and Management* (Vols. 5–5, pp. 172–194). <https://aucjc.ro/wp-content/uploads/2019/11/aucjcm-vol-5-2019-172-194.pdf>
- Ralston, A., Reilly, E. D., & Hemmendinger, D. (2001). Encyclopedia of computer science. *Choice Reviews Online*, 38(07), 38–3650. <https://doi.org/10.5860/choice.38-3650>
- Research on Intelligent Manufacturing Development Strategy in China. (2018). *Strategic Study of CAE*, 20(4), 1. <https://doi.org/10.15302/j-sscae-2018.04.001>
- Robotnik. (2023, October 25). The future is here: artificial intelligence robots transforming industries. *Robotnik*. <https://robotnik.eu/the-future-is-here-artificial-intelligence-robots-transforming-industries/>
- Sarker, I. H. (2021). Machine learning: algorithms, real-world applications and research directions. *SN Computer Science* 2(3). <https://doi.org/10.1007/s42979-021-00592-x>
- Sarker, I. H. (2022). AI-Based modeling: techniques, applications and research issues towards automation, intelligent and smart systems. *SN Computer Science* 3(2). <https://doi.org/10.1007/s42979-022-01043-x>
- Sarker, I. H., Kayes, A. S. M., Badsha, S., AlQahtani, H., Watters, P. A., & Ng, A. (2020). Cybersecurity data science: an overview from machine learning perspective. *Journal of Big Data*, 7(1). <https://doi.org/10.1186/s40537-020-00318-5>
- Schumpeter, J. A. (1934). The theory of economic development: an inquiry into profits, capital, credit, interest, and the business cycle. *SSRN Electronic Journal*. https://papers.ssrn.com/sol3/papers.cfm?abstract_id=1496199
- Shah, E. (2023, June 8). *Rule-based systems in AI - Scaler topics*. Scaler Topics. <https://www.scaler.com/topics/artificial-intelligence-tutorial/rule-based-system-in-ai/>
- Shed, S. (2017, January 3). Amazon now has 45,000 robots in its warehouses | Business Insider India. *Business Insider*. <https://www.businessinsider.in/amazon-now-has-45000-robots-in-its-warehouses/articleshow/56315471.cms>
- Sheikh, H., Prins, C., & Schrijvers, E. (2023). Mission AI. In *Research for policy*.

<https://doi.org/10.1007/978-3-031-21448-6>

- Smith, A. (1776). An inquiry into the nature and causes of the wealth of nations. In *Oxford University Press eBooks*. <https://doi.org/10.1093/oseo/instance.00043218>
- Tavassoli, S., & Karlsson, C. (2015). Persistence of various types of innovation analyzed and explained. *Research Policy*, 44(10), 1887–1901. <https://doi.org/10.1016/j.respol.2015.06.001>
- Tzokas, N., Hultink, E. J., & Hart, S. (2004). Navigating the new product development process. *Industrial Marketing Management*, 33(7), 619–626. <https://doi.org/10.1016/j.indmarman.2003.09.004>
- Van Der Aalst, W. M. P., Bichler, M., & Heinzl, A. (2018). Robotic process automation. *Business & Information Systems Engineering*, 60(4), 269–272. <https://doi.org/10.1007/s12599-018-0542-4>
- Varadarajan, R. (2009). Fortune at the bottom of the innovation pyramid: the strategic logic of incremental innovations. *Business Horizons*, 52(1), 21–29. <https://doi.org/10.1016/j.bushor.2008.03.011>
- Wang, Y., Zhang, H., & Song, M. (2020). Does big data–embedded new product development influence project success? *Research Technology Management*, 63(4), 35–42. <https://doi.org/10.1080/08956308.2020.1762447>
- Zamani, E. D., Smyth, C., Gupta, S., & Dennehy, D. (2022). Artificial intelligence and big data analytics for supply chain resilience: a systematic literature review. *Annals of Operation Research/Annals of Operations Research*, 327(2), 605–632. <https://doi.org/10.1007/s10479-022-04983-y>
- Zhang, H., Zhang, X., & Song, M. (2021). Deploying AI for new product development success. *Research Technology Management*, 64(5), 50–57. <https://doi.org/10.1080/08956308.2021.1942646>

Dovydas Alčauskas

DIRBTINIO INTELEKTO (DI) TAIKYMAS INOVATYVIŲ PRODUKTŲ KŪRIMUI

Darbo tikslas ir uždaviniai

Tikslas

Išanalizavus mokslinę literatūrą bei atlikus empirinius tyrimus parengti ir pasiūlyti struktūruotą modelį, įvertinantį dirbtinio intelekto įtaką inovatyvių produktų kūrimui.

Uždaviniai

1. Atlikti mokslinės literatūros analizę, įvertinančios dirbtinio intelekto įtaką inovatyvių produktų kūrimui.
2. Apžvelgti ir išanalizuoti kitų tyrėjų taikytus empirinių tyrimų metodus tiriant DI panaudojimą inovatyvių produktų kūrimui ir pasirinkti metodą/-us savo empirinei tyrimo daliai.
3. Atlikti empirinius tyrimus ir išanalizuoti gautus rezultatus.
4. Parengti ir pasiūlyti struktūruotą modelį, įvertinantį dirbtinio intelekto įtaką inovatyvių produktų kūrimui.
5. Atlikti simuliacinį modeliavimą remiantis sudarytu struktūruotu modeliu.

Inovacijos samprata

Inovacijos – tai naujos idėjos, kurias sudaro: nauji produktai ir paslaugos, naujas esamų produktų panaudojimas, naujos esamų produktų rinkos arba nauji rinkodaros metodai (Simmonds, 1986).


Inovacijos yra pagrindinis rodiklis įtakojantis ekonomikos augimą, komercinį pelną ir kuriantis visuomenės gerovės jėgą (Schumpeter, 1934)

Inovatyvių produktų kūrimo procesas

Visą procesą galima žiūrėti iš matematinės perspektyvos: produkto savybės (F), tikslinės rinkos segmentas (M), kaina (C), laikas iki rinkos pasiekimo (T) ir kokybė (Q). Tikslas yra rasti optimalų šių kintamųjų derinį, kad būtų maksimaliai padidintas rinkos potencialas ir pelningumas (Montagna, 2023).

Produkto kūrimo procesas (F, M, C, T, Q) → Inovatyvus produktas


“Stage-Gate” modelis (R.Cooper)



Pav. 1. “Stage-Gate” (Cooper, 2021)

Literatūros analizė

Dirbtinio intelekto klasifikavimas



Pav. 2. Dirbtinio intelekto klasifikavimas Lei Wang (2021)


Tyrimo metodu pasirinkimas ir eiga

1. Remiantis atlikta literatūros analizė, pasirenkamas populiarus inovatyvių produktų kūrimo modelis – “Stage-Gate”.
2. Analizuoti DI taikymo aspektai kiekviename produkto kūrimo etape.
3. Naudojamas modeliavimo metodas. Sukuriamas modelis.
4. Tinkamai suprasti pasiūlytą struktūrizuotą modelį, atliekamas simuliacijos metodas.
5. Atsižvelgiant į simuliacijos rezultatus pateikiamas galutinis modelis.


Empirinio tyrimo eiga ir rezultai

I Etapas. Idėjų generavimas	II Etapas. Apžvalga	III Etapas. Verslo planas	IV Etapas. Kūrimas	V Etapas. Testavimas	VI Etapas. Paleidimas
- Idėjų generavimas; - Technologijų analizė; - Rinkos analizė. - Idėjų tyrinėjimas;	- Vartotojų poreikių analizė; - Rizikų identifikavimas; - Koncepcijos plėtojimas; - Verslo galimybių vertinimas.	- Verslo plano kūrimas; - Pardavimų prognozė; - Konkurentų analizė; - Technologijų tinkamumas.	- Produkto dizaino projektavimas; - Darbo automatizavimas; - Projektų valdymas. - Technologijų testavimas; - Prototipo vystymas;	- Našumo optimizavimas; - Rizikų valdymas; - Reglamentavimas. - Simuliaciniai modeliai;	- Gamybos optimizavimas. - Rinkodaros strategijos įgyvendinimas; - Klientų pasitenkinimas; - Kainodaros strategija;
Natūralios kalbos apdorojimas: - Teksto analizė; - Teksto generavimas; Prižiūrimas mokymasis: - Klasifikavimas; - Regresija; Nepržiūrimas mokymasis: - Klasterizacija; - Asociacijos; Kompiuterinė rega.	Natūralios kalbos apdorojimas: - Teksto analizė; - Teksto generavimas; Prižiūrimas mokymasis: - Klasifikavimas; - Regresija; Nepržiūrimas mokymasis: - Klasterizacija; - Asociacijos; Sustiprintas mokymasis; Kompiuterinė rega.	Natūralios kalbos apdorojimas: - Teksto analizė; - Teksto generavimas; Prižiūrimas mokymasis: - Klasifikavimas; - Regresija; Nepržiūrimas mokymasis: - Klasterizacija; - Asociacijos; Sustiprintas mokymasis; Kompiuterinė rega.	Natūralios kalbos apdorojimas: - Teksto analizė; - Teksto generavimas; Prižiūrimas mokymasis: - Klasifikavimas; - Regresija; Nepržiūrimas mokymasis: - Klasterizacija; - Asociacijos; Kompiuterinė rega; Genratyvinis DI; Robotiniu Procesų Automatizavimu;	Natūralios kalbos apdorojimas: - Teksto analizė; - Teksto generavimas; Prižiūrimas mokymasis: - Klasifikavimas; - Regresija; Nepržiūrimas mokymasis: - Klasterizacija; - Asociacijos; Sustiprintas mokymasis; Kompiuterinė rega. Robotiniu Procesų Automatizavimu;	Natūralios kalbos apdorojimas: - Teksto analizė; - Teksto generavimas; Prižiūrimas mokymasis: - Klasifikavimas; - Regresija; Nepržiūrimas mokymasis: - Klasterizacija; - Asociacijos; Sustiprintas mokymasis; Kompiuterinė rega. Robotiniu Procesų Automatizavimu;

Pirminis modelis





Simuliacija




```
1 import spacy
2 from spacy.pipeline.textcat import TextCategorizer
3 import random
4 nlp = spacy.blank("en")
5
6 textcat = nlp.add_pipe("textcat", last=True)
7
8 textcat.add_label("Filmmaking")
9 textcat.add_label("Construction")
10 textcat.add_label("Agriculture")
11 textcat.add_label("Environment")
12 textcat.add_label("Technology")
13
14 train_data = [
15     ("Drone for travel video creation with AI integration.", {"cats": {"Filmmaking": 1, "Construction": 0, "Agriculture": 0, "Environment": 0, "Technology": 0}}),
16     ("Drone for construction site monitoring.", {"cats": {"Filmmaking": 0, "Construction": 1, "Agriculture": 0, "Environment": 0, "Technology": 0}}),
17     ("Agricultural drone for crop monitoring.", {"cats": {"Filmmaking": 0, "Construction": 0, "Agriculture": 1, "Environment": 0, "Technology": 0}}),
18     ("Drone for reforestation and planting trees.", {"cats": {"Filmmaking": 0, "Construction": 0, "Agriculture": 0, "Environment": 1, "Technology": 0}}),
19     ("Drone for detecting plant diseases.", {"cats": {"Filmmaking": 0, "Construction": 0, "Agriculture": 1, "Environment": 0, "Technology": 0}}),
20     ("Photographic projection drone.", {"cats": {"Filmmaking": 0, "Construction": 0, "Agriculture": 0, "Environment": 0, "Technology": 1}}),
21     ("Laser drone for pest control.", {"cats": {"Filmmaking": 0, "Construction": 0, "Agriculture": 0, "Environment": 1, "Technology": 0}}),
22 ]
23
24 optimizer = nlp.begin_training()
25 for epoch in range(50):
26     random.shuffle(train_data)
27     for text, annotations in train_data:
28         doc = nlp.make_doc(text)
29         example = spacy.training.Example.from_dict(doc, annotations)
30         nlp.update([example], optimizer)
31     nlp.to_disk("drone_text_classification_model")
32
33 print("Modelis sėkmingai išauktas kaip 'drone_text_classification_model'!")
34
35 # Test
36 import spacy
37 nlp = spacy.load("drone_text_classification_model")
38
39 text = "Drone equipped with AI for video editing"
40 doc = nlp(text)
41
42 print("Kategorijos (vertinimas: (doc.cats))")
43
44 best_category = max(doc.cats.items(), key=lambda item: item[1])
45 print("Geriausia kategorija: (best_category)")
46
47 # Test
48 nlp = spacy.load("drone_text_classification_model")
49
50 text = "The drone is designed for agriculture, it can monitor crops and assess their health"
51 doc = nlp(text)
52
53 print("Kategorijos (vertinimas: (doc.cats))")
54
55 best_category = max(doc.cats.items(), key=lambda item: item[1])
56 print("Geriausia kategorija: (best_category)")
57
58 # Test
59 nlp = spacy.load("drone_text_classification_model")
60
61 text = "The drone is designed for agriculture, it can monitor crops and assess their health"
62 doc = nlp(text)
63
64 print("Kategorijos (vertinimas: (doc.cats))")
65
66 best_category = max(doc.cats.items(), key=lambda item: item[1])
67 print("Geriausia kategorija: (best_category)")
```

Supp	Conf	Covr	Strg	Lift	Levr	Antecedent	Consequent
0.300	0.600	0.500	1.400	0.857	-0.050	Baterija=1	→ Sensorius=1
0.300	0.429	0.700	0.714	0.857	-0.050	Sensorius=1	→ Baterija=1
0.200	0.667	0.300	2.333	0.952	-0.010	D?klas=1	→ Sensorius=1
0.200	0.286	0.700	0.429	0.952	-0.010	Sensorius=1	→ D?klas=1
0.200	0.667	0.300	1.667	1.333	0.050	D?klas=1	→ Baterija=1
0.200	0.400	0.500	0.600	1.333	0.050	Baterija=1	→ D?klas=1
0.100	0.500	0.200	3.500	0.714	-0.040	Baterija=1, D?klas=1	→ Sensorius=1
0.100	0.500	0.200	2.500	1.000	0.000	Sensorius=1, D?klas=1	→ Baterija=1
0.100	0.333	0.300	1.000	1.111	0.010	D?klas=1	→ Sensorius=1, Baterija=1
0.100	0.333	0.300	1.000	1.111	0.010	Sensorius=1, Baterija=1	→ D?klas=1
0.100	0.200	0.500	0.400	1.000	0.000	Baterija=1	→ Sensorius=1, D?klas=1
0.300	0.600	0.500	1.400	0.857	-0.050	DI integracijos programa=1	→ Sensorius=1
0.300	0.429	0.700	0.714	0.857	-0.050	Sensorius=1	→ DI integracijos programa=1
0.300	0.600	0.500	1.000	1.200	0.050	DI integracijos programa=1	→ Baterija=1
0.300	0.600	0.500	1.000	1.200	0.050	Baterija=1	→ DI integracijos programa=1




```
C:\Users> doryd\Desktop> Test > klasterizavimas.py > ...
1 import pandas as pd
2 import numpy as np
3 from sklearn.cluster import KMeans
4 from sklearn.preprocessing import StandardScaler
5 import matplotlib.pyplot as plt
6
7 data = {
8     'Plotas_ha': [10, 20, 30, 40, 50, 60, 70, 80, 90, 100], # ūkio plotas hektarais
9     'Kvieciu_plotas_ha': [5, 10, 15, 20, 25, 30, 35, 40, 45, 50], # kviečių plotas hektarais
10    'Mieziu_plotas_ha': [3, 6, 9, 12, 15, 18, 21, 24, 27, 30], # miežių plotas hektarais
11    'Naudoja_dronus': [1, 0, 1, 0, 1, 0, 1, 0, 1, 0], # 1 - naudoja dronus, 0 - nenaudoja
12    'Vidutinis_derlius': [3.5, 4.0, 3.8, 4.2, 4.5, 3.7, 4.1, 4.3, 4.0, 4.4], # vidutinis derlius (t/ha)
13    'Investicijos_eurais': [1000, 2000, 1500, 3000, 2500, 4000, 3500, 5000, 4500, 6000], # investicijos
14    'Amzius': [30, 40, 50, 60, 35, 45, 55, 65, 70, 75], # ūkininko amžius
15    'Patirtis_metai': [5, 10, 15, 20, 7, 12, 18, 22, 25, 30] # patirtis ūkininkauti metais
16 }
17
18 #Konvertuojame duomenis į pandas DataFrame
19 df = pd.DataFrame(data)
20
21 #Atrenkame tik skaitinius duomenis
22 X = df.values
23
24 # 4. Normalizuojame duomenis (kad visi stulpeliai būtų vienodo svorio)
25 scaler = StandardScaler()
26 X_scaled = scaler.fit_transform(X)
27
28 #Atliekame klasterizaciją naudodami K-means
29 kmeans = KMeans(n_clusters=3) # nustatome klasterių skaičių
30 kmeans.fit(X_scaled)
31
32 #Pridame klasterio etiketes prie duomenų
33 df['Klasteris'] = kmeans.labels_
34
35 #Atvaizduojame rezultatus grafiškai
36 plt.figure(figsize=(12, 6))
37
38 # Scatter plot pagal vidutinį derlių ir investicijas
39 plt.subplot(1, 2, 1) # Pirmas grafikas
40 plt.scatter(df['Vidutinis_derlius'], df['Investicijos_eurais'], c=df['Klasteris'], cmap='viridis', s=100)
41 plt.xlabel('Vidutinis derlius (t/ha)')
42 plt.ylabel('Investicijos į technologijas (eurais)')
43 plt.title('Derlius vs Investicijos')
44 plt.colorbar(label='Klasteris')
45 plt.grid(True)
46
47 # Scatter plot pagal amžių ir patirtį
48 plt.subplot(1, 2, 2) # Antras grafikas
49 plt.scatter(df['Amzius'], df['Patirtis_metai'], c=df['Klasteris'], cmap='plasma', s=100)
50 plt.xlabel('Amzius')
51 plt.ylabel('Patirtis ūkininkauti (metai)')
52 plt.title('Amzius vs Patirtis')
53 plt.colorbar(label='Klasteris')
54 plt.grid(True)
55
56 plt.tight_layout()
57 plt.show()
58
59 # Rezultatas
60 print("Sugrupuoti duomenys:")
61 print(df)
```

Simuliacija



Galutinis modelis



Išvados ir rekomendacijos

Išvados

- Dirbtinio intelekto (DI) integravimas „Stage-Gate“ metodologijoje reikšmingai pagerina produkto kūrimo efektyvumą, kokybę ir rinkos poreikių atitikimą.
- Didžiausias teigiamas poveikis buvo pastebėtas idėjų generavime, koncepcijos plėtojime, vartotojų poreikių analizėje, operacijų valdyme, verslo analizėje ir produkto projektavime.
- Mažesnis poveikis užfiksuotas produkto testavimo, idėjų tyrinėjimo, technologijų, prototipo vystymo, kainodaros strategijos etapuose
- Strategiškai diegiant DI technologijas sumažėja produkto kūrimo trukmė, išlaidos ir sustiprėja įmonių konkurencingumas.
- Svarbūs DI integravimo sėkmės veiksniai: technologinis pasirengimas, duomenų kokybė ir darbuotojų kompetencijos.

Rekomendacijos

- 1) Vykdyti išsamesnius empirinius tyrimus, apimant įvairesnius sektorius Lietuvoje.
- 2) Giliau analizuoti konkrečius DI metodus (pvz., neuroninius tinklus), jų optimizavimo galimybes ir pritaikomumą skirtingiems įmonių dydžiams bei rinkoms.