



Kauno technologijos universitetas
Mechanikos inžinerijos ir dizaino fakultetas

Techninio padalinio efektyvumo didinimas taikant dirbtinio intelektu priemonės gedimų šalinimo procesuose

Baigiamasis magistro projektas

Mantas Pinkevičius
Projekto autorius

Asist. dr. Ingrida Venytė
Vadovė

Kaunas, 2026



Kauno technologijos universitetas
Mechanikos inžinerijos ir dizaino fakultetas

Techninio padalinio efektyvumo didinimas taikant dirbtinio intelekto priemones gedimų šalinimo procesuose

Baigiamasis magistro projektas
Gamybos inžinerija (6211EX015)

Mantas Pinkevičius
Projekto autorius

Asist. dr. Ingrida Venytė
Vadovė

Asist. dr. Darius Pauliukaitis
Recenzentas

Kaunas, 2026



Kauno technologijos universitetas
Mechanikos inžinerijos ir dizaino fakultetas
Mantas Pinkevičius

Techninio padalinio efektyvumo didinimas taikant dirbtinio intelekto priemones gedimų šalinimo procesuose

Akademinio sąžiningumo deklaracija

Patvirtinu, kad:

1. baigiamąjį projektą parengiau savarankiškai ir sąžiningai, nepažeisdama(s) kitų asmenų autoriaus ar kitų teisių, laikydamasi(s) Lietuvos Respublikos autorių teisių ir gretutinių teisių įstatymo nuostatų, Kauno technologijos universiteto (toliau – Universitetas) intelektinės nuosavybės valdymo ir perdavimo nuostatų bei Universiteto akademinės etikos kodekse nustatytų etikos reikalavimų;
2. baigiamajame projekte visi pateikti duomenys ir tyrimų rezultatai yra teisingi ir gauti teisėtai, nei viena šio projekto dalis nėra plagijuota nuo jokių spausdintinių ar elektroninių šaltinių, visos baigiamojo projekto tekste pateiktos citatos ir nuorodos yra nurodytos literatūros sąrašė;
3. įstatymų nenumatytų piniginių sumų už baigiamąjį projektą ar jo dalis niekam nesu mokėjęs (-usi);
4. suprantu, kad išaiškėjus nesąžiningumo ar kitų asmenų teisių pažeidimo faktui, man bus taikomos akademinės nuobaudos pagal Universitete galiojančią tvarką ir būsiu pašalinta(s) iš Universiteto, o baigiamasis projektas gali būti pateiktas Akademinės etikos ir procedūrų kontrolieriaus tarnybai nagrinėjant galimą akademinės etikos pažeidimą.

Mantas Pinkevičius

Patvirtinta elektroniniu būdu



Kaunas technologijos universitetas
Mechanikos inžinerijos ir dizaino fakultetas

Baigiamojo magistro projekto užduotis

Studentui – Mantui Pinkevičiui

1. Projekto tema –

Techninio padalinio efektyvumo didinimas taikant dirbtinio intelekto priemones gedimų šalinimo procesuose

(Lietuviškai)

Improving Technical Department Efficiency through Application of Artificial Intelligence in Fault Management Process

(Angliškai)

2. Projekto tikslas ir uždaviniai

Tikslas: įvertinti dirbtinio intelekto priemonių taikymo galimybes techninio padalinio veikloje, siekiant padidinti efektyvumą gedimų diagnostikos ir šalinimo procesuose.

Uždaviniai:

1. nustatyti techninio padalinio efektyvumo įtaką gamybos stabilumui;
2. atlikti įrenginių gedimų duomenų praktinę analizę;
3. įdiegti dirbtinio intelekto sprendimus techniniame padalinyje ir įvertinti jų poveikį darbo efektyvumui;
4. pateikti rekomendacijas integruoti dirbtinio intelekto priemones techninio padalinio veikloje.

3. Pagrindiniai reikalavimai ir sąlygos

visi pateikti rodikliai turi būti pateikti įrašant vertes.

4. Papildomi reikalavimai projektui, ataskaitai ir jos priedams

Netaikoma

Projekto autorius

Mantas Pinkevičius

2025-09-30

(Vardas, Pavardė)

(Parašas)

(Data)

Projekto vadovė

Ingrida Venytė

2025-09-30

(Vardas, Pavardė)

(Parašas)

(Data)

Krypties studijų
programų vadovė

Regita Bendikienė

2025-09-30

(Vardas, Pavardė)

(Parašas)

(Data)

Pinkevičius, Mantas. Techninio padalinio efektyvumo didinimas taikant dirbtinio intelekto priemones gedimų šalinimo procesuose. Magistro baigiamasis projektas, vadovė Asist. dr. Ingrida Venytė; Kauno technologijos universitetas, Mechanikos inžinerijos ir dizaino fakultetas.

Studijų kryptis ir sritis (studijų kryptių grupė): Gamybos inžinerija (E10), Inžinerijos mokslai (E).

Reikšminiai žodžiai: dirbtinis intelektas, išmaniosios technologijos, įrenginių techninė priežiūra, gedimų diagnostika, gamybos įrenginių patikimumas, techninio padalinio efektyvumas.

Kaunas, 2026. 63 p.

Santrauka

Baigiamajame magistro projekte nagrinėjamos išmaniųjų technologijų taikymo galimybės įrenginių techninei priežiūrai, siekiant mažinti gedimų sukeltą prastovą ir didinti gamybos stabilumą. Temos aktualumą lemia didėjantis automatizuotų gamybos linijų sudėtingumas ir poreikis greitai atkurti jų darbą žmogiškųjų išteklių trūkumo sąlygomis. Tyrimo naujumas susijęs su tuo, kad gamybos įmonės techniniame padalinyje praktiškai išbandoma dirbtinio intelekto pokalbių sistema, kuri apjungia įrangos dokumentaciją, gedimų istoriją ir technikų sukauptas žinias bei realiu laiku padeda priimti remonto sprendimus. Tyrimo objektas – tiriamos gamyklos techninio padalinio darbas, naudojant dirbtinio intelekto priemones įrenginių gedimų diagnostikai ir šalinimui. Projekto tikslas – įvertinti dirbtinio intelekto priemonių taikymo galimybes techninio padalinio veikloje, siekiant padidinti efektyvumą gedimų diagnostikos ir šalinimo procesuose. Teorinėje dalyje apžvelgti techninio padalinio veiklos efektyvumo rodikliai, įrenginių patikimumo vertinimo metodai ir darbuotojų žinių perdavimo bei naujų technikų įvedimo į darbą iššūkiai, kuriuos padeda spręsti skaitmeninės žinių bazės ir išmaniosios pagalbos sistemos. Tyrime taikyta vieno atvejo analizė: remtasi kompiuterizuotos techninės priežiūros valdymo sistemos duomenimis, buvo vertinamos gamybos apimtys, gedimų dažnis, vidutinis gedimo šalinimo laikas ir vidutinis veikimo laikas tarp gedimų, taip pat analizuotas technikų darbas, naudojant dirbtinio intelekto įrankį kasdienėje praktikoje. Rezultatai parodė, kad didėjant gamybos apimtims dirbtinio intelekto priemonė padėjo išlaikyti stabilų gedimų lygį, sutrumpinti diagnostikos etapą ir sumažinti vidutinį gedimo šalinimo laiką, o tai leido sumažinti įrangos prastovų kaštus. Ekonominė analizė atskleidė, kad net ir konservatyviai vertinant dirbtinio intelekto indėlį, sistemos sukūrimo ir palaikymo sąnaudos gali atsipirkti per santykinai trumpą laikotarpį. Tyrimo rezultatai riboti, nes apima vieną cechą ir trumpą stebėjimo laikotarpį, tačiau jie atskleidžia kryptį tolesniems tyrimams, plečiant sprendimo taikymą skirtingose įrangos grupėse ir vertinant ilgalaikį poveikį įrenginių patikimumui. Darbe daroma išvada, kad dirbtinis intelektas gali tapti veiksminga pagalbine priemone technikams, jei jis integruojamas į aiškiai apibrėžtą gedimų valdymo procesą, užtikrinant kokybiškus duomenis, tvarkingą dokumentaciją ir darbuotojų kompetencijų stiprinimą.

Pinkevičius, Mantas. Improving Technical Department Efficiency through Application of Artificial Intelligence in Fault Management Process. Master's Final Degree Project, supervisor Assist. Prof. Dr. Ingrida Venytė ; Faculty of Mechanical Engineering and Design, Kaunas University of Technology.

Study field and area (study field group): Production and Manufacturing Engineering (E10), Engineering Sciences (E).

Keywords: artificial intelligence, smart technologies, equipment maintenance, failure diagnostics, production equipment reliability, technical department efficiency.

Kaunas, 2026. 63 p.

Summary

The master's thesis examines the possibilities of applying smart technologies to equipment maintenance in order to reduce downtime caused by failures and increase production stability. The relevance of the topic is driven by the growing complexity of automated production lines and the need to restore their operation quickly under conditions of skilled labour shortage. The novelty of the research lies in the practical testing of an artificial intelligence-based conversational system in the maintenance department of a manufacturing company. This system integrates equipment documentation, failure history and technicians' accumulated knowledge and provides real-time support for repair decisions. The object of the research is the work of the case company's maintenance department when using artificial intelligence tools for equipment failure diagnostics and troubleshooting. The aim of the project is to assess the potential of artificial intelligence tools in maintenance activities in order to increase efficiency in failure diagnosis and repair processes. The theoretical part reviews maintenance department performance indicators, methods for assessing equipment reliability, and the challenges of knowledge transfer and onboarding of new technicians, which can be addressed through digital knowledge bases and intelligent support systems. The empirical research is based on a single-case study. Data from the computerised maintenance management system were analysed, including production volumes, failure frequency, mean time to repair and mean time between failures, as well as technicians' work with the artificial intelligence tool in daily practice. The results show that, as production volumes increased, the artificial intelligence solution helped to keep failure levels stable, shorten the diagnostic stage and reduce the average repair time, which in turn lowered equipment downtime costs. The economic analysis indicates that, even under conservative assumptions about the contribution of artificial intelligence, the costs of developing and maintaining the system can be recovered within a relatively short period. The findings are limited by the focus on a single shop floor and a short observation period, but they indicate directions for further research by extending the solution to different equipment groups and assessing its long-term impact on equipment reliability. The thesis concludes that artificial intelligence can become an effective support tool for maintenance technicians if it is integrated into a clearly defined failure management process, with high-quality data, well-maintained documentation and continuous development of employee competences.

Turinys

Lentelių sąrašas	8
Paveikslų sąrašas	9
Santrumpų ir terminų sąrašas	10
Įvadas.....	11
1. Techninio padalinio veiklos efektyvumo teoriniai pagrindai	13
1.1. MTTR ir MTBF rodikliai	13
1.2. Dirbtinio intelekto reikšmė techninio padalinio veikloje	14
1.3. Naujų darbuotojų įvedimo problemos, iššūkiai ir DI galimybės.....	16
1.4. Skyriaus apibendrinimas	17
2. Techninio padalinio veiklos ir gedimų duomenų analizė.....	18
2.1. Techninio padalinio X veiklos situacija	18
2.2. Techninės priežiūros modeliai ir efektyvumo vertinimas	22
2.3. MTTR ir MTBF mažinimo teoriniai būdai	23
2.4. Dirbtinio intelekto sprendimai techninio padalinio veiklai	24
2.4.1. Dirbtinio intelekto įrankių pasirinkimas.....	26
2.4.2. Dirbtinio intelekto sistemų lyginamoji analizė.....	27
2.5. Saugumas naudojant AI.....	35
2.6. Skyriaus apibendrinimas	35
3. Dirbtinio intelekto taikymo tyrimas gamyklos X techniniame padalinyje	37
3.1. Dirbtinio intelekto taikymo tyrimo metodika techninio padalinio veikloje	37
3.2. Dirbtinio intelekto įrankio kūrimas ir diegimas	39
3.3. Tyrimo eiga	47
3.4. Tyrimo rezultatai	51
3.5. Rekomendacijos	53
3.6. Skyriaus apibendrinimas	55
4. Ekonominė dalis.....	56
4.1. Dirbtinio intelekto sprendimo įdiegimo kaštų įvertinimas	56
4.2. Skyriaus apibendrinimas	58
Išvados	59
Literatūros sąrašas	60
Priedai.....	64
1 priedas. Gedimo fiksavimo ir šalinimo schema	64
2 priedas. Gedimo šalinimo schema	64

Lentelių sąrašas

1 lentelė. Tiriamo cecho gamybos ir gedimų rodikliai.....	18
2 lentelė. „ChatGPT“ funkcijos ir savybės [31-33].....	28
3 lentelė. „IBM Watson Discovery“ funkcijos ir savybės [34-36].....	29
4 lentelė. „Microsoft Copilot“ funkcijos ir savybės [37-39]	30
5 lentelė. „Azure AI“ funkcijos ir savybės [40-41]	31
6 lentelė. „Humata AI „funkcijos ir savybės [42-43]	32
7 lentelė. „ChatDOC“ funkcijos ir savybės [44-46].....	33
8 lentelė. Dirbtinio intelekto sistemų vertinimas.....	34
9 lentelė. Gamybos apimtys ir gedimų skaičiaus kaita tyrimo laikotarpiu.....	51
10 lentelė. MTTR, MTBF ir gamybos augimo dinamika tyrimo laikotarpiu.....	52
11 lentelė. DI sprendimo atsiperkamumo scenarijų palyginimas.....	58

Paveikslų sąrašas

1 pav. MTTR ir MTBF schema [2]	13
2 pav. Alldevice“ sistemos darbinio lango pavyzdys [17]	19
3 pav. Gedimo šalinimo supaprastinta schema.....	21
4 pav. Generatyvaus dirbtinio intelekto pokalbių agentų rinkos dalys 2025 m. [26].....	26
5 pav. Sukuriamas naujas „ChatGPT“ modelis	39
6 pav. „GPT“ konfigūravimas dialogo režimu bendraujant su sistema.....	40
7 pav. „GPT“ rankinio konfigūravimo langas	40
8 pav. „GPT“ papildomų galimybių pasirinkimas	41
9 pav. „GPT“ veiksmo kūrimo langas	42
10 pav. Pavyzdinė „Google Drive“ paieškos API „OpenAPI“ specifikacija	42
11 pav. „Google Apps Script“ žiniatinklio paslaugos kodas dokumentų paieškai „Google Drive“ sistemoje	43
12 pav. GPT, „Google Apps Script“ ir „Google Drive“ sąveikos schema atliekant gedimo priežasčių paiešką	44
13 pav. Darbų akto pavyzdys	45
14 pav. Tyrime naudojamų duomenų srautas	46
15 pav. Techniko į „GPT“ įvestas gedimo aprašymas šnekamuoju stiliumi.....	48
16 pav. „GPT“ atsakymas, identifikavus įrenginį ir suformulavus problemos aprašymą.....	48
17 pav. „GPT“ pateikti ankstesnių remontų aprašai.....	48
18 pav. „GPT“ pateikta rekomenduojama gedimo šalinimo seka	49
19 pav. Sistemos pateikiami papildomi patikros punktai technikui	49
20 pav. Techniko atliktų darbų ir papildomų patikrinimų aprašymas GPT pokalbyje	49
21 pav. „GPT“ sugeneruotas atliktų darbų aprašas ir prevencinės priežiūros rekomendacijos	49
22 pav. Klaidingas „GPT“ atsakymas, kai apie įrenginį trūksta informacijos	50
23 pav. „GPT“ nustatymas „Ilgesnis galvojimas“	50
24 pav. Gedimų skaičiaus 1000 pagamintų gaminių pokytis tyrimo laikotarpiu	52

Santrumpų ir terminų sąrašas

Santrumpos:

MTBF (Mean Time Between Failures) – vidutinis laikas tarp gedimų, rodiklis, parodantis įrangos patikimumą, tai yra kiek ilgai įrenginys veikia be sutrikimų.

MTTR (Mean Time To Repair) – vidutinis remonto laikas, rodiklis, parodantis, kiek užtrunka pašalinti įvykusį įrenginio gedimą nuo jo užregistravimo iki visiško įrangos atstatymo.

TPM (Total Productive Maintenance) – įmonės valdymo metodas, apimantis visų darbuotojų įsitraukimą į įrangos priežiūrą, siekiant sumažinti gedimus, prastovas ir maksimaliai padidinti įrenginių našumą.

ITOps (IT Operations) – informacinių technologijų skyrių veikla, susijusi su organizacijos sistemų, serverių, tinklų, saugumo ir infrastruktūros valdymu, priežiūra ir palaikymu.

DevOps (Development and Operations) – praktika, integruojanti programų kūrimo ir diegimo veiklas, siekiant užtikrinti greitą, patikimą ir dažną atnaujinimų diegimą bei IT procesų automatizavimą.

DI (Artificial Intelligence (AI)) – technologijų sritis, kuri kuria sistemas, gebančias atlikti žmogaus intelektui būdingas užduotis, tokias kaip mokymasis, mąstymas, sprendimų priėmimas ir kalbos ar vaizdų atpažinimas.

XAI (Explainable Artificial Intelligence) – Tai dirbtinio intelekto modeliai, kurių veikimą galima suprasti ir paaiškinti žmonėms. Tokie modeliai padeda užtikrinti skaidrumą ir pasitikėjimą DI sprendimais, ypač techninėse srityse.

API (Application Programming Interface) – programų sąsaja, leidžianti skirtingoms sistemoms ir programoms keistis duomenimis ir funkcijomis per standartizuotas užklausas.

HTTP (HyperText Transfer Protocol) – hiperteksto perdavimo protokolas, naudojamas duomenų mainams tarp žiniatinklio naršyklės ir serverio.

Apps Script (Apps Script) – „Google“ aplinkai pritaikyta scenarijų (skriptų) kalba, leidžianti automatizuoti procesus ir kurti pritaikytas funkcijas „Google“ paslaugoms.

Web App (Web Application) – internetinė taikomoji programa, kuri veikia serverio pusėje ir vartotojui pasiekama per žiniatinklio naršyklę.

CMMS (Computerized Maintenance Management System) – kompiuterizuota techninės priežiūros valdymo sistema, skirta planuoti, registruoti ir analizuoti įrangos priežiūros darbus bei gedimus.

GPT (Generative Pre-trained Transformer) – generatyvinio dirbtinio intelekto modelis, skirtas generuoti tekstą ir teikti atsakymus į vartotojo užklausas pokalbio forma.

JSON (JavaScript Object Notation) – lengvas duomenų mainų formatas, naudojamas struktūruotai informacijai saugoti ir perduoti tarp skirtingų sistemų.

YAML (YAML Ain't Markup Language) – žymėjimo kalba, naudojama konfigūracijų ir kitų struktūruotų duomenų aprašymui žmogui suprantamu formatu.

CSV (Comma-Separated Values) – tekstinis duomenų formatas, kuriame lentelės duomenys saugomi atskiriant stulpelius skyrikliais (dažniausiai kableliais) ir kuris plačiai naudojamas duomenų eksportui bei analizei.

OOE (Overall Equipment Effectiveness) – bendras įrenginių efektyvumo rodiklis, parodantis, kaip gerai įranga išnaudojama pagal prieinamumą, našumą ir kokybę.

Ivadas

Šiuolaikinėje gamybos pramonėje vis daugiau dėmesio skiriama techninių padalinių veiklos efektyvumui, nes nuo jų darbo tiesiogiai priklauso įrenginių patikimumas ir bendras gamybos proceso stabilumas. Įvykus gedimui sustoja gamybos linija, o tai lemia papildomas finansines išlaidas, prarandamą laiką ir sumažintą įmonės konkurencingumą. Vienu svarbiausių techninio padalinio veiklos rodiklių tampa vidutinis gedimo šalinimo laikas, parodantis, kiek laiko prireikia pašalinti įvykusį gedimą nuo jo užregistravimo iki visiško įrangos atstatymo. Praktikoje dažnai matyti, kad šis laikas pailgėja dėl gana paprastų priežasčių: technikai sugaišta daug laiko ieškodami informacijos skirtinguose dokumentuose ir susirašinėjimuose, konsultuodamiesi tarpusavyje arba bandydami kelis skirtingus sprendimo variantus. Tai ne tik prailgina prastovas, bet ir didina įtampą darbuotojams bei klaidų tikimybę, todėl tampa aktualu ieškoti naujų būdų, kaip sutrumpinti diagnostikos etapą ir pagerinti sprendimų priėmimą realiomis darbo sąlygomis. Papildomą iššūkį kelia kvalifikuotų technikų trūkumas ir ilgametę patirtį turinčių darbuotojų kaita, kai reikšminga dalis žinių lieka „galvose“, o ne formaliose žinių bazėse, todėl naujiems specialistams sudėtinga greitai perimti reikalingą informaciją.

Mokslinėje literatūroje vis plačiau nagrinėjami įrenginių patikimumo rodikliai, kompiuterizuotų techninės priežiūros valdymo sistemų taikymas, planinės ir prognozuojamosios priežiūros metodai. Ankstesni tyrimai rodo, kad informacijos centralizavimas, aiškus gedimų registravimas ir duomenų analizė padeda mažinti prastovas ir gerinti techninio padalinio veiklos rodiklius. Pastaraisiais metais vis daugiau dėmesio skiriama dirbtinio intelekto ir mašininio mokymosi taikymui gamyboje: analizuojami įrenginių jutiklių duomenys, prognozuojami gedimai, kuriamos sprendimų paramos sistemos. Vis dėlto dauguma sprendimų orientuoti į automatizuotų signalų ir didelių duomenų srautų analizę, o mažiau nagrinėjama, kaip išnaudoti jau sukauptą dokumentaciją, gedimų istorijas ir darbuotojų patirtį, ją sujungiant į vieną lengvai prieinamą žinių šaltinį. Nedaug tyrimų detalizuotai analizuoja, kaip dirbtinio intelekto priemonės gali būti panaudotos ne tik prognozavimui, bet ir kaip kasdienis pagalbininkas technikui, padedantis greičiau rasti reikiamą informaciją ir priimti sprendimus remonto metu, ypač tokioje aplinkoje, kur žinios išskaidytos tarp dokumentacijos, istorinių įrašų ir darbuotojų patirties.

Šis tyrimas siekia užpildyti šią spragą praktiškai įvertinant išmaniosios technologijos taikymą konkrečios gamybos įmonės techniniame padalinyje. Darbe nagrinėjama, kaip dirbtinio intelekto pagrindu veikiantis įrankis, turintis prieigą prie įrenginių dokumentacijos ir gedimų istorijos, gali būti integruotas į realų gedimų diagnostikos ir šalinimo procesą, ir koks yra jo poveikis remonto laikui bei informacijos paieškos efektyvumui. Tyrimas atliktas realiomis gamybos sąlygomis, tiriant gamyklos X cecho įrenginių gedimų duomenis, technikų darbą ir dirbtinio intelekto rekomendacijų pritaikomumą. Taip sukuriamos naujos žinios apie tai, kokiomis sąlygomis tokia sistema iš tikrųjų padeda sutrumpinti gedimų sprendimo laiką, kokie duomenų ir dokumentacijos reikalavimai yra kritiniai, kokie iššūkiai kyla darbuotojams ją taikant ir kokios rekomendacijos gali būti pateiktos įmonėms, planuojančioms diegti panašius sprendimus. Be to, tyrimas leidžia įvertinti ne tik techninį, bet ir ekonominį dirbtinio intelekto sprendimo pagrįstumą, nes analizuojami prastovų kaštai ir galimos sutaupytos lėšos. Toks praktinis atvejo tyrimas leidžia ne tik patikrinti teorines dirbtinio intelekto taikymo prielaidas, bet ir pasiūlyti konkrečius sprendimo būdus, kurie gali būti pritaikyti ir kitose gamybos organizacijose, siekiančiose didinti įrenginių priežiūros efektyvumą ir spartinti technikų darbo įvedimą bei žinių perdavimą.

Tikslas: įvertinti dirbtinio intelekto priemonių taikymo galimybes techninio padalinio veikloje, siekiant padidinti efektyvumą gedimų diagnostikos ir šalinimo procesuose.

Uždaviniai:

1. nustatyti techninio padalinio efektyvumo įtaką gamybos stabilumui;
2. atlikti įrenginių gedimų duomenų praktinę analizę;
3. įdiegti dirbtinio intelekto sprendimus techniniame padalinyje ir įvertinti jų poveikį darbo efektyvumui;
4. pateikti rekomendacijas integruoti dirbtinio intelekto priemones techninio padalinio veikloje.

Hipotezė: Dirbtinio intelekto priemonių taikymas techninio padalinio veikloje leidžia sumažinti vidutinį gedimų šalinimo laiką ir padidinti remonto procesų efektyvumą.

1. Techninio padalinio veiklos efektyvumo teoriniai pagrindai


Šiame skyriuje nagrinėjama gamybos įmonės techninio padalinio veikla ir jos efektyvumas šalinant įrangos gedimus. Aptariama, kaip organizuojamas šis procesas, kokie rodikliai naudojami efektyvumui vertinti ir kokios problemos kyla kasdienėje praktikoje. Vienas svarbiausių rodiklių yra vidutinis įrenginio remonto laikas (MTTR), parodantis, kiek trunka pašalinti gedimą nuo jo užregistravimo iki visiško įrangos atstatymo. MTTR siejamas su kitu rodikliu – vidutiniu laiku tarp gedimų (MTBF), nes kokybiškai atliktas remontas prailgina įrenginio darbo laiką iki kito sutrikimo.

Dažnai technikai susiduria su sunkumais ieškodami informacijos dokumentuose, o sprendimai remiami asmenine patirtimi ar kolegų patarimais. Tai prailgina prastovų trukmę, mažina darbo našumą ir stabdo gamybą. Techninio padalinio veiklos rezultatai taip pat priklauso nuo darbuotojų kompetencijos ir jų parengimo, todėl svarbu vertinti ne tik technologinius, bet ir organizacinius bei žmogiškuosius veiksnius.

Toliau skyriuje pateikiami tarptautinių įmonių pavyzdžiai ir praktikos, padedančios didinti techninio padalinio efektyvumą naudojant pažangias technologijas. Aptariami ekonominiai, organizaciniai ir techniniai aspektai, susiję su dirbtinio intelekto diegimu, jo teikiama nauda ir iššūkiais. Pabaigoje pristatomos šiuolaikinės DI taikymo tendencijos, įskaitant paaiškinamojo dirbtinio intelekto (XAI) principus, kurie užtikrina sprendimų skaidrumą ir patikimumą. Šios išvalgos sudaro pagrindą tolesnei analizei, siekiant mažinti MTTR rodiklį ir didinti įrenginių patikimumą.

1.1. MTTR ir MTBF rodikliai

Analizuojant techninio padalinio darbą, svarbu turėti aiškius rodiklius, kurie padeda objektyviai įvertinti darbo efektyvumą. Dažniausiai tam naudojami du pagrindiniai rodikliai – MTTR ir MTBF (žr. 1 pav.). Kaip nurodo Rodrigues [1], jie yra glaudžiai susiję, tačiau vertina skirtingus aspektus: MTBF parodo, kiek laiko įranga vidutiniškai veikia be sutrikimų, o MTTR – kiek laiko užtrunka ją suremontuoti po gedimo.



1 pav. MTTR ir MTBF schema [2]

Vidutinis įrenginio remonto laikas nusako, kiek vidutiniškai trunka pašalinti gedimą – nuo remonto pradžios iki pabaigos, kai įranga vėl gali būti eksploatuojama. Į šį laiką neįeina diagnostika ar gedimo priežasties nustatymas, todėl MTTR tiksliau atspindi paties remonto proceso efektyvumą. Jo reikšmė glaudžiai siejasi su įmonės procesų organizavimu: jei greitai užtikrinamas dalių tiekimas, aiškiai

paskirstyta atsakomybė ir darbuotojai apmokyti, MTTR reikšmė mažėja. Tuo tarpu neapibrėžti procesai ir informacijos stoka šį laiką ilgina, o tai tiesiogiai didina gamybos prastovas bei nuostolius [3].

Vidutinis laikas tarp gedimų parodo, kiek ilgai įranga veikia be sutrikimų tarp gedimų [1]. Tai patikimumo rodiklis, padedantis nustatyti, kaip stabiliai ir kokybiškai veikia įrenginys. Kuo didesnė MTBF reikšmė, tuo įranga patikimesnė, nes gedimai pasitaiko rečiau. Šis rodiklis taip pat leidžia planuoti profilaktinę ar prognozuojamąją priežiūrą, nes remiantis ankstesnių gedimų duomenimis galima nustatyti, kada tikėtinas kitas sutrikimas. Dėl to MTBF tampa strateginiu įrankiu, leidžiančiu pereiti nuo reaguojamosios prie planinės priežiūros. Be to, jis padeda identifikuoti įrenginių, kurių gedimų dažnis didesnis nei vidutinis, sritis ir nukreipti dėmesį į prevencinių priemonių taikymą.

Sharif [4] pateikia dar vieną įžvalgą – MTTR neturėtų būti suprantamas tik kaip remonto trukmė, bet ir kaip nuolatinio tobulinimo ciklo dalis. Organizacijos skatinamos po kiekvieno incidento atlikti priežasties analizę, kad būtų galima nustatyti silpnąsias vietas ir užtikrinti, jog panašūs gedimai ateityje būtų sprendžiami greičiau. Šiuolaikinės DevOps (programų kūrimo ir IT operacijų integruotos praktikos) bei ITOps (informacinių technologijų operacijų valdymo sistemos) koncepcijos rodo, kad mažesnis MTTR dažnai siejamas ne tik su greitesniu gedimų šalinimu, bet ir su pačios sistemos architektūra, automatizavimu bei efektyvia komunikacija tarp komandų [4].

Mokslinėje literatūroje pabrėžiama, kad vien MTTR ir MTBF stebėsenos nebepakanka. Kaip teigia Prasad ir kiti [5], šiuolaikinėje pramonės aplinkoje vis dažniau taikomi integruoti priežiūros vadybos modeliai, apimantys ne tik gedimų šalinimą, bet ir platesnį požiūrį į įrangos eksploatavimą bei nuolatinį tobulinimą. Tokiuose modeliuose derinamos skirtingos strategijos – prognozuojamoji, prevencinė ir visuotinio produktyvumo priežiūra (TPM). Šis požiūris leidžia ne tik sumažinti prastovų riziką, bet ir kurti tvarią priežiūros kultūrą organizacijoje. Integruotas modelis orientuojasi ne vien į techninius rodiklius, tokius kaip MTTR ar MTBF, bet ir į platesnius tikslus – saugumą, kokybę, aplinkosaugą bei ilgalaikį produktyvumą. Tokia priežiūros sistema prisideda prie didesnio išteklių efektyvumo, ilgalaikio įmonės pelningumo ir konkurencinio pranašumo rinkoje [5].

1.2. Dirbtinio intelekto reikšmė techninio padalinio veikloje

Gamyboje techninių padalinių vaidmuo tampa vis svarbesnis, nes nuo jų darbo priklauso ne tik įrenginių patikimumas, bet ir bendras gamybos proceso efektyvumas. Tradiciniai priežiūros metodai, paremti reaktyvia arba prevencine strategija, ne visada užtikrina optimalius rezultatus, todėl įmonės vis dažniau atsisgręžia į išmaniąsias technologijas.

Remiantis Achouch ir kt. [6], šiandieninėse gamybos įmonėse didžiausią poveikį techninių padalinių darbui daro dirbtinio intelekto taikymas prognozuojamojoje priežiūroje. Įmonės vis dažniau pereina nuo tradicinių reaktyvios arba prevencinės priežiūros modelių prie pažangesnių, kurie remiasi nuolatinių įrenginių būklės stebėjimu. Tokios sistemos leidžia realiu laiku rinkti duomenis iš sensorių ir kitų šaltinių, juos apdoroti bei nustatyti galimus gedimų požymius dar prieš jiems įvykstant. Techniniam skyriui tai reiškia efektyvesnį resursų planavimą, mažiau neplanuotų prastovų ir greitesnį sprendimų priėmimą, nes DI modeliai pateikia rekomendacijas, paremtas faktiniais įrenginių darbo rodikliais.

Straipsnyje teigiama, kad dirbtinio intelekto ir duomenimis pagrįstos priežiūros taikymas leidžia žymiai pagerinti remonto procesų efektyvumą ir sumažinti prastovas, tačiau tikslus poveikis MTTR

nėra pateiktas procentine ar skaitine forma. Toks poveikis gaunamas, nes technikai gauna išankstinę informaciją apie galimas problemas ir gali tinkamai pasiruošti jų šalinimui. Be to, padidėja įrenginių patikimumas ir prailgėja jų vidutinis veikimo tarp gedimų laikas, kadangi priežiūra atliekama ne akiai pagal grafiką, bet tik tada, kai to reikia. Tokiu būdu techninis skyrius gali daugiau dėmesio skirti planiniams darbams ir ilgalaikiams patobulinimams, užuot nuolat reagavęs į staigius gedimus. Tai ne tik didina darbo efektyvumą, bet ir stiprina bendrą įmonės konkurencingumą, nes gamybos procesai tampa stabilesni, o produkcijos tiekimas – patikimesnis [6].

Autorius Dereci ir kiti [7] kalba, kad prognozuojamoji priežiūra tampa vis svarbesnė gamybos pramonėje, nes leidžia sumažinti neplanuotų prastovų skaičių ir padidinti įrangos patikimumą. Tyrėjai sistemingai peržvelgė įvairias praktikas ir metodus, kurie taikomi skirtingose įmonėse, ir nustatė, jog pagrindinė sėkmės sąlyga yra tinkama technologijų integracija į techninio skyriaus darbą. Tam būtina ne tik techninė infrastruktūra : išmanūs sensoriai, duomenų bazės, DI algoritmai, bet ir organizaciniai pokyčiai, susiję su procesų planavimu bei priežiūros kultūra. Techniniai padaliniai, kurie aktyviai naudoja prognozuojamosios priežiūros metodus, dažniau pasiekia geresnius darbo rodiklius, nes remiasi realiais duomenimis, o ne tik laiko intervalais nustatyta priežiūra.

Dar vienas akcentas – žmogiškasis faktorius. Net ir pažangiausios technologijos negali duoti laukiamų rezultatų, jei techninis personalas nėra tinkamai paruoštas ir motyvuotas dirbti su išmaniais įrankiais. Todėl itin svarbi tampa nuolatinė mokymų sistema, kuri padeda technikams suprasti, kaip naudoti surinktus duomenis sprendimų priėmimui. Be to, apžvalga parodė, kad ekonominis efektas pasireiškia tik per laiką – įmonės, kurios investuoja į prognozuojamąją priežiūrą, ilgainiui pastebi mažėjančias remonto išlaidas, geresnį atsarginių dalių planavimą bei aukštesnį bendrą gamybos našumą [7].

Dar vienas svarbus aspektas, kurį išskiria Benhanifia ir kt. [8], yra rodiklių integravimas į sprendimų priėmimo procesus. Straipsnyje pabrėžiama, kad vien tik duomenų turėjimas nesukuria vertės, jei jie nėra panaudojami praktikoje. Todėl būtina, jog techninis padalinys kartu su vadovybe kurtų sprendimų priėmimo mechanizmus, paremtus realiu rodiklių stebėjimu. Tai gali būti automatiniai pranešimai apie nukrypimus, planinių darbų koregavimas pagal faktinius gedimų modelius arba išmaniųjų dirbtinio intelekto sistemų rekomendacijos. Tokiu būdu rodikliai tampa ne tik matavimo priemone, bet ir kasdienio darbo įrankiu, leidžiančiu užtikrinti didesnę techninio padalinio indėlį į bendrą įmonės konkurencingumą.

Šiuolaikinėse gamybos įmonėse vis dažniau pabrėžiama, kad pagrindinė sąnaudų dalis susidaro ne įrenginio įsigijimo metu, o jo naudojimo ir priežiūros etape – net 70–80 % visų turto išlaidų tenka eksploatacijai ir priežiūrai. Todėl būtent čia slypi didžiausios galimybės optimizuoti kaštus: patikima priežiūros praktika leidžia juos sumažinti, o prastas planavimas ar perteklinis darbų organizavimas sukuria nereikalingas atliekas. Visgi daugelyje įmonių priežiūros veikla išlieka reaktyvi – Amissa Giddens [9] apklausa parodė, kad net 61 % priežiūros padalinių gedimus šalina tik jiems įvykus, dažnai užduotis perduodant neformaliais kanalais-pokalbiais, užrašais ar elektoriniais laiškais. Tokia praktika kelia riziką prarasti svarbią informaciją ir mažina skaidrumą, todėl vis aktualesnės tampa dirbtinio intelekto pagrįstos sistemos, užtikrinančios tvarkingesnę planavimą bei geresnę remonto kokybę. Didelę pažangą rodo DI taikymas gedimų diagnostikoje – Zachariades [10] ir kiti tyrėjai analizuoja, kaip neuroniniai tinklai, gilusis mokymasis, ekspertinės sistemos ir kiti algoritmai padeda techniniams padaliniams realiu laiku gauti duomenis apie įrenginių būklę. Tokios sistemos leidžia greitai atpažinti anomalijas, nustatyti galimas gedimų priežastis ir iš karto imtis tinkamų veiksmų,

užuot problemą identifikavus bandymų ir klaidų būdu. Tai sutrumpina diagnostikos laiką, sumažina žmogiškųjų klaidų tikimybę ir prisideda prie efektyvesnio remonto proceso. Be to, šios sistemos kaupia istorinius duomenis, kurie ilgainiui leidžia tobulinti remonto strategijas bei didinti įrangos patikimumą. Tokiu būdu dirbtinis intelektas tampa ne tik pagalbininku einamuosiuose remonto darbuose, bet ir ilgalaikiu partneriu, užtikrinančiu stabilų įmonės veikimą bei konkurencingumą rinkoje.

Dar vienas svarbus aspektas – paaiškinamasis dirbtinis intelektas (XAI), kuris reiškia, kad DI sistemos ne tik pateikia rezultata, bet ir paaiškina, kokiais duomenimis ar logika jis buvo pagrįstas. Kaip pažymi Caçõ ir kt. [11], techniniam personalui svarbu ne tik gauti informaciją apie gedimą, bet ir suprasti, kodėl sistema pateikė būtent tokią diagnozę. Skirtingai nei „juodosios dėžės“ modeliai, pateikiantys tik rezultata, XAI suteikia žmogui suprantamus paaiškinimus. Jie gali būti vizualūs, pavyzdžiui, šilumos žemėlapiai, rodantys, kuris jutiklis turėjo daugiausia įtakos, arba tekstiniai – aiškiai išdėstytos taisyklės, nurodančios galimas priežastis. Tokie paaiškinimai padeda technikams greičiau nustatyti gedimo priežastį ir priimti tinkamus sprendimus. Nors šiuo metu XAI taikymai pramonėje dažniausiai dar gana paprasti, jų plėtra gali iš esmės pakeisti remonto procesus. Be to, XAI padeda užtikrinti atitiktį ES Dirbtinio intelekto akto reikalavimams dėl skaidrumo ir patikimumo. Praktikoje tai reiškia, kad technikas gauna ne tik signalą apie problemą, bet ir aiškų paaiškinimą bei galimų veiksmų alternatyvas, kas sumažina klaidų riziką, padidina sprendimų kokybę ir leidžia efektyviau atkurti įrenginių veikimą [11].

1.3. Naujų darbuotojų įvedimo problemos, iššūkiai ir DI galimybės

Remiantis Bradač Hojnik ir kt [12], nors dirbtinio intelekto sprendimai gamybos įmonėse turi didelį potencialą, jų diegimas kelia nemažai iššūkių. Įmonės susiduria su duomenų kokybės ir prieinamumo problemomis – dažnai surinkti duomenys būna fragmentiški, nepilni arba nesuderinti tarp skirtingų sistemų. Tai riboja dirbtinio intelekto modelių tikslumą, todėl techninis skyrius negali pilnai pasikliauti prognozėmis.

Kitas esminis iššūkis yra didelės pradinės investicijos į technologijas bei kvalifikuotų specialistų trūkumas. Įmonėms reikia ne tik modernių sensorių ir duomenų analitikos įrankių, bet ir žmonių, gebančių juos valdyti bei interpretuoti gautą informaciją. Finansai ypač svarbūs – DI diegimas reikalauja reikšmingų pinigų sąnaudų, susijusių su įrangos modernizavimu, programinės įrangos licencijomis, darbuotojų mokymais bei sistemų integracija į esamą infrastruktūrą. Straipsnyje pažymima, kad mažesnėms įmonėms šios išlaidos gali būti per didelės, todėl jos dažnai renkasi hibridinius arba dalinius sprendimus, siekdamos išskaidyti investicijas laike [6]. Be to, investicijų grąžos klausimas yra sunkiai nuspėjamas – nors dirbtinis intelektas gali sumažinti prastovas ir pagerinti našumą, realios finansinės naudos pasiekiamos tik po kelių metų nuoseklaus naudojimo. Dėl šios priežasties įmonės turi kruopščiai vertinti planuojamą naudą ir finansinius kaštus, kad išvengtų neapgalvotų sprendimų.

Dar vienas akcentuojamas iššūkis yra organizacinė kultūra ir pasipriešinimas pokyčiams. Techniniai darbuotojai gali skeptiškai vertinti naujovių diegimą, baimindamiesi technologijų nepatikimumo ir darbo krūvio padidėjimu. Tam būtina užtikrinti tinkamą komunikaciją, mokymus ir laipsnišką technologijų įvedimą. Galiausiai, kyla ir teisiniai bei saugumo klausimai – nuo duomenų privatumo iki kibernetinių atakų grėsmės. Todėl sėkmingas dirbtinio intelekto diegimas reikalauja ne tik

technologinių, bet ir strateginių vadybinių sprendimų, kurie užtikrintų ilgalaikį sistemos veikimą bei pasitikėjimą ja [7].

Pasak Mark Holliday [13], naujų darbuotojų įvedimas yra labai svarbus procesas, nes nuo jo priklauso, kaip greitai žmogus pradės dirbti pilnu pajėgumu, ar jausis motyvuotas ir norės likti įmonėje ilgesnį laiką. Straipsnyje teigiama, kad dažniausiai pasitaikančios klaidos yra per ilgas arba per trumpas įvedimo laikas, per daug arba per mažai informacijos, nepakankamas vadovų įsitraukimas, silpna komunikacija bei aiškių užduočių ir atsakomybės trūkumas. Visa tai sukelia pasimetimą, mažina pasitikėjimą savo jėgomis ir stabdo produktyvumą.

Ypatingų iššūkių kyla techniniams skyriams, kuriuose nauji specialistai turi labai greitai perprasti sudėtingą įrangą ir gamybos procesus. David Boyes analizė rodo, kad automobilių pramonėje technikų įvedimą dažnai apsunkina nepakankamas praktinis mokymas, fragmentiškai pateikiama informacija ir nepakankamas dėmesys individualių įgūdžių ugdymui, todėl dalis naujokų patiria nuovargį, motyvacijos kritimą ir užtrunka ilgiau, kol tampa pilnaverčiais komandos nariais [14]. Šiuos pastebėjimus patvirtina ir moksliniai tyrimai – Rachel Konyefa nustatė, kad struktūruotas ir tikslingas įvedimas reikšmingai padidina naujokų lojalumą bei sumažina ankstyvo išėjimo iš darbo riziką. Tai reiškia, jog įvedimo kokybė daro tiesioginę įtaką organizacijos stabilumui, darbuotojų įsitraukimui ir personalo kaitos kaštams [15].

Šiame kontekste vis daugiau dėmesio sulaukia išmaniosios technologijos, ypač dirbtinis intelektas. Pasak Lorelei Trisca [16] apžvalgos, dirbtinis intelektas gali iš esmės transformuoti įvedimo procesą: automatizuoti dokumentacijos tvarkymą, personalizuoti mokymosi turinį pagal individualias darbuotojo kompetencijas, pasiūlyti interaktyvias virtualias pagalbos sistemas bei nuolat stebėti naujokų pažangą realiu laiku. Tokiu būdu sumažinamas žmogiškųjų klaidų skaičius, darbuotojai gauna aiškesnes ir labiau pritaikytas instrukcijas, o padaliniai gali efektyviau planuoti mokymus bei užduotis. Be to, dirbtinis intelektas suteikia galimybę kurti individualizuotus mokymosi scenarijus, kurie ypač padeda darbuotojams greičiau perprasti sudėtingas technologijas ir įrenginių valdymą.

1.4. Skyriaus apibendrinimas

Apibendrinant galima sakyti, kad techninio padalinio veiklos efektyvumas tiesiogiai priklauso nuo gedimų šalinimo proceso organizavimo ir pagrindinių rodiklių – MTTR bei MTBF. MTTR parodo, kiek laiko vidutiniškai užtrunka pašalinti gedimą nuo jo užregistravimo iki visiško įrangos atstatymo, o MTBF leidžia įvertinti įrenginio veikimo patikimumą ir planuoti priežiūros darbus. Aiškiai apibrėžtos atsakomybės, efektyvus atsarginių dalių organizavimas ir lengva prieiga prie informacijos lemia trumpesnę MTTR, o nuoseklus duomenų kaupimas ir analizė padeda didinti MTBF reikšmę bei pereiti nuo reaktyvios prie prevencinės priežiūros. Skyriuje taip pat nustatyta, kad techninio padalinio efektyvumo augimą lemia ir naujos technologijos tokios kaip dirbtinio intelekto taikymas. Prognozuojamosios priežiūros sprendimai leidžia iš anksto identifikuoti galimus gedimus, o paaiškinamojo dirbtinio intelekto modeliai užtikrina sprendimų skaidrumą ir pagrįstumą. Šios technologijos padeda technikams priimti tikslesnius sprendimus, mažina klaidų tikimybę ir sutrumpina įrenginių prastovų laiką. Nors dirbtinio intelekto diegimas reikalauja investicijų, patikimų duomenų ir darbuotojų kompetencijų stiprinimo, jo taikymas kartu su gerai sutvarkytais procesais ir rodiklių valdymu leidžia nuosekliai gerinti techninio padalinio efektyvumą.

2. Techninio padalinio veiklos ir gedimų duomenų analizė

Antrajame skyriuje apžvelgiami teoriniai aspektai, kuriais remiamasi siekiant didinti gamyklos X techninio padalinio efektyvumą. Pirmiausia pristatoma esama padalinio veiklos situacija, aptariami taikomi techninės priežiūros modeliai ir pagrindiniai patikimumo rodikliai – MTTR ir MTBF – bei literatūroje siūlomos priemonės šiems rodikliams gerinti. Toliau nagrinėjami inovatyvūs dirbtinio intelekto taikymo būdai techninio padalinio veikloje ir konkrečių DI įrankių pasirinkimo kriterijai, o pabaigoje aptariami su šiomis technologijomis susiję saugumo ir atitikties reikalavimai. Taip suformuojamas teorinis pagrindas, kuriuo remiamasi vėlesniuose skyriuose atliekant tyrimą.

2.1. Techninio padalinio X veiklos situacija

Analizuojamame gamyklos X ceche veikia 135 įrenginiai, kurių techninę priežiūrą užtikrina du pamainomis dirbantys technikai – vienas dirba rytinėje, kitas – popietinėje pamainoje. Šis cechasis yra vienas iš trijų, už kuriuos atsakingi tie patys techninio padalinio darbuotojai, o iš viso įmonėje eksploatuojama apie 390 įvairių įrenginių, todėl techninio padalinio darbo krūvis yra didelis ir planuoti darbus sudėtinga. Dėl didelės įrangos apimtys greitas reagavimas į gedimus tampa kritiškas gamybos tęstinumui, nes sustojus vienai iš grandžių dažnai nukenčia visas gamybos srautas. 2025 m. rugpjūčio mėnesį tiriamajame ceche buvo užregistruoti 86, o rugsėjo mėnesį – jau 102 gedimai, tai rodo intensyvų gamybos režimą ir didėjančią įrangos apkrovimą. Tiriamajame ceche rugpjūčio mėnesį buvo pagaminti 23 276 oro filtrai, o rugsėjo mėnesį – 31 618 oro filtrai, todėl galima teigti, kad gamybos apimtys analizuojamu laikotarpiu nuosekliai augo. Šių mėnesių gamybos ir gedimų duomenys susisteminti ir pateikti 1 lentelėje, kurioje matyti pagrindiniai tyrimui svarbūs rodikliai. Įmonėje skaičiuojamos faktinės atskirų įrenginių prastovos finansine išraiška, tačiau paprastesniam vertinimui taikoma supaprastinta metodika – laikoma, kad bet kurio įrenginio vienos prastovos valandos nuostolis sudaro apie 1200 Eur, nes dėl sustojusios grandies visa operacija negali tęsti darbo ir stabdo bendrą gamybos srautą. Toks vertinimo būdas leidžia greitai įsivertinti, kokią finansinę riziką kelia kiekvienas ilgesnis gedimas, ir vėlesniuose skyriuose naudoti šiuos duomenis analizuojant dirbtinio intelekto sprendimo įtaką prastovų trumpėjimui.

1 lentelė. Tiriamo cecho gamybos ir gedimų rodikliai

Rodiklis	Rugpjūtis 2025	Rugsėjis 2025	Paaiškinimas
Gaminių kiekis, vnt.	23 276	31 618	Pgamintų oro filtrų skaičius tiriamame ceche
Gedimų skaičius	86	102	„Alldevice“ sistemoje užregistruotų gedimų skaičius
Gedimų sk. 1000 gaminių	3,69	3,23	Santykinis gedimų dažnis
Vidutinis remonto laikas (MTTR), min	28	42	Vidutinė trukmė nuo gedimo registracijos iki remonto pabaigos
Vidutinis laikas tarp gedimų (MTBF), dienų	4,9	6,1	Vidutinis laikotarpis tarp dviejų gedimų
Gamybos augimas, %	-	35,8	Rugsėjo gamyba, palyginti su rugpjūčiu

Techninės priežiūros procesai įmonėje yra skaitmenizuoti – naudojama „Alldevice“ sistema, kuri apjungia gedimų registravimo, planinių darbų valdymo, užduočių paskirstymo ir įrenginių priežiūros

istorijos saugojimo funkcijas (žr. 2 pav.). Ši sistema įdiegta ir nuosekliai naudojama jau ketverius metus, o jos paskirtis – centralizuoti visą informaciją apie įrenginių būklę, atliktus darbus ir atsarginių dalių sunaudojimą. „Alldevice“ veikia kaip internetinė ir mobili platforma, prieinama tiek per kompiuterį, tiek per išmaniuosius telefonus, todėl darbuotojai gali operatyviai registruoti informaciją tiesiog darbo vietoje. Kiekvienas technikas turi asmeninę paskyrą ir kasdien gauna darbo planą, kuriame pateikiamos suplanuotos užduotys – planiniai patikrinimai, profilaktiniai darbai ar anksčiau suplanuoti remontai. Atsiradus nenumatytam ar avariniam gedimui, sistemoje sukuriami nauja užduotis, kurioje nurodomas įrenginys, darbo aprašas, vieta, terminas bei atsakingas asmuo. Tokia struktūra leidžia užtikrinti darbų tęstinumą, aiškiai matyti prioritetus ir efektyviai paskirstyti resursus tarp technikų.

The screenshot shows the 'Alldevice' software interface. The top navigation bar includes 'Reports', 'Orders', 'Work orders', 'Calendar', 'Devices', 'Settings', and 'System'. The 'Demo Factory' is selected. The left sidebar shows a tree view of the factory structure, including 'Factory', 'Boilerhouse 1', 'Boilerhouse 2', 'Factory 1', 'Factory 2', 'Office', 'Pumping station 1', 'Pumping station 2', 'P201', 'C201 (coupler)', 'M201 (motor)', 'P201 (pump)', 'P202', 'P104', 'Tankfarm 1', 'Tankfarm 2', 'Transportation Line', 'Outside the territory (in repair)', 'Storage', 'Trainings', 'Service Company 1', and 'Service company 2'. The main table displays a list of devices with columns: Status, Name, Manufacture, Device type, Device location, Category, Serial number, and Inventory number. The table shows 8 devices, all of which are 'Flowserve' pumps. The status of the devices is indicated by icons: a wrench for P210, P202, P103, P102, and P101; a red circle with a white 'X' for P201; and a red circle with a white 'X' for P104. The bottom of the interface shows 'Page 1 of 1' and 'Displaying 1 - 8 of 8'.

Status	Name	Manufacture	Device type	Device location	Category	Serial number	Inventory number
	P210	Flowserve	200L18K400	Factory / Outside the ter...	Pumps	175242	
	P202	Flowserve	125-100CPK250	Factory / Pumping station ...	Pumps	432958-0020-22	
	P201 (pump)	Flowserve	125-100CPK250	Factory / Pumping station ...	Pumps	432958-0020-21	
	P104	Flowserve	125-100CPK250	Factory / Storage	Pumps	432958-0020-14	
	P103	Flowserve	125-100CPK250	Factory / Pumping station 2	Pumps	432958-0020-19	
	P102	Flowserve	125-100CPK250	Factory / Pumping station 1	Pumps	432958-0020-13	
	P101	Flowserve	125-100CPK250	Factory / Pumping station ...	Pumps	432958-0020-12	
	P101	Flowserve	125-100CPK250	Factory / Pumping station ...	Pumps	432958-0020-11	

2 pav. Alldevice“ sistemos darbinio lango pavyzdys [17]


Įmonėje nustatyta standartizuota gedimų fiksavimo ir šalinimo tvarka, suskaidyta į aiškius etapus – nuo sutrikimo pastebėjimo iki remonto rezultatų analizės. Pirmasis etapas – gedimo nustatymas ir pirminis įvertinimas. Įvykus sutrikimui, už įrenginį atsakingas operatorius per pirmąsias 10 minučių privalo įvertinti, ar problema nesusijusi su paprastomis priežastimis: neteisingais nustatymais, medžiagos tiekimo sutrikimu, užsikimšimu, sensorių užsiteršimu ar neteisingu žaliavos padavimu. Jeigu per šį laiką sutrikimo pašalinti nepavyksta, operatorius sustabdo įrenginį pagal saugos reikalavimus, trumpai aprašo gedimą ir informuoja cecho meistrą. Antrajame etape vyksta gedimo registravimas ir užduoties sukūrimas „Alldevice“ sistemoje – cecho meistras pasirenka įrenginį iš sąrašo ir sistemoje aprašo žinomus gedimo požymius. Užduočiai sistema automatiškai priskiria prioritetinę klasę pagal įrenginio svarbą (A, B, C arba D). Įrenginiai įmonėje suskirstyti į keturias grupes pagal jų įtaką gamybai: A klasė – kritiniai įrenginiai, kurių sustojimas stabdo viso cecho darbą; B klasė – svarbūs įrenginiai, sukeltys reikšmingas prastovas, bet leidžiantys dalinai tęsti gamybą; C klasė – pagalbinė įranga, daranti ribotą įtaką gamybos apimtims; D klasė – nedidelės svarbos įrenginiai, kurių sustojimas neturi esminės įtakos gamybai. Cecho meistras parenka atsakingą techniką, dirbantį toje pamainoje, ir jam supildo užduotį. Gavęs pranešimą telefone, techniką ją mato

įtrauktą į savo dienos darbų sąrašą. Taip užtikrinama, kad visi gedimai būtų fiksuojami vienodai, o sprendimo eiga būtų matoma realiu laiku. Detali gedimo fiksavimo schema pateikiama 1 priede, kuriame nuosekliai pavaizduotas visas informacijos perdavimo ir registravimo srutas.

Trečiajame etape vyksta techniko reagavimas ir pirminė diagnostika. Naują užduotį gavęs technikas įvertina įrenginio klasę ir savo esamą užimtumą. Jeigu tuo metu jis remontuoja žemesnės klasės (pvz., C ar D) įrenginį, darbas gali būti sustabdomas ir prioritetą suteikiamas aukštesnės klasės A ar B įrenginiui. Jei jau tvarkomas kritinės klasės A įrenginys, technikas informuoja meistrą apie numatomą remonto pabaigos laiką ir derinamas sprendimas dėl naujo gedimo nukėlimo arba kito techniko įtraukimo. Atėjęs prie įrenginio, technikas per 30 minučių atlieka pirminę diagnostiką: patikrina akivaizdžias priežastis, atlieka pagrindinius matavimus, įvertina, ar gedimą galima pašalinti iškart, ar reikalingos papildomos dalys, specializuota įranga ar papildomos konsultacijos.

Ketvirtajame etape priimamas sprendimas dėl remonto plano ir reikalingų resursų. Jei gedimą galima pašalinti vidiniais resursais ir nereikia specifinių dalių, technikas nedelsdamas atlieka remontą, užbaigia darbus ir „Alldevice“ sistemoje atnaujina užduoties būseną į „Atlikta“, nurodydamas faktinę trukmę, panaudotas dalis ir nustatytą gedimo priežastį. Jei per 30 minučių nustatoma, kad problema sudėtingesnė, technikas parengia išsamesnį aprašą techninio padalinio vadovui ir toliau tęsia darbus prie įrenginio. Gavęs šią informaciją, vadovas per vieną valandą įvertina gedimo kritiškumą, remonto apimtį ir reikalingus resursus. Jeigu gedimas patenka į technikų kompetencijos ribas, nustatomas konkretus remonto terminas. Jei diagnostika rodo, kad būtinos gamintojo konsultacijos ar specializuotas servisas, technikas surenka visus papildomai reikalingus duomenis – nuotraukas, parametrų išrašus, klaidų kodus, šiuos duomenis perduoda vadovui ir eina prie kitų suplanuotų darbų. Išsami gedimo šalinimo proceso schema pateikiama 2 priede, kurioje detalios pavaizduoti visi sprendimų priėmimo ir atsakomybių perdavimo žingsniai, o supaprastinta šio proceso schema pateikiama 3 paveiksle.

Apie sudėtingus ir ilgiau truncančius gedimus techninio padalinio vadovas informuoja gamybos vadovą, nurodydamas preliminarą prastovos trukmę ir galimą įtaką gamybos planui. Jei numatoma, kad remontas truks ilgiau nei vieną pamainą, gamybos vadovas per keturias valandas parengia alternatyvų gamybos planą: perskirsto užsakymus į kitas linijas, koreguoja pamainų grafiką arba perduoda informaciją pardavimų skyriui dėl užsakymų pagaminimo vėlavimų. Taip gedimų sprendimas derinamas su gamybos tikslais, o finansiniai nuostoliai minimizuojami. Užbaigus remontą, technikas „Alldevice“ sistemoje užpildo atliktų darbų aktą: pažymi faktinę prastovos trukmę, padaro priežasties aprašą, aprašo atliktus veiksmus bei pažymi panaudotas atsargines dalis. Šie duomenys naudojami periodinei analizei – techninio padalinio vadovas reguliariai peržiūri daugiausiai prastovų sukėlusius įrenginius, dažniausiai pasikartojančius gedimus ir ilgiausiai trukusius remontus. Remiantis šia informacija formuojami prevencinių darbų planai, koreguojamos priežiūros instrukcijos ir priimami sprendimai dėl įrangos modernizavimo ar darbuotojų mokymų. Toks nuoseklus procesas leidžia ne tik greičiau reaguoti į gedimus ir valdyti prioritetus, bet ir sistemingai kaupti duomenis apie gedimų priežastis, remonto trukmę ir pasikartojimą.



3 pav. Gedimo šalinimo supaprastinta schema

Nepaisant pažangios sistemos, modernių procesų ir aiškiai apibrėžtų atsakomybės grandžių, atliktų darbų analizei vis dar skiriama nepakankamai dėmesio. Norint nustatyti, ar konkretus gedimas kartojasi, technikams ar vadovams tenka rankiniu būdu peržiūrėti kiekvieną įrašą, analizuoti ataskaitas ir lyginti skirtingų laikotarpių duomenis, todėl šis procesas tampa imlus laikui ir praktikoje dažnai neatliekamas. Dėl to didelė dalis informacijos apie pasikartojančius gedimus, priežastis ir sprendimo būdus lieka techninių darbuotojų atmintyje, o tai riboja galimybes atlikti sisteminę analizę. Technikai dažniausiai remiasi savo patirtimi ir siekia kuo greičiau atkurti įrenginio veikimą, todėl prioritetas teikiamas operatyviam reagavimui, o ne išsamiam priežasties nustatymui.

Kaip matyti iš 1 lentelėje pateiktų duomenų, tiriamame ceche 2025 m. rugpjūčio mėnesį buvo užregistruoti 86 įrenginių gedimai, vidutinis gedimo šalinimo laikas (MTTR) siekė 28 minutes, o vidutinis laikas tarp gedimų (MTBF) – 4,9 dienos. Rugsėjo mėnesį MTTR padidėjo iki 42 minučių, o MTBF – iki 6,1 dienos, todėl galima teigti, kad įrenginių stabilumas (ilgesnis laikas tarp gedimų) gerėja, tačiau remonto trukmė išlieka problema. Tai rodo, kad vien esamų techninės priežiūros procesų ir esamos analizės nepakanka – gedimų šalinimas vis dar užtrunka per ilgai, didindamas gamybos prastovų sąnaudas. Dėl šios priežasties tolesniame poskyryje nagrinėjami techninės priežiūros modeliai ir patikimumo rodikliai, kurie leidžia šias problemas vertinti sistemiskai ir pagrįsti poreikį taikyti pažangesnes priemones.

2.2. Techninės priežiūros modeliai ir efektyvumo vertinimas

Atsižvelgiant į tai, kad tiriamame ceche fiksuojamas didelis gedimų skaičius ir ilgas prastovų laikas, būtina taikyti struktūruotą priežiūros modelį. Mokslinėje literatūroje tam dažniausiai siūlomi įvairūs priežiūros metodai, kurių tikslas – sumažinti gamybos įrenginių prastovų trukmę ir prailginti įrangos darbo laiką tarp gedimų. Vieni populiariausių metodų – visuotinė produktyvioji priežiūra (TPM), patikimumu grįsta priežiūra (RCM) bei rizika paremta priežiūra (RBM). TPM orientuojasi į šešių pagrindinių nuostolių – gedimų, smulkių sustojimų, greičio mažėjimo, broko ir kitų problemų – eliminavimą, taip tiesiogiai mažinant vidutinį remonto laiką. Tuo tarpu RCM metodika leidžia identifikuoti gedimų režimus ir parinkti tinkamiausias prevencines priemones pagal riziką, o RBM modeliai padeda priežiūrą planuoti remiantis tikimybėmis ir galimų pasekmių rimtumu. Kaip pažymi Lundgren ir kt., šie metodai teoriškai sukuria pagrindą trumpesniai gedimų šalinimo laikui bei ilgesniai veikimo tarp gedimų laikotarpiui, tačiau jų praktinis taikymas pramonėje neretai ribotas dėl sudėtingo įgyvendinimo ir duomenų trūkumo [18].

Nepaisant skirtingų akcentų, visų šių metodų tikslas yra mažinti prastovas ir didinti įrangos patikimumą, o jų veiksmingumas praktikoje vertinamas remiantis pagrindiniais patikimumo rodikliais – vidutiniu laiku tarp gedimų ir vidutiniu remonto laiku. Rodrigues [1] pateikia šių rodiklių apskaičiavimo pavyzdžius. Vidutinis laikas tarp gedimų (MTBF) nustatomas padalijus bendrą įrenginio veikimo laiką iš per tą laikotarpį užfiksuotų gedimų skaičiaus:

$$MTBF = \frac{\text{Bendras veikimo laikas}}{\text{Gedimų skaičius}}. \quad (1)$$

Tarkime, įranga, kurios bendras veikimo laikas sudaro 7200 valandų, o per tą laiką įvyksta 5 gedimai. Tokiu atveju MTBF bus $7200 / 5 = 1440$ valandų – tai reiškia, kad vidutiniškai kas 1440 valandų pasitaiko vienas gedimas.

Vidutinis remonto laikas (MTTR) skaičiuojamas padalijus bendrą remontui sugaištą laiką iš atliktų remontų skaičiaus:

$$MTTR = \frac{\text{Bendras remonto laikas}}{\text{Remontų skaičius}}. \quad (2)$$

Jei 5 remontams sugaišta 15 valandų, MTTR reikšmė bus $15 / 5 = 3$ valandos. Tokie skaičiavimai leidžia įvertinti, kaip dažnai pasitaiko prastovų bei kiek laiko vidutiniškai užtrunka jų šalinimas [1].

Wendy Torell [19] pabrėžia, kad MTBF yra glaudžiai susijęs su patikimumu, o įrenginių prieinamumas labiau priklauso nuo to, kiek greitai sistema gali būti atkurta po gedimo. Sistemos pralaidumas skaičiuojamas pagal formulę:

$$\text{Pralaidumas} = \frac{MTBF}{(MTBF + MTTR)}. \quad (3)$$

Tai reiškia, kad kuo ilgesnis vidutinis laikas tarp gedimų ir kuo trumpesnis vidutinis remonto laikas, tuo didesnis yra sistemos pralaidumas, o prastovų rizika – mažesnė [5].

Wendy Torell straipsnyje [19] akcentuojama, kad techninio padalinio darbo efektyvumui itin svarbus tampa tinkamas rodiklių pasirinkimas ir jų nuoseklus taikymas. Autoriai pažymi, jog tradiciškai įmonės apsiriboja vien tik gamybos apimčių arba gedimų skaičiaus stebėseną, tačiau siekiant užtikrinti efektyvų priežiūros procesų valdymą, daug svarbesni tampa tokie parametrai kaip MTTR ir MTBF. Šie rodikliai leidžia objektyviai įvertinti ne tik įrangos patikimumą, bet ir techninio skyriaus veiksmų efektyvumą.

Tiriamoje įmonėje šie rodikliai vertinami naudojant „Alldevice“ sistemą, kurioje kaupiami visi gedimų registrai, darbų ataskaitos ir įrenginių veikimo duomenys. Sistema automatiškai fiksuoja įrenginio remonto trukmę, darbų pradžios bei pabaigos laikus ir leidžia remiantis šiais duomenimis apskaičiuoti vidutinį remonto laiką bei vidutinį laiką tarp gedimų. Tokiu būdu įmonė gali stebėti, kaip keičiasi įrenginių patikimumas skirtinguose cechuose, vertinti technikų darbo efektyvumą ir nustatyti, kurie įrenginiai sudaro daugiausiai prastovų. Šiame poskyryje aptarti priežiūros modeliai ir rodikliai toliau naudojami kaip teorinis pagrindas tiriamo cecho duomenų analizei trečiajame skyriuje.

2.3. MTTR ir MTBF mažinimo teoriniai būdai

Techninio padalinio efektyvumas tiesiogiai priklauso nuo prieš tai aptartų dviejų pagrindinių rodiklių – vidutinio remonto laiko ir vidutinio laiko tarp gedimų. Pirmasis parodo, kaip greitai įmonė gali reaguoti į sutrikimus ir atstatyti įrangos veikimą, o antrasis – kiek patikimai įrenginiai veikia be trikdžių. Šių rodiklių valdymas leidžia įmonei pereiti nuo reaktyvios priežiūros prie nuoseklaus, duomenimis pagrįsto gedimų sprendimo plano.

Vienas iš pagrindinių būdų mažinti MTTR – priežiūros procesų standartizavimas. Aiškiai apibrėžtos remonto procedūros, atsakomybės ir užduočių seka leidžia technikams reaguoti greitai ir užtikrintai. Lundgren ir kt. [18] pabrėžia, kad standartizuoti procesai sumažina subjektyvumo įtaką, todėl net skirtingi darbuotojai, susidūrę su tuo pačiu gedimu, pasiekia panašius rezultatus. Eisner [20] akcentuoja, kad centralizuota informacijos bazė – įrenginių istorijos, ankstesnių gedimų analizės ir

sprendimų istorija – leidžia technikams lengvai rasti panašius atvejus ir išvengti klaidų, kurios anksčiau lėmė prastovas. Tokia žinių bazė tampa praktiniu įrankiu MTTR mažinimui.

Kitas svarbus veiksnys – išmanioji gedimų analizė. Neumeier [21] nurodo, kad realaus laiko stebėjimas, paremtas sensorių duomenų surinkimu ir atvaizdavimu, leidžia operatyviai nustatyti galimus gedimus įrenginiuose, pateikti pirmines išvadas apie galimas priežastis ir suteikti technikams galimybę greičiau imtis tikslingų veiksmų. Tokios sistemos sumažina žmogiškųjų klaidų tikimybę ir leidžia sprendimus grįsti faktais, o ne intuicija. MTBF didinimas čia siejamas su prevencinės ir prognozuojamosios priežiūros taikymu – gedimai identifikuojami dar prieš jiems sukelti prastovas.

Torell ir Avelar [19] pažymi, kad patikimumo didinimas yra ne tik techninis, bet ir vadybinis uždavinys. Aiškiai apibrėžtos atsakomybės, periodinė diagnostika ir darbuotojų įtraukimas į kasdienį priežiūros procesą leidžia vienu metu mažinti MTTR ir ilginti MTBF. Tokia sistema veikia kaip nuolatinio tobulinimo ciklas: kiekvienas gedimas analizuojamas, priežastys dokumentuojamos, o gautos įžvalgos panaudojamos formuojant prevencines priemones ateičiai.

Benhanifia ir kt. [8] pabrėžia, kad moderniose įmonėse šie rodikliai vis dažniau valdomi pasitelkiant prognozuojamosios priežiūros modelius, integruotus su dirbtinio intelekto algoritmais. Tokios sistemos analizuoja istorinius duomenis, identifikuoja pasikartojančias gedimų priežastis ir pateikia rekomendacijas dėl dalių keitimo ar techninės priežiūros laiko. Dėl to priežiūros ištekliai sutelkiami į labiausiai rizikingas zonas, o ne paskirstomi tolygiai visai įrangai.

Ne mažiau svarbus aspektas – žmogiškasis faktorius. Techninio padalinio darbuotojų kompetencija, bendradarbiavimas ir žinių perdavimas lemia, kaip efektyviai taikomos techninės priemonės. Tyrėjai [12; 18; 20] pabrėžia, kad įmonės, kurios investuoja į nuolatinį personalo tobulinimą, diegia mokymų programas ir taiko struktūruotas gedimų analizės metodus, pasiekia stabilesnį procesų valdymą bei greitesnę reakciją į gedimus. Tokia žinių kaupimo ir dalijimosi sistema užtikrina, kad sukaupta patirtis taptų organizacijos dalimi, o ne priklausytų tik atskiriems darbuotojams.

Sisteminis požiūris, jungiantis procesų standartizavimą, duomenų analizę, dirbtinio intelekto sprendimus ir nuolatinį mokymąsi, leidžia vienu metu mažinti MTTR ir didinti MTBF. Tai lemia ne tik trumpesnes prastovas, bet ir didesnę įrenginių patikimumą, gamybos stabilumą bei ilgalaikį techninio padalinio tvarumą. Remiantis šiais praktiniais pavyzdžiais, kitame poskyryje detaliau analizuojamos konkrečios dirbtinio intelekto platformos ir jų tinkamumas techninio padalinio veiklai.

2.4. Dirbtinio intelekto sprendimai techninio padalinio veiklai

Remiantis 2.1–2.3 poskyriuose išanalizuotomis problemomis ir rodikliais, šiame poskyryje nagrinėjami inovatyvūs dirbtinio intelekto sprendimai, galintys padėti mažinti MTTR, didinti MTBF ir palengvinti technikų darbą. Šiuolaikinėje pramonėje vis svarbesnį vaidmenį įgauna dirbtinio intelekto technologijos, leidžiančios ne tik automatizuoti procesus, bet ir efektyviau valdyti organizacijos žinias. Techninės priežiūros padaliniuose, kuriuose kasdien sprendžiami įvairūs įrenginių gedimai, darbuotojai dažnai susiduria su iššūkiu – informacija apie ankstesnius gedimus, jų priežastis bei sprendimus būna išskaidyta po darbų aktus, gamintojo instrukcijas ar kolegų patirtį. Dėl to informacijos paieška tampa laikui imliu procesu, o sprendimų priėmimas priklauso nuo individualios darbuotojų patirties. Moksliniai tyrimai rodo, kad šias problemas galima spręsti pasitelkiant dirbtinio intelekto sistemas, kurios veikia kaip virtualūs padalinio asistentai – gebantys

analizuoti dokumentaciją, atpažinti pasikartojančius atvejus ir pateikti rekomendacijas pagal istorinius duomenis.

Rajat Khanda [22] savo tyrime pabrėžia, kad vienas pažangiausių būdų pagerinti sprendimų priėmimą yra „paieška paremta generacija“ (angl. Retrieval-Augmented Generation, RAG) metodų taikymas, kai dirbtinio intelekto modelis, užuot tik generavęs atsakymus, pirmiausia suranda ir analizuoja susijusius įmonės dokumentus. Tokia technologija leidžia gauti ne teorinius, o realiais įmonės duomenimis paremtus sprendimus. Tyrime nurodoma, kad RAG technologija padeda sukurti dinaminę ryšį tarp dokumentacijos, darbo ataskaitų ir remonto istorijų – taip sumažinamas laikas, reikalingas tinkamai informacijai surasti. Tokios sistemos veikia kaip žinių bazės, kurios automatiškai apibendrina esamą informaciją ir pritaiko ją konkrečiam atvejui. Pasak autoriaus, tokia prieiga ne tik pagreitina problemų sprendimą, bet ir padeda išvengti žmogiškųjų klaidų, kai technikai remiasi atmintimi, o ne faktais.

Billy Cassano [23] savo straipsnyje aprašo, kaip įmonė „Tractian“ pritaikė dirbtinį intelektą priežiūros veikloje automatizuodama žinių paiešką ir dokumentų analizę. Autorius pabrėžia, kad modernios CMMS sistemos, sujungtos su DI moduliais, gali atpažinti dėsningumus remonto įrašuose, išanalizuoti pasikartojančius gedimus ir automatiškai generuoti priežiūros rekomendacijas. Tokios sistemos leidžia technikams greitai pasiekti svarbiausią informaciją – nuo schemų iki veiksmų eigos, remiantis tuo, kas jau buvo atlikta anksčiau. Be to, dirbtinio intelekto algoritmai analizuoja ne tik tekstinius duomenis, bet ir vaizdus ar nuotraukas, todėl gali identifikuoti vizualinius defektus ir susieti juos su istorijoje buvusiais atvejais. Straipsnyje teigiama, kad įmonės, taikančios tokias sistemas, sumažino vidutinį gedimų šalinimo laiką ir padidino priežiūros tikslumą, nes sprendimai paremti visapuse informacija, o ne pavienėmis patirtimis.


Panaši dirbtinio intelekto logika taikoma ir kitose srityse. Sujit Kumaras [24] pabrėžia, kad dirbtinis intelektas gali būti naudojamas kaip „žinių asistentas“, gebantis palengvinti sprendimų priėmimą. Tyrime nagrinėjama, kaip DI analizuoja didelius kiekius istorinių įrašų, identifikuoja pasikartojančias situacijas ir teikia personalizuotas rekomendacijas darbuotojams realiu laiku. Nors tyrimas orientuotas į klientų aptarnavimą, jo principai visiškai pritaikomi ir techninės priežiūros kontekste: sistema, pasitelkdama natūralios kalbos apdorojimą, geba suprasti techniko pateiktą užklausą, palyginti ją su ankstesniais gedimais ir pasiūlyti efektyviausią veiksmų planą. Kumaras teigia, kad tokie modeliai gali sumažinti informacijos paieškos laiką iki 60 %, nes DI pats atrenka svarbiausius duomenis iš šimtų įrašų, pateikdamas tik tikslingą informaciją. Toks žmogaus ir DI bendradarbiavimo modelis padidina darbuotojų efektyvumą ir mažina informacijos perkrovą.

Dar vienas praktinis DI taikymo pavyzdys pateikiamas Joyce Birkinso straipsnyje [25], kuriame aprašomas „Neutron“ platformos naudojimas branduolinės energetikos ir naftos sektoriuose. Ši sistema sujungia vidinius įmonės duomenis, techninę dokumentaciją ir išorinius reglamentus į bendrą žinių bazę, prieinamą visiems darbuotojams. Pasitelkiant dirbtinį intelektą, sistema geba interpretuoti užklausas natūralia kalba ir pateikti išsamius atsakymus – nuo eksploatacijos procedūrų iki konkrečių remonto etapų. Tokiu būdu inžinieriai gali greitai priimti sprendimus, remdamiesi realia, patikrinta informacija, o ne asmenine patirtimi ar spėjimais. Birkinso teigimu, „Neutron“ modelis iš esmės keičia žinių prieigos kultūrą – kiekvienas darbuotojas gali veikti efektyviau, nes DI padeda sisteminti ir analizuoti informaciją, kuri anksčiau buvo išskaidyta tarp kelių šaltinių.

2.4.1. Dirbtinio intelekto įrankių pasirinkimas

Sparčiai augant dirbtinio intelekto taikymo galimybėms pramonėje, vis daugiau organizacijų ieško efektyvių platformų, galinčių ne tik automatizuoti veiklos procesus, bet ir padėti priimti sprendimus bei valdyti žinias. Atliekant šį tyrimą analizuojamos keturios pagrindinės dirbtinio intelekto sistemos – „ChatGPT (GPT-5)“, „IBM Watson Discovery“, „Microsoft Copilot“, „Azure AI“ ir „Humata AI“ / „ChatDOC“. Jos atspindi skirtingas technologines kryptis – nuo universalių kalbos modelių iki specializuotų dokumentų analizės įrankių, kuriuos galima pritaikyti techninės priežiūros procesų palaikymui.

Pasak Fabio Duarte [26], „ChatGPT“ išlieka populiariausia generatyvaus dirbtinio intelekto platforma pasaulyje – daugiau nei 700 milijonų aktyvių savaitinių naudotojų atlieka apie 2,5 milijardo užklausų per dieną. „Exploding Topics“ duomenimis, ši sistema užima apie 59 procentus visos dirbtinio intelekto rinkos, o tai patvirtina jos dominavimą tiek individualių, tiek verslo naudotojų tarpe. Matija Golubovič [27] pateikia 2025 m. birželio mėnesio duomenis (žr. 4 pav.), rodančius, kad „ChatGPT“ užima apie 60,6 procento generatyvaus dirbtinio intelekto pokalbių agentų rinkos, gerokai lenkdama artimiausius konkurentus – „Microsoft Copilot“ (14,3 procento) ir „Google Gemini“ (13,4 procento). Plati vartotojų bazė ir rinkos dalis rodo, kad „ChatGPT“ jau tapo universalia platforma, gebančia atlikti dokumentų analizę, kurti santraukas, versti tekstus bei generuoti rekomendacijas. Tyrimo kontekste ši sistema gali būti taikoma kaip natūralios kalbos apdorojimo priemonė, leidžianti greitai apibendrinti dokumentus ar pateikti siūlomus sprendimus pagal internete ar serveryje prieinamus duomenis, todėl laikytina stipria baze žinių paieškai ir sprendimų palaikymui.



4 pav. Generatyvaus dirbtinio intelekto pokalbių agentų rinkos dalys 2025 m. [26]

Anot Sarah Benchaita [28], „IBM Watson Discovery“ yra viena iš dažniausiai įmonėse taikomų dirbtinio intelekto sistemų, skirtų dokumentų analizei ir informacijos paieškai. IBM atliktas „Global AI Adoption Index“ tyrimas atskleidžia, kad 42 procentai įmonių pasaulyje jau yra įdiegusios dirbtinio intelekto sprendimus, o dar daug organizacijų aktyviai testuoja ar ruošiasi jų diegimui. Didelę šio augimo dalį lemia „Watson Discovery“ sistema, orientuota į įmonių dokumentų analizę ir informacijos paiešką. Ji geba atpažinti ryšius tarp įvairių tekstinių šaltinių – ataskaitų, instrukcijų ir kitų dokumentų – ir pateikti tikslus, kontekstinius atsakymus su citatomis. Toks funkcionalumas itin vertingas įmonėse, kur sprendimai dažnai grindžiami ankstesne patirtimi ar dokumentacija. Be to, „Watson“ išsiskiria aukštu duomenų saugumo lygiu, galimybe veikti lokaliajoje infrastruktūroje bei

integracija su pramoninėmis priežiūros valdymo sistemomis, pavyzdžiui, „IBM Maximo“. Nors įdiegimas yra sudėtingesnis ir brangesnis, ši sistema laikoma viena pažangiausių patikimos žinių bazės valdymo požiūriu.

Joaquin Fernandez [29] duomenimis, „Microsoft Copilot“ ir „Azure AI“ užima apie 13–14 procentų generatyvaus dirbtinio intelekto rinkos ir yra diegiami daugiau nei 60 procentų „Fortune 500“ įmonių. „Copilot“ sėkmę lemia glaudi integracija su „Microsoft 365“ ekosistema – „Word“, „Excel“, „Teams“ ir „Power BI“ – kuri leidžia automatizuoti rutinines užduotis, generuoti ataskaitas bei apibendrinti informaciją be papildomų įrankių. Techninės priežiūros kontekste ši sistema gali būti naudojama užduočių planavimui, gedimų analizės santraukų rengimui ar rekomendacijų pateikimui remiantis duomenimis iš „Azure“ duomenų bazių. Pagrindiniai privalumai – duomenų saugumas, centralizuota prieiga ir infrastruktūros patikimumas. Pagrindinis trūkumas – licencijavimo sąlygos ir priklausomybė nuo „Azure“ aplinkos, tačiau pramonėje ši sistema laikoma viena patikimiausių, kai siekiama efektyviai integruoti dirbtinį intelektą į organizacijos darbo procesus.

Remiantis Jorge Farah [30], tiek „Humata AI“, tiek „ChatDOC“ laikomi naujos kartos dirbtinio intelekto įrankiais, keičiančiais dokumentų analizės procesą. Šios platformos leidžia vartotojams įkelti įvairių formatų failus – PDF, DOCX ar TXT – ir užduoti klausimus natūralia kalba, o sistema pateikia atsakymus su tiksliais citatomis iš dokumento. „Humata AI“ pasižymi gebėjimu apdoroti didelius duomenų kiekius ir rengti išsamias santraukas, o „ChatDOC“ išsiskiria tiksliai PDF struktūrų atpažinimu bei nuorodomis į šaltinį, kas užtikrina atsakymų patikimumą. Tokie sprendimai tampa vis populiariausi įvairiose srityse – nuo švietimo ir mokslinių tyrimų iki verslo ir inžinerijos – nes leidžia efektyviau dirbti su informacija, sumažinti laiko sąnaudas ir pagerinti duomenų prieinamumą.

Šių platformų analizė sudaro pagrindą tolesniam jų tinkamumo vertinimui techninio padalinio žinių valdymui ir gedimų diagnostikai tiriamoje įmonėje.

2.4.2. Dirbtinio intelekto sistemų lyginamoji analizė

Šiame poskyryje lyginamos tyrimui pasirinktos dirbtinio intelekto sistemos, vertinant jų funkcines galimybes, integracijos su kitomis įmonės naudojamomis sistemomis galimybes ir pritaikomumą techninio padalinio veiklai. Pirmiausia trumpai apžvelgiamos atskiros platformos, o vėliau jų savybės sistemiskai palyginamos lentelėse 2–8, kuriose susisteminti svarbiausi organizacijai reikšmingi parametrai.

„ChatGPT“ – „OpenAI“ sukurta pažangi generatyviojo dirbtinio intelekto platforma, paremta GPT-5 architektūra. Ji geba analizuoti natūralią kalbą, generuoti tekstus, kurti santraukas, ieškoti ir apdoroti informaciją, taip pat interpretuoti vaizdinį turinį. Sistema supranta sudėtingas, kelių žingsnių užklausas, atpažįsta kontekstą ir pateikia logiškus, nuoseklius atsakymus, todėl plačiai taikoma švietimo, verslo, mokslo ir kūrybinėse srityse. Nuo 2024 m. pristatytos „ChatGPT Team“ ir „ChatGPT Enterprise“ versijos sudaro galimybes integruoti sistemą į organizacijų vidinę IT infrastruktūrą, užtikrinti duomenų konfidencialumą, komandinius pokalbius ir ilgalaikės atminties išsaugojimą. Šios funkcijos leidžia komandoms efektyviau bendradarbiauti, dalintis informacija ir kurti centralizuotas žinių bazines, kurios padeda priimti greitesnius ir duomenimis grįstus sprendimus. Platforma išsiskiria intuityvia vartotojo sąsaja, plačiomis integracijos galimybėmis bei nuolatiniu tobulinimu, todėl laikoma viena pažangiausių šiuolaikinių generatyvaus dirbtinio intelekto sistemų. Dėl universalumo ir gebėjimo prisitaikyti prie įvairių užduočių „ChatGPT“ tampa tinkama baze sprendimams, skirtiems informacijai kurti, valdyti ir analizuoti techninio padalinio veikloje [31–33].

2 lentelė. „ChatGPT“ funkcijos ir savybės [31-33]

Funkcijos / savybės	Sistemos apibūdinimas
Pagrindinė paskirtis	Universalus pokalbių ir analizės įrankis, tinkamas įvairioms užduotims.
Natūralios kalbos supratimas	Labai aukštas – supranta kontekstą, gali vesti dialogą ir paaiškinti sudėtingas temas.
Dokumentų analizė (PDF, DOCX)	Gali skaityti įkeltus dokumentus, apibendrinti ir paaiškinti turinį.
Informacijos pateikimas	Išsamiai paaiškina, pagrindžia ir gali pateikti apibendrintą atsakymą.
Integracija su CMMS / įmonės duomenų bazėmis	Galima per OpenAI API – reikia papildomo sujungimo.
Automatinės santraukos ir ataskaitos	Gali automatiškai apibendrinti ilgus tekstus, generuoti ataskaitas ir pateikti išvadas paprasta kalba (pvz., projekto santrauka, gedimų analizės ataskaita).
Rekomendacijų generavimas pagal istorinius duomenis	Galima – remiasi kontekstu ir įrašyta informacija.
Naudojimas	Labai patogus – veikia kaip pokalbis.
Pritaikymas lietuvių kalbai	Puikus – puikiai supranta ir rašo lietuviškai.
Duomenų saugumas ir prieigos kontrolė	Vidutinis – duomenys apdorojami „OpenAI“ debesijoje, privatumo lygis priklauso nuo plano (Team/Enterprise turi papildomą šifravimą ir privatumo garantijas).
Veikimas be interneto / lokaliai	Neveikia be interneto.
Reikalaujama infrastruktūra / licencijos	Reikia OpenAI paskyros arba „Team“ plano.
Komandinis darbas	Galimas „Team“ planuose.
Kaina	29 Eur/mėn. (Team planas, metinė) arba 34 Eur/mėn. (mėnesinė) – vienam naudotojui
Mokymosi / adaptacijos galimybės	Galima pritaikyti modelį konkrečiai temai per API.
Atsakymų tikslumas	Aukštas – pateikia išsamius ir logiškus atsakymus.
Atminties funkcija (tarp sesijų)	Palaikoma

„IBM Watson Discovery“ – tai pažangi dirbtinio intelekto platforma, skirta dokumentų analizei ir duomenų paieškai, veikianti pagal natūralios kalbos apdorojimo ir mašininio mokymosi principus. Sistema geba automatiškai išgauti reikšmingą informaciją iš įvairių šaltinių – tekstinių dokumentų, el. laiškų, duomenų bazių ir ataskaitų – bei pateikti tikslus, kontekstinius atsakymus. Viena iš esminių sistemos funkcijų yra išmanusis dokumentų supratimas, leidžiantis vizualiai mokyti modelį atpažinti dokumentų struktūras ir teksto elementus. Tokiu būdu sistema gali tiksliai identifikuoti svarbiausius duomenis ir jų tarpusavio priklausomybes net ir labai dideliuose informacijos rinkiniuose. „Watson Discovery“ glaudžiai integruota su „watsonx.ai“ ekosistema, kuri suteikia galimybę naudoti išplėstinius analizės modelius, duomenų vizualizacijos įrankius ir individualiai pritaikytas DI programas. Svarbus sistemos privalumas – aukštas duomenų saugumo lygis: taikomas griežtas prieigos valdymas, duomenų šifravimas ir galimybė sprendimą diegti lokaliuose serveriuose. Dėl šių savybių „IBM Watson Discovery“ plačiai taikoma įvairiose srityse, kur būtinas giluminis tekstinių duomenų supratimas, efektyvus informacijos apdorojimas ir automatizuota analizė, taip pat ir techninės priežiūros procesų dokumentacijos bei žinių bazės valdymui [34–36].

3 lentelė. „IBM Watson Discovery“ funkcijos ir savybės [34-36]

Funkcijos / savybės	Sistemos apibūdinimas
Pagrindinė paskirtis	Duomenų ir dokumentų analizės sistema, skirta išvalgoms iš tekstinių šaltinių.
Natūralios kalbos supratimas	Aukštas – puikiai analizuoja prasmę ir ištraukia esmines išvalgas.
Dokumentų analizė (PDF, DOCX)	Naudoja „Smart Document Understanding“, todėl atpažįsta lenteles, grafikus, antraštes – analizuoja kaip žmogus.
Informacijos pateikimas	Pateikia struktūruotas išvadas iš dokumentų, pabrėžia šaltinius.
Integracija su CMMS / įmonės duomenų bazėmis	Turi tiesioginę integraciją su vietinėmis įmonės duomenų bazėmis
Automatinės santraukos ir ataskaitos	Kuria tiksliai santraukas iš didelių dokumentų rinkinių, atpažįsta pagrindines temas ir raktinius duomenis; gali generuoti struktūruotas ataskaitas iš kelių šaltinių.
Rekomendacijų generavimas pagal istorinius duomenis	Aukštas lygis – analizuoja istorinius įrašus ir prognozuoja tendencijas.
Naudojimas	Sudėtingesnis – reikia suprasti sistemos logiką.
Pritaikymas lietuvių kalbai	Ribotas – daugiausia anglų kalba.
Duomenų saugumas ir prieigos kontrolė	Aukštas – duomenys gali būti saugomi tik įmonės serveryje arba „IBM Cloud“ aplinkoje, palaikomas pilnas prieigos valdymas.
Veikimas be interneto / lokaliai	Gali veikti vietiniame serveryje.
Reikalaujama infrastruktūra / licencijos	Reikalinga „IBM Cloud“ ar įmonės licencija.
Komandinis darbas	Palaikomas – keli naudotojai gali dirbti kartu.
Kaina	Nuo 429 Eur/mėn. už 10 000 dokumentų ir 10 000 užklausų; papildomai 42,9 Eur už 1 000 dokumentų ir 17,1 Eur už 1 000 užklausų
Mokymosi / adaptacijos galimybės	Galima apmokyti „Watsonx“ modelius pagal įmonės duomenis.
Atsakymų tikslumas	Aukštas – pagrįstas duomenų analize.
Atminties funkcija (tarp sesijų)	Palaikoma

„Microsoft Copilot“ – tai pažangus dirbtinio intelekto įrankis, integruotas į „Microsoft 365“ ekosistemą ir skirtas padėti vartotojams generuoti tekstus, kurti santraukas, analizuoti duomenis ir automatizuoti įvairias užduotis „Word“, „Excel“, „PowerPoint“, „Teams“ ir „Power BI“ programose. Sistema veikia pasitelkdama „OpenAI“ GPT-4 modelį, tačiau funkcionuoja per „Microsoft Azure“ infrastruktūrą, kuri užtikrina aukštą duomenų saugumo lygį, prieigos kontrolę ir informacijos atskyrimą nuo viešųjų modelių. „Copilot“ geba apdoroti didelius duomenų kiekius, rengti analitines ataskaitas, apibendrinti sudėtingus dokumentus ar el. laiškų srautus ir pateikti naudotojui aiškias, duomenimis grįstas išvalgas. Įrankis integruojamas su verslo duomenų bazėmis, todėl gali teikti personalizuotas rekomendacijas bei automatizuoti darbo eigą pagal konkrečius organizacijos poreikius. Dėl glaudaus ryšio su plačiai naudojamomis „Microsoft“ programomis, išplėstinių duomenų analizės galimybių ir centralizuoto informacijos valdymo „Copilot“ laikomas viena pažangiausių platformų, padedančių didinti darbo našumą, mažinti pasikartojančių užduočių apimtį ir gerinti informacijos valdymo procesus [37–39].

4 lentelė. „Microsoft Copilot“ funkcijos ir savybės [37-39]

Funkcijos / savybės	Sistemos apibūdinimas
Pagrindinė paskirtis	Pagalbininkas „Microsoft 365“ ekosistemoje – rašymui, analizėms, skaičiavimams.
Natūralios kalbos supratimas	Aukštas – gerai interpretuoja MS dokumentų turinį.
Dokumentų analizė (PDF, DOCX)	Skaito Word, Excel, PowerPoint dokumentus MS 365 aplinkoje.
Informacijos pateikimas	Integruotas į Word/Excel – pateikia atsakymus šalia darbo dokumento.
Integracija su CMMS / įmonės duomenų bazėmis	Pilnai integruotas į „Microsoft 365“ sistemas.
Automatinės santraukos ir ataskaitos	Automatiškai apibendrina „Word“, „Excel“ ar „Teams“ turinį; sukuria santraukas susitikimų, el. laiškų ar dokumentų pagrindu.
Rekomendacijų generavimas pagal istorinius duomenis	Gali generuoti pasiūlymus pagal įmonės duomenis.
Naudojimas	Paprastas naudotojams.
Pritaikymas lietuvių kalbai	Gali dirbti lietuviškai per GPT-4.
Duomenų saugumas ir prieigos kontrolė	Aukštas – integruotas su „Microsoft Entra ID“ (buv. Azure AD), suteikia tapatybės ir teisių valdymą „MS 365“ ekosistemoje.
Veikimas be interneto / lokaliai	Dalinai – kai kurie duomenys prieinami be interneto.
Reikalaujama infrastruktūra / licencijos	Įtraukta į „Microsoft 365 E3/E5“.
Komandinis darbas	Palaikomas visose MS 365 paskyrose.
Kaina	25,7 Eur/mėn. vienam naudotojui (M365 Copilot) / 30,9 Eur su „Business Basic“ planu
Mokymosi / adaptacijos galimybės	Ribota – mokosi iš vartotojo rašymo stiliaus.
Atsakymų tikslumas	Aukštas – tikslūs atsakymai iš dokumentų.
Atminties funkcija (tarp sesijų)	Tam tikrais atvejais

„Azure AI“ – tai „Microsoft“ sukurta dirbtinio intelekto platforma, apimanti kelis tarpusavyje susijusius sprendimus: „Azure Cognitive Services“, „Azure Machine Learning“ ir „Azure Document Intelligence“. Ši ekosistema sukurta organizacijoms, siekiančioms integruoti dirbtinio intelekto technologijas į duomenų valdymo sistemas ir automatizuoti tekstų, garso, vaizdų bei dokumentų apdorojimo procesus. Platforma veikia pagal „Paieška paremta generacija“ (RAG) principus, kurie leidžia sistemai jungtis prie įmonės vidinių duomenų šaltinių ir pateikti atsakymus, paremtus realiais, nuolat atnaujinamais duomenimis, o ne vien iš anksto išmokta informacija. Toks veikimo būdas užtikrina aukštą atsakymų tikslumą, kontekstinį atitikimą ir didesnę pritaikomumą konkrečioms organizacijos užklausoms. „Azure AI“ suteikia galimybę kurti individualiai pritaikytus modelius, mokyti juos pagal konkrečius įmonės poreikius bei centralizuotai valdyti visą dirbtinio intelekto infrastruktūrą. Dėl lankstumo, patikimo duomenų saugumo ir plačių integracijos galimybių ši platforma plačiai taikoma gamybos, finansų, sveikatos apsaugos ir kituose skyriuose, kur reikalingi patikimi, didelius duomenų kiekius apdorojantys DI sprendimai [40–41].

5 lentelė. „Azure AI“ funkcijos ir savybės [40-41]

Funkcijos / savybės	Sistemos apibūdinimas
Pagrindinė paskirtis	Platforma AI sprendimams kurti ir diegti įmonėse.
Natūralios kalbos supratimas	Aukštas – veikia su NLP moduliais.
Dokumentų analizė (PDF, DOCX)	Naudoja „Document Intelligence“ modulį – analizuoja dokumentų struktūrą.
Informacijos pateikimas	Pateikia duomenų santraukas per API ar vizualizacijas.
Integracija su CMMS / įmonės duomenų bazėmis	Lanksti integracija su „Azure“ duomenų bazėmis.
Automatinės santraukos ir ataskaitos	Naudoja „Text Analytics“ ir „Language Service“ modulius ataskaitoms bei suvestinėms generuoti iš dokumentų ar duomenų bazių.
Rekomendacijų generavimas pagal istorinius duomenis	Galima – per mašininio mokymosi modelius.
Naudojimas	Vidutinio sudėtingumo – reikalauja programinės patirties.
Pritaikymas lietuvių kalbai	Palaiko lietuvių kalbą, bet ne visur tiksliai.
Duomenų saugumas ir prieigos kontrolė	Aukštas – taikoma „Azure Active Directory“, „RBAC“ prieigos kontrolė, šifruojamas duomenų perdavimas.
Veikimas be interneto / lokaliai	Gali veikti lokaliai „Azure“ serveryje.
Reikalaujama infrastruktūra / licencijos	Reikia „Azure“ prenumeratos.
Komandinis darbas	Palaikomas.
Kaina	„Read“ modelis 1,29 Eur už 1 000 psl.; >1 mln. psl. 0,51 Eur už 1 000 psl.; „Query Fields“ 8,6 Eur už 1 000 psl.
Mokymosi / adaptacijos galimybės	Galima kurti ir apmokyti modelius.
Atsakymų tikslumas	priklauso nuo sukonfigūravimo
Atminties funkcija (tarp sesijų)	Tam tikrais atvejais

„Humata AI“ – tai pažangi dirbtinio intelekto sistema, skirta dokumentų analizei ir informacijos paieškai. Ji leidžia vartotojams įkelti PDF, DOCX ir kitų formatų failus ir gauti kontekstinius atsakymus, pagrįstus konkreto dokumento turiniu. Įrankis naudoja semantinės paieškos ir natūralios kalbos apdorojimo technologijas, kurios leidžia identifikuoti svarbiausias teksto dalis, pateikti tikslias citatas ir suformuluoti atsakymus į naudotojo klausimus. Sistema veikia kaip virtualus asistentas, gebantis greitai apdoroti didelius informacijos kiekius, analizuoti tekstų struktūrą ir sisteminti duomenis pagal užklausos kontekstą. „Humata AI“ plačiai taikoma analizuojant techninius dokumentus, mokslines ataskaitas, teisės aktus ir verslo sutartis, kai būtina greitai surasti konkrečius faktus, terminus ar argumentus. Dėl paprasto naudojimo, efektyvaus atsakymų generavimo ir gebėjimo dirbti su įvairių formatų dokumentais ši sistema laikoma patogia priemone, skirta informacijos paieškai ir turinio analizės automatizavimui [42–43].

6 lentelė. „Humata AI „funkcijos ir savybės [42-43]

Funkcijos / savybės	Sistemos apibūdinimas
Pagrindinė paskirtis	Paprastas įrankis greitai PDF analizei ir klausimų–atsakymų paieškai.
Natūralios kalbos supratimas	Vidutinis – tinkamas paprastiems klausimams.
Dokumentų analizė (PDF, DOCX)	Skaito PDF ir leidžia užduoti klausimus apie tekstą.
Informacijos pateikimas	Parodo atsakymus iš konkretaus PDF puslapio.
Integracija su CMMS / įmonės duomenų bazėmis	Neturi integracijos – tik PDF analizė.
Automatinės santraukos ir ataskaitos	Sukuria trumpas PDF ar DOCX dokumentų santraukas; nurodo pagrindines pastraipas ir ištraukas, tinka greitai peržiūrai.
Rekomendacijų generavimas pagal istorinius duomenis	Nepalaikoma.
Naudojimas	Labai paprastas – tinkamas pradedantiesiems.
Pritaikymas lietuvių kalbai	Ribotas – dažnai netikslūs vertimai.
Duomenų saugumas ir prieigos kontrolė	Žemas – duomenys laikomi debesyje be išplėstinės kontrolės; jautri informacija gali būti rizikinga.
Veikimas be interneto / lokaliai	Neveikia.
Reikalaujama infrastruktūra / licencijos	Nemokama / mokama versija.
Komandinis darbas	Dalinai palaikomas.
Kaina	„Student“ plano 1,7 Eur/mėn.; „Expert“ plano 8,6 Eur/mėn.; „Team“ plano 42 Eur/mėn. vienam naudotoju
Mokymosi / adaptacijos galimybės	Nėra.
Atsakymų tikslumas	Vidutinis – priklauso nuo PDF kokybės.
Atminties funkcija (tarp sesijų)	Nėra.

„ChatDOC“ – tai dirbtinio intelekto pagrindu veikianti dokumentų analizės sistema, leidžianti vartotojams natūralia kalba užduoti klausimus PDF ar Word formato dokumentams ir gauti aiškius, kontekstinius atsakymus. Sistema geba išgauti pagrindines įžvalgas, pateikti tikslias citatas iš šaltinio ir automatiškai generuoti santraukas, apibendrinančias svarbiausią dokumento turinį. Viena iš išskirtinių „ChatDOC“ savybių – galimybė dirbti komandiniu režimu, kai keli vartotojai vienu metu gali analizuoti tuos pačius dokumentus, dalintis įžvalgomis ir kurti bendras ataskaitas. Ši funkcija ypač naudinga tyrimų, inžinerijos ir gamybos srityse, kur informacijos kiekis didelis, o bendradarbiavimo poreikis nuolatinis. Sistema veikia debesijos principu, todėl yra prieinama iš bet kurios vietos, o jos pateikiami atsakymai grindžiami tiek dokumentų turiniu, tiek modelio generuojamais kontekstiniais paaiškinimais. Dėl patogaus naudojimo, greito atsakymų pateikimo ir integruotų bendradarbiavimo funkcijų „ChatDOC“ plačiai taikoma projektuose, kuriuose reikalinga efektyvi dokumentų analizė ir centralizuota informacijos prieiga [44–46].

7 lentelė. „ChatDOC“ funkcijos ir savybės [44-46]

Funkcijos / savybės	Sistemos apibūdinimas
Pagrindinė paskirtis	Dokumentų skaitymo ir klausimų–atsakymų sistema su ribotu kontekstu.
Natūralios kalbos supratimas	Vidutinis – supranta paprastus klausimus apie dokumentą.
Dokumentų analizė (PDF, DOCX)	Skaity PDF ir Word failus, atsako į klausimus tiesiogiai iš turinio.
Informacijos pateikimas	Atsako konkrečiai, bet be platesnio konteksto.
Integracija su CMMS / įmonės duomenų bazėmis	Neturi integracijos – tik dokumentų skaitymas.
Automatinės santraukos ir ataskaitos	Sukuria sutrumpintą turinį su klausimų–atsakymų santrauka; gali pateikti pagrindines dokumento dalis, tačiau be išsamaus paaiškinimo.
Rekomendacijų generavimas pagal istorinius duomenis	Nepalaikoma.
Naudojimas	Labai paprastas – intuityvus.
Pritaikymas lietuvių kalbai	Ribotas – kartais praleidžia žodžių reikšmes.
Duomenų saugumas ir prieigos kontrolė	Žemas – dokumentai saugomi debesijos serveriuose, nėra prieigos valdymo ar vietinio saugojimo galimybės.
Veikimas be interneto / lokaliai	Neveikia.
Reikalaujama infrastruktūra / licencijos	Nemokama / mokama versija
Komandinis darbas	Palaikomas.
Kaina	Pro planas 7,7 Eur už 30 d. arba 77 Eur metams
Mokymosi / adaptacijos galimybės	Nėra.
Atsakymų tikslumas	Vidutinis – dažnai apsiriboja trumpais atsakymais.
Atminties funkcija (tarp sesijų)	Nėra

2.4.2.1. Dirbtinio intelekto sistemų vertinimas

Remiantis 2.4.1 poskyryje atlikta dirbtinio intelekto sistemų analize, sudaryta vertinimo sistema, paremta balų skale, leidžiančia įvertinti kiekvienos platformos tinkamumą pagal pasirinktus kriterijus (žr. 8 lentelę). Vertinimo reikšmės apibūdinamos taip: 1 – tinkama, visiškai atitinka vertinamą kriterijų; 0,5 – iš dalies atitinka arba yra vidutiniškai tinkama; 0 – netinkama, neatitinka vertinamo kriterijaus. Kadangi šiame darbe siekiama pasirinkti konkrečiam tyrimui tinkamiausią sistemą, vertinime ypatingas dėmesys skiriamas duomenų patikimumui ir saugumui, diegimo ir naudojimo kaštams bei galimybei lanksčiai pritaikyti sprendimą techninio padalinio veiklos poreikiams. Tokia vertinimo sistema suteikia galimybę kiekybiškai palyginti skirtingų platformų savybes ir pagrįstai nustatyti, kuri iš jų geriausiai tinka šiam tyrimui atlikti. Be to, vienoda balų skalė padeda sumažinti subjektyvaus vertinimo įtaką ir užtikrina, kad visos sistemos būtų vertinamos pagal tuos pačius, iš anksto apibrėžtus kriterijus.

8 lentelė. Dirbtinio intelekto sistemų vertinimas

Funkcijos/savybės	„ChatGPT“	„IBM Watson Discovery“	„Microsoft Copilot“	„Azure AI“	„Humata AI“	„ChatDOC“
Pagrindinė paskirtis	1	1	0,5	1	1	1
Natūralios kalbos supratimas	1	1	0,5	1	1	1
Dokumentų analizė (PDF, DOCX)	1	1	0,5	1	1	1
Informacijos pateikimas	1	1	1	1	1	1
Integracija su CMMS / įmonės duomenų bazėmis	1	1	1	1	0	0
Automatinės santraukos ir ataskaitos	1	1	1	1	1	0,5
Rekomendacijų generavimas pagal istorinius duomenis	1	1	1	1	0	0
Naudojimas	1	0,5	1	0,5	1	1
Pritaikymas lietuvių kalbai	1	0,5	0,5	0,5	0,5	0,5
Duomenų saugumas ir prieigos kontrolė	1	1	1	1	0	0
Veikimas be interneto / lokaliai	0	1	1	1	0	0
Reikalaujama infrastruktūra / licencijos	0	0	0	0	1	1
Komandinis darbas	1	1	1	1	0,5	0,5
Kaina	0,5	0	0,5	0,5	1	1
Mokymosi / adaptacijos galimybės	1	1	0,5	1	0	0
Atsakymų tikslumas	1	1	1	0,5	0	0
Atminties funkcija (tarp sesijų)	1	1	0,5	0,5	0	0
Vertinimo balas	14,5	14	12,5	13,5	9	8,5

Remiantis atliktu dirbtinio intelekto priemonių vertinimu, daugiausia balų surinko „ChatGPT“ sistema, todėl tolesniame tyrime ji pasirenkama kaip pagrindinė naudojama priemonė. Kadangi ši sistema dirbs su vidiniais įmonės duomenimis, būtina įvertinti ir jos naudojimo saugumo bei teisinio reguliavimo aspektus, kurie aptariami tolesniame poskyryje.

2.5. Saugumas naudojant AI

Kadangi pasirenkama sistema dirbs su įmonės techninės priežiūros duomenimis, būtina įvertinti jos naudojimo saugumo ir teisinio reguliavimo aspektus.

Pastaraisiais metais dirbtinio intelekto sistemų diegimas įmonėse tapo itin spartus, tačiau kartu išaugo ir poreikis užtikrinti šių technologijų saugų bei atsakingą naudojimą. Kaip nurodo Europos Komisijos „Dirbtinio intelekto akto“ (Artificial Intelligence Act) reglamentas [47], pats dirbtinis intelektas savaime nėra pavojingas – riziką lemia tai, kaip ir kokiam kontekste sistema naudojama. Šiuo principu grindžiamas visos Europos Sąjungos požiūris į dirbtinio intelekto saugumą: vietoje griežto draudimo konkrečioms technologijoms nustatomi naudojimo, priežiūros ir atsakomybės reikalavimai. Pagal Europos Komisijos dokumentą dirbtinio intelekto sistemos klasifikuojamos pagal rizikos lygį – nuo minimalios iki nepriimtinos rizikos. Šis klasifikavimas padeda ne įvertinti, kuri platforma „pavojinga“, o nustatyti, kokios saugos priemonės turi būti taikomos jos naudojimui. Aukštos rizikos sistemoms (pavyzdžiui, naudojamoms sveikatos, švietimo ar įdarbinimo srityse) privaloma įdiegti aiškią rizikos valdymo procedūrą, užtikrinti duomenų kokybę, žmogiškąją priežiūrą ir veiklos atsekamumą. Taip siekiama, kad sprendimai, priimami naudojant dirbtinį intelektą, būtų skaidrūs, tikslūs ir nepažeistų žmogaus teisių.

Tą pačią mintį pabrėžia ir Nacionalinio kibernetinio saugumo centro dokumentas „Generatyvinio dirbtinio intelekto organizacijoje naudojimo gairės“ [48]. Nacionalinis kibernetinio saugumo centras akcentuoja, kad pagrindinė grėsmė nėra pačios dirbtinio intelekto platformos, o neteisingas ar neatsakingas jų naudojimas. Įmonės, naudodamos tokias sistemas kaip „ChatGPT“, „Microsoft Copilot“ ar kitas dirbtinio intelekto priemones, turi užtikrinti, kad darbuotojai neįkeltų konfidencialių, asmens ar komercinių duomenų. Dokumente teigiama, jog būtina turėti aiškią dirbtinio intelekto naudojimo politiką, kurioje apibrėžtos atsakomybės, leidžiamos užklausos ir informacijos valdymo taisyklės. Be to, rekomenduojama naudoti tik patikimų tiekėjų platformas, kurios atitinka Europos Sąjungos duomenų apsaugos ir saugumo standartus, pavyzdžiui, leidžia išjungti duomenų panaudojimą modelių mokymui arba užtikrina lokalų duomenų saugojimą [48].

Tiek Europos Sąjungos, tiek Nacionalinio kibernetinio saugumo centro dokumentai pabrėžia, kad saugumas dirbtinio intelekto srityje nėra pačios technologijos savybė, o jos taikymo rezultatas. Net ir pažangiausia sistema gali tapti rizikingu įrankiu, jei ja naudojamas neatsakingai – dalijamasi netinkama informacija, nesilaikoma prieigos kontrolės ar neįvertinamos klaidų pasekmės. Todėl įmonėms rekomenduojama įdiegti rizikos vertinimo ir incidentų valdymo procesus, reguliariai atnaujinti programinę įrangą, stebėti dirbtinio intelekto veikimą ir mokyti darbuotojus, kaip atpažinti bei išvengti pavojingų situacijų. Šie reikalavimai tampa ypač aktualūs renkantis sistemą, kuri bus naudojama techninės priežiūros duomenų analizei tiriamoje įmonėje.

2.6. Skyriaus apibendrinimas

Antrajame skyriuje suformuotas teorinis pagrindas, kuriuo remiantis vertinamas dirbtinio intelekto taikymas techninio padalinio veikloje. Parodyta, kaip priežiūros modeliai ir patikimumo rodikliai – MTTR ir MTBF – susiję su procesų standartizavimu, informacijos prieinamumu ir naudojamų įrankių integracija. Pabrėžta, kad tinkamai organizuota veikla ir duomenimis grįsti sprendimai leidžia greičiau reaguoti į sutrikimus, mažinti prastovas ir didinti įrenginių patikimumą. Taip pat apibendrinta esama tiriamo techninio padalinio situacija: ceche fiksuojamas didelis gedimų skaičius ir prastovų trukmė, o „Alldevice“ sistema, nors ir kaupia detalius gedimų duomenis, daugiausia

naudojama operatyviam darbų administravimui, bet ne nuosekliai MTTR ir MTBF analizei. Išanalizavus skirtingas DI platformas („ChatGPT“, „IBM Watson Discovery“, „Microsoft Copilot“, „Azure AI“, „Humata AI“, „ChatDOC“), nustatyta, kad jos gali veikti kaip pagalbiniai žinių ir dokumentų analizės įrankiai, padedantys technikams greičiau surasti informaciją ir priimti pagrįstus sprendimus, tačiau jų taikymas turi atitikti ES ir nacionalinius duomenų saugumo bei atsakingo DI naudojimo reikalavimus. Lyginamoji analizė parodė, kad pagal funkcionalumo ir naudojimo paprastumo kriterijus geriausią rezultatą surinko „ChatGPT“ sistema, todėl trečiajame skyriuje praktiškai vertinamas būtent šios sistemos taikymas tiriamo cecho duomenų analizei.

3. Dirbtinio intelekto taikymo tyrimas gamyklos X techniniame padalinyje

Šiame skyriuje pristatomas gamybos įmonės X techninio padalinio tyrimas, kuriuo praktiškai vertinamos išmaniųjų technologijų taikymo galimybės įrenginių priežiūrai. Šioje dalyje įgyvendinami antrasis, trečiasis ir ketvirtasis projekto uždaviniai. Tyrimas vykdomas realioje gamybos įmonėje, todėl leidžia įvertinti ne tik teorinį dirbtinio intelekto potencialą, bet ir praktines taikymo ribas, darbuotojų sąveiką su nauju įrankiu bei jo įtaką kasdieniams priežiūros procesams.

Empirinėje dalyje analizuojamas vieno X gamyklos cecho darbas. Šiame ceche gaminami pramoniniai kišeniniai oro filtrai, skirti vėdinimo ir kondicionavimo sistemoms. Analizėje vertinamas įrenginių gedimų dažnis, vidutinis gedimų šalinimo laikas (MTTR), laikas tarp gedimų (MTBF) ir prastovų trukmė laikotarpiu prieš dirbtinio intelekto priemonių diegimą ir po jo. Tyrime taikomas specialiai šiam projektui sukurtas „GPT“ modeliu pagrįstas pagalbinis įrankis, integruotas į techninio padalinio darbo praktiką ir papildytas įrenginių dokumentais bei istorinių gedimų duomenimis. Pirmiausia aprašomas tiriamojo cecho ir techninio padalinio kontekstas, tuomet detalizuojama tyrimo metodika ir ribotumai, pristatoma dirbtinio intelekto sistemos diegimo eiga, pateikiami kiekybiniai tyrimo rezultatai ir jų ekonominis vertinimas, o skyriaus pabaigoje formuluojamos rekomendacijos dėl tolesnės dirbtinio intelekto integracijos į techninio padalinio veiklą.

3.1. Dirbtinio intelekto taikymo tyrimo metodika techninio padalinio veikloje

Šiame poskyryje aprašomas gamybos įmonės X techninio padalinio tyrimo kontekstas ir tyrimo logika, kuria remiantis vertinamos dirbtinio intelekto taikymo galimybės įrenginių gedimų diagnostikos ir šalinimo procesuose bei jo įtaka techninio padalinio veiklos efektyvumui. Įmonėje eksploatuojama apie 390 įvairių gamybos ir pagalbinių įrenginių, o tiriamame ceche – 135 gamybos įrenginiai, kurių priežiūrą užtikrina du technikai, dirbantys skirtingose pamainose. Šis cechasis yra vienas iš trijų, už kuriuos atsakingi tie patys techninio padalinio darbuotojai, todėl jų darbo krūvis nuolat didelis ir reikalaujantis greito reagavimo į sutrikimus. Tiriamasis cechasis pasirinktas kaip pagrindinis tyrimo objektas dėl reikšmingai didelio gedimų kiekio ir intensyvios įrangos eksploatacijos: 2025 metų rugpjūčio mėnesį buvo užregistruoti 86 gedimai, rugsėjo mėnesį gedimų skaičius išaugo iki 102, o per tą patį laikotarpį cecho gamybos apimtys didėjo nuo 23 276 gaminių rugpjūčio mėnesį iki 31 618 gaminių rugsėjo mėnesį ir 37 091 gaminių spalio mėnesį. Tokie duomenys rodo aukštą įrenginių apkrovą ir stabiliai didelį techninio padalinio darbo krūvį, todėl šis cechasis suteikia tinkamas sąlygas vertinti dirbtinio intelekto poveikį remonto efektyvumui ir gedimų diagnostikos procesui didėjant gamybos apimtims.

Tyrimas priskirtinas vieno atvejo analizei, kai vienoje organizacijoje detalčiai nagrinėjama konkreiti naujos technologijos taikymo situacija ir jos poveikis darbuotojų darbui. Tyrimo apimtį sudaro tiriamo cecho įrenginių gedimų duomenys, techninio padalinio veiklos informacija, įrenginių dokumentacija ir eksperimentinis dirbtinio intelekto sistemos taikymas realiomis darbo sąlygomis. Empirinėje dalyje analizuojamas vieno cecho darbas, vertinant kiekybinius techninės priežiūros rodiklius ir jų pokyčius, kai technikai pradeda naudoti dirbtinio intelekto įrankį. Siekiant įvertinti dirbtinio intelekto taikymo poveikį techninio padalinio veiklos efektyvumui, šiame tyrime kaip pagrindinė naudojama DI priemonė pasirinkta „ChatGPT“ sistema, parinkta atlikus skirtingų DI platformų lyginamąją analizę (žr. 2.4 skyrių). Kiekybiniai duomenys buvo gauti iš skaitmeninės techninės priežiūros valdymo sistemos „Alldevice“, kuri kaupia visus gedimų registrus, jų sprendimo eigą, remonto trukmę, panaudotas atsargines dalis ir technikų veiksmus. Analizei pasirinkti dviejų

mėnesių – rugpjūčio ir rugsėjo – faktiniai gedimų duomenys: gedimų skaičius, prastovų trukmė, remonto laikai ir automatiškai apskaičiuotos vidutinio gedimo šalinimo laiko ir vidutinio laiko tarp gedimų reikšmės. Rugpjūčio mėnesį tiriamame ceche vidutinis gedimo šalinimo laikas siekė 28 minutes, o vidutinis laikas tarp gedimų – 4,9 dienos; rugsėjo mėnesį vidutinis gedimo šalinimo laikas padidėjo iki 42 minučių, o vidutinis laikas tarp gedimų – iki 6,1 dienos. Šie rodikliai atspindi įprastą techninio padalinio veiklos dinamiką be papildomų dirbtinio intelekto priemonių ir tyrime naudojami kaip pradinė bazė, su kuria vėliau lyginami rezultatai, kai technikai pradeda sistemingai taikyti dirbtinio intelekto sprendimą gedimų diagnostikai ir remonto planavimui. Šiame tyrime vidutinis gedimo šalinimo laikas apskaičiuojamas kaip bendra per pasirinktą laikotarpį gedimams šalinti sugaišta trukmė, padalytas iš per tą laikotarpį užregistruotų gedimų skaičiaus, o vidutinis laikas tarp gedimų – kaip įrenginio veikimo laikas tarp dviejų nuosekliai užfiksuotų gedimų.

Be kiekybinių duomenų, tyrime buvo sistemingai fiksuojama, kaip dirbtinio intelekto sistema padeda technikams spręsti realius gedimus. Tiriamo cecho technikai gedimų šalinimo metu naudojo dirbtinio intelekto įrankį informacijos paieškai ir galimų gedimų priežasčių nustatymui, formuluodami užklausas pagal pastebėtus įrangos veikimo simptomus. Po kiekvieno gedimo išsprendimo technikai pažymėdavo, ar gautas atsakymas buvo naudingas sprendžiant problemą, ar nepateikė pritaikomų rekomendacijų. Taip buvo sukaupiti duomenys apie tai, kiek kartų dirbtinio intelekto pasiūlyta gedimo kryptis pasitvirtino ir kiek kartų rekomendacijos nebuvo naudingos, o šie pažymėjimai vėliau naudojami vertinant dirbtinio intelekto atsakymų tikslumo procentą ir realų jo indėlį į remonto procesą.

Tyrimo metu dirbtinio intelekto sistemai buvo suteikta prieiga prie tiriamo cecho įrenginių dokumentacijos: gamintojų naudojimo ir remonto instrukcijų, techninių kortelių, ankstesnių gedimų aktų, remonto ataskaitų ir elektroninių susirašinėjimų (išsaugotų PDF formatu) su įrangos gamintojais, kuriuose aprašomos įrenginių problemos ir jų sprendimo būdai. Į dirbtinio intelekto sistemą integravus didžiąją dalį šių dokumentų, sukurta kiek įmanoma pilnesnė informacinė bazė, reikalinga gedimų diagnostikai ir remonto planavimui. Toks dokumentų kiekis leidžia sistemai generuoti tikslingesnes rekomendacijas, surasti panašius ankstesnius gedimus ir pateikti aiškesnį remonto veiksmų planą. Ši funkcija ypač svarbi todėl, kad iki dirbtinio intelekto priemonių diegimo technikams reikėdavo rankiniu būdu ieškoti reikalingų failų serveriuose ar popieriniuose archyvuose, o tai dažnai užimdavo daugiau laiko nei pats remontas. Integruota dokumentų bazė sumažino informacijos paieškos laiką ir sudarė prielaidas daugiau darbo laiko skirti realiam gedimų šalinimui, o ne duomenų paieškai.

Tyrime dalyvavo du techninio padalinio technikai, turintys skirtingą darbo patirtį ir skirtingą pasirengimą dirbti su skaitmeninėmis sistemomis: vieno techniko darbo patirtis siekia maždaug vienerius metus, kito – apie aštuonerius metus. Jiems buvo paaiškintas dirbtinio intelekto įrankio veikimo principas, pateiktos rekomendacijos dėl užklausų formavimo ir pabrėžta, kad sistema yra pagalbinė priemonė, o galutinė atsakomybė už priimtus sprendimus išlieka technikams. Vykdamas tyrimą buvo laikomasi duomenų saugumo ir etikos principų: į dirbtinio intelekto sistemą nebuvo integruojami darbuotojų asmens duomenys, o naudojami tik su įrenginių veikimu susiję duomenys – prastovų trukmės, gedimų aprašymai, įrangos parametrai ir techninės dokumentacijos turinys. Vidinėse ataskaitose ir gedimų aktuose esantys konkretūs asmens duomenys buvo pašalinti, kad jie nebūtų matomi formuojant užklausas ir analizuojant atsakymus.


Tyrimas turi kelis svarbius ribotumus, kuriuos būtina įvertinti interpretuojant rezultatus. Pirmiausia, analizuojami duomenys apima tik vieną gamyklos cechą, todėl dirbtinio intelekto poveikis įvertintas konkrečiame kontekste. Antra, dirbtinio intelekto taikymas buvo bandomasis ir neapėmė ilgesnio laikotarpio su visais sezoniškumo ir gamybinių pikų svyravimais, todėl gauti rezultatai atspindi konkrečias veiklos sąlygas, o ne visų galimų situacijų spektrą. Trečia, tyrime dalyvavo tik du technikai, todėl dirbtinio intelekto sprendinių vertinimas yra susietas su jų patirtimi, darbo stiliumi ir gebėjimu formuluoti užklausas sistemai. Vis dėlto dėl didelio gedimų kiekio ir intensyvaus įrenginių darbo tiriamasis cechasis suteikia pakankamai duomenų patikimam dirbtinio intelekto taikymo efektyvumo vertinimui. Tyrime naudojami rodikliai – vidutinis gedimo šalinimo laikas, vidutinis laikas tarp gedimų, remonto trukmė, prastovų valandos – leidžia objektyviau nustatyti, ar dirbtinio intelekto įrankis prisideda prie efektyvesnio, greitesnio ir kokybiškesnio gedimų šalinimo proceso ir sudaro pagrindą tolesniems platesnio masto tyrimams.

3.2. Dirbtinio intelekto įrankio kūrimas ir diegimas

Šiame poskyryje aprašomas pasirinktos „ChatGPT“ sistemos pagrindu sukurtas dirbtinio intelekto įrankio sukūrimas ir diegimas į tiriamo techninio padalinio darbo praktiką. Ši sistema leidžia automatizuoti informacijos paiešką techniniuose dokumentuose ir gedimų istorijoje, geba apdoroti įvairius tekstinius formatus (pvz., PDF, DOCX) ir pateikti atsakymus į užklausas natūralia kalba. Dėl šių savybių sistema yra patogi technikams, kuriems svarbu greitai gauti aiškią informaciją apie įrenginio istoriją, klaidų kodus ar remonto seką, nes nereikia naudotis sudėtingomis paieškos užklausomis ar rankiniu būdu peržiūrinėti didelių dokumentų kiekių. Papildomas privalumas – galimybė naudotis sistema tiek kompiuteryje, tiek telefone, todėl DI įrankis gali būti pasiekiamas tiesiogiai prie įrenginio darbo vietoje.

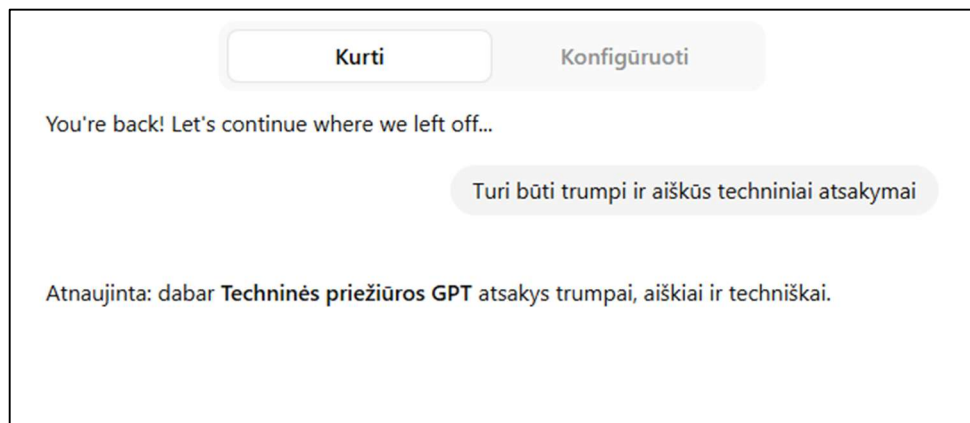
Svarbu paminėti, kad individualius „GPT“ modelius (specializuotus DI asistentus su atskiromis instrukcijomis ir dokumentų baze) gali kurti tik vartotojai, turintys mokamą „ChatGPT“ versiją. Tyrimo metu buvo naudota asmeninė mokama prenumerata, suteikusi galimybę sukurti atskirą uždarą modelį, skirtą tik techniniam padaliniui. Tokiu būdu suformuota atskira darbo aplinka, kurioje DI veikia pagal konkrečias taisykles ir remiasi tik įkeltų dokumentų turiniu. Prieiga prie šio modelio suteikta tik tyrime dalyvavusiems technikams ir tyrėjui, naudojant specialią nuorodą, todėl užtikrinamas ribotas ir kontroliuojamas sistemos naudojimas.

Pirmame etape buvo sukurtas atskiras „ChatGPT“ modelis pavadinimu „Techninės priežiūros GPT“ (žr. 5 pav.).



5 pav. Sukuriamas naujas „ChatGPT“ modelis

„ChatGPT“ modelio konfigūravimas buvo atliktas dviem būdais, kuriuos suteikia platforma. Pirmasis būdas – tiesioginis konfigūravimas bendraujant su sistema (žr. 6 pav.), kai nustatymai tikslinami pokalbio metu. Šiuo atveju sistema pati siūlo papildomas galimybes, automatiškai užpildo dalį laukų ir pateikia papildomus klausimus, kurie padeda iš anksto numatyti galimus trukdžius ir juos suvaldyti kuriant „Techninės priežiūros GPT“. Šis būdas pasirodė patogus, nes leidžia interaktyviai tikslinti instrukcijas, iš karto matant, kaip keičiasi modelio atsakymai. Antrasis būdas – užpildyti konfigūracijos laukus rankiniu būdu (žr. 7 pav.), aiškiai įrašant modelio paskirtį, naudojimo ribas, atsakymų struktūrą ir pagrindinius dokumentų šaltinius. Šiuo etapu buvo apibrėžtos pagrindinės elgesio taisyklės kurios užtikrina, kad DI būtų naudojamas kaip pagalbinė priemonė, o galutinius sprendimus vis tiek priimtų technikai.



6 pav. „GPT“ konfigūravimas dialogo režimu bendraujant su sistema

7 pav. „GPT“ rankinio konfigūravimo langas

Toliau buvo parengtos detalesnės modelio instrukcijos (žr. 7 pav.) , kuriomis „Techninės priežiūros GPT“ turi vadovautis atsakinėdamas į technikų klausimus. Instrukcijose numatyta, kad modelis pirmiausia turi išsiaiškinti, koks tai įrenginys – paprašyti vartotojo nurodyti tikslų įrenginio

pavadinimą ir modelį. Gavęs šią informaciją, DI turi ieškoti susijusių duomenų priskirtuose failuose ir, remdamasis rasta dokumentų duomenimis, pateikti galimas gedimo priežastis bei siūlomus šalinimo veiksmus. Jei galimi keli sprendimo variantai, modelis turi nurodyti jų patikimumo lygį arba rekomenduojamą patikros eiliškumą. Tais atvejais, kai informacijos nepakanka, „GPT“ privalo aiškiai įspėti vartotoją ir pasiūlyti, kokios papildomos informacijos reikėtų tikslesniam sprendimui. Po gedimo pašalinimo modelis pateikia prevencines rekomendacijas (ką dar verta patikrinti įrenginyje) ir paragina vartotoją trumpai aprašyti atliktus darbus, pavyzdžiui, ką pakeitė, ką patikrino ir koks rezultatas. Instrukcijų tekstas sistemoje suformuluotas taip: „GPT modelis pirmiausia turi išsiaiškinti, koks tai įrenginys – paprašyti vartotojo nurodyti tikslų įrenginio pavadinimą ir modelį. Gavęs šią informaciją, modelis ieško susijusių duomenų priskirtuose failuose ir remdamasis rasta dokumentų duomenimis, pateikia galimas gedimo priežastis bei siūlomus šalinimo veiksmus. Jei galimi keli sprendimo variantai, modelis turi nurodyti jų tikimybę arba veiksmų eiliškumą, kuriuo rekomenduojama juos tikrinti. Tais atvejais, kai informacijos nepakanka, GPT aiškiai įspėja vartotoją ir pasiūlo, kokios papildomos informacijos reikia tiksliam sprendimui. Po gedimo pašalinimo modelis pateikia rekomendacijas, ką dar verta patikrinti įrenginyje prevenciniais tikslais, ir pasiūlo vartotojui parašyti trumpą atliktų darbų aprašą, pavyzdžiui: „gedimas nustatytas, pakeista detalė X, įrenginys paleistas, atlikti šie veiksmai“.

Kitas žingsnis – parinkti, kokias papildomas galimybes turės kuriamas modelis (žr. 8 pav.). Buvo pasirinkta „Drobės“ funkcija, leidžianti vienoje vietoje kurti, redaguoti ir išsaugoti ilgesnius tekstus, matyti pakeitimus realiu laiku ir prireikus tęsti darbą vėliau. Taip pat įjungta vaizdo generavimo funkcija, suteikianti galimybę sukurti iliustracijas, pavyzdžiui, schematiškai pavaizduoti, kaip turi būti sujungti įrenginio komponentai. Būtinai įjungtas „kodo interpretatorius ir duomenų analizė“, nes ši funkcija leidžia vykdyti skaičiavimus, kurti grafikus, analizuoti failus (pvz., Excel, CSV, PDF) ir automatiškai generuoti rezultatus bei išvadas. Tuo tarpu žiniatinklio paieška buvo sąmoningai išjungta, kad „GPT“ nebandytų ieškoti papildomos informacijos apie įrenginius internete, nes tai gali iškraipyti informaciją, kuri yra pateikiama priskirtuose įmonės failuose, ir sumažinti rekomendacijų atitikimą realioms X gamyklos darbo sąlygoms.

Galimybės

- ☐ Žiniatinklio paieška
- ☒ Drobė
- ☒ Vaizdo generavimas
- ☒ Kodo interpretatorius ir duomenų analizė ?

8 pav. „GPT“ papildomų galimybių pasirinkimas

Sekančiu žingsniu yra sukuriamas veiksmas (žr. 9 pav.). Šis veiksmas leidžia „GPT“ modeliui pasiekti reikalingą informaciją išoriniuose šaltiniuose, šiuo atveju išorinių failų aplankuose. Kad sistema pasiektų reikiamus failus ir tinkamai ieškotų informacijos turi būti parašoma specifikacija „YAML“ formatu. Nuo specifikacijos parašymo kokybės priklauso kaip „GPT“ modelis lengvai ir tiksliai galės surasti informaciją. Tyrimo metu buvo sukurta specifikacija nurodanti failų ieškoti įmonės X serverio aplankuose.

9 pav. „GPT“ veiksmo kūrimo langas

Kadangi dėl saugumo negalima dalintis X įmonės vidiniais duomenimis, toliau pateikiamas pavyzdinis kodas, skirtas failų paieškai „Google Drive“ sistemoje. Jis demonstruoja, kaip „GPT“ modelis galėtų perduoti paieškos užklausą į „Google Apps Script“ žiniatinklio paslaugą. 10 paveiksle pateikta specifikacija naudojama kaip iliustracinis integracijos principo pavyzdys.

```
openapi: 3.1.0
info:
  title: Google Drive Search API
  description: |
    GPT veiksmas, kuris leidžia ieškoti dokumentų Google Drive pagal vartotojo pateiktą užklausą.
    Naudotojas pateikia natūralios kalbos užklausą (pvz. „girdisi guolio ūžimas“),
    GPT ją interpretuoja ir siunčia atitinkamus raktinius žodžius bei failo tipą į Google Apps Script
API.
  version: 1.0.0
servers:
  - url: https://script.google.com/macros/s/TIKRAS_SCRIPT_ID/exec
    description: Google Apps Script Web App URL
paths:
  /:
    post:
      operationId: searchDriveFiles
      summary: Atlieka Google Drive failų paiešką pagal nurodytą failo tipą ir raktinius žodžius
      requestBody:
        required: true
        content:
          application/json:
            schema:
              type: object
              properties:
                fileType:
                  type: string
                  description: |
                    MIME tipo filtras. Naudojamas nurodyti, kokio tipo failų ieškoti.
                    Pvz. PDF: `application/pdf`
                    example: application/pdf
                keywords:
                  type: array
                  items:
                    type: string
                    description: Raktiniai žodžiai, kurių bus ieškoma failų turinyje.
                    example: ["guolio", "ūžimas"]
              required:
                - fileType
                - keywords
      responses:
        '200':
          description: Paieškos rezultatai
          content:
            application/json:
              schema:
                type: object
                properties:
                  results:
                    type: array
                    description: Sąrašas rastų failų, atitinkančių paieškos kriterijus
                    items:
                      type: object
                      properties:
                        name:
                          type: string
                          description: Failo pavadinimas
                          example: Diagnostika_Guoliai_2022.pdf
                        url:
                          type: string
                          format: uri
                          description: Nuoroda į failą Google Drive
                          example: https://drive.google.com/file/d/abc123456/view
```

10 pav. Pavyzdinė „Google Drive“ paieškos API „OpenAPI“ specifikacija

Toliau būtina sukurti „Google Apps Script“ žiniatinklio paslaugą (žr. 11 pav.), kuri veiktų kaip tarpinė sąsaja tarp „GPT“ modelio ir išorinės dokumentų saugyklos „Google Drive“. Ši paslauga priima iš „GPT“ veiksmų siunčiamą užklausą, apdoroja joje pateiktus parametrus ir grąžina atsakymą „JSON“ formatu. „Google Apps Script“ kodas yra atsakingas už realios dokumentų paieškos logiką, failų tikrinimą ir rezultatų formavimą. Siekiant užtikrinti, kad „GPT“ modelis galėtų bendrauti su šia paslauga, sukurtas „Apps Script“ turi būti paskelbtas kaip „Web App“, suteikiant galimybę jį pasiekti per „HTTP“ užklausas. Tai leidžia „GPT“ modeliui siųsti paieškos parametrus, tokius kaip raktažodžiai, failo tipas ar aplanko identifikatorius, o paslauga, remdamasi gauta informacija, grąžina struktūruotus duomenis reikiamu formatu.

```
function doPost(e) {
  const request = JSON.parse(e.postData.contents);

  const folderId = request.folderId; // aplanko ID kuriame ieškoma
  const keywords = request.keywords || []; // raktažodžiai, pvz. ["guolis"]
  const mimeType = request.mimeType || ""; // nurodo kokio tipo failų reikia ieškoti

  const folder = DriveApp.getFolderById(folderId);
  const files = folder.getFiles();

  const results = [];

  while (files.hasNext()) {
    const file = files.next();
    const name = file.getName();
    const id = file.getId();
    const type = file.getMimeType();

    let matchFound = false;
    let snippet = "";

    // 1. Tikrinamas failo pavadinimas
    for (let k of keywords) {
      if (name.toLowerCase().includes(k.toLowerCase())) {
        matchFound = true;
        snippet = "Raktažodis rastas failo pavadinime.";
        break;
      }
    }

    // 2. Jei failas yra Google Doc – tikrinamas turinys
    if (!matchFound && type === "application/vnd.google-apps.document") {
      const doc = DocumentApp.openById(id).getBody().getText();

      for (let k of keywords) {
        const index = doc.toLowerCase().indexOf(k.toLowerCase());
        if (index !== -1) {
          matchFound = true;

          // ištraukiamas kontekstas
          const start = Math.max(0, index - 60);
          const end = Math.min(doc.length, index + k.length + 60);
          snippet = doc.substring(start, end).trim();
          break;
        }
      }
    }


    // 3. Jei rasta atitiktis – įtraukiamas į rezultatus
    if (matchFound) {
      results.push({
        name: name,
        url: file.getUrl(),
        snippet: snippet,
        mimeType: type
      });
    }
  }

  // Atsakymas JSON formatu
  const response = {
    status: "success",
    foundCount: results.length,
    results: results
  };

  return ContentService
    .createTextOutput(JSON.stringify(response, null, 2))
    .setMimeType(ContentService.MimeType.JSON);
}
```

11 pav. „Google Apps Script“ žiniatinklio paslaugos kodas dokumentų paieškai „Google Drive“ sistemoje

Tokiu būdu sukuriamas vientisas ryšys tarp dirbtinio intelekto modelio ir dokumentų saugyklos: „GPT“ modelis suformuoja užklausą, „Google Apps Script“ ją apdoroja ir atrenka atitinkamus failus, o gautas atsakymas vėl perduodamas „GPT“ modeliui interpretavimui. Tokia architektūra užtikrina, kad sistema gebėtų gauti aktualią techninę informaciją iš dokumentų ir panaudoti ją įrenginių gedimų priežasčių nustatymui bei diagnostikos proceso palaikymui. Veikimo schema pateikiama 12 paveikslėlyje. X Įmonės informacinių technologijų specialistui kodų parengimas vidiniam naudojimui užtruko apie 4 valandas.



12 pav. GPT, „Google Apps Script“ ir „Google Drive“ sąveikos schema atliekant gedimo priežasčių paiešką

Dirbtinio intelekto modeliui reikalingi duomenys buvo surenkami ir saugomi atskirame projekto aplanke X įmonės vidiniame serveryje, prieinamame tik įmonės darbuotojams. Šiam tyrimui sukurtame specialiaame aplanke kiekvienam iš 135 tiriamo cecho įrenginių priskirtas atskiras poaplankis. Į šiuos poaplankius kelta gamintojo techninė dokumentacija, vidinės techninės priežiūros instrukcijos ir iš „Alldevice“ sistemos eksportuoti atliktų darbų aktai. Visi failai pavadinti tiksliais įrenginių pavadinimais. Toks struktūravimas leido ne tik greičiau surasti reikiamą dokumentą, bet ir užtikrino, kad dirbtinio intelekto modelis, gaudamas užklausą apie konkretų įrenginį, naudotų tik su juo susijusius duomenis ir neklaidintų technikų nesusijusia informacija.

Pirmiausia tyrimui reikalingi duomenys buvo surinkti iš „Alldevice“ sistemos, kurioje kiekvienas įrenginys turi atskirą techninę kortelę su unikaliu identifikavimo numeriu. Atidarius įrenginio kortelę ir pasirinkus skiltį „Istorija“, matomi visi prie šio įrenginio atlikti darbai – tiek neplaniniai gedimų šalinimai, tiek planinės priežiūros užduotys. Paspaudus ant konkrečios eilutės atidaromas darbų akto langas, kuriame pateikiama išsami informacija: pilnas įrenginio pavadinimas, lokacija, darbo sukūrėjas ir sukūrimo data, atlikto darbo pavadinimas, darbų atlikimo data ir trukmė, techniko vardas ir pavardė, atliktų veiksmų punktai, techniko pastabos, pridėtos nuotraukos bei techniko ir darbus priėmusio darbuotojo parašai. Kuriant „Techninės priežiūros GPT“ modelį siekta, kad dirbtinis intelektas analizuotų didžiąją dalį darbų akte pateiktos techninės informacijos – gedimo aprašymą, prastovos trukmę, atliktus veiksmus, pastabas, darbo indentifikavimo numerį– ir ją panaudotų diagnostikos pasiūlymams formuoti. Gamykloje taikomas susitarimas, kad technikui atlikus darbus,

įrenginio operatorius privalo juos priimti ir pasirašyti po atliktų darbų aprašu. Dėl šios dvigubos patikros darbų aktuose atsispindi ne tik techniniai veiksmai ir atsakomybės pasidalijimas, bet ir sumažėja rizika, kad technikas įrašys neteisingą ar klaidinančią informaciją. Dėl šios priežasties darbų aktai šiame tyrime laikomi pagrindiniu praktinės informacijos šaltiniu: juose sukaupta reali gedimų istorija, tipinės priežastys ir patikrinti sprendimai.

Siekiant užtikrinti duomenų saugumą ir laikytis asmens duomenų apsaugos principų, tyrimo metu „Alldevice“ sistemoje buvo parinktas nustatymas, kad konvertuojant darbų aktą į PDF formą nebūtų rodomi techniko ir darbą priėmusio darbuotojo vardai, pavardės ir parašai. Eksportuojant darbų aktus į PDF taip pat nebuvo įtraukiamos prie jų prisegtos nuotraukos, nes jos ženkliai didina failų apimtį, o šiame tyrime naudojamas DI modelis analizuoja tik tekstinę informaciją ir labai ribotai gali apdoroti vaizdinę medžiagą. Taip išsaugomas darbų turinys ir techninė informacija, bet pašalinama perteklinė, tyrimui nebūtina informacija. Atliktų darbų aktai iš „Alldevice“ sistemos buvo eksportuoti PDF formatu nuo 2020-01-01, filtruojant tik tiriamo cecho įrenginius. Eksportuoti aktai buvo saugomi taip, kad failo pavadinime būtų nurodytas įrenginio pavadinimas ir laikotarpis, kurį apima darbų aktai (nuo kurios datos iki kurios datos PDF failų rinkinyje yra įtraukti darbų įrašai), pavyzdžiui: „Įrenginio pavadinimas_2020-01-01–2024-12-31“. Iš „Alldevice“ sistemos darbų aktų nebūtina eksportuoti po vieną – galima iš karto eksportuoti visą gedimų ir aptarnavimo istoriją iš įrenginio kortelės, pažymint varneles prie darbų, kurių aktus norima išskirti į PDF failų rinkinį. Tačiau sistema neleidžia eksportuoti daugiau kaip 50 darbų aktų vienu metu, todėl kai kuriems įrenginiams visą istoriją teko eksportuoti per kelis kartus, papildomai tikrinant, ar neliko neužfiksuotų laikotarpių. Darbų akto pavyzdys pateikiamas 13 paveiksle.

Atliktų darbų (priėmimo – perdavimo) aktas: 30380

Data 2025-11-10

rankinė kirpimo mašina

/ / Ila.

Kliento el. paštas:

Kliento el. paštas 2:

Darbo pavadinimas Pavyzdys [Neplaninis-avarinis darbas, Darbo eil. nr.: 33749]

Vykdytojas (-ai)	Data	Darbas pradėtas	Darbas pabaigtas	Laikas
	2025-11-10	08:00	08:18	00:18
Iš viso:				00:18

Atliktų darbų / veiksmų sąrašas	Užbaigta	
	Taip	Ne
Pavyzdys 1	✓	
Pavyzdys 2	✓	
Pavyzdys 3		✗
Komentaras papildomas		
Pavyzdys 4	✓	


Pastabos

Pavyzdys

13 pav. Darbų akto pavyzdys

Papildomai tyrime buvo naudojama įmonės serveriuose jau anksčiau sukurta įrenginių dokumentacijos duomenų bazė. Tyrimo metu ši dokumentacija buvo sistemingai peržiūrėta ir atrinkta, kurie dokumentai gali būti naudingi dirbtinio intelekto modeliui, o kurie – ne. Kadangi DI

modeliui svarbiausia tekstinė informacija, skenuoti, žemos raiškos arba prastai atpažįstamą tekstą turintys dokumentai nebuvo įtraukiami į projekto duomenų rinkinį ir nepateko į „Techninės priežiūros GPT“ naudojamus aplankus. Iš šios duomenų bazės buvo atrinkti tik kokybiški, aiškų tekstą turintys failai ir sukelti į projekto aplanką pagal įrenginių pavadinimus – į tuos pačius aplankus, kuriuose buvo saugomi ir darbų aktų PDF failai. Įrenginių dokumentacija ir darbų aktai kartu sudaro apie 40 000 PDF puslapių, kurių bendra apimtis siekia 6,4 GB, todėl susiformavo pakankamai didelė duomenų bazė, iš kurios „Techninės priežiūros GPT“ vėlesniuose tyrimo etapuose gali gauti reikiamą informaciją (žr. 14 pav.). Visų failų (darbų aktų ir dokumentacijos) surinkimas ir struktūravimas užtruko apie 16 valandų, tai leido užtikrinti tvarkingą dokumentų struktūrą ir palengvino DI sistemos atliekamą paiešką bei informacijos panaudojimą gedimų diagnostikai. Šių duomenų surinkimo, saugojimo ir panaudojimo „Techninės priežiūros GPT“ modeliui eiga pavaizduota 14 paveiksle.



14 pav. Tyrime naudojamų duomenų srautas

Tyrimo metu failų eksportavimo ir perkėlimo procesas buvo atliekamas rankiniu būdu: darbuotojas prisijungdavo prie „Alldevice“ sistemos, atrinkdavo reikiamą įrenginį, pažymėdavo atliktus darbus, eksportuodavo darbų aktus į PDF formatą ir perkeldavo juos į atitinkamą aplanką X įmonės serveryje. Iš dokumentacijos duomenų bazės atrinkti failai taip pat buvo rankiniu būdu perkelti į tuos pačius projekto aplankus pagal atitinkamą įrenginį. Nors toks procesas yra pakankamas tyrimo tikslams, jis reikalauja daug laiko ir yra priklausomas nuo žmogaus dėmesingumo. Ateityje darbų aktų ir dokumentų perkėlimą į reikiamus failų aplankus būtų galima automatizuoti, pasitelkiant išmaniuosius informacinių technologijų sprendimus – pavyzdžiui, naudojant „Alldevice“ API arba automatizuotas užklausas, kurios reguliariai eksportuotų naujus darbų aktus ir pagal įrenginio identifikatorių juos automatiškai paskirstytų į atitinkamus aplankus dokumentų sistemoje. Tai sumažintų rankinio darbo apimtį, klaidų tikimybę ir užtikrintų, kad dirbtinio intelekto modelis visuomet naudotų naujausią gedimų bei dokumentacijos istoriją.

3.3. Tyrimo eiga

Tyrimo metu technikų telefonuose buvo įdiegta „ChatGPT“ mobilioji programėlė ir suteikta nuoroda į specialiai šiam projektui sukurtą uždara „GPT“ modelį. Prieiga prie šios sistemos buvo ribota – ja galėjo naudotis tik projekto dalyviai, gavę individualią nuorodą, todėl buvo užtikrintas įmonės dokumentacijos konfidencialumas ir aiškiai atskirta bandomoji aplinka nuo bendro pobūdžio DI įrankių. Prieš pradėdant aktyvų naudojimą su technikai aptarta darbo tvarka ir pagrindinės taisyklės: kada kreiptis į DI sistemą, kokią informaciją būtina pateikti ir kaip vertinti gautus pasiūlymus. Susitarta, kad esant neaiškiems, sudėtingesniems ar rečiau pasitaikantiems gedimams, pirmasis žingsnis turėtų būti problemos suformulavimas „GPT“ pokalbyje, o tik po to – galutinio sprendimo priėmimas prie įrenginio. Taip dirbtinis intelektas buvo integruotas į kasdienę praktiką ne kaip atskira priemonė, o kaip realus darbo proceso elementas.

Tyrimo eiga rėmėsi standartiniu veiksmų ciklu, atspindinčiu faktinę techninio padalinio veiklą. Pirmiausia cecho meistras „Alldevice“ sistemoje registruodavo neplaninį gedimą ir kviesdavo techniką. Atėjęs prie įrenginio technikas surinkdavo pirminę informaciją apie problemas: įrenginio veikimo pasikeitimus, klaidų pranešimus, neįprastus garsus ar vibracijas, produkcijos kokybės nukrypimus. Jeigu akivaizdžių, greitai pašalinamų priežasčių (pvz., neteisingų parametrų, užstrigusio ruošinio, medžiagos tiekimo sutrikimo) nenustatydavo, technikas atsidarydavo „GPT“ pokalbį ir aprašydavo situaciją šnekamuoju stiliumi. Modelis, įvertinęs pateiktą informaciją, užduodavo papildomus klausimus arba iš karto pasiūlydavo galimų gedimo priežasčių sąrašą su rekomenduojama patikrinimų seka. Darbo dienos pabaigoje technikas perduodavo informaciją savo vadovui: kiek kartų naudojosi „GPT“ pokalbiu ir kiek kartų atsakymai buvo teisingi. Šie duomenys buvo renkami modelio atsakymų vertinimui.

Praktinio taikymo (2025-10-01 iki 2025-10-31) metu sistema buvo aktyviai naudojama įvairiais gedimų atvejais – nuo paprastesnių mechaninių sutrikimų iki sudėtingesnių elektronikos ar valdymo sistemos problemų. Technikai kreipdavosi į „GPT“ modelį tiek tada, kai jiems patiems trūkdavo idėjų, kokią mazgą tikrinti toliau, tiek tada, kai norėdavo patikrinti savo jau suformuotą hipotezę. Didesnę patirtį turintis technikas sistemą dažniau naudojo kaip papildomą patikros įrankį, o mažiau patyręs – kaip pagalbinį gidą, padedantį apsispręsti, kokius parametrus, detales ar įrenginio modulius tikrinti pirmiausia ir kokia veiksmų seka būtų racionaliausia. Taip DI sistema tapo ne tik informacijos paieškos priemone, bet ir struktūruotos diagnostikos šablonu, kuris padėjo nuosekliau organizuoti gedimo sprendimo eigą.

Tyrimo eigoje detaliau analizuotas konkretus atvejis, susijęs su siuvimo pusautomatžio gedimu, kuris iliustruoja sistemos veikimo principą. Technikas „Alldevice“ sistemoje gavo užpildytą neplaninį avarinį gedimo įrašą, apibūdinantį prastėjančią siūlės kokybę ir įrenginio darbo trikdžius. Atėjęs prie įrenginio jis patikrino priežastis, tačiau jų nenustatė, todėl perėjo prie darbo su „GPT“ modeliu. Pokalbyje technikas šnekamuoju stiliumi aprašė problemą, nenaudodamas lietuviškų ženklų ir įrašydamas tik dalį įrenginio pavadinimo. Nepaisant to, sistema sugebėjo tiksliai atpažinti, apie kurį įrenginį kalbama, ir sugeneravo trumpą, aiškų problemos aprašymą, kuris buvo naudojamas tolesnei diagnostikai (15–16 pav.). Tai parodė, kad modelis geba prisitaikyti prie realios darbo aplinkos, kurioje gedimai aprašomi ne idealia literatūrine kalba, o natūraliais, kasdieniais darbuotojų pasakojimais. Pastaba: įrenginių pavadinimai yra užtušuoti dėl įmonės vidinės duomenų apsaugos politikos.

irenginyje [redacted] siuvimo pusautomatis daro negrazia siūle

15 pav. Techniko į „GPT“ įvestas gedimo aprašymas šnekamuoju stiliumi

Kadangi įvardinai, kad [redacted] daroma negraži siūlė, remiantis dokumente esančia priežiūros ir remonto istorija, galima nustatyti kelias galimas priežastis ir veiksmų seką:

16 pav. „GPT“ atsakymas, identifikavus įrenginį ir suformulavus problemos aprašymą

Remdamasis gauta informacija, „GPT“ modelis pasiūlė kelias labiausiai tikėtinas gedimo priežastis ir suformavo rekomenduojamą gedimo šalinimo eigą: kokius mazgus tikrinti pirmiausia, ką įvertinti vizualiai, kokius parametrus matuoti. Papildomai sistema, pasitelkusi integraciją su dokumentų ir istorinių įrašų baze, pateikė ankstesnių remonto atvejų santraukas – kokie panašūs gedimai šiame įrenginyje jau buvo fiksuoti, kokie sprendimo veiksmai atlikti ir koks rezultatas pasiektas (17 pav.). Tokiu būdu technikas gavo ne tik abstrakčias teorines rekomendacijas, bet ir konkrečias nuorodas į pasiteisinusius sprendimus realiomis sąlygomis. Atlikęs siūlomus patikrinimus ir pašalinęs gedimą, technikas sugrįžo į „GPT“ pokalbį ir trumpai aprašė, kokius veiksmus atliko ir kas buvo priežastis. Remdamasis šiuo aprašymu modelis sugeneravo struktūruotą atliktų darbų įrašą bei papildomas prevencinės priežiūros rekomendacijas, kurias technikas galėjo perkelti į „Alldevice“ sistemą (18–21 pav.). Taip DI sistema prisidėjo tiek prie konkretaus gedimo sprendimo, tiek prie sistemingo žinių kaupimo ateičiai.

📌 Dažniausios negražios siūlės priežastys [redacted]:

1. Adatos pažeidimai arba netinkamas sumontavimas

Buvo keistos adatos (pvz., [33051] „nulūžo pusautomatžio pėdutė“ → adatos ir pėdutė keistos).

2. Kilpiklio pažeidimas arba netikslus darbas

Daug atvejų (pvz., [32980], [33021], [32778]) kai dėl adatos/kilpiklio sugadinimų siūlė iškraipoma ar visai nesiuvama.

3. Siūlės peiliukų netikslus prispaudimas arba nusidėvėjimas

Pvz., [32723] – keisti peiliukai, sureguliuota siūlė; [32778] – plokštelės tarpai leido praslysti siūlui.

4. Siūlų prispaudimo problema

Pvz., [32502] – siūlų prispaudėjas veikia, bet „netinkamai“, siūlė vizualiai negraži.

17 pav. „GPT“ pateikti ankstesnių remontų aprašai

 **Rekomenduojama gedimo šalinimo seka (pagal tikimybę ir dažnumą):**

- 1. Patikrink:**
 - Ar adata nėra kreiva, įskilusi ar netinkamai įstatyta.
 - Kilpiklio padėtį ir judėjimą – ar jis sinchroniškai juda su adata.
 - Peiliukų padėtį ir jų prispaudimą (ypač jei siūlė netolygi arba neišbaigta).
 - Ar siūlas gerai įvestas ir perveriamas per reikiamus taškus.
- 2. Išvalyk ir sutepk:**
 - Kilpiklius, peilių mechanizmą, sriegio įtempimo zonas.
 - Patikrink, ar nėra tepalų pertekliaus ties siūlės zonomis.
- 3. Vizualiai įvertink siūlę:**
 - Ar visose siūlės dalyse yra vienodas dygsnio ilgis?
 - Ar nėra praleistų siūlių, įtrūkimų ar siūlo kilpų?
- 4. Papildomi patikrinimai:**
 - Patikrink siuvimo greičio nustatymus – jei inverteris [redacted] netinkamai reguliuoja greitį, dygsniai gali skirtis.
 - Patikrink ar nesukritę siūlių įtempimo spyruoklės ar stabdžiai.

18 pav. „GPT“ pateikta rekomenduojama gedimo šalinimo seka

 **Po gedimo pašalinimo:**

- 1.** Padaryk testinį siuvimą ant kelių medžiagos gabalėlių.
- 2.** Patikrink siūlės kokybę visuose kampuose ir ties siūlės pradžia/pabaiga.
- 3.** Jei viskas gerai – vėl dar kartą patikrini:
 - Visų keturių pusautomatinių tepimo lygius.
 - Ar nesikaupia dulkių ant kapoklių ar guoliaviečių.

19 pav. Sistemos pateikiami papildomi patikros punktai technikui

Radau neįdomiai linkusę adata ir pažeistą kilpiklį. Šias detales pakeičiau naujomis. Įrenginį patikrinau, veikia gerai. Papildomai patikrinau visų pusautomatinių tepalo lygį ir ar nėra prisinešusių dulkių.

20 pav. Techniko atliktų darbų ir papildomų patikrinimų aprašymas GPT pokalbyje

Puiku, spręsti pradėta nuo teisingo galo – kreiva adata ir pažeistas kilpiklis dažniausiai ir būna negražios siūlės kaltininkai, ypač jei siūlė būna netolygi, su kilpom arba praleidimais.

 **Užfiksuotas atliktų darbų aprašymas:**

Gedimas: negraži siūlė.
Priežastis: neįdomiai linkusi adata ir pažeistas kilpiklis.
Veiksmai: pakeista adata ir kilpiklis naujomis detalėmis, įrenginys patikrintas – veikia gerai.
Papildomai: patikrintas visų pusautomatinių tepalo lygis ir dulkių sankaupos – viskas tvarkoje.

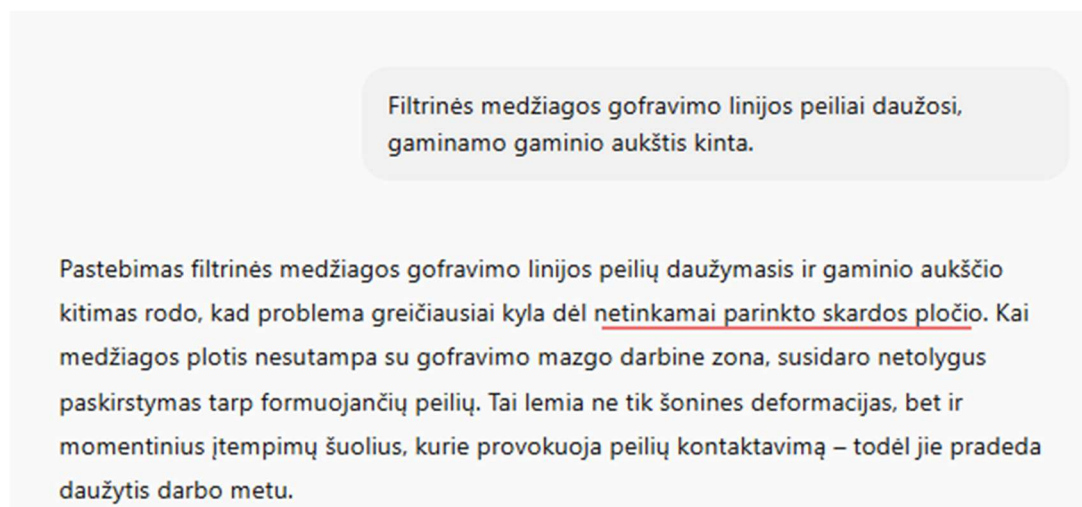
 **Rekomendacija prevencijai:**

Kad tokie gedimai nepasikartotų:

- Apsvarstyk reguliarią adatų keitimo rutiną (pvz., kas 2 savaitės, jei gamyba intensyvi).
- Peržiūrėk kilpiklius kas 1 mėnesį – ar nėra įbrėžimų, iškrypimų.
- Gal vėl verta pagalvoti apie nuolatinį oro pūtimą (nuputimą) į kilpiklio zoną – apie tai jau buvo minėta ataskaitoje [33021], kad nuo G4 medžiagų viskas apsineša ir mechanizmai stringa.


21 pav. „GPT“ sugeneruotas atliktų darbų aprašas ir prevencinės priežiūros rekomendacijos

Tyrimo įgyvendinimo metu pasitaikė situacijų, kai dirbtinio intelekto pateikti atsakymai buvo netikslūs ar klaidinantys. Dažniausiai taip nutikdavo tada, kai technikas nepakankamai aiškiai aprašydavo problemą, pateikdavo per mažai faktinių simptomų, netiksliai nurodydavo įrenginį arba sistemoje nebūdavo su konkrečia problema tiesiogiai susijusių dokumentų, todėl modelis bandydavo pritaikyti panašią informaciją, susijusią su kitu įrenginiu. Tokiais atvejais modelis stengdavosi „užpildyti spragas“ ir pateikdavo tariamą sprendimą, kuris neatitiko realios gedimo priežasties (22 pav.). Nors dalis siūlomų veiksmų vis tiek nukreipdavo į tam tikras tikrintinas vietas, bendra rekomendacija dažnai būdavo per daug apibendrinta arba netinkama konkrečiai situacijai. Visi tokie atvejai buvo fiksuojami ir sukaupta informacija numatyta naudoti sistemos tobulinimui ateityje. Praktinė patirtis parodė, kad DI negali būti naudojamas kaip neklystantis asistentas – technikas turi kritiškai vertinti gautas rekomendacijas ir galutinius sprendimus priimti remdamasis realia situacija.



22 pav. Klaidingas „GPT“ atsakymas, kai apie įrenginį trūksta informacijos

Papildomai pastebėta, kad parinkus „GPT“ modelyje funkciją „Ilgesnis galvojimas“, dalyje sudėtingesnių atvejų buvo gauti tikslesni ir labiau pagrįsti atsakymai. Šiuo nustatymu modelis sugeneruodavo ilgesnę analizę, aiškiau išdėstydavo galimų gedimo priežasčių grandinę, argumentuodavo, kodėl tam tikras mazgas turėtų būti tikrinamas pirmiausia, ir pateikdavo struktūruotą veiksmų seką su prevencijos rekomendacijomis. Nors toks atsakymas sugeneruojamas šiek tiek lėčiau, praktikoje tai atsipirkdavo mažesniu klaidų skaičiumi ir geresniu diagnostikos nuoseklumu. Parametro parinkimo pavyzdys pateiktas 23 paveikslėlyje ir rekomenduotas naudoti tais atvejais, kai gedimas yra sudėtingas ar potencialiai susijęs su kelių sistemų sąveika, o klaidingas sprendimas galėtų lemti ilgesnes prastovas.



23 pav. „GPT“ nustatymas „Ilgesnis galvojimas“

Per tyrimo laikotarpį tiriamajame ceche užfiksuoti 87 neplaniniai avariniai gedimai. Sukurtas „GPT“ modelis per tą patį laikotarpį buvo panaudotas 116 kartų – į šį skaičių įeina tiek realios situacijos, kai technikai ieškojo konkretaus gedimo priežasčių ir sprendimo būdų, tiek papildomi testavimo klausimai, skirti patikrinti sistemos veikimą, imituojant jau žinomus gedimus ir jų priežastis.

Fiksuota, kad sistema neteisingai arba nepakankamai tiksliai atsakė 32 kartus, tai yra 27,6 % visų užklausų, o likusiais atvejais (72,4 %) pateikti atsakymai buvo vertinami kaip tinkami arba naudingi techniko sprendimo priėmimui.

3.4. Tyrimo rezultatai

Tyrimo metu buvo vertinama, kaip dirbtinio intelekto pagrindu sukurtas „GPT“ modelis gali padėti technikams greičiau nustatyti gedimų priežastis, sutrumpinti diagnostikos laiką ir išlaikyti įrangos patikimumą didėjant gamybos apimtims. Analizė atlikta realiomis sąlygomis, kai tiriamajame ceche fiksuotas nuoseklus gamybos augimas, o techniniam padaliniui teko spręsti daugiau gedimų ir dirbti esant intensyvesnei įrangos eksploatacijai. Tokios sąlygos sudarė prielaidas įvertinti, ar DI priemonės leidžia efektyviau valdyti didėjančią krūvį ir kartu mažinti prastovų riziką.

Praktinio taikymo laikotarpiu technikai pateikė 116 užklausų „GPT“ modeliui, aprašydami realius gedimų simptomus. Į šį skaičių įeina tiek realios situacijos, kai buvo ieškoma konkrečių gedimo priežasčių ir sprendimų, tiek testavimo atvejai, kai tikrintas sistemos veikimas imituojant jau žinomus gedimus ir jų priežastis. Fiksuota, kad sistema neteisingai arba nepakankamai tiksliai atsakė 32 kartus, kai pateiktos rekomendacijos nepadėjo nustatyti realios gedimo priežasties arba buvo per daug abstrakčios. Likusiais atvejais – 84 kartus – modelio pateikti atsakymai buvo vertinami kaip tinkami arba naudingi techniko sprendimo priėmimui (padėjo susiaurinti tikėtinų priežasčių ratą, pasiūlė logišką patikrinimų seką ar priminė anksčiau buvusius panašius atvejus). Taip apskaičiuota, kad praktiniam darbui naudingų atsakymų dalis sudarė apie 72,4 %, o netikslių ar nepakankamai informatyvių – apie 27,6 %. Toks santykis rodo, kad modelis jau pirmojo taikymo etapo metu gebėjo dažniau padėti nei trukdyti, tačiau tuo pačiu aiškiai išryškėjo poreikis tikslinti naudojimo taisykles ir dokumentacijos bazę.


Analizuojant cecho veiklos rodiklius nustatyta, kad tyrimo laikotarpiu gamybos apimtys reikšmingai išaugo, tačiau gedimų skaičius nepadidėjo proporcingai (žr. 9 lentelė). Rugpjūčio mėnesį buvo pagaminta 23 276 gaminiai ir užfiksuoti 86 neplaniniai gedimai, rugsėjį gamyba išaugo iki 31 618 gaminių, o gedimų skaičius padidėjo iki 102. Spalį, kai techninis padalinys pradėjo naudoti „GPT“ modelį, gamybos apimtys toliau augo ir pasiekė 37 091 gaminių, tačiau gedimų skaičius sumažėjo iki 87. Tai reiškia, kad esant didžiausiai gamybos apimčiai tyrimo laikotarpiu, gedimų skaičius buvo panašus kaip rugpjūtį, kai gamyba buvo gerokai mažesnė. Nors toks rezultatas negali būti tiesiogiai priskirtas vien DI priemonėms, jis rodo, kad techninis padalinys sugebėjo suvaldyti gedimų skaičių nepaisant augančio krūvio.

9 lentelė. Gamybos apimtys ir gedimų skaičiaus kaita tyrimo laikotarpiu

Mėnuo	Gaminių kiekis vnt.	Gedimų sk.
Rugpjūtis	23276	86
Rugsėjis	31618	102
Spalis	37091	87

Tyrimo laikotarpiu gamybos apimtys didėjo, todėl įranga dirbo intensyviau, o tai sudarė palankias sąlygas įvertinti, ar dirbtinio intelekto priemonės išlaiko veiksmingumą esant didesniai apkrovai. Siekiant atskirti gamybos apimtys įtaką nuo įrenginių patikimumo, atlikta santykinė analizė, apskaičiuojant, kiek gedimų tenka 1000 pagamintų gaminių kiekvieną mėnesį (žr. 24 pav.). Rugpjūtį 1000 gaminių teko apie 3,69 gedimo, rugsėjį šis rodiklis sumažėjo iki maždaug 3,23 gedimo, o spalį

– iki 2,35 gedimo. Lyginant spalį su rugpjūčiu, gedimų skaičius 1000 gaminių sumažėjo apie 36,5 %, o lyginant su rugsėju – apie 27,3 %. Tai rodo, kad tiriamojo cecho įrangos patikimumas augo – gedimų tenka vis rečiau, net ir esant didesniai gamybos kiekiui. Tokia tendencija leidžia teigti, kad techninis padalinys ne tik mechanškai „gesino“ sutrikimus, bet ir ėmė efektyviau valdyti gedimų priežastis, o dirbtinio intelekto priemonės galėjo prisidėti prie greitesnio diagnostikos proceso ir labiau pagrįstų sprendimų priėmimo.



24 pav. Gedimų skaičiaus 1000 pagamintų gaminių pokytis tyrimo laikotarpiu

Taip pat buvo analizuojami pagrindiniai techninės priežiūros rodikliai – vidutinis gedimo šalinimo laikas (MTTR) ir vidutinis laikas tarp gedimų (MTBF), siekiant įvertinti, kaip jie kito didėjant gamybos apimtims ir pradėjus taikyti „GPT“ modelį (10 lentelė). Rugpjūčio mėnesį MTTR siekė 28 minutes, o MTBF – 4,9 dienos. Rugsėjį, išaugus tiek gamybos apimtims, tiek gedimų skaičiui, vidutinis gedimo šalinimo laikas padidėjo iki 42 minučių (+50 % lyginant su rugpjūčiu), o MTBF pailgėjo iki 6,1 dienos (+24,5 %). Tai rodo, kad nors gedimų skaičius išaugo, tarp gedimų vidutiniškai praeidavo daugiau laiko, tačiau kiekvieno gedimo šalinimas tapo sudėtingesnis ir ilgesnis. Spalį, gamybai dar labiau išaugus (+17,3 % lyginant su rugsėju), MTTR sumažėjo iki 36,5 minutės (–13,1 % lyginant su rugsėju), o MTBF siekė 5,5 dienos. Nors vidutinė gedimų šalinimo trukmė išliko didesnė nei rugpjūtį, ji sumažėjo, lyginant su rugsėjo piku, ir kartu išlaikytas ilgesnis laikas tarp gedimų nei pradinio laikotarpio. Tai leidžia teigti, kad techninis padalinys pradėjo efektyviau valdyti didėjančią apkrovą: kiekvienas gedimas buvo šalinamas greičiau, nei būtų galima tikėtis vien pagal augančias gamybos apimtis, o dirbtinio intelekto priemonės galėjo prisidėti prie diagnostikos etapo sutrumpėjimo.

10 lentelė. MTTR, MTBF ir gamybos augimo dinamika tyrimo laikotarpiu

Mėnuo	MTTR, min	MTBF, dienomis	Gamybos augimas, %
Rugpjūtis	28	4,9	
Rugsėjis	42	6,1	35,80%
Spalis	36,5	5,5	17,30%

Ekonominiu požiūriu svarbus pokytis yra vidutinio gedimo šalinimo laiko sumažėjimas tarp rugsėjo ir spalio mėnesių. MTTR sumažėjo nuo 42 iki 36,5 minutės, tai yra vidutiniškai 5,5 minutės vienam

gedimui. Spalio mėnesį buvo užfiksuoti 87 gedimai, todėl bendra sutaupyto laiko suma siekė apie 478,5 minutes, arba maždaug 8 valandas. Atsižvelgiant į tai, kad 1 valandos įrangos prastova įmonei vidutiniškai kainuoja apie 1200 Eur, galima apskaičiuoti, jog per vieną mėnesį buvo išvengta iki maždaug 9576 Eur galimų nuostolių. Šis įvertinimas yra orientacinis ir atspindi potencialų finansinį efektą, jei laikoma, kad sutrumpėjęs gedimų šalinimo laikas tiesiogiai mažina prastovų trukmę. Realiai naudą gali veikti ir kiti veiksniai – pamainų organizavimas, gamybos planavimo lankstumas ar detalūs gedimų scenarijai – todėl DI indėlis į šį rezultatą vertintinas kaip vienas iš kelių prisidėjusių veiksnių.

Apibendrinant galima teigti, kad augant gamybos apimtims ir didėjant cecho apkrovai, techninis padalinys sugebėjo palaikyti arba pagerinti pagrindinius patikimumo rodiklius: sumažėjo gedimų skaičius 1000 gaminių, sumažėjo vidutinė gedimų šalinimo trukmė lyginant su didžiausio apkrovimo laikotarpiu, o vidutinis laikas tarp gedimų išliko ilgesnis nei pradžioje mėnesiu. Dirbtinio intelekto pagrindu sukurtas „GPT“ modelio taikymas prisidėjo prie to, kad technikai dažniau turėjo struktūruotą diagnostikos eigą, greičiau rasdavo galimas priežastis ir galėjo atsiremti į ankstesnių atvejų dokumentaciją. Nors dėl riboto tyrimo laikotarpio ir dviejų dalyvių skaičiaus negalima visų pokyčių tiesiogiai priskirti DI sistemai, gauti rezultatai rodo, kad tokio tipo priemonės turi potencialo mažinti diagnostikos trukmę, padėti valdyti didėjančią darbo krūvį ir kurti prielaidas mažesniems prastovų kaštams.

3.5. Rekomendacijos

Tyrimo rezultatai parodė, kad dirbtinio intelekto priemonių taikymas gali realiai prisidėti prie trumpesnio gedimų diagnostikos laiko, greitesnio žinių panaudojimo ir santykinio gedimų skaičiaus mažėjimo, net didėjant gamybos apimtims. Kartu paaiškėjo ir ribojantys veiksniai. Svarbiausi jų – duomenų kokybė, neišsamūs gedimų aprašymai ir tai, kad modelis, trūkstant informacijos, linkęs „užpildyti spragas“ prielaidomis. Todėl tolesnei DI integracijai techninio padalinio veikloje siūloma taikyti nuoseklų ir etapais išdėstytą požiūrį. Jis turėtų apimti sistemos pasirinkimą, darbo organizavimą, duomenų valdymą, saugų naudojimą ir ilgalaikę plėtros kryptį. Kiekviename etape svarbu aiškiai nusistatyti, kokį poveikį tikimasi pasiekti MTTR ir MTBF rodiklių atžvilgiu.

Pirma, prieš diegiant DI priemones būtina atsakingai pasirinkti pačią sistemą. Įmonė pirmiausia turėtų aiškiai įsivardyti poreikius: kokiems tikslams bus naudojamas DI (diagnostikai, dokumentacijos paieškai, mokymuisi), kokias sistemas jis turi pasiekti (CMMS, dokumentų saugykla), kokiomis kalbomis turi veikti. Remiantis šiais poreikiais verta sudaryti pagrindinių reikalavimų sąrašą ir juo vadovautis lyginant skirtingus sprendimus. Renkantis sistemą svarbu įvertinti integracijos galimybes, licencijavimo sąlygas, duomenų saugumo užtikrinimą ir tiekėjo techninį palaikymą. Tikslinga pradėti nuo bandomojo etapo, kuriame būtų lyginami keli variantai arba testuojamas vienas pasirinktas sprendimas realiomis sąlygomis. Bandomojo projekto metu rekomenduojama fiksuoti ne tik techninius rodiklius, bet ir darbuotojų atsiliepimus apie sistemos patogumą bei naudingumą. Tik įsitikinus, kad sprendimas atitinka įmonės poreikius ir duoda vertę, verta planuoti platesnį diegimą.

Antra, pasirinkus tinkamą sprendimą, DI priemonės reikėtų formaliai įtraukti į gedimų diagnostikos procesą. Svarbu, kad jos nebūtų naudojamos tik kaip „papildomas žaislas“, o taptų aiškiai apibrėžta proceso dalimi. Rekomenduojama parengti trumpą, bet privalomą standartizuotą procedūrą technikams. Joje turi būti nurodyta, kada DI naudojamas (pavyzdžiui, kai A arba B klasės gedimo diagnostika užtrunka ilgiau nei 10 minučių), kokią informaciją būtina pateikti (įrenginio kodą, klaidos pranešimą, pagrindinius simptomus, jau atliktus veiksmus) ir kaip dokumentuojamos gautos įžvalgos

„CMMS“ sistemoje. Naudinga parengti pavyzdinius užklausų šablonus ir trumpą instrukciją su ekrano nuotraukomis. Tai padėtų technikams greičiau perprasti, kaip formuluoti aiškius ir tikslius klausimus. Įvedant šią tvarką svarbu priminti, kad DI yra pagalbinė priemonė: galutiniai sprendimai dėl remonto ir saugos veiksmų išlieka technikų atsakomybė, o modelio rekomendacijos turi būti vertinamos kritiškai ir tikrinamos realiomis sąlygomis.

Trečia, norint, kad DI atsakymai būtų patikimi, būtina kryptingai kelti duomenų ir techninės dokumentacijos kokybę. Rekomenduojama centralizuoti įrenginių dokumentaciją, brėžinius ir instrukcijas, susiejant juos su konkrečiais įrenginių kodais ir tais pačiais identifikatoriais, kurie naudojami „CMMS“ sistemoje. Po kiekvieno remonto ar modifikacijos turėtų būti atnaujinami ne tik įrašai apie atliktus darbus, bet ir susiję dokumentai. Gedimų registravimui verta nustatyti privalomus laukus: gedimo kodą, faktinę priežastį, panaudotas detales, atliktus veiksmus ir rezultatą. Laisvo teksto laukus reikėtų palikti tik ten, kur tikrai reikia papildomų paaiškinimų, o kitur naudoti kodus ar pasirenkamus sąrašus. Tai padėtų sumažinti skirtingų formuluočių ir netikslių aprašymų kiekį. Praktinėje veikloje naudinga paskirti atsakingą asmenį (pvz., techninio padalinio vadovą ar inžinierių), kuris kartą per mėnesį peržiūrėtų naujausius įrašus, atkreiptų dėmesį į pasikartojančias klaidas ir inicijuotų korekcijas. Papildomai galima automatizuoti dokumentų perkėlimą iš „CMMS“ į DI naudojamus aplankus, kad modelis visada pasiektų naujausią informaciją ir nesiremtų pasenusiais failais. Tai leistų sistemai geriau matyti sąsajas tarp atliktų remontų ir perduoti svarbią informaciją kitai techninio padalinio pamainai net ir tada, kai darbuotojas jos neperduoda arba ją pamiršta. Taip būtų aiškiai susiejama, kokie darbai jau atlikti ir kuris technikas juos vykdė.

Ketvirta, stiprinant DI taikymą būtina užtikrinti duomenų saugumą ir aiškiai apibrėžti prieigos teises. Pirmiausia reikia nuspręsti, kur bus saugomi techniniai dokumentai ir gedimų istorija – vidiniuose įmonės serveriuose, debesijos sprendimuose ar DI paslaugos aplinkoje. Kiekvienam variantui būtina įvertinti kibernetinio saugumo, konfidencialumo ir veiklos tęstinumo rizikas. Tyrimo metu naudotas atskiras projektinis aplankas su ribota prieiga pasiteisino kaip praktiškas kompromisas. Tačiau plečiant sprendimą visai įmonei reikėtų įdiegti griežtesnį vartotojų autentifikavimą, sluoksniuotas prieigos teises pagal pareigas ir aiškias taisykles, kokia informacija gali būti perduodama DI sistemai. Pavyzdžiui, nesiųsti komercinių kainų, klientų duomenų ir asmens duomenų. Šias taisykles verta įforminti vidinė instrukcija ir periodiškai priminti darbuotojams mokymų ar susirinkimų metu. Tai padės sumažinti netyčinio duomenų nutekėjimo riziką ir užtikrins atsakingą technologijų naudojimą.

Žvelgiant į ateitį, DI sprendimus rekomenduojama palaipsniui plėsti nuo diagnostikos prie prognozuojamosios priežiūros. Tai turėtų būti daroma tik tada, kai diagnostikos etapas veikia stabiliai, o duomenų kokybė yra pakankama. Prognozuojamosios priežiūros modeliams nepakanka tik dokumentų ir istorinių gedimų aprašų. Reikia struktūrizuotų įrenginių apkrovos, sensorių, prastovų ir procesinių parametrų duomenų, kaupiamų per ilgesnį laiką. Pradiniame etape tikslinga pasirinkti vieną ar dvi kritines įrenginių grupes, pavyzdžiui, tas, kurios sukelia daugiausia prastovų arba generuoja didžiausius kaštus. Šiose grupėse galima kurti pilotinį prognozuojamosios priežiūros projektą. Jame būtina aiškiai nusistatyti tikslus: sumažinti neplanuotų prastovų skaičių, padidinti MTBF ar sumažinti prastovų kaštus tam tikru procentu. Atsižvelgiant į šio tyrimo rezultatus, rekomenduojama pirmiausia stabilizuoti DI taikymą gedimų diagnostikai, sutvarkyti duomenų ir dokumentacijos kokybę bei saugumo procesus, o tik tuomet etapais plėsti sprendimą prognozuojamosios priežiūros kryptimi. Toks nuoseklus kelias padėtų išvengti perteklinių investicijų ir užtikrintų, kad DI sprendimai kurtų apčiuopiamą vertę techniniam padaliniui ir visai gamybos sistemai.

3.6. Skyriaus apibendrinimas

Apibendrinant galima teigti, kad dirbtinio intelekto priemonių integravimas į techninio padalinio veiklą turi realią praktinę vertę ir gali reikšmingai pagerinti gedimų diagnostikos bei sprendimo procesus. Tyrimo rezultatai parodė, kad net didėjant gamybos apkrovai dirbtinio intelekto naudojimas padėjo sumažinti vidutinį gedimų šalinimo laiką, o santykinis gedimų skaičius tūkstančiui pagamintų gaminių išliko mažėjantis. Tai rodo, jog dirbtinis intelektas gali papildyti technikų kompetencijas ir suteikti reikalingas įžvalgas greičiau, nei naudojantis vien tradiciniais informacijos paieškos ir žodinės patirties perdavimo būdais. Vis dėlto galutiniams priežastiniams ryšiams pagrįsti būtinas ilgesnis ir platesnės apimties tyrimas, apimantis ilgesnį laikotarpį ir daugiau įrenginių grupių.

Efektyvi dirbtinio intelekto integracija reikalauja kokybiškos techninės dokumentacijos, nuoseklaus gedimų registravimo, patikimo duomenų saugojimo ir aiškiai apibrėžtų prieigos teisių. Tyrimas parodė, kad būtent duomenų kokybė ir gedimų aprašų tikslumas lemia, ar modelio atsakymai bus konkretūs ir praktiškai pritaikomi, ar pernelyg apibendrinti ir mažai naudingi. Todėl dirbtinis intelektas turi būti naudojamas kaip pagalbinė priemonė: galutiniai diagnostikos ir remonto sprendimai turi išlikti technikų atsakomybė, o modelio rekomendacijos – kritiškai vertinamos, atsižvelgiant į realias darbo sąlygas ir saugos reikalavimus. Nuoseklus sistemos tobulinimas, periodinė modelio veikimo analizė ir papildomų duomenų šaltinių integravimas sudaro prielaidas dar tikslesnei diagnostikai ir artėjančių gedimų identifikavimui. Atlikta įrenginių gedimų ir pagrindinių techninio padalinio rodiklių analizė realioje gamybos aplinkoje sudaro pagrindą ekonominei dirbtinio intelekto taikymo naudų ir kaštų analizei.

4. Ekonominė dalis

Šiame skyriuje atliekamas dirbtinio intelekto pagrindu sukurto sprendimo ekonominis vertinimas X įmonės techninio padalinio kontekste. Vertinimas grindžiamas realiais tyrimo laikotarpiu sukauptais duomenimis apie įrangos prastovas, remonto trukmę ir gamybos apimtis, taip pat „CV banko“ skelbiamais vidutiniais IT specialisto, techninio padalinio vadovo ir techninės priežiūros mechaniko darbo užmokesčio lūkesčiais. Pirmiausia įvertinamos vienkartinės diegimo sąnaudos – laikas, kurį IT specialistas ir techninio padalinio vadovas turi skirti sistemos parengimui ir dokumentacijos struktūravimui. Toliau apskaičiuojami mėnesiniai eksploatacijos kaštai, į kuriuos įtraukiama DI įrankio licencijos kaina ir periodinis darbuotojų išitraukimas sistemos palaikymui. Galiausiai, remiantis MTTR pokyčiu ir sumažėjusia įrangos prastovų trukme, įvertinama, kokio dydžio potencialią žalą įmonei padeda sumažinti taikoma DI priemonė, ir apskaičiuojamas jos atsiperkamumo laikotarpis skirtingais scenarijais.

4.1. Dirbtinio intelekto sprendimo įdiegimo kaštų įvertinimas

Tyrimo metu taikytas dirbtinio intelekto sprendimas buvo kurtas remiantis esama įmonės infrastruktūra – „Alldevice“ techninės priežiūros sistema ir turima įrangos dokumentacija. Tai leido išvengti didelių pradinių investicijų į naują programinę įrangą ar įrangos atnaujinimą, tačiau pareikalavo darbo laiko, skirto sistemos parengimui. Įdiegimo procesą sudarė keli pagrindiniai etapai: techninės dokumentacijos atranka ir struktūravimas, uždaro „GPT“ modelio sukūrimas ir testavimas, taip pat technikų apmokymai. Diegiant šią sistemą turi dalyvauti IT skyriaus specialistas ir techninio padalinio vadovas, kad būtų tinkamai parengta sistemos struktūra ir į ją perkeliama diagnostikai reikalinga informacija. Remiantis „CV banko“ duomenimis, vidutinis Informacinių technologijų palaikymo specialisto labiausiai tikėtinas mėnesio darbo užmokesčio lūkestis yra 2 447 Eur neatskaičius mokesčių [49], o techninio padalinio vadovo – 3 708 Eur [50], neatskaičius mokesčių. Daroma prielaida, kad vidutinė mėnesio darbo laiko trukmė yra 168 valandos, todėl IT specialisto valandinis darbo užmokestis sudaro apie 14,57 Eur /val. (2 447 Eur / 168 val.), o techninio padalinio vadovo – apie 22,07 Eur /val. (3 708 Eur / 168 val.). Įdiegti sistemą tyrimo atveju techninio padalinio vadovui prireikė 16 valandų vienam cechui, o įmonėje veikia trys tokie cechai, todėl bendra vadovo numatoma sąnauda sudaro 48 valandas (diegiant sekančius cechus laikas yra trumpesnis, nes jau yra sudaryti aplankai ir dalis įrenginių kartojasi). IT specialisto išitraukimas, susijęs su pradiniu sistemos paruošimu ir integravimu, truko apie 4 valandas (Prijungiant sekančius cechus naujo kodo nereikia). Taigi vienkartinės diegimo sąnaudos apskaičiuojamos taip: techninio padalinio vadovo kaina – 48 val. × 22,07 Eur /val. ≈ 1 059 Eur, IT specialisto – 4 val. × 14,57 Eur /val. ≈ 58 Eur, o bendra sistemos parengimo kaina įmonei siekia apie 1 118 Eur.

Sistemos eksploatavimo kaštai susideda iš licencijos mokesčio ir periodinių darbuotojų sąnaudų. Sistemos mėnesio kaina komandiniam darbui (pasirenkant metinį planą) yra 29 Eur. Vertinama, kad techninio padalinio vadovui per mėnesį reikės skirti apie 4 valandas naujų duomenų įkėlimui, esamų klaidų peržiūrai ir turinio atnaujinimui. Esant 22,07 Eur /val. valandinei kainai, tai sudaro apie 88,28 Eur per mėnesį. IT specialistui numatoma skirti vidutiniškai 2 valandas per mėnesį sistemos saugumo patikrai, smulkiems atnaujinimams ir techninei priežiūrai; tai sudarytų apie 29,14 Eur per mėnesį (2 val. × 14,57 Eur /val.). Bendra mėnesinė sistemos palaikymo kaina, įskaitant licenciją, yra apie 146 Eur (29 Eur + 88,28 Eur + 29,14 Eur = 146,42 Eur). Jeigu ateityje būtų įdiegtas automatinis dokumentų importas iš „CMMS“ sistemos į failų aplankus, tai techninio padalinio vadovui galėtų

sutaupyti apie 1 valandą darbo per mėnesį, tai yra maždaug 22 Eur ($1 \text{ val.} \times 22,07 \text{ Eur /val.}$), tačiau ši potenciali nauda į tolesnius skaičiavimus neįtraukiama ir vertinama kaip papildoma rezervo dalis.

Tyrimo rezultatai parodė, kad po DI priemonės įdiegimo vidutinis remonto laikas (MTTR) sumažėjo nuo maždaug 42 iki 36,5 minutės vienam gedimui, tai yra apie 5,5 minutės. Per tiriamą laikotarpį cecho buvo užfiksuoti 87 neplaniniai gedimai, todėl bendra sutrumpėjusi prastovų trukmė sudarė apie 478,5 minutės ($5,5 \text{ min} \times 87$), arba 7,98 valandos. Pagal įmonės vidaus vertinimą viena neplanuotos įrangos prastovos valanda vidutiniškai kainuoja apie 1 200 Eur, įskaitant prarastą produkcijos kiekį, darbo sąnaudas ir energijos kaštus. Atitinkamai $7,98 \text{ val.} \times 1 200 \text{ Eur /val.} \approx 9 576 \text{ Eur}$. Ši suma tolesniuose skaičiavimuose vertinama kaip orientacinė per vieną mėnesį sumažintos galimos žalos vertė, būdinga analizuotam cechui ir konkrečiam gamybos krūviui.

Svarbu pabrėžti, kad ne visa MTTR mažėjimo dalis gali būti tiesiogiai priskirta DI įrankio naudojimui. Gedimų šalinimo laikas taip pat priklauso nuo technikų patirties augimo, procesų organizavimo, operatorių įgūdžių ir gamybos planavimo pokyčių. Siekiant išvengti perteklinio DI efekto sureikšminimo, taikomas scenariinis požiūris ir daroma prielaida, kad DI priemonės prisidėjo tik prie dalies užfiksuoto prastovų sumažėjimo. Jei laikoma, kad DI įrankis lėmė 30 % MTTR sumažėjimo, jam tenkanti prastovų kaštų mažėjimo dalis sudarytų apie 2 873 Eur per mėnesį ($0,30 \times 9 576 \text{ Eur}$). Konservatyvesniu 15 % scenarijumi DI indėlis siektų apie 1 436 Eur per mėnesį, o optimistiškesniu 50 % scenarijumi – apie 4 788 Eur per mėnesį. Net ir labiausiai konservatyviu atveju DI kuriama ekonominė nauda kelis kartus viršija vien mėnesinės licencijos išlaidas, neįtraukiant darbuotojų darbo užmokesčio kaštų. Be to, šiuose skaičiavimuose atskirai neskaičiuojama techniko darbo laiko ekonominė nauda: remiantis „CV banko“ duomenimis, techninės priežiūros mechaniko labiausiai tikėtinas darbo ieškančio lūkestis yra 2 266 Eur per mėnesį [51], o tai, vertinant 168 valandų darbo mėnesį, sudaro apie 13,49 Eur /val. ($2 266 \text{ Eur} / 168 \text{ val.}$). Kiekviena sutrumpinta techniko darbo valanda papildomai mažina darbo sąnaudas, tačiau ši nauda čia vertinama tik per įrangos prastovų kaštų prizmę.

Šiame poskyryje pateikti skaičiavimai atspindi konkrečią X įmonės situaciją. Įmonė jau turi gerai veikiančią „CMMS“ sistemą ir savo serveriuose sukaupusi daug istorinių techninės priežiūros dokumentų, gedimų aprašymų ir kitos susijusios informacijos. Dėl to DI sprendimo diegimas buvo paprastesnis – nemaža dalis reikalingų duomenų buvo lengvai pasiekiami ir nereikėjo papildomų investicijų į duomenų rinkimą ar sistemų kūrimą nuo nulio. Kitų įmonių atveju, ypač jei „CMMS“ sistema neveikia pakankamai efektyviai arba techninė dokumentacija yra neišsami ir neišstruktūruota, tiek diegimo trukmė, tiek IT ir techninio padalinio darbuotojų kaštai gali reikšmingai skirtis ir būti gerokai didesni. Be to, ekonominis vertinimas šiame tyrime atliekamas tokiai pačiai supaprastintai sistemai, kokia buvo taikyta empiriniame eksperimente – naudojama esama „CMMS“ sistema, bazinė dokumentų atranka ir santykinai paprastas uždaras „GPT“ modelis. Jeigu įmonė siektų kurti gerokai išmanesnę DI sistemą (pvz., automatizuotą integraciją su keliomis vidinėmis sistemomis, išplėstinį auditą, personalizuotas rekomendacijas ar prognozavimo funkcijas), IT specialisto darbo valandų poreikis diegimo metu tikėtina būtų didesnis, o kai kuriais atvejais galėtų prireikti ir išorinio DI konsultanto paslaugų, kas padidintų pradinės investicijas.

Lyginant gautą naudą su anksčiau apskaičiuotais diegimo kaštais, galima įvertinti DI sprendimo atsiperkamumą. Vienkartinė investicija į sistemos parengimą sudarė apie 1 118 Eur, o mėnesiniai sistemos palaikymo kaštai – apie 146 Eur. Pagrindiniai skirtingų scenarijų skaičiavimo rezultatai pateikiami 11 lentelėje. Kaip matyti iš jos, esant 30 % scenarijui DI priemonė užtikrina apie 2 727

Eur grynos mėnesinės naudos, todėl vienkartinė investicija atsiperka maždaug per 0,41 mėnesio, tai yra per maždaug 12 kalendorinių dienų. Taikant atsargesnį 15 % scenarijų, grynoji mėnesinė nauda siekia apie 1 290 Eur, o atsiperkamumo laikotarpis – apie 0,87 mėnesio, tai yra maždaug 26 dienos. Tai rodo, kad jau per vieną intensyvesnę gamybos mėnesį DI priemonė gali pilnai padengti savo įdiegimo ir eksploatacijos kaštus, o vėlesniais mėnesiais generuoti gryną ekonominę naudą. Be to, tyrimo rezultatai atskleidžia, kad net ir paprasta, papildomų didelių investicijų nereikalaujanti DI sistema, paremta esamomis įmonės technologijomis ir dokumentacija, gali sukurti reikšmingą ekonominę naudą ir būti realiai pritaikoma gamybinėje aplinkoje.

11 lentelė. DI sprendimo atsiperkamumo scenarijų palyginimas

Scenarijus	Mėnesinė prastovų žalos sumažėjimo vertė, Eur	Mėnesiniai DI sistemos kaštai, Eur	Grynoji mėnesinė nauda, Eur	Atsiperkamumo laikotarpis, d.
30%	2 873	146	2 727	12
15%	1 436	146	1 290	26

Taip pat šioje analizėje pinigine išraiška įvertinta tik dalis DI sprendimo kuriamos naudos – sumažėjusi prastovų trukmė ir iš dalies efektyviau panaudojamas techniko darbo laikas. Nepiniginiai efektai, tokie kaip greitesnis naujų darbuotojų įvedimas, mažesnė klaidų tikimybė, didesnis technikų pasitikėjimas priimamų sprendimų kokybe ar sklandesnė žinių sklaida tarp pamainų, skaičiavimuose nebuvo įtraukti. Praktikoje šie veiksniai taip pat gali prisidėti prie mažesnio gedimų skaičiaus, trumpesnės diagnostikos trukmės ir retesnio pasikartojančių gedimų atsiradimo, todėl reali DI sprendimo sukurta ekonominė nauda tikėtina būtų didesnė, nei parodyta atliktuose skaičiavimuose.

4.2. Skyriaus apibendrinimas

Šio skyriaus ekonominė analizė parodė, kad po DI priemonės įdiegimo ceche per mėnesį sutrumpėjusi įrangos prastovų trukmė atitiko maždaug 9 576 Eur sumažintą galimą žalą. Konservatyviai vertinant, kad DI įrankis prisidėjo tik prie dalies šio pokyčio, jo indėlis gali siekti apie 1 436–4 788 Eur per mėnesį, priklausomai nuo taikomo scenarijaus. Lyginant šias sumas su vienkartinėmis diegimo sąnaudomis (apie 1 118 Eur) ir maždaug 146 Eur mėnesiniais palaikymo kaštais, matyti, kad sprendimas atsiperka per trumpesnę nei vieno mėnesio laikotarpį ir vėliau generuoja gryną ekonominę naudą. Tai leidžia teigti, kad net ir supaprastinta, esama „CMMS“ infrastruktūra paremta DI sistema gali užtikrinti reikšmingą finansinį efektą, mažinant prastovų kaštus ir efektyvinant techninio padalinio darbą.

Išvados

1. Nustatyta, kad techninio padalinio veiklos efektyvumas yra vienas pagrindinių gamybos stabilumą lemiančių veiksnių. Gamyklos X atveju kritinių įrenginių prastovos tiesiogiai stabdo gamybą, o viena neplanuotos prastovos valanda kainuoja apie 1 200 Eur, todėl MTTR ir MTBF rodiklių pokyčiai tiesiogiai veikia nuostolių dydį. Nustatyta, kad mažesnis MTTR ir didesnis MTBF leidžia išlaikyti gamybos tęstinumą ir patikimiau vykdyti planus augant gamybos apimtims.
2. Gamyklos X tiriamojo cecho įrenginių gedimų duomenų praktinė analizė parodė, kad didėjant gamybos apimtims santykinis gedimų skaičius 1 000 gaminių mažėjo (nuo 3,69 iki 2,35). Baziniu laikotarpiu iki dirbtinio intelekto taikymo MTTR padidėjo nuo 28 iki 42 minučių, o MTBF – nuo 4,9 iki 6,1 dienos, todėl nustatyta, kad gamybos stabilumą labiausiai riboja ilgesnė gedimų šalinimo trukmė, o ne gedimų dažnis.
3. Įdiegus dirbtinio intelekto modeliu pagrįstą pagalbos technikams įrankį, vidutinis gedimo šalinimo laikas (MTTR) sumažėjo nuo 42 iki 36,5 minutės (–13,1 %), nors gamybos apimtys tuo pačiu laikotarpiu augo apie 17 %. Tai leido per 87 gedimus sutrumpinti prastovas apie 8 valandomis ir potencialiai išvengti apie 9,6 tūkst. Eur nuostolių. Dėl trumpo tyrimo laikotarpio ir kitų veiksnių neįmanoma tiksliai atriboti, kokia šio pokyčio dalis tiesiogiai priskirtina dirbtinio intelekto sprendimui, tačiau net konservatyviai vertinant 15 % jo indėlį, sutaupymas sudarytų apie 1,4 tūkst. Eur per mėnesį, todėl nustatyta teigiama jo įtaka techninio padalinio darbo efektyvumui.
4. Parengtos rekomendacijos parodė, kad sėkmingam dirbtinio intelekto taikymui techniniame padalinyje būtina aiški naudojimo tvarka ir kokybiški, sistemingai kaupiami duomenys. Rekomenduojama centralizuoti įrenginių dokumentaciją, tvarkingai registruoti gedimus „CMMS“ sistemoje ir MTTR bei MTBF naudoti kaip pagrindinius efektyvumo rodiklius. Tai sudaro prielaidas nuosekliai mažinti prastovas ir ateityje plėtoti pažangesnius techninės priežiūros sprendimus.

Literatūros sąrašas

1. RODRIGUES, M. What's the Difference Between MTTR, MTBF, MTTD, and MTTF, 2024. Prieiga per internetą: <https://www.logicmonitor.com/blog/whats-the-difference-between-mttr-mtttd-mttf-and-mtbf> [žiūrėta 2025-09-15]
2. LUCERO, A. MTBF imperatyvas: ilgalaikio patikimumo užtikrinimas pramoniniuose Ethernet tinkluose, 2025. Prieiga per internetą: <https://fiberroad.com/lt/resources/resources/the-mtbf-imperative-ensuring-long-term-reliability-in-industrial-ethernet-networks/> [žiūrėta 2025-11-20]
3. RAZA, M. What's MTTR? Mean Time to Repair: Definitions, Tips, & Challenges, 2024. Prieiga per internetą: https://www.splunk.com/en_us/blog/learn/mttr-mean-time-to-repair.html [žiūrėta 2025-09-15]
4. SHARIF, A. Mean Time to Repair Explained, 2022. Prieiga per internetą: <https://www.crowdstrike.com/en-us/cybersecurity-101/next-gen-siem/mean-time-to-repair-mttr/> [žiūrėta 2025-09-16]
5. PRASAD, H. B.; BHARDWAJ, M. An Integrated Maintenance Management: A Practical Approach, 2019. Prieiga per internetą: https://link.springer.com/chapter/10.1007/978-981-15-8704-7_17 [žiūrėta 2025-09-15]
6. ACHOUCH, M.; DIMITROVA, M.; ZIANE, K.; KARGANROUDI, S. S.; DHOUIB, R.; IBRAHIM, H.; ADDA, M. On predictive maintenance in industry 4.0: Overview, models, and challenges, 2022. Prieiga per internetą: <https://www.mdpi.com/2076-3417/12/16/8081> [žiūrėta 2025-09-18]
7. DEREČI, U.; TUZKAYA, G. An explainable artificial intelligence model for predictive maintenance and spare parts optimization, 2024. Prieiga per internetą: <https://www.sciencedirect.com/science/article/pii/S2949863524000219> [žiūrėta 2025-09-21]
8. BENHANIFIA, A.; CHEIKH, Z. B.; OLIVEIRA, P. M.; VALENTE, A.; LIMA, J. Systematic review of predictive maintenance practices in the manufacturing sector, Intelligent Systems with Applications, 2025. Prieiga per internetą: <https://www.sciencedirect.com/science/article/pii/S2667305325000274> [žiūrėta 2025-09-21]
9. GIDDENS, A. AI in Maintenance: 9 Ways To Revolutionize Your Operations, 2024. Prieiga per internetą: <https://upkeep.com/blog/how-ai-is-revolutionizing-maintenance-and-reliability/> [žiūrėta 2025-09-21]
10. ZACHARIADES, C.; XAVIER, V. A Review of Artificial Intelligence Techniques in Fault Diagnosis of Electric Machines, 2025. Prieiga per internetą: <https://www.mdpi.com/1424-8220/25/16/5128> [žiūrėta 2025-09-23]
11. CAÇÃO, J.; SANTOS, J.; ANTUNES, M. Explainable AI for industrial fault diagnosis: A systematic review, Journal of Industrial Information Integration, 2025. Prieiga per internetą: <https://www.sciencedirect.com/science/article/pii/S2452414X25001281> [žiūrėta 2025-09-23]
12. BRADAČ HOJNIK, B.; HUĐEK, I. Small and medium-sized enterprises in the digital age: Understanding characteristics and essential demands, 2023. Prieiga per internetą: <https://www.mdpi.com/2078-2489/14/11/606> [žiūrėta 2025-09-18]
13. HOLLIDAY, M. 14 Onboarding Mistakes to Avoid, 2025. Prieiga per internetą: <https://www.netsuite.com/portal/resource/articles/human-resources/onboarding-mistakes-problems.shtml> [žiūrėta 2025-09-21]

14. BOYES, D. Tips for Automotive Technician Onboarding, 2025. Prieiga per internetą: <https://www.todaysclass.com/blog/tips-for-automotive-technician-onboarding-todays-class> [žiūrėta 2025-09-21]
15. RACHEL, K.; OYEINKORIKIYE, S. An Exploration of Effective Onboarding on Employee Engagement and Retention in Work Organizations, 2024. Prieiga per internetą: https://www.researchgate.net/publication/379689942_An_Exploration_Of_Effective_Onboarding_On_Employee_Engagement_And_Retention_In_Work_Organizations [žiūrėta 2025-09-15]
16. TRISCA, L. How to Use AI in Employee Onboarding: 7 Key Use Cases to Drive Success, 2025. Prieiga per internetą: <https://www.deel.com/blog/ai-employee-onboarding/> [žiūrėta 2025-09-21]
17. Alldevice. Alldevice, Svetainė, 2025. Prieiga per internetą: <https://www.alldevice.com/lt/> [žiūrėta 2025-10-25]
18. LUNDGREN, C.; SKOOGH, A.; BOKRANTZ, J. Quantifying the effects of maintenance – a literature review of maintenance models, 2018. Prieiga per internetą: https://research.chalmers.se/publication/507434/file/507434_Fulltext.pdf [žiūrėta 2025-09-15]
19. TORELL, W.; AVELAR, V. Mean time between failure: Explanation and standards, White Paper, 2004. Prieiga per internetą: https://www.researchgate.net/publication/251895269_Mean_Time_Between_Failure_Explanation_and_Standards [žiūrėta 2025-09-20]
20. EISNER, C. MTBF and MTTR: What's the Difference?, 2025. Prieiga per internetą: <https://www.getmaintainx.com/blog/mtbf-and-mttr-whats-the-difference> [žiūrėta 2025-10-01]
21. NEUMEIER, S. 4 Proven Ways to Reduce MTTR and Strengthen System Reliability, 2025. Prieiga per internetą: <https://blog.paessler.com/4-proven-ways-to-reduce-mttr-and-strengthen-system-reliability> [žiūrėta 2025-10-02]
22. KHANDA, R. Agentic AI-Driven Technical Troubleshooting for Enterprise Systems, 2024. Prieiga per internetą: <https://arxiv.org/html/2412.12006v2> [žiūrėta 2025-10-02]
23. CASSANO, B. Turn Manuals into Insights with AI Document Analysis (AI Document Analysis Features Spotlight), 2025. Prieiga per internetą: <https://traction.com/en/blog/ai-maintenance-knowledge-automation-features> [žiūrėta 2025-10-05]
24. KUMAR, S. Designing the Intelligent Contact Center: Human–AI Collaboration in Real-Time Customer Service, 2025. Prieiga per internetą: <https://ejournals.org/wp-content/uploads/sites/21/2025/05/Designing-the-Intelligent-Contact-Center.pdf> [žiūrėta 2025-10-05]
25. BIRKINS, J. AI-Based Retrieval, Q&A, and Industry Document Generation for Nuclear Energy and Oil & Gas, 2025. Prieiga per internetą: <https://medium.com/@joycebirkins/ai-based-retrieval-q-a-and-industry-document-generation-for-nuclear-energy-and-oil-gas-2025-c5c6a6bd7068> [žiūrėta 2025-10-05]
26. DUARTE, F. Number of ChatGPT Users (October 2025), 2025. Prieiga per internetą: <https://explodingtopics.com/blog/chatgpt-users> [žiūrėta 2025-10-05]
27. MATIJA GOLUBOVIC. AI Search Industry Report 2025: Key Trends & Market Insights, Prieiga per internetą: <https://www.omnius.so/blog/ai-search-industry-report> [žiūrėta 2025-10-25]

28. BENCHAITA, S. Data Suggests Growth in Enterprise Adoption of AI is Due to Widespread Deployment by Early Adopters, But Barriers Keep 40% in the Exploration and Experimentation Phases, 2024. Prieiga per internetą: <https://newsroom.ibm.com/2024-01-10-Data-Suggests-Growth-in-Enterprise-Adoption-of-AI-is-Due-to-Widespread-Deployment-by-Early-Adopters> [žiūrėta 2025-10-12]
29. FERNANDEZ, J. The Leading Generative AI Companies, 2025. Prieiga per internetą: <https://iot-analytics.com/leading-generative-ai-companies/> [žiūrėta 2025-10-06]
30. FARAH, J. Humata AI: Alternatives to Chat with PDF like ChatGPT, 2024. Prieiga per internetą: <https://blog.invgate.com/humata-ai> [žiūrėta 2025-10-25]
31. OPENAI. ChatGPT, Svetainė, 2025. Prieiga per internetą: <https://chatgpt.com/overview> [žiūrėta 2025-10-05]
32. TIMONERA, K. Comprehensive ChatGPT Review: Latest Features, Pros, and Cons, 2024. Prieiga per internetą: <https://www.eweek.com/artificial-intelligence/chatgpt-review> [žiūrėta 2025-10-14]
33. VALCHANOV, L. ChatGPT Review: Is It Worth It in 2025? [In-Depth], 2025. Prieiga per internetą: <https://team-gpt.com/blog/chatgpt-review> [žiūrėta 2025-10-15]
34. IBM. IBM Watson Discovery, Svetainė, 2025. Prieiga per internetą: <https://www.ibm.com/products/watson-discovery> [žiūrėta 2025-10-18]
35. PUTRI, S.; PANGAN, K. An Honest Look at Watson AI Reviews in 2025, 2025. Prieiga per internetą: <https://www.eesel.ai/blog/watson-ai-reviews> [žiūrėta 2025-10-18]
36. OLAWANLE, J. How to Use IBM Watson for Business Analytics, 2025. Prieiga per internetą: <https://verpex.com/blog/marketing-tips/how-to-use-ibm-watson-for-business-analytics-and-insights> [žiūrėta 2025-10-18]
37. SPATARO, J. Introducing Microsoft 365 Copilot – Your Copilot for Work, 2023. Prieiga per internetą: <https://blogs.microsoft.com/blog/2023/03/16/introducing-microsoft-365-copilot-your-copilot-for-work> [žiūrėta 2025-10-12]
38. GRALLA, P. Copilot for Microsoft 365 Deep Dive: Productivity at a Steep Price, 2024. Prieiga per internetą: <https://www.computerworld.com/article/2513395/copilot-for-microsoft-365-review-hands-on-deep-dive.html> [žiūrėta 2025-10-18]
39. GARRY, G. Azure AI vs AWS AI – Which Cloud AI Platform Wins in 2025?, 2025. Prieiga per internetą: <https://empathy-technologies.com/azure-ai-vs-aws-ai-which-is-better> [žiūrėta 2025-10-22]
40. MICROSOFT. Microsoft Azure AI, Svetainė, 2025. Prieiga per internetą: <https://azure.microsoft.com/en-us/solutions/ai> [žiūrėta 2025-10-25]
41. HARISUDHAN, S. Azure Open AI vs Azure AI Services vs Azure AI Foundry, 2025. Prieiga per internetą: <https://www.sharepointeurope.com/azure-open-ai-vs-azure-ai-services-vs-azure-ai-foundry> [žiūrėta 2025-10-17]
42. Humata AI. Humata AI, Svetainė, 2025. Prieiga per internetą: <https://www.humata.ai> [žiūrėta 2025-10-20]
43. PREISER, A. Humata AI Review 2025, 2024. Prieiga per internetą: <https://www.wpcrafter.com/review/humata-ai> [žiūrėta 2025-10-22]
44. ChatDOC. ChatDOC, Svetainė, 2025. Prieiga per internetą: <https://chatdoc.com> [žiūrėta 2025-10-23]
45. BOUCHRIKA, I. ChatDOC Review 2025: Pricing, Features, Pros & Cons, Ratings & More, 2025. Prieiga per internetą: <https://research.com/software/reviews/chatdoc> [žiūrėta 2025-10-24]


46. SAMUE, A. ChatDOC AI Review 2025: Features, Pros, Cons & Alternatives, 2024. Prieiga per internetą: <https://ai.tenorshare.com/comparisons-and-reviews/chatdoc-review.html> [žiūrėta 2025-10-25]
47. EUROPEAN COMMISSION. AI Act, 2024. Prieiga per internetą: <https://digital-strategy.ec.europa.eu/en/policies/regulatory-framework-ai> [žiūrėta 2025-10-19]
48. ADOMAITIS, N.; GRINCEVIČIUS, T.; MATUKAITĖ, L.; BITINAS, V.; GRIGALIŪNAS, Š.; ZIGMANTAS, L.; TICHONOV, J.; VITKUS, D. Generatyvinio dirbtinio intelekto (GenDI) saugaus naudojimo organizacijoje gairės, 2024. Prieiga per internetą: https://www.nksc.lt/doc/biuletiniai/2024_Generatyvinio_dirbtinio_intelektio_organizacijoje_naudojimo_gaires.pdf [žiūrėta 2025-10-20]
49. CVBANKAS. IT palaikymo specialisto atlyginimų statistika, Svetainė, 2025. Prieiga per internetą:
https://www.cvbankas.lt/atlyginimai/statistika.html?position=IT+palaikymo+specialistas&position_key=IT+Support+Specialist&location= [žiūrėta 2025-11-18]
50. CVBANKAS. Techninio skyriaus vadovo atlyginimų statistika, Svetainė, 2025. Prieiga per internetą:
https://www.cvbankas.lt/atlyginimai/statistika.html?position=Techninio+skyriaus+vadovas&position_key=Head+of+Technical+Department&location= [žiūrėta 2025-11-18]
51. CVBANKAS. Maintenance Mechanic atlyginimų statistika, Svetainė, 2025. Prieiga per internetą:
https://www.cvbankas.lt/atlyginimai/statistika.html?position_key=Maintenance+Mechanic [žiūrėta 2025-11-18]

Priedai

1 priedas. Gedimo fiksavimo ir šalinimo schema

2 priedas. Gedimo šalinimo schema

1 Priedas. Gedimo fiksavimo ir šalinimo schema



2 Priedas. Gedimo šalinimo schema

