

Mechanics and materials engineering Mechanika ir medžiagų inžinerija

DIRBTINIO INTELEKTO (DI) TAIKYMAS INOVATYVIEMS PRODUKTAMS KURTI

Dovydas ALČAUSKAS  

Vilniaus Gedimino technikos universitetas, Vilnius, Lietuva

- gauta 2025 m. gegužės 28 d.
- priimta 2025 m. lapkričio 13 d.

Santrauka. Dabartinėje ekonominėje aplinkoje, kurioje technologinė pažanga vyksta labai sparčiai, o produktų gyvavimo ciklas trumpėja, įmonėms reikia ne tik inovatyvios produktų kūrimo strategijos, bet ir supratimo apie veiksnus, lemiančius naujų produktų sėkmę rinkoje. Vienas iš sprendimo būdų – inovatyvaus produkto kūrimas pasitelkiant dirbtinį intelektą. Šio straipsnio tikslas – ištirti kaip dirbtinio intelekto integravimas veikia inovatyvaus produkto kūrimo procesą. Straipsnyje analizuojama inovacijų ir dirbtinio intelekto samprata, sąsaja tarp šių procesų ir klasifikavimo modeliai. Remiantis sukurta tyrimo metodologija, atliekama mokslinės literatūros analizė, o pagal ją 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. Identifikuojamos sąsajos tarp pasirinkto modelio elementų ir dirbtinio intelekto integravimo galimybių. Siekdami pasiūlyti struktūruotą modelį, įvertinantį dirbtinio intelekto įtaką inovatyvių produktų kūrimo procesui, autoriai taiko modeliavimo metodą. Jis padeda suprasti empirinio tyrimo rezultatų ir elementų, ryšius bei sąsajas. Remiantis šiuo metodu, sukuriamas modelis. Tyrimo pabaigoje, norint patikrinti pasiūlytą struktūruotą modelį, taikomas simuliacijos metodas. Straipsnio pabaigoje pateiktos tyrimo išvados ir rekomendacijos.

Reikšminiai žodžiai: dirbtinis intelektas, dirbtinio intelekto integravimas, inovacijų strategija, inovatyvus produktas, inovatyvus produktų kūrimas, simuliacijos metodas.

✉ Autorius susirašinėti. El. paštas dovydas.alcauskas98@gmail.com

1. Įvadas

Inovatyvaus produkto kūrimas laikomas vienu svarbiausių procesų, užtikrinančių sėkmę sparčiai besivystančiose ir konkurencingose rinkose (Brown & Eisenhardt, 1995). Inovatyvaus produkto vertė atsiskleidžia tik tada, kai produktas sąveikauja su kitais suinteresuotais produktais tam tikrame kontekste (Chesbrough, 2010). Šiuolaikinėje ekonominėje aplinkoje, kurioje technologijų pažanga vyksta labai sparčiai, o produktų gyvavimo ciklas trumpėja, įmonėms reikia ne tik inovatyvios produktų kūrimo strategijos, bet ir žinoti veiksnus, 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 naudoja DI savo veikloje, o daugiau nei 50 % planuoja integruoti šias technologijas 2023 m. Dėl augančio poreikio DI vis sparčiau institucionalizuojasi visuomenėje (World Bank, 2019). Sparčiai kylant DI paklausai, įmonės yra priverstos ne tik diegti šią technologiją, bet ir suprasti, kaip ją tinkamai panaudoti inovatyvaus produkto kūrimo procesuose ir sėkmę lemiančiuose veiksmuose (Ghosh, 2022). Toks sprendimas

gali reikšmingai sutrumpinti produkto patekimo į rinką laiką, pagerinti jo kokybę, sumažinti sąnaudas, sukurti naujų darbo vietų ir sustiprinti įmonės konkurencingumą (Bughin et al., 2018; Fujitsu, 2017).

Lietuvoje vienas iš didžiausių ekonomikos sektorių – gamyba. Remiantis 2024 m. „Eurostat“ duomenimis, gamybos sektorius sudaro apie 14 % šalies bendrojo vidaus produkto (Eurostat, 2024). Viena reikšmingiausių Lietuvos gamybos sektoriaus problemų – žemas darbo našumo lygis. Pagal 2019 m. „Our World in Data“ skelbiamus pasaulio šalių duomenis Lietuva užima tik 38-ąją vietą, o darbo našumas siekia 34,45 PPP JAV dolerio per valandą (Ritchie & Roser 2019). Šią problemą galima spręsti pasitelkiant dirbtinį intelektą – automatizuojant kasdienes įmonės veiklas ir kuriant inovatyvius sprendimus produkto kūrimo etapuose (Nolan, 2021). Tačiau Oficialios statistikos portalo 2021 m. duomenimis, Lietuvoje darbo procesams automatizuoti su DI naudojo tik 2,3 % įmonių. Toks DI integravimas gamybos sektoriuje paskatintų vietinės ir pasaulinės rinkos konkurencingumą, padidintų darbo našumą ir pridėtinę vertę, o taip pat generuotų naujas darbo vietas, susijusias su automatizacijos procesais.

2. Literatūros analizė dirbtinio intelekto taikymo inovatyvių produktų kūrimo kontekste

2.1. 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 poreikius ir lūkesčius, laikantis gamybos apribojimų, susijusių su sąnaudomis, laiku ir kokybe. Šis sudėtingas, daugialypis procesas apima inžineriją, dizainą, rinkodarą ir valdymą (Montagna, 2023). Inovatyvaus produkto kūrimas grindžiamas naujai suformuota produkto strategija, kuria siekiama suderinti įmonės pastangas su jos strateginiais imperatyvais (Hargadon, 2004). Toks derinimas užtikrina, kad planuojami nauji produktai palaikys strateginius įmonės tikslus ir geriausiai išnaudos strategines kompetencijas (Tzokas et al., 2003).

Rinkoje taikomi įvairūs inovatyvaus produkto kūrimo proceso modeliai. Viena iš labiausiai paplitusių pasaulyje, užtikrinantis sklandžią idėjos realizavimo eigą, yra „Stage-Gate“ modelis (Cooper, 2008). Ši sistema lėmė daugelio tarptautinių įmonių sėkmę. 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 naujiems produktams kurti 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 šio modelio principas susideda iš dviejų dalių: inovacijų procesų etapų (angl. *stages*) ir vartų sistemos (angl. *gates*) (1 paveikslas).

Kiekviename etape įmonė turi atlikti suplanuotus veiksmus, o pasiekus vartus priimamas sprendimas – tęsti projektą toliau, grąžinti tobulinti ar jo apskritai atsisakyti. „Stage-Gate“ metodas dažniausiai vykdomas tokia seka:

1. **Idėjų generavimas.** Išankstinis darbas, skirtas atrasti ir atskleisti verslo galimybes, kurti naujas idėjas.


2. **Apimties nustatymas.** Greitas, pigus, išankstinis projekto tyrimas ir apimties nustatymas.
3. **Verslo strategija.** Išsamus tyrimas, apimantis pirminius tyrimus (kliento, rinkos ir techninius), kurių rezultatas – verslo strategija. Ji dažniausiai susideda iš produkto ar projekto apibrėžimo, pagrindimo ir siūlomo plėtros plano.
4. **Kūrimas.** Detalus naujo produkto projektavimas ir kūrimas bei operacijų arba gamybos proceso, reikalingo masinei gamybai, planavimas.
5. **Testavimas.** Bandymai gamykloje ir rinkoje, siekiant patikrinti ir patvirtinti siūlomą naują produktą, jo gamybos ar veiklos planus.
6. **Paleidimas.** Komercializacija – masinės gamybos, rinkodaros ir pardavimo pradžia.

2.2. Dirbtinio intelekto samprata ir klasifikavimas


Dirbtinis intelektas (DI) kaip akademinė sritis pradėjo formuotis šeštajame dešimtmetyje. Terminas pirmą kartą pavartotas per daugiadisciplinę programą, pristatytą Dartmute 1956 m (Benbya et al., 2020). Programa siekė ištirti galimybę, kad mašinos gali imituoti žmogaus intelektą, ir sutelkė įvairių sričių mokslininkus – matematikus ir filosofus. DI apibrėžiamas kaip kompiuterinės sistemos, galinčios suvokti aplinką, mąstyti, mokytis ir išspręsti problemas siekiant konkretaus tikslo (PwC, 2018).

Nepaisant ankstyvų vilčių dėl praktinio DI pritaikymo, septintajame ir aštuntajame dešimtmėčiuose jo vystymasis iš esmės nepasiteisino ir susidūrė su keliomis kliūtimis. Didžiausia iš jų buvo – skaičiavimo galios stoka. Mokslinių tyrimų finansavimas pamažu sustojo ir prarado pagreitį. Devintajame ir dešimtajame dešimtmėčiuose vyriausybės ir įmonės daug investavo į ekspertinių sistemų tyrimus, o tai atgaivino susidomėjimą dirbtiniu intelektu (Benbya et al., 2020).

Apibendrintai DI gali būti suprantamas kaip intelektinės operacijos, kurias atlieka tam tikros mašinos, sukurtos atkartoti žmogaus smegenų galimybes naudojant algoritmus derinius. Mokslinėje literatūroje yra išskiriama keletas



1 paveikslas. „Stage-Gate“ modelis (šaltinis: sudaryta autoriaus, remiantis Cooper, 2008)




2 paveikslas. DI klasifikavimas (šaltinis: sudaryta autoriaus, remiantis Benbya et al., 2020)

DI klasifikavimo būdų. Vieną jų siūlo Hindo Benbya, kuris susideda iš trijų tipų: pagal intelektą, pagal į DI sistemą integruotos technologijos tipą ir pagal DI atliekamą funkciją (2 paveikslas).

Šiame darbe aktualiausia yra technologijomis grįsta kategorija. Pagal antrąją Benbya et al. siūlomą tipologiją DI sistemose išskiriamos technologijos, tarp kurių svarbiausią vietą užima mašininis mokymasis (angl. *machine learning*).

Pasak Fulkerson (1995), mašininis mokymasis paprastai apima loginėmis arba dvejetainėmis operacijomis pagrįstas automatinio skaičiavimo procedūras, kurios iš pateiktų pavyzdžių išmoka užduotį. Mašininio mokymosi tikslas – sukurti pakankamai aiškias klasifikavimo išraiškas, kad jas lengvai suprastų žmogus. Šios sistemos turi pakankamai tiksliai imituoti žmogaus samprotavimus, kad būtų galima suprasti sprendimų priėmimo procesą. Paprastai mašininis mokymasis skaidomas į keturias atskiras kategorijas: pusiau prižiūrimas mokymasis, prižiūrimas mokymasis, neprižiūrimas mokymasis ir sustiprintas mokymasis (3 paveikslas).

- **Neprižiūrimas mokymasis** (angl. *unsupervised learning*) analizuoja nepažymėtus duomenų rinkinius be žmogaus įsikišimo – tai visiškai duomenimis grįstas procesas (Han et al., 2011). Jis plačiai naudojamas generatyviems požymiams išgauti, reikšmingoms tendencijoms ir struktūroms identifikuoti, rezultatams grupuoti ir tiriamiesiems tikslams nustatyti. Dažniausiai pasitaikantys neprižiūrimo mokymosi uždaviniai: klasterizavimas, tankio įvertinimas, požymių mokymasis, matmenų mažinimas, asociacijų taisyklių paieška, neatitikimų aptikimas ir kt. (Sarker, 2021).
- **Prižiūrimas mokymasis** (angl. *supervised learning*) – tai mašininio mokymosi metodas, kai modelis mokomas jau paženklintų duomenų. Mokymo rinkinį sudaro įvesties objektų (paprastai vektorių) ir pageidaujamų išvesties reikšmių poros. Modelio išvestis gali būti nepertraukiama reikšmė (regresija) arba įvesties objekto klasės etiketė (klasifikacija). Prižiūrimo besimokančiojo užduotis – suteikus pakankamą mokymo pavyzdžių skaičių, gebėti tiksliai prognozuoti funkcijos reikšmę



3 paveikslas. Mašininio mokymosi klasifikavimas (šaltinis: sudaryta autoriaus, remiantis Sarker, 2021)

bet kokiam galiojančiam įvesties objektui. 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 užduotį orientuotas metodas (Sarker, 2021).

- **Hibridinis mokymasis** (angl. *semi-supervised learning*) gali būti apibrėžiamas kaip minėtų prižiūrimų ir neprižiūrimų metodų hibridas, nes jis veikia ir su pažymėtais, ir su nepažymėtais duomenimis (Sarker, 2021). Galutinis šio modelio tikslas – užtikrinti geresnį prognozavimo rezultatą nei tas, kuris gaunamas naudojant tik paženklintus modelio duomenis
- **Sustiprintas mokymasis** (angl. *reinforcement learning*) – 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 metodas (Kaelbling et al., 1996).

2.3. Dirbtinio intelekto sąsaja su inovatyvių produktų kūrimu

Remiantis Pasaulio ekonomikos forumo duomenimis, įdiegus dirbtinį intelektą gamybos procesuose, sąnaudos gali sumažėti iki 30 % (World Economic Forum, 2023), o „Accenture“ tarptautinė profesionalių paslaugų įmonė prognozuoja, kad iki 2035 m. DI 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 et al., 2023).


Chandra (2019) atliktame tyrime nagrinėtas DI valdymų prognozuojamos techninės priežiūros sistemų nauda mažinant prastovas ir minimizuojant techninės priežiūros išlaidas gamybos įmonėse, pabrėžiant DI potencialą didinti

veiklos efektyvumą ir našumą. Be to, Ivanovo tyrime nagrinėtas DI pagrįstų paklausos prognozavimo modelių taikymas tiekimo grandinės valdyje, parodant, kad gerokai pagerėjo atsargų valdymas ir užsakymų įvykdymo rodikliai (Zamani et al., 2022).

Plathottam et al. (2023) moksliniame tyrime apie dirbtinio intelekto pritaikymą gamybos sektoriuje, pateikia detalesnę DI taikymo architektūrą (4 paveikslas). Schemoje pateikiama, kad DI pritaikymas plačiąja prasme klasifikuojamas į dvi atskiras šakas: operacijos ir dizaino sferas.

- **Operacijos** susijusios su faktiniu gamybos įrangos ir išteklių naudojimu. Fizinio požiūriu tai apima pramonines mašinas, jutiklius ir valdiklius, darbuotojus ir įrangos infrastruktūrą. Operacijos gali būti skirstomos į ilgalaikį įrenginių ir procesų planavimą arba realiojo laiko veiksmus gamykloje (angl. *real time*), priklausomai nuo atitinkamo laiko poreikio. Jos labai svarbios siekiant užtikrinti, kad pramonės įranga veiktų pagal numatytus parametrus ir būtų išlaikyta produkto kokybė.
- **Dizainas ir 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 sustiprintą mokymąsi.

Zhang et al. (2021) atliktame tyrime buvo nagrinėjami 558 inovatyvių produktų kūrimo projektai, iš kurių 282 buvo sėkmingi, o 276 – nesėkmingi. Pagrindinis tyrimo tikslas – nustatyti, kokią įtaką DI daro tiek sėkmingiems, tiek nesėkmingiems inovatyvaus produkto kūrimo procesams.



4 paveikslas. DI pritaikymas gamybos sektoriuje (šaltinis: sudaryta autoriaus, remiantis Plathottam et al., 2023)

Tyrimo rezultatai parodė, kad DI naudojimas visuose septyniuose etapuose turi didelį poveikį projekto sėkmės rodikliams, tačiau šis poveikis skirtinguose etapuose labai skiriasi. Didžiausią naudą suteikia DI naudojimo didinimas operacijų valdymo srityje (sėkmės rodiklis padidėja 46,6 %), verslo analizėje (sėkmės rodiklis padidėja 45,2 %) ir produkto projektavime (sėkmės rodiklis padidėja 43,0 %). Mažiausia nauda nustatyta didinant DI taikymą produkto testavimo etape.

3. Dirbtinio intelekto taikymo inovatyviems produktams tyrimo metodologija

Tyrimo eiga struktūrizuota taip, kad būtų galima nuosekliai ištirti dirbtinio intelekto įtaką inovatyvių produktų kūrimo procesui. Pirmiausiai atliekama mokslinės literatūros šaltinių analizė, apimanti DI sampratą, jo taikymo sąsajas su inovatyvių produktų kuriančių įmonių veiklos rezultatais. Literatūros analizė padeda geriau suprasti nagrinėjamą objektą, analizuoti inovatyvaus produkto kūrybos ir dirbtinio intelekto apibrėžimus, sampratas, sąsajas, klasifikavimą iš skirtingų autorių perspektyvos. Šiame darbe mokslinės literatūros analizę galima skaidyti į tris nagrinėjamus etapus: inovatyvaus produkto kūrimo sampratą, dirbtinio intelekto sampratą, inovatyvaus produkto kūrimo ir dirbtinio intelekto sąsajas pramonės inžinerijoje. Informacijai rinkti naudojamos mokslinės literatūros duomenų bazės, įskaitant recenzuojamus žurnalus, knygas, mokslinius straipsnius ir kitus akademinius veikalus.

Inovatyvaus produkto kūrimo sampratos analizėje pagrindinis tikslas išnagrinėti, kas yra inovatyvus produktas, kokie procesai lemia jo inovatyvumą, kokius metodus / modelius taiko įmonės kurdamos 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 siekiama išsiaiškinti, kokiose inovatyvaus produkto kūrimo procesuose dirbtinis intelektas gali turėti įtakos, kokią naudą ir žalą sukelia, 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 tyrimo daliai.

Toliau buvo išanalizuoti kitų tyrėjų empiriniai darbai – juose taikyti metodai, tyrimų kontekstas ir 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, tapęs 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 sudarytas susisteminus literatūros analizės ir empirinio tyrimo rezultatus.

Pasiūlytam modeliui patikrinti sukuriami simuliacija, leidžianti atkartoti ar imituoti realią situaciją, išskiriant tik esmines realaus gyvenimo charakteristikas ir perkeltiant jas į nerizikingą aplinką. Simuliacijai pasirinktas realus inovatyvus agrokultūros dronas, o jo kūrimo eigai pritaikytas galutinis struktūrizuotas modelis. Gauti rezultatai įvertina, kokią naudą teikia sukurtas modelis.

4. Dirbtinio intelekto taikymo inovatyvių produktų kūrimo procese empirinis tyrimas

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, tada formuojamas atitinkamas struktūrizuotas modelis, o galiausiai atliekama jo simuliacija. Tyrimo metu taikomas modeliavimo metodas, leidžiantis sukurti struktūrinį požiūrį į DI integraciją įvairiuose produkto kūrimo etapuose. Simuliacijos metodas pasirinktas siekiant atvaizduoti ir įvertinti modelio veikimą bei rezultatus virtualioje, nerizikingoje aplinkoje. Tokiu būdu siekiama ne tik pagrįsti modelio teorinį aktualumą, bet ir įvertinti jo praktinio taikymo galimybes.

I etapas. Idėjų generavimas

Šiame etape DI naudojamas kaip ankstyvos analizės įrankis. Generatyviniai teksto modeliai (pvz., *ChatGPT*) leidžia automatizuotai generuoti idėjas, taikant įvairius kūrybinius metodus – nuo minčių žemėlapių iki SCAMPER strategijos. Vaizdiniai modeliai (pvz., *DALL-E*) suteikia galimybę vizualizuoti idėjų koncepcijas, kas padeda geriau jas ankstyvose kūrimo stadijose.

Technologijų analizėje DI naudojamas moksliniams straipsniams, patentams ir rinkos duomenims peržiūrėti ir klasifikuoti automatinio būdu. Pasitelkus natūralios kalbos apdorojimo priemones, galima ne tik susisteminti istorinę technologijų raidą, bet ir numatyti ateities tendencijas. Mašininio mokymosi algoritmai (klasterizacija, regresija) padeda struktūrizuoti technologijų duomenis ir įvertinti jų potencialą.

Idėjų tyrinėjime taikomas neprižiūrimas mokymas leidžia grupuoti idėjas pagal turinį ar struktūrinius bruožus, o sustiprintas mokymasis padeda interaktyviai tobulinti idėjas, atsižvelgiant į rinkos duomenis ar vartotojų poreikius. Kompiuterinė rega papildomai padeda vertinant vizualines koncepcijas – nuo eskizų iki konkurentų produktų.

Rinkos analizėje natūralios kalbos apdorojimo priemonės padeda automatizuoti socialinės medijos, apžvalgų ar klientų atsiliepimų analizę. Prižiūrimo mokymosi metodai

leidžia prognozuoti rinkos elgseną, atlikti klientų segmentavimą ir rinkos dydžio bei potencialo vertinimą.

II etapas. Pirminė apžvalga

Koncepcijos detalizavimo metu DI padeda išgryninti pasirinktas idėjas. Natūralios kalbos apdorojimo priemonės automatizuoja informacijos rinkimą ir analizę, mašininio mokymosi modeliai (klasifikacija, regresija) prognozuoja sėkmės tikimybę, sąnaudų struktūrą ir suderinamumą su rinka. Asociacijų taisyklių analizė, pvz., taikant *Apriori* algoritmus, atskleidžia ryšius tarp produktų ar vartotojų pasirinkimų.

Vartotojų poreikių analizėje natūralios kalbos apdorojimo priemonės leidžia semantiškai analizuoti klientų komentarus, nustatyti pagrindines temas, o generatyviniai modeliai greitai formuoja rinkos segmentų aprašus. Kompiuterinė rega gali būti naudojama analizuoti socialinių tinklų turinį, pvz., vartotojų nuotraukas ar prekių žymas.

Rizikų identifikavimo etape DI analizuoja įvairius duomenų šaltinius (ataskaitas, sutartis) ir automatizuotai nustato galimas grėsmes. Sentimentų analizė leidžia reaguoti į neigiamas nuomones, o mašininio mokymosi algoritmai grupuoja rizikas ir modeliuoja strategijas joms mažinti.

Verslo galimybių vertinime automatizuota dokumentų analizė leidžia greitai įvertinti verslo planus. Regresija numato finansinius rodiklius, o klasterizacija padeda identifikuoti pelningiausius segmentus. Vizualizacijoms pasitelkiamos tokios platformos kaip *Tableau* ar *Power BI*.

III etapas. Verslo analizė

Verslo plano kūrimo etape natūralios kalbos apdorojimo priemonės ir generatyviniai modeliai gali automatiškai rengti strateginius dokumentus, o mašininio mokymosi modeliai padeda įvertinti potencialų pelningumą ir riziką. Sustiprintas mokymasis naudojamas optimizuoti verslo plėtros scenarijus.

Pardavimų prognozėje natūralios kalbos apdorojimo priemonės analizuoja klientų atsiliepimus, o regresijos modeliai numato pardavimų apimtį. Laiko eilučių analizė (pvz., ARIMA) leidžia prognozuoti sezonines ar ilgalaikes tendencijas.

Konkurencinėje analizėje natūralios kalbos apdorojimo priemonės leidžia sisteminti duomenis apie konkurentų veiklą, o generatyviniai modeliai automatizuoja strategijų kūrimą. Klasterizacija identifikuoja konkurentų grupes pagal rinkos nišas ar kainodarą.

Technologijų tinkamumo vertinime mašininio mokymosi metodai padeda nustatyti, kurios technologijos geriausiai atitinka produkto reikalavimus. Sustiprintas mokymasis leidžia testuoti įvairius scenarijus, o kompiuterinė rega padeda analizuojant prototipus.

IV etapas. Produkto kūrimas

Produkto dizaino ir projektavimo etape taikomas generatyvinis dizainas, leidžiantis kurti ir optimizuoti komponentus pagal įvairius kriterijus (svoris, tvirtumas, estetika). Nau-

dojamos tokios priemonės kaip *Fusion 360*, *Siemens NX*. Kompiuterinė rega naudojama vizualinei kokybės kontrolei.

Prototipo vystymo etape svarbus vizualinių defektų aptikimas realiuoju laiku – kompiuterinės regos algoritmai lygina fizinį objektą su idealiu modeliu.

Technologijų testavimas apima našumo analizę, regresinį modeliavimą ir anomalijų aptikimą. Tai leidžia iš anksto nustatyti veikimo trūkumus ar nestabilumus.

Darbo srutams automatizuoti taikomas robotizuotas procesų automatizavimo modelis, kuris imituoja pasikartojančius žmogiškuosius veiksmus IT sistemose. Tai leidžia automatizuoti duomenų įvedimą, dokumentų apdorojimą ir kitus procesus.

Projektų valdyme natūralios kalbos apdorojimo priemonės padeda apdoroti dokumentaciją, generatyviniai modeliai padeda formuoti ataskaitas ir komunikacijas, o mašininio mokymosi metodai – prognozuoti eigą ir valdyti rizikas.

V etapas. Testavimas ir įgyvendinimas

Simuliaciniai modeliai ir skaitmeniniai dvyniai leidžia virtualiai testuoti produktus realiomis sąlygomis. Generatyviniai modeliai kuria įvairius testavimo scenarijus, o daiktų internetu grįsti dvyniai leidžia modeliuoti objekto veikimą realiuoju laiku.

Rizikų valdyme taikoma klasifikacija, regresija, sustiprintas mokymasis ir kompiuterinė rega, kurie leidžia automatiškai aptikti, vertinti ir mažinti rizikas.

Optimizuojant našumą regresija ir klasifikacija padeda nustatyti pagrindinius rodiklius, o anomalijų aptikimas identifikuoja neefektyvias vietas. Kompiuterinė rega stebi gamybos procesą ir nustato nukrypimus.

Reglamentavimo procese natūralios kalbos apdorojimo priemonės leidžia greitai analizuoti dokumentus ir palyginti juos su reguliavimo reikalavimais. Klasterizacija padeda grupuoti reglamentus pagal jų tarpusavio ryšius, taupant analizės laiką.

VI etapas. Produkto paleidimas

Klientų pasitenkinimo analizėje natūralios kalbos apdorojimo priemonės ir sentimentų analizė leidžia stebėti vartotojų reakcijas socialiniuose tinkluose. Kompiuterinė rega analizuoja vizualinį turinį. Regresija prognozuoja pasitenkinimo indeksą.

Rinkodaros strategijų įgyvendinime DI generuoja reklaminį turinį – tekstus, vaizdus – pritaikytus tikslinei auditorijai. Rinkodaros efektyvumas stebimas realiuoju laiku.

Kainodaros strategijoje natūralios kalbos apdorojimo priemonės analizuoja rinkos komentarus apie kainas, o regresija prognozuoja kainos poveikį pardavimams. Klasifikacija padeda identifikuoti, kaip skirtingi segmentai reaguoja į kainas.

Gamybos optimizavime kompiuterinė rega naudojama defektams aptikti ir kokybės kontrolei. Integruota robotika ir robotizuotas procesų automatizavimas užtikrina efektyvius automatizuotus procesus.

5. Pirminis dirbtinio intelekto integracijos modelis inovatyvių produktų kūrimo procesuose


Šioje dalyje, remiantis literatūros analize ir empiriniu tyrimu, sukurtas DI integracijos modelis inovatyvių produktų kūrimo procesuose (5 paveikslas).

Modelis sistemingai vaizduoja DI integraciją į inovacijų kūrimo procesą, remiantis „Stage-Gate“ modeliu. Jis suskirstytas 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 ir idėjų tyrinėjimą. „Pirminės apžvalgos“ etape daugiausia dėmesio skiriama koncepcijai plėtoti, vartotojų poreikiams analizuoti ir rizikoms identifikuoti. Vėlesniuose etapuose – „Verslo atvejo analizėje“, „Kūrime“ ir „Testavime“ – DI pasitelkiamas verslo planams rengti, prototipams testuoti, technologijų tinkamumui vertinti, našumui optimizuoti, reglamentavimo atitikčiai ir rizikai valdyti. Galiausiai, „Paleidimo“ fazėje DI naudojamas

klientų pasitenkinimo analizei, kainodaros strategijai kurti, gamybai optimizuoti ir rinkodaros sprendimams įgyvendinti.

Modelyje išskirtos DI kategorijos parodo taikomų technologijų įvairovę. Dominuoja natūralios kalbos apdorojimas, taikomas tekstui analizuoti ir automatinio turinio generavimui, dažniausiai naudojant tokias sistemas kaip *ChatGPT*. Prižiūravimo mokymosi metodai – klasifikacija ir regresija, pasitelkiami prognozuoti rinkos elgseną, analizuoti vartotojų duomenis, vertinti verslo rizikas ar pardavimų dinamiką. Neprižiūrimas mokymasis, apimantis klasifikaciją ir asociacijų analizę, naudojamas idėjų ar klientų segmentams grupuoti bei netipinių duomenų struktūroms atpažinti. Kai kuriuose etapuose pasitelkiamas ir sustiprintas mokymasis, leidžiantis 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.



5 paveikslas. Pirminis DI integracijos modelis inovatyvių produktų kūrimo procesuose (šaltinis: sudaryta autoriaus)


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

6. Simuliacijos metodas

Pirmame etape buvo taikytas užklausų formavimo metodas, kai užklausa suskaidoma į dalis pagal paskirtį: algoritmo vaidmuo, papildomus kriterijus, pagrindinį tikslą ir atsakymo formatą. Tokia struktūra užtikrina tikslesnį modelio atsakymą. Palyginus skirtingo detalumo užklausas nustatyta, kad

detalesnės užklausos suteikia kokybiškesnius ir tikslesnius rezultatus. Buvo išgrynintos septynios inovatyvių dronų idėjos, apimančios įvairias taikymo sritis – nuo vaizdo kūrimo iki pasėlių stebėjimo ir miškų atkūrimo. Naudojant DALL-E modelį šios idėjos buvo vizualizuotos techninio eskizo stiliumi, o tai leido įvertinti įvairius technologinius ir dizaino sprendimus. Sukurtos vizualizacijos papildomai sustiprino sprendimų priėmimą tolesniuose etapuose. Pasirinktoms idėjoms buvo atlikta technologijų analizė, skirstant jas į taikomas, tobulinamas ir naujas technologijas, pvz., žemės ūkiui skirtiems dronams priskirtos tokios technologijos kaip daugiaspektrė fotografija, DI, GPS ir automatinės purškimo sistemos, o naujoms technologijoms – spiečiaus valdymas, prognozuojamoji analitika ir dirvožemio analizės jutikliai.

Antrame etape idėjoms tyrinėti pasitelkta teksto klasifikacija naudojant „SpaCy“ biblioteką. Sukurtas klasifikatorius gebėjo tiksliai priskirti idėjas atitinkamoms kategorijoms pagal jų kontekstinę reikšmę. Testavimo metu modelio tikslumas siekė >85 %, patvirtindamas simuliacijos pagrįstumą. Rinkos analizė atlikta remiantis DI sugeneruotomis



6 paveikslas. Galutinis DI integravimo modelis inovatyvių produktų kūrimo procesuose (šaltinis: sudaryta autoriaus)

lentelėmis. Nustatyta, kad kai kurios idėjos, kaip kelionių dronas ar žemės ūkio sprendimai, turi didelį rinkos potencialą, o kitos, tokios kaip holografinės projekcijos dronas – laikytinos nišinėmis. Vartotojų sentimentų analizė, atlikta *Google Cloud Natural Language* sistema, leido struktūrizuoti klientų atsiliepimus, įvertinti emocijas ir aktualias temas.

Vartų sistemai modeliuoti taikytas „Stage-Gate“ metodas, kurio metu įvertintos verslo galimybės, strateginis tinkamumas, išteklių poreikiai ir kt. Pagal šiuos kriterijus atrinktos keturios idėjos tolimesniam vystymui, iš kurių detalai analizuota viena – žemės ūkio dronas pasėliams stebėti. Vystant šią idėją atliktas koncepcijos detalizavimas: nustatyti techniniai reikalavimai (daugiaspektrės kameros, DI analizė, GPS, autonominė navigacija), ekonominiai aspektai (pradinės investicijos, eksploatacijos sąnaudos, mastelio keitimas), vartotojo poreikiai (paprastumas, integracija, palaikymas), pagrindinės funkcijos (ankstyvas ligų aptikimas, derliaus prognozė, stebėjimas realiuoju laiku). Asociacijų analizė, atlikta „Orange“ programine įranga, parodė stiprų korelinacinį ryšį tarp drono ir papildomų priedų (senorių, dėklo, baterijos) pirkimų. Tikimybė kartu su dronu įsigyti sensorius siekė 70 %.

Vartotojų poreikių analizė apėmė segmentavimą pagal demografinius, geografinius, psichografinius ir elgsenos aspektus, apklausos analizę ir vaizdinės informacijos klasifikavimą naudojant „DeepFace“. Identifikuota, kad pagrindiniai segmentai – vidutinio ir didelio dydžio ūkiai, kuriuos valdo inovacijoms atviri, tačiau finansiškai riboti ūkininkai. *K-means* klasterizacija atskleidė tris ūkininkų grupes, pagal jų amžių, patirtį, investicijas ir derlių. Šie rezultatai leidžia formuoti skirtingas rinkodaros strategijas, pritaikytas pagal klasterių ypatybes.

Rizikų analizė išskyrė septynias pagrindines rizikų kategorijas: finansines, technologines, teises, operacines, rinkos, reputacijos ir aplinkosaugos. Kiekvienai jų priskirti konkretūs rizikos veiksniai ir galimi sprendimai.

Trečiajame etape verslo galimybių vertinimas apėmė rinkos analizę, konkurencinės aplinkos įvertinimą, unikalių vertės pasiūlymų formulavimą, kainodaros strategijų parengimą, reguliacinių reikalavimų analizę, rinkos tendencijas ir galimų partnerysčių nustatymą. Išryškėjo prenumeratos modelio, duomenų analizės paslaugų ir nuomos galimybių potencialas. Verslo planas sukurtas pasitelkiant „Miro“ platformą ir „Business Model Canvas“ metodiką, generuojant pagrindinius komponentus: klientų segmentai, vertės pasiūlymas, kanalai, sąnaudų struktūra ir kt. Pardavimų prognozės pateiktos naudojant tiek kokybinius (sezoniskumas, kainodaros dinamika), tiek kiekybinius rodiklius.

Galiausiai, konkurencinėje analizėje atlikta PESTEL, SSGG ir Porterio penkių jėgų analizės atskleidė tiek makrolygio rizikas (pvz., duomenų apsauga, aviacijos reglamentai), tiek mikrolygio veiksniai (konkurencija, vartotojų elgsena).

Ši simuliacija atskleidžia, kaip dirbtinis intelektas gali būti taikomas inovatyviems sprendimams generuoti, vertinti ir vystyti – nuo idėjos formavimo iki pardavimų prognozių. Simuliacija pagrindžia DI modelių integracijos svarbą sprendimų priėmimo procesuose, tačiau taip pat išryškino, kad DI reikšmė skirtinguose etapuose nėra vienoda.

Remiantis simuliacijos rezultatais, pirminis modelis buvo pakoreguotas, o 6 paveiksle pateikiamas galutinis modelio variantas. Pagrindinis pokytis matomas integravimo srityje, kurioje papildomai nurodomas DI reikšmingumo lygis kiekviename inovatyvaus produktų kūrimo etape (aukštas, vidutinis, žemas).

7. Išvados ir rekomendacijos

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

Pirmausia buvo atlikta mokslinės literatūros analizė, kurios metu išnagrinėta inovatyvaus produkto ir dirbtinio intelekto samprata bei jų tarpusavio sąsajos. Pirmajame etape nustatyta, 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, ir kokie įmonių veiklos rodikliai gali būti paveikti. Paaiškėjo, kad dirbtinio intelekto technologijos tampa vis svarbesniu veiksniumi valdant inovacijas ir naujų produktų kūrimą. DI ne tik didina proceso efektyvumą, bet ir skatina kūrybiškumą, sisteminį mąstymą ir greitesnį sprendimų priėmimą. Jis gali būti taikomas įvairiuose produkto kūrimo etapuose – nuo idėjų generavimo, rinkos analizės, techninių sprendimų formavimo iki produkto paleidimo. Literatūros šaltiniai atskleidžia, kad DI potencialas dažnai lieka neišnaudotas dėl organizacinės inercijos, kompetencijų stokos ir metodologinio neapibrėžtumo. Dėl šios priežasties būtina ne tik apibendrinti DI taikymo praktikas, bet ir sukurti teorinį pagrindą jų sistemingam vertinimui.

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 poveikio 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 ir galimybė vertinti kiekvieną kūrimo etapą atskirai sudarė prielaidas atlikti sisteminę analizę bei simuliaciją, paremtą realiais duomenimis ir loginiais ryšiais tarp produkto kūrimo etapų.

Empirinio tyrimo ir simuliacijos rezultatai parodė, kad DI taikymas inovatyviems produktams kurti gali labiau padidinti proceso efektyvumą, ypač ankstyvuosiuose etapuose – generuojant idėjas, vartotojų poreikių analizės metu. Simuliacinio modeliavimo metu įvertinta, kad tokie DI sprendimai, tokie kaip natūralios kalbos apdorojimas,

automatizuota duomenų analizė ir prognozavimo modeliai leidžia sumažinti kūrimo laiką, rizikas ir resursų sąnaudas. Vėlesniuose etapuose – testavimo, prototipavimo ir paleidimo – DI nauda labiau priklauso nuo specifinių įmonės technologinių galimybių ir žmogiškųjų išteklių pasirengimo. Tai leidžia teigti, kad DI nauda inovacijų procese nėra vienalytė ir reikalauja diferencijuoto vertinimo.

Parengtas struktūruotas DI integracijos modelis pateikia sisteminę DI taikymo schemą inovatyvių produktų kūrimo procese, remiantis „Stage-Gate“ metodologija. Modelyje vizualizuojama, kuriuose etapuose DI daro didžiausią 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 inovatyvių produktų kūrimo procesuose gali gerokai prisidėti prie organizacijų konkurencingumo, darbo našumo ir inovatyvumo didinimo. Tačiau tam būtina kryptinga, etapais grįsta integracijos strategija. DI diegimas neturėtų būti vertinamas kaip pavienis technologinis sprendimas – veikiau kaip kompleksinė inovacijų valdymo priemonė, reikalaujanti metodinio pagrindimo ir aiškių taikymo ribų kiekviename produkto kūrimo etape. Remiantis atliktu magistrinio darbo tyrimu apie dirbtinio intelekto (DI) integravimą į inovatyvių produktų kūrimą procesą, siūlomos šios kryptys tolesniems moksliniams tyrimams ir praktiniam taikymui:

1. Rekomenduojama atlikti platesnio masto empirinius tyrimus, įtraukiant įvairių sektorių įmones Lietuvoje. Tokie tyrimai padėtų tiksliau įvertinti DI poveikį įvairiuose verslo sektoriuose ir išryškintų specifinius integravimo iššūkius bei galimybes.
2. Rekomenduojama tirti konkrečius DI metodus, pavyzdžiui, giliuosius neuroninius tinklus ir jų optimizavimo galimybes inovatyvių produktų kūrimo procesuose. Taip pat verta išanalizuoti DI modelių adaptavimą įvairių dydžių įmonėms ir skirtingoms rinkoms.

Literatūra

- Benbya, H., Davenport, T. H., & Pachidi, S. (2020). *Artificial intelligence in organizations: Current state and future opportunities*. SSRN. <https://doi.org/10.2139/ssrn.3741983>
- Brown, S. L., & Eisenhardt, K. M. (1995). Product development: Past research, present findings, and future directions. *The Academy of Management Review*, 20(2), 343–378. <https://doi.org/10.5465/amr.1995.9507312922>
- Chandra, D. (2019). *Role of artificial intelligence in strengthening democratic institution in India*. https://papers.ssrn.com/sol3/papers.cfm?abstract_id=3508720
- Chesbrough, H. (2010). Business model innovation: Opportunities and barriers. *Long Range Planning*, 43(2–3), 354–363. <https://doi.org/10.1016/j.lrp.2009.07.010>
- 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., & 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>
- Eurostat. (2024). *Manufacturing sector share in GDP*. <https://ec.europa.eu/eurostat>
- Fujitsu. (2017). AI-powered design innovation. *Fujitsu Scientific & Technical Journal*, 53(4).
- Fulkerson, B. (1995). Machine learning, neural and statistical classification. *Technometrics*, 37(4), 459. <https://doi.org/10.2307/1269742>
- Ghosh, S. (2022). *How AI capabilities influence data-driven business model innovation* [Conference presentation]. World Open Innovation Conference, Eindhoven, the Netherlands.
- Han, J., Kamber, M., & Pei, J. (2011). *Data mining: Concepts and techniques* (3rd ed.). Morgan Kaufmann Publishers.
- Hargadon, A. (2004). How breakthroughs happen: The surprising truth about how companies innovate. *Choice Reviews Online*, 41(10). <https://doi.org/10.5860/choice.41-6004>
- 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>
- Montagna F. (2023). *Optimizing product development and innovation processes with artificial intelligence* [Thesis, Politecnico di Torino]. <https://webthesis.biblio.polito.it/27710/>
- Nolan, A. (2021). *Artificial intelligence, its diffusion and uses in manufacturing* (OECD Going Digital Toolkit Notes, No. 12). OECD Publishing. <https://doi.org/10.1787/249e2003-en>
- Plathottam, S. J., Rzonca, A., Lakhnori, R., & Illoeje, C. O. (2023). A review of artificial intelligence applications in manufacturing operations. *Journal of Advanced Manufacturing and Processing*, 5(3), Article e10159. <https://doi.org/10.1002/amp.2.10159>
- PwC. (2018). *Harnessing artificial intelligence for the earth*. <https://www.pwc.com/gx/en/sustainability/assets/ai-for-the-earth-jan-2018.pdf>
- Ritchie, H., & Roser, M. (2019). *Productivity: Output per hour worked*. Our World in Data. <https://ourworldindata.org/grapher/labor-productivity-per-hour-pennworldtable>
- Sarker, I. H. (2021). Machine learning: Algorithms, real-world applications and research directions. *SN Computer Science*, 2(3), Article 60. <https://doi.org/10.1007/s42979-021-00592-x>
- Tzokas, N., Hultink, E. J., & Hart, S. (2003). Navigating the new product development process. *Industrial Marketing Management*, 33(7), 619–626. <https://doi.org/10.1016/j.indmarman.2003.09.004>
- Valstybės duomenų agentūra. (2021). *Dirbtinis intelektas 2021 m.* Oficialiosios statistikos portalas. <https://osp.stat.gov.lt/skaitmenine-ekonomika-ir-visuomene-lietuvoje-2021/dirbtinis-intelektas>
- World Bank. (2019). *Artificial Intelligence: Investment trends and selected industry uses*. <http://documents.worldbank.org/curated/en/617511573040599056>
- World Economic Forum. (2023). *Annual report 2023–2024*. <https://www.weforum.org/publications/annual-report-2023-2024/>
- 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 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>

ARTIFICIAL INTELLIGENCE (AI) FOR INNOVATIVE PRODUCTS DEVELOPMENT

D. Alčauskas

Abstract

In today's economic environment, where technological progress is rapid and product life cycles are getting shorter, companies not only need an innovative product development strategy but also an understanding of the factors that determine the success of new products in the market. One solution is the development of innovative products using artificial intelligence. This article aims to investigate how the integration of artificial intelligence affects the process of innovative product development. The article explores the concept of innovation and artificial intelligence, the link between these processes and classification models. A text analysis is carried out according to the developed research methodology. Based on the literature analysis, a popular model of innovative product development is selected. By integrating artificial intelligence into this model, various aspects of its application are examined, such as process automation, data analysis techniques and decision-making improvement. Links between the chosen model and the integration of artificial intelligence are found. A simulation approach is used to propose a structured model to assess the impact of AI on innovative product development. This approach helps to understand the relationships and interconnections between the results and the elements of the empirical study. At the end of the study, a simulation approach is carried out to test the proposed structured model. The paper concludes with conclusions and suggestions.

Keywords: artificial intelligence, artificial intelligence integration, innovation strategy, innovative product, innovative product development, simulation method.