



Kauno technologijos universitetas

Ekonomikos ir verslo fakultetas

Didžiųjų duomenų ir ekspertinių įžvalgų integravimas į dirbtinio intelekto finansinių prognozių sprendimus

Magistro baigiamasis projektas

Aistė Čirvinskaitė

Projekto autorė

Doc. dr. Kęstutis Duoba

Vadovas

Kaunas, 2026



Kauno technologijos universitetas

Ekonomikos ir verslo fakultetas

Didžiųjų duomenų ir ekspertinių įžvalgų integravimas į dirbtinio intelekto finansinių prognozių sprendimus

Magistro baigiamasis projektas

Inovacijų valdymas ir antreprenerystė (6211LX031)

Aistė Čirvinskaitė

Projekto autorė

Doc. dr. Kęstutis Duoba

Vadovas

Doc. dr. Inga Stankevičė

Recenzentė

Kaunas, 2026



Kauno technologijos universitetas

Ekonomikos ir verslo fakultetas

Aistė Čirvinskaitė

Didžiųjų duomenų ir ekspertinių įžvalgų integravimas į dirbtinio intelekto finansinių prognozių sprendimus

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.

Aistė Čirvinskaitė

Patvirtinta elektroniniu būdu

Čirvinskaitė, Aistė. Didžiųjų duomenų ir ekspertinių įžvalgų integravimas į dirbtinio intelekto finansinių prognozių sprendimus. Magistro baigiamasis projektas / vadovas doc. dr. Kęstutis Duoba; Kauno technologijos universitetas, Ekonomikos ir verslo fakultetas.

Studijų kryptis ir sritis (studijų krypčių grupė): Vadyba, Verslas ir viešoji vadyba.

Reikšminiai žodžiai: didieji duomenys, ekspertinės įžvalgos, dirbtinis intelektas, finansinių prognozių modeliai, integracija.

Kaunas, 2026. 76 p.

Santrauka

Šiame darbe analizuojamos didžiųjų duomenų ir ekspertinių įžvalgų integravimo į dirbtinio intelekto finansinių prognozių sprendimus galimybės bei problematika. Temos aktualumą lemia spartus duomenų kiekio augimas, finansinių procesų sudėtingumas ir vis platesnis dirbtinio intelekto taikymas finansų analitikoje. Nors dirbtinio intelekto modeliai leidžia efektyviai apdoroti didelius duomenų kiekius ir identifikuoti sudėtingus dėsningumus, finansinių prognozių sudaryme vis dar svarbų vaidmenį atlieka ekspertinės žinios ir vadovų sprendimai.

Darbo tikslas – pagrįsti didžiųjų duomenų ir ekspertinių įžvalgų integravimo į dirbtinio intelekto finansinių prognozių sprendimus modelį. Tyrimo metu nustatyta, kad tradiciniai finansinių prognozių metodai susiduria su nestacionarumo, režimų kaitos, nelineariųjų ryšių bei riboto kontekstinės informacijos integravimo problemomis. Taip pat išryškintos duomenų kokybės, prognozių paaiškinamumo ir ekspertinių žinių sisteminio integravimo problemos.

Teorinėje darbo dalyje išanalizuoti didžiųjų duomenų, dirbtinio intelekto ir ekspertinių žinių integravimo principai bei suformuotas integruotas finansinių prognozių modelis, jungiantis Zhuang ir kt. (2017) AI 2.0 koncepciją ir Park ir kt. (2023) adaptyvų ekspertinių žinių integravimo mechanizmą. Modelyje dirbtinis intelektas generuoja bazinę prognozę, o ekspertinių žinių svoris priklauso nuo situacijos reprezentatyvumo istoriniuose duomenyse.

Empiriniam tyrimui pasirinktas pusiau struktūruotas ekspertinis interviu, leidžiantis analizuoti finansų specialistų požiūrį į dirbtinio intelekto taikymą finansinių prognozių sudaryme. Tyrimo rezultatai parodė, kad organizacijose prognozės dažniausiai grindžiamos istoriniais duomenimis ir statistiniais modeliais, tačiau reikšmingą vaidmenį išlaiko ekspertinės korekcijos bei vadovų įžvalgos. Nustatyta, kad dirbtinis intelektas padeda automatizuoti analizę ir identifikuoti sudėtingus dėsningumus, tačiau išlieka pasitikėjimo, prognozių paaiškinamumo ir duomenų kokybės problemos. Atliktas tyrimas leidžia teigti, kad efektyvus finansinių prognozių sudarymas ateityje bus grindžiamas hibriniais sprendimais, integruojančiais didžiuosius duomenis, ekspertines žinias ir paaiškinamus dirbtinio intelekto modelius.

Čirvinskaitė, Aistė. Integration of Big Data and Expert Insights into AI-Driven Financial Forecasting Decisions. Master's Final Degree Project / supervisor Assoc. Prof. Kęstutis Duoba; School of Economics and Business, Kaunas University of Technology.

Study field and area (study field group): Management, Business and Public Management.

Keywords: Big Data, Expert Knowledge, Artificial Intelligence, Financial Forecast Models, Integration.

Kaunas, 2026. 76.

Summary

This paper analyzes the possibilities and challenges of integrating Big Data and expert insights into artificial intelligence-based financial forecasting solutions. The relevance of the topic is driven by the rapid growth of data volumes, the increasing complexity of financial processes, and the expanding application of artificial intelligence in financial analytics. Although artificial intelligence models enable efficient processing of large amounts of data and identification of complex patterns, financial forecasting still heavily relies on expert knowledge and managerial decision-making.

The aim of the study is to substantiate a model for integrating Big Data and expert insights into artificial intelligence-based financial forecasting solutions. The research revealed that traditional financial forecasting methods face challenges related to non-stationarity, regime shifts, nonlinear relationships, and the limited ability to integrate contextual information. In addition, issues related to data quality, forecast explainability, and the systematic integration of expert knowledge were identified.

The theoretical part of the paper analyzes the principles of integrating Big Data, artificial intelligence, and expert knowledge, and develops an integrated financial forecasting model combining the AI 2.0 conceptual framework proposed by Zhuang et al. (2017) and the adaptive expert knowledge integration mechanism proposed by Park et al. (2023). In the model, artificial intelligence generates the baseline forecast, while the weight of expert knowledge depends on how representative the current situation is within historical data.

A semi-structured expert interview method was selected for the empirical research, enabling an in-depth analysis of finance professionals' perspectives on the application of artificial intelligence in financial forecasting. The research results revealed that financial forecasts in organizations are primarily based on historical data and statistical models, while expert adjustments and managerial insights continue to play a significant role. It was found that artificial intelligence helps automate analysis and identify complex patterns; however, issues related to trust, forecast explainability, and data quality remain significant.

The findings of the study suggest that effective financial forecasting in the future will be based on hybrid solutions integrating Big Data, expert knowledge, and explainable artificial intelligence models.

Turinys

Lentelių sąrašas.....	6
Paveikslų sąrašas.....	7
Įvadas	8
1. Didžiųjų duomenų ir ekspertinių įžvalgų integravimo į dirbtinio intelekto finansinių prognozių sprendimus problemos analizė.....	10
2. Didžiųjų duomenų ir ekspertinių įžvalgų integravimo į dirbtinio intelekto finansinių prognozių sprendimus teorinė analizė	19
2.1. Finansinių prognozių sudarymo teoriniai principai ir vertinimo logika dirbtinio intelekto taikymo kontekste.....	19
2.2. Didžiųjų duomenų analitikos teoriniai sprendimai finansuose.....	21
2.3. Dirbtinio intelekto metodai finansinių prognozių sudaryme	23
2.4. Ekspertinių žinių formalizavimo ir integravimo teoriniai sprendimai dirbtinio intelekto prognozėse.....	25
2.5. Didžiųjų duomenų ir ekspertinių įžvalgų integravimo į dirbtinio intelekto finansinių prognozių sprendimus modeliai	27
2.5.1. Integruoti finansiniai prognozavimo modeliai.....	27
2.5.2. Integruotų finansinių prognozavimo modelių analizė.....	32
2.6. Didžiųjų duomenų ir ekspertinių įžvalgų integravimo į dirbtinio intelekto finansinių prognozių sprendimus teorinis modelis	34
3. Didžiųjų duomenų ir ekspertinių įžvalgų integravimo į dirbtinio intelekto finansinių prognozių sprendimus tyrimo metodologija	40
4. Didžiųjų duomenų ir ekspertinių įžvalgų integravimo į dirbtinio intelekto finansinių prognozių sprendimus empirinis tyrimas	44
4.1. Tyrimo informantų pristatymas	44
4.2. Teminės analizės rezultatai.....	46
4.3. Didžiųjų duomenų ir ekspertinių įžvalgų integravimo į dirbtinio intelekto finansinių prognozių sprendimus modeliai vertinimas	60
4.4. Didžiųjų duomenų ir ekspertinių įžvalgų integravimo į dirbtinio intelekto finansinių prognozių sprendimus koreguotas modelis.....	63
4.5. Diskusija	67
Išvados	72
Literatūros sąrašas.....	73
Priedai	77
1 priedas. Interviu transkriptas Nr. 1	77
2 priedas. Interviu transkriptas Nr. 2	81
3 priedas. Interviu transkriptas Nr. 1	89
4 priedas. Interviu transkriptas Nr. 1	96
5 priedas. Interviu transkriptas Nr. 1	99
6 priedas. Interviu transkriptas Nr. 1	101

Lentelių sąrašas

1 lentelė. Finansinių prognozių sudarymo teoriniai principai ir vertinimo logika dirbtinio intelekto taikymo kontekste	19
2 lentelė. Didžiųjų duomenų analitikos teoriniai sprendimai finansuose	21
3 lentelė. Dirbtinio intelekto metodai finansinių prognozių sudaryme	23
4 lentelė. Ekspertinių žinių formalizavimo ir integravimo teoriniai sprendimai dirbtinio intelekto prognozėse.....	26
5 lentelė. Integruotų finansinių prognozavimo modelių analizė	32
6 lentelė. Tyrimo klausimynas	42
7 lentelė. Tyrimo informantų pristatymas.....	44
8 lentelė. Finansinių prognozių daugialypiškumas ir skirtingi prognozavimo horizontai	46
9 lentelė. Prognozavimas kaip kolektyvinis ir tarpdisciplininis procesas	48
10 lentelė. Istoriniai duomenys kaip bazė, bet ne galutinė prognozės tiesa	49
11 lentelė. Ekspertinių žinių vaidmuo prognozavimo procese	50
12 lentelė. Skepticizmas autonominio dirbtinio intelekto atžvilgiu	52
13 lentelė. Dirbtinis intelektas kaip pagalbinė, o ne strateginė priemonė	54
14 lentelė. Duomenų kokybės svarba prognozių tikslumui	55
15 lentelė. Prognozavimas kaip nuolatinis tikslinimo ir kontrolės procesas	57
16 lentelė. Sektoriaus specifikos įtaka prognozavimo logikai	59
17 lentelė. Didžiųjų duomenų ir ekspertinių įžvalgų integravimo į dirbtinio intelekto finansinių prognozių sprendimus modeliai vertinimas	60

Paveikslų sąrašas

1 pav. Literatūros žemėlapis	13
2 pav. Probabilistinis grafinis modelis	28
3 pav. Korekcinis modelis.....	29
4 pav. Technologinis modelis	30
5 pav. Adaptacinis modelis	31
6 pav. Konceptualus DI 2.0 modelis	32
7 pav. Didžiųjų duomenų ir ekspertinių įžvalgų integravimo į dirbtinio intelekto finansinių prognozių sprendimus teorinis modelis	35
8 pav. Koreguotas modelis.....	65

Ivadas

Pastaraisiais metais finansinių prognozių sudarymas išgyvena reikšmingą transformaciją, kurią lemia spartus duomenų apimčių augimas, skaitmenizacija ir dirbtinio intelekto (DI) metodų plėtra. Organizacijos vis dažniau susiduria su situacija, kai tradiciniai statistiniai prognozavimo metodai nebepajėgia efektyviai apdoroti didelio masto, heterogeniškų ir greitai kintančių duomenų srautų. Šiame kontekste dirbtinio intelekto taikymas finansinėse prognozėse tampa viena svarbiausių inovacijų krypčių, leidžiančių analizuoti sudėtingus nelinearinius ryšius, integruoti alternatyvius duomenų šaltinius bei didinti prognozių tikslumą ir prisitaikomumą prie dinamiškos aplinkos (Tang et al., 2022; Cao et al., 2024).

Nepaisant spartaus dirbtinio intelekto metodų vystymosi, mokslinėje literatūroje ir praktikoje vis dažniau akcentuojama, kad vien algoritminiai sprendimai neužtikrina patikimų ir organizacijų sprendimų priėmimui tinkamų finansinių prognozių. Finansinių prognozių sudarymas praktikoje vis dar stipriai priklauso nuo ekspertinių žinių, vadovų patirties bei kontekstinės informacijos apie rinkos pokyčius, strateginius organizacijos sprendimus ar netipinius įvykius. Tokios išvalgos dažnai nėra formalizuotos ir lieka už statistinių modelių ribų, todėl organizacijose susidaro atotrūkis tarp duomenimis grįstų prognozių ir realaus sprendimų priėmimo proceso (Park et al., 2023; Franses, 2024).

Papildomą sudėtingumą finansinių prognozių srityje sukuria didžiųjų duomenų problematika. Nors dideli duomenų kiekiai suteikia galimybę plačiau analizuoti organizacijos veiklą ir išorinę aplinką, praktikoje išryškėja duomenų kokybės, nestacionarumo, triukšmo bei prognozių paaiškinamumo problemos. Finansų srityje prognozės naudojamos aukšto lygmens sprendimams, todėl organizacijoms tampa svarbu ne tik prognozės tikslumas, bet ir jos pagrįstumas, aiškumas bei galimybė interpretuoti modelio sprendimų logiką (Mohammed et al., 2025; Dessaint et al., 2024). Dėl šios priežasties vis aktualesnis tampa klausimas, kaip sistemiskai integruoti didžiuosius duomenis, dirbtinio intelekto metodus ir ekspertines žinias į vientisą finansinių prognozių sudarymo sistemą.

Mokslinėje literatūroje daug dėmesio skiriama atskirų prognozavimo metodų efektyvumui, tačiau vis dar trūksta tyrimų, analizuojančių, kaip praktiškai derinti didžiųjų duomenų analitiką, dirbtinį intelektą ir ekspertines išvalgas viename adaptyviame prognozavimo procese. Taip pat išlieka nepakankamai išspręstas ekspertinių žinių formalizavimo klausimas bei žmogaus ir dirbtinio intelekto sąveikos problema finansinių prognozių sudaryme. Tai pagrindžia nagrinėjamos temos aktualumą tiek teoriniu, tiek praktiniu požiūriu.

Tyrime taikomi metodai: mokslinės literatūros analizė, sisteminimas ir lyginimas, teorinių modelių analizė, pusiau struktūruotas ekspertinis interviu bei teminė kokybinė duomenų analizė.

Darbo struktūrą sudaro keturios pagrindinės dalys. Pirmojoje darbo dalyje analizuojama didžiųjų duomenų, dirbtinio intelekto ir ekspertinių žinių integravimo problematika finansinių prognozių kontekste. Antrojoje dalyje nagrinėjami teoriniai sprendimai ir formuojamas integruotas finansinių prognozių modelis. Trečiojoje darbo dalyje pristatoma tyrimo metodologija, o ketvirtojoje – pateikiami ir analizuojami empirinio tyrimo rezultatai, vertinamas bei koreguojamas teorinis modelis. Darbo pabaigoje pateikiamos išvados, diskusija ir rekomendacijos tolimesniems tyrimams.

Tyrimo objektas – finansinių prognozių sprendimai.

Tyrimo tikslas – pagrįsti didžiųjų duomenų ir ekspertinių įžvalgų integravimo į dirbtinio intelekto finansinių prognozių sprendimus modelį.

Siekiant įgyvendinti tyrimo tikslą, darbe keliami šie **uždaviniai**:

- Išanalizuoti didžiųjų duomenų ir ekspertinių įžvalgų integravimo į dirbtinio intelekto finansinių prognozių sudarymo problematiką mokslinėje literatūroje;
- Teoriškai pagrįsti didžiųjų duomenų ir ekspertinių įžvalgų integravimo į dirbtinio intelekto finansinių prognozių sprendimus.
- Suformuoti tyrimo metodologiją, skirtą didžiųjų duomenų ir ekspertinių įžvalgų integravimo į dirbtinio intelekto finansinių prognozių sprendimus modelio patikrinimui.
- Patikrinti didžiųjų duomenų ir ekspertinių įžvalgų integravimo į dirbtinio intelekto finansinių prognozių sprendimus empiriniu tyrimu.

***Mokslinė problema** - Kaip integruoti didžiuosius duomenis ir ekspertines įžvalgas į dirbtinio intelekto finansinių prognozių sprendimus?*

1. Didžiųjų duomenų ir ekspertinių įžvalgų integravimo į dirbtinio intelekto finansinių prognozių sprendimus problemos analizė

Šiame skyriuje analizuojama finansinių prognozių sudarymo problematika, išskiriant pagrindinius tradicinių metodų ribotumus, didžiųjų duomenų taikymo iššūkius, ekspertinių žinių vaidmenį bei jų integracijos su statistiniais modeliais trūkumus.

Finansinių prognozių reikšmė organizacijų sprendimų priėmime

Finansinės prognozės yra vienas svarbiausių organizacijų valdymo instrumentų, leidžiančių struktūruotai numatyti būsimus finansinius srautus, įvertinti rizikas ir pagrįsti strateginius bei operacinius sprendimus (Olaniyan et al., 2024). Dinamiškoje ir neapibrėžtoje verslo aplinkoje prognozės tampa ne tik planavimo priemone, bet ir „bendraja kalba“, sujungiančia finansų padalinio, vadovybės ir kitų funkcinių sričių lūkesčius dėl ateities rezultatų. Praktikoje prognozės dažniausiai naudojamos biudžetavimo procesuose, likvidumo ir apyvartinio kapitalo valdyme, investicijų planavime, finansavimo poreikio nustatyme ir veiklos efektyvumo stebėsenoje.

Mokslinėje literatūroje pabrėžiama, kad prognozės atlieka ne tik „skaičiavimo“ funkciją, bet ir formuoja sprendimų priėmimo elgseną. Simon ir Shrader (2022) teigia, jog finansinės prognozės gali tapti atskaitos taškais (angl. reference points), pagal kuriuos vertinami faktiniai rezultatai ir priimami rizikingesni arba konservatyvesni sprendimai. Kitaip tariant, prognozė sukuria konkretų lūkestį (pvz., pajamų ar pelno lygį), o nukrypimai nuo jo gali keisti vadovų rizikos toleranciją, veiksmų intensyvumą ar net strateginių iniciatyvų pasirinkimą. Tikslūs finansiniai prognozavimai padeda įmonėms ir investuotojams priimti pagrįstus sprendimus, kas leidžia geriau paskirstyti išteklius, kurti investavimo strategijas ir formuluoti įmonės ir finansų politiką (Olaniyan et al., 2024). Tai aktualu finansinių prognozių kontekste, nes jų kokybė ir interpretacija turi tiesiogines pasekmes sprendimams – nuo investicijų atidėjimo iki agresyvesnės plėtros ar kaštų mažinimo programų.

Taip pat literatūroje pabrėžiama, kad finansinės prognozės organizacijose tampa ne tik planavimo priemone, bet ir strateginio lankstumo pagrindu, leidžiančiu greičiau reaguoti į neapibrėžtus rinkos pokyčius ir koreguoti sprendimus realiuoju laiku. Fildes, Ma ir Kolassa (2019) pažymi, kad prognozių kokybė tiesiogiai siejama su organizacijos gebėjimu koordinuoti veiklą tarp skirtingų funkcinių padalinių bei efektyviau valdyti veiklos rizikas.

Svarbus finansinių prognozių vaidmuo išryškėja ir biudžetavimo bei kontrolės sistemose. Prognozės leidžia įmonėms įvertinti savo finansinę būklę, pelningumą ir ilgalaikį tvarumą, taip pat nustatyti silpnąsias vietas ir optimizuoti veiklą, siekiant finansinės pusiausvyros ir verslo augimo (Zopounidis ir Lemonakis, 2024). Lipelis (2025) empiriškai pagrindžia ryšį tarp prognozių tikslumo ir biudžeto rezultatų: didesnis prognozių tikslumas, geresnė finansinio planavimo funkcijų integracija bei vadovų „agilumas“ siejami su mažesniais biudžeto nuokrypiais ir geresniais kontrolės rezultatais. Tai leidžia teigti, kad prognozės organizacijoje yra ne izoliuotas finansų skyriaus produktas, bet dalis platesnės valdymo architektūros, kuri turi būti suderinta su sprendimų priėmimo procesais. Net ir pakankamai tikslios prognozės gali nekurti vertės, jei jos nėra laiku panaudojamos, jei organizacijoje trūksta koordinacijos arba jei prognozės nėra „įsiūtos“ į biudžeto koregavimo ir vykdymo kontrolės mechanizmus.

Finansinių prognozių reikšmė organizacijų sprendimų priėmime pasireiškia trimis lygmenimis: (1) kaip planavimo ir resursų paskirstymo pagrindas, (2) kaip rizikos ir neapibrėžtumo valdymo priemonė, (3) kaip elgseną formuojantis atskaitos taškas, galintis daryti įtaką vadovų sprendimų

logikai. Šios išvalgos pagrindžia poreikį toliau analizuoti, kaip prognozavimo procesuose suderinti (a) didelių duomenų ir statistinių modelių teikiamą informacinę bazę bei (b) organizacijos ekspertines žinias (vadovų ir rinkos praktikų išvalgas), kurios dažnai nėra formalizuotos, tačiau gali kritiškai pakeisti prognozių prielaidas ir jų interpretaciją.

Tradicinių finansinių prognozavimo metodų ribotumai

Tradiciniai finansinių prognozių sudarymo metodai (pvz., regresiniai modeliai, ARIMA šeimos laiko eilučių modeliai, GARCH tipo volatilumo modeliai) ilgą laiką buvo laikomi „standartu“, nes jie yra palyginti lengvai interpretuojami, paremti aiškiais statistinėmis prielaidomis ir dažnai reikalauja mažiau duomenų nei sudėtingi dirbtinio intelekto modeliai (Rubio ir kt., 2023). Vis dėlto pastarųjų metų mokslinė literatūra vis dažniau pabrėžia, kad šių metodų taikymas realiose finansų rinkose ir įmonių finansų prognozėse susiduria su sisteminiiais ribotumais, ypač kai aplinka pasižymi dideliu nepastovumu, struktūriniais lūžiais ir nelineariomis priklausomybėmis.

Vienas kertinių tradicinių metodų ribotumų yra jų priklausomybė nuo prielaidų apie duomenų stabilumą (stacionarumą) ir struktūros pastovumą laike. Finansiniai procesai dažnai keičiasi: atsiranda nauji reguliaciniai režimai, pasikeičia monetarinė politika, įvyksta geopolitiniai šokai ar rinkos krizės, dėl kurių istorinių ryšių „perkėlimas“ į ateitį tampa nepatikimas. Tai itin ryšku volatilumo prognozėse: analizuodami rinkas su struktūriniais lūžiais, Chung, Espinoza ir Quispe (2025) parodė, kad ignoruojant struktūrinius lūžius, tradiciniai GARCH tipo modeliai linkę pervertinti volatilumo „atkaklumą“ (angl. persistence) ir dėl to prastėja prognozių tikslumas, o nelinearūs ir laike kintantys modeliai vidutiniu bei ilguoju laikotarpiu dažnai pasirodo pranašesni.

Dar vienas svarbus ribotumas – tradicinių metodų (ypač ARIMA ir klasikinių regresijų) ribotas gebėjimas modeliuoti nelinearinius ryšius ir sudėtingą dinamiką. Finansinėse laiko eilutėse dažni režimų pokyčiai, „uodegų“ (angl. fat tails) efektai, volatilumo klasterizacija ir asimetrijos, kurios sunkiai telpa į paprastas linijines struktūras. Sisteminga šių metodų ir ML palyginimų apžvalga rodo, kad daugelyje prognozavimo taikymų (įskaitant finansų sritį) mašininio mokymosi metodai dažnai pranoksta ARIMA dėl geresnio prisitaikymo prie nelinearių priklausomybių ir sudėtingesnių dėsningumų, o ARIMA stiprybės labiau pasireiškia specifinėse, labiau „tvarkingose“ laiko eilutėse ar mažų imčių situacijose (Kontopoulou, Panagopoulou, Kakkos, & Matsopoulos, 2023).

Tradiciniai metodai yra jautrūs išskirtinėms reikšmėms ir ekstremaliems įvykiams, kurie finansuose yra ne „išimtis“, o struktūrinė realybė. Dėl šios priežasties literatūroje daugėja tyrimų, kuriuose tradiciniai modeliai yra „stiprinami“ papildomais mechanizmais (dekompozicija, struktūrinių lūžių identifikavimas, hibridizacija su ML). Pavyzdžiui, Cheng, Yi, Yang, Lai ir Seco (2022) tyrime, prognozuojant naftos kainas, struktūriniai lūžiai ir ekstremalūs įvykiai traktuojami kaip esminė prognozavimo kokybę lemianti dalis: autoriai parodo, kad vien ARIMA tipo modelių nepakanka, o prognozavimo tikslumas pagerėja tik tada, kai į procesą įtraukiamas struktūrinių lūžių aptikimas ir hibridinis modeliavimas.

Taip pat akcentuojama, kad tradiciniai ekonometriniai modeliai dažnai remiasi pernelyg supaprastintomis prielaidomis apie finansinių rinkų racionalumą ir stabilumą, kurios realiose situacijose retai išlieka pastovios. Makridakis, Spiliotis ir Assimakopoulou (2020) teigia, kad sparčiai kintančioje aplinkoje klasikiniai modeliai tampa mažiau efektyvūs dėl riboto gebėjimo prisitaikyti prie netikėtų struktūrinių pokyčių ir didelio duomenų kompleksiskumo.

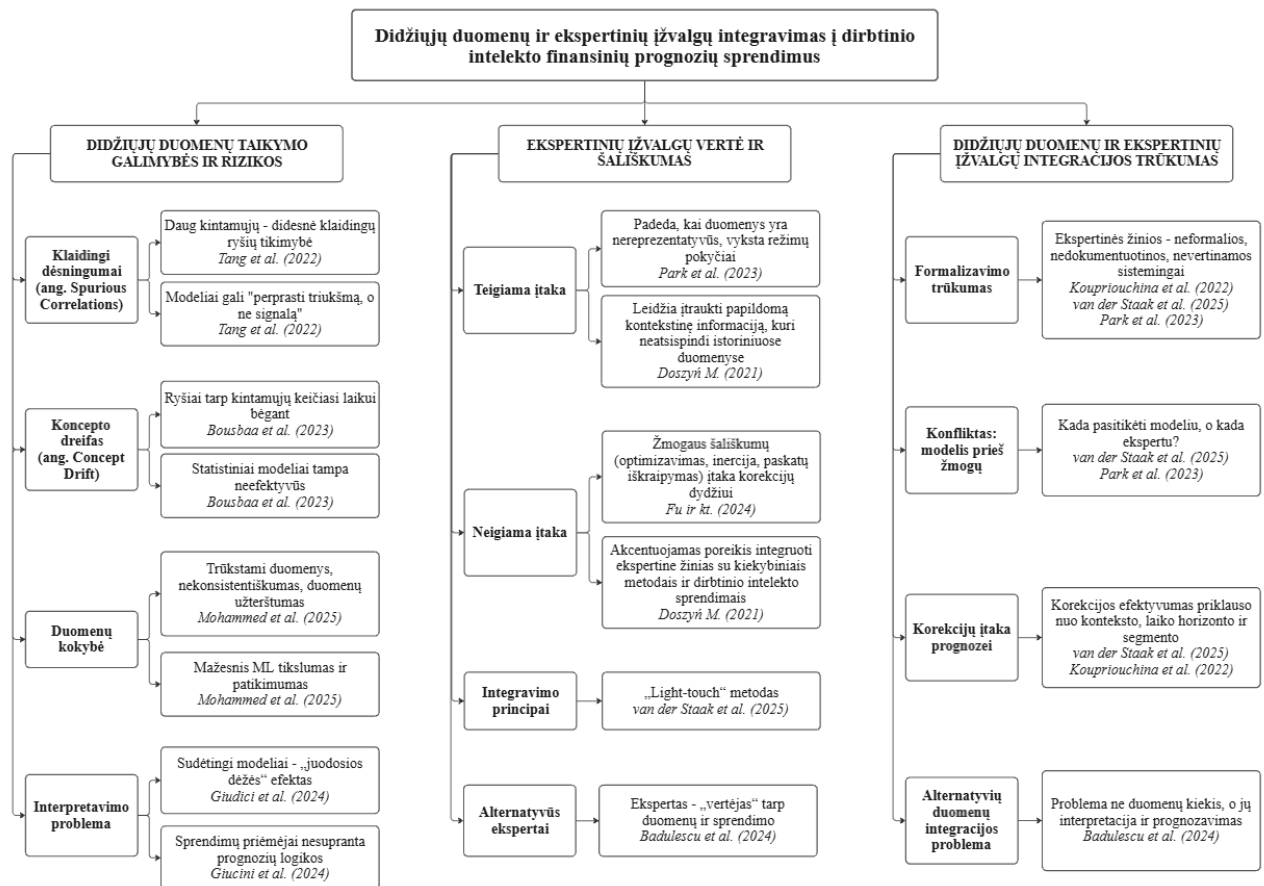
Nors tradicinė ekonometrika gali būti plečiama (pvz., įtraukiant slenkstinius ar Markovo režimų persijungimo modelius), praktikoje išlieka kompromisas tarp modelio sudėtingumo, interpretavimo ir prisitaikymo. Kılıç (2025) lygindamas linijinius, nelinearinius ekonometrinius (įskaitant režimų persijungimą) ir ML metodus realizuoto volatilumo prognozavime parodo, kad „vien tik daugiau sudėtingumo“ (pvz., ML) automatiškai negarantuoja geresnio rezultato: kai prognozavimo aplinkoje svarbūs režimų pokyčiai, interpretuojami režimų persijungimo ekonometriniai modeliai gali nuosekliai konkuruoti ar net pranokti ML, ypač kai prognozavimui prieinamų prediktorių yra mažai. Tai patvirtina, kad vienas esminių tradicinių metodų ribotumų yra ne pats „statistinis pobūdis“, o nepakankamas struktūrinių pokyčių ir režimų kaitos įvertinimas realiame procese.

Taigi, naujausia literatūra leidžia išskirti kelias tradicinių metodų ribotumų grupes: (1) prielaidų apie stabilumą ir stacionarumą neatitikimas realioms rinkoms, (2) ribotas nelinearių ir laike kintančių ryšių modeliavimas, (3) jautrumas ekstremaliems įvykiams ir struktūriniams lūžiams, (4) ribotas pritaikomumas, kai tikslas – integruoti daugiau informacijos šaltinių (pvz., alternatyvius duomenis ar ekspertines prielaidas). Šie aspektai tiesiogiai pagrindžia poreikį analizuoti inovatyvesnius sprendimus, įskaitant hibridinius metodus, kurie vienu metu gali išnaudoti duomenų struktūrą, prisitaikyti prie režimų pokyčių ir sudaryti prielaidas integruoti papildomą (ne tik istorinę) informaciją.

Tradicinių prognozavimo metodų ribotumai kartu atskleidė poreikį ieškoti pažangesnių analitinių sprendimų, gebančių apdoroti didesnės apimties, įvairesnius ir dinamiškesnius duomenų srautus. Sparčiai didėjantis finansinių ir nefinansinių duomenų kiekis, skaitmenizacijos plėtra bei realaus laiko informacijos prieinamumas sudarė prielaidas finansinių prognozių procese vis plačiau taikyti didžiųjų duomenų analitiką ir dirbtinio intelekto metodus. Skirtingai nei tradiciniai ekonometriniai modeliai, didžiųjų duomenų pagrindu veikiančios sprendimai leidžia integruoti ne tik istorinius finansinius rodiklius, bet ir alternatyvius duomenų šaltinius – vartotojų elgsenos informaciją, naujienų srautus, socialinių tinklų signalus ar makroekonominius rodiklius. Tačiau kartu su šiomis galimybėmis atsiranda ir naujų problemų, susijusių su duomenų kokybe, triukšmu, koncepto dreifu bei prognozių interpretavimo sudėtingumu. Dėl šios priežasties tampa aktualu detaliau analizuoti didžiųjų duomenų taikymo finansinėse prognozėse galimybes ir jų keliamus iššūkius.

Didžiųjų duomenų ir ekspertinių įžvalgų integravimo literatūros žemėlapis

Žemiau pateikiamas literatūros žemėlapis, leidžiantis sistemingai apibendrinti nagrinėjamą mokslinę problematiką ir identifikuoti pagrindines tyrimų kryptis. Literatūros žemėlapis padeda atskleisti ryšius tarp skirtingų teorinių požiūrių bei išryškinti nagrinėjamos temos tyrimų spragas.



1 pav. Literatūros žemėlapis

Literatūros analizė rodo, kad daugelyje finansinių prognozavimo taikymų DI modelių rezultatai priklauso nuo duomenų rinkinių kokybės, reprezentatyvumo ir stabilumo. Tang ir kt. (2022) apžvalgoje akcentuojama, kad finansinės laiko eilutės yra triukšmingos, nestacionarios ir linkusios į režimų pokyčius, todėl net ir pažangūs modeliai (pvz., LSTM ar hibridiniai metodai) gali prarasti prognozavimo galią, kai istoriniai duomenys tampa mažiau tinkami dabartinėms sąlygoms. Tai reiškia, kad DI „stiprybė“ – mokymasis iš didelių duomenų – kartu tampa ir rizika: jei duomenys neatspindi realių pokyčių, modelis gali išmokti klaidingus ryšius ir blogai generalizuoti.

Antra, DI prognozių patikimumą stipriai veikia duomenų kokybės problematika (trūkstanti duomenys, netikslumai, skirtingi dažniai, „užterštumas“), kuri finansų srityje yra dažna dėl skirtingų šaltinių sujungimo ir dinamiško atsinaujinimo. Mohammed ir kt. (2025) empiriškai parodė, kad skirtingos duomenų kokybės dimensijos (pvz., tikslumas, pilnumas, konsistentiškumas) reikšmingai keičia mašininio mokymosi rezultatų stabilumą, o „užteršti“ duomenys gali lemti klaidingas išvadas net ir tada, kai algoritmas formaliai veikia „teisingai“. Finansinių prognozių kontekste tai ypač svarbu, nes prognozės naudojamos sprendimams, kurie turi finansines pasekmes (pvz., investicijos, likvidumo planavimas, kaštų optimizavimas).

Trečia, DI taikymo plėtrą riboja „juodosios dėžės“ problema ir prognozių paaiškinamumo trūkumas. Organizacijose prognozės dažnai turi būti paaiškinamos vadovybei ir suinteresuotoms šalims: ne tik „kiek bus“, bet ir „kodėl taip manoma“ bei „kiek galima pasitikėti“. Giudici ir kt. (2024) pabrėžia, kad finansinėms laiko eilutėms reikalingi paaiškinami DI metodai (XAI), kurie atsižvelgtų į laiko priklausomybes ir leistų suprasti veiksmų indėlį į prognozę. Vis dėlto literatūra rodo, kad net ir taikant

XAI, paaiškinimai gali būti riboti, nestabilūs keičiantis rinkos režimams arba sunkiai interpretuojami praktiniame valdymo kontekste, ypač kai duomenų šaltiniai įvairūs, o modeliai sudėtingi.

Ketvirta, DI dažnai neatsako į vieną svarbiausių šio darbo problemos aspektų: kaip sistemingai suderinti statistinius duomenis ir organizacijos ekspertines žinias. Praktikoje direktoriai ir vadovai turi kontekstinę informaciją apie būsimus strateginius sprendimus, derybų eigą, reguliavimo rizikas ar specifinius rinkos signalus, kurie gali kardinaliai pakeisti prognozės prielaidas, tačiau tokios žinios dažnai nėra formalizuotos ir nepatenka į modelio mokymosi aibę. Park ir kt. (2023) atkreipia dėmesį į situacijas, kai ekspertų sprendimas konfliktuoja su modelio prognoze, ypač kai mokymo duomenys nėra reprezentatyvūs. Tai leidžia teigti, kad DI modelių tikslumas vien iš „Big Data“ ne visuomet sprendžia realią prognozavimo problemą, nes svarbi dalis informacijos lieka už modelio ribų, o korekcijos atliekamos neformaliai.

Apibendrinant, DI prognozavime finansų srityje turi didelį potencialą, tačiau naujausia mokslinė literatūra rodo kelias esmines neišspręstas problemas: (1) prognozių jautrumą duomenų nestabilumui ir režimų pokyčiams, (2) duomenų kokybės poveikį modelių patikimumui, (3) ribotą prognozių paaiškinamumą ir sprendimų skaidrumą, (4) nepakankamai išspręstą ekspertinių žinių integravimo klausimą. Šios išvalgos tiesiogiai pagrindžia tolimesnių darbo dalių būtinybę: teorinių sprendimų dalyje tikslinga nagrinėti metodinius integravimo principus (pvz., hibridinius modelius ir XAI), o empiriniame tyrime – patikrinti, ar pasirinkti sprendimai realiomis sąlygomis pagerina prognozių tikslumą, stabilumą ir pritaikomumą sprendimų priėmimui, kaip to reikalauja magistro BP logika.

Didžiųjų duomenų taikymas finansinėse prognozėse ir jo problemos

Pastaraisiais metais finansinių prognozių sudaryme vis didesnę reikšmę įgauna didieji duomenys (angl. „Big Data“) – didelės apimties, didelės įvairovės ir didelio generavimo greičio duomenys, kurie papildomai apima tiek struktūruotus (pvz., finansines ataskaitas, rinkos kainas, makroekonominis rodiklius), tiek nestruktūruotus šaltinius (pvz., naujienų srautus, socialinių tinklų tekstus, alternatyvius duomenis) (Ishwarappa ir Anuradha, 2015). Mokslinė literatūra pabrėžia, kad finansinės laiko eilutės pasižymi sudėtingomis savybėmis – jos yra dinamiškos, nelinearios, chaotiškos ir triukšmingos, todėl prognozavimas tampa itin jautrus naudojamų duomenų struktūrai ir kokybei (Tang et al., 2022).

Didieji duomenys įgalina platesnę informacijos panaudojimą, tačiau kartu sukuria naują problemų sluoksnį. Pirmiausia, didelis duomenų kiekis didina riziką identifikuoti statistiškai „gražius“, bet ekonomiškai nereikšmingus dėsningumus (spurious correlations). Finansiniuose duomenyse triukšmas ir netikrumas yra struktūrinė ypatybė, todėl didesnis prediktorių skaičius gali ne sumažinti, o padidinti klaidų tikimybę, ypač jei modeliai nėra pakankamai atsparūs duomenų nestabilumui ir režimų kaitai. Tang ir kt. (2022) apžvalgoje akcentuojama, kad daug pažangių prognozavimo modelių (pvz., LSTM ir hibridiniai sprendimai) taikomi siekiant geriau „pagauti“ sudėtingą dinamiką, tačiau kartu pripažįstamos metodinės ribos, susijusios su duomenų triukšmu, nestacionarumu ir modelių generalizacijos problema. Papildomai mokslinėje literatūroje pabrėžiama, kad didžiųjų duomenų aplinkoje viena svarbiausių problemų tampa ne duomenų kiekis, o gebėjimas identifikuoti ekonomiškai reikšmingą informaciją tarp didelio triukšmo kiekio. Hashem ir kt. (2015) teigia, kad didžiųjų duomenų vertė finansų srityje priklauso nuo organizacijos gebėjimo efektyviai integruoti skirtingus duomenų šaltinius bei užtikrinti duomenų analizės infrastruktūros lankstumą.

Didieji duomenys finansuose dažnai turi „srautinių duomenų“ (angl. streaming data) pobūdį: rinkos kainos ir rodikliai nuolat atsinaujina, o jų generuojami dėsningumai gali greitai keistis. Tai vadinama

koncepto dreifu (angl. concept drift) – situacija, kai ryšys tarp įėjimo kintamųjų ir prognozuojamo rodiklio laikui bėgant pasikeičia. Bousbaa, Sanchez-Medina ir Bencharef (2023) parodo, kad finansinių laiko eilučių prognozavime statiniai (vieną kartą apmokyti) modeliai tampa neadekvatūs, nes rinkos „mokosi“ ir keičiasi: reikalingi adaptyvūs mechanizmai (pvz., slankiojančio lango strategijos, pokyčių aptikimas), kurie padėtų atskirti realius struktūrinius pokyčius nuo trumpalaikių svyravimų. Kitaip tariant, didžiųjų duomenų aplinkoje prognozavimo sistema turi būti ne tik tiksli, bet ir gebanti nuolat atsinaujinti bei reaguoti į režimų pasikeitimus.

Taip pat kyla ryški duomenų kokybės problema. Didelė apimtis savaime negarantuoja patikimumo: finansiniuose duomenų rinkiniuose dažni trūkštami įrašai, netikslumai, nekonsistentiškumas, skirtingi matavimo dažniai bei duomenų „užterštumas“ (angl. data pollution). Mohammed ir kt. (2025) empiriškai įrodo, kad įvairios duomenų kokybės dimensijos (pvz., tikslumas, pilnumas, konsistentiškumas) daro reikšmingą įtaką mašininio mokymosi algoritmų veikimui, o „užteršti“ mokymo ar testavimo duomenys gali lemti ne tik mažesnę tikslumą, bet ir mažiau patikimus sprendimus. Tai ypač svarbu finansinių prognozių kontekste, kur klaidos materializuojasi kaip realūs nuostoliai (pvz., neteisingi investiciniai sprendimai, likvidumo planavimo klaidos).

Šios tematikos sprendimai dažnai susiduria su interpretavimo ir skaidrumo iššūkiu. Didelės apimties ir įvairovės duomenys skatina naudoti sudėtingus dirbtinio intelekto modelius, tačiau tai apsunkina prognozės prielaidų supratimą ir paaiškinimą vadovybei (ypač kai prognozė naudojama strateginiams sprendimams). Giudici, Piergallini, Recchioni ir Raffinetti (2024) pabrėžia, kad finansinių laiko eilučių prognozavime vis dažniau reikalingi paaiškinami dirbtinio intelekto metodai (XAI), kurie atsižvelgia į laiko priklausomybę ir leidžia interpretuoti, kokie veiksniai lemia prognozę. Jų tyrimas rodo, kad net ir geriausiai veikiančių modelių atveju aiškinamumas gali būti ribotas, o tai kelia praktinę problemą: organizacijos gali turėti „tikslėnę“ prognozę, bet ne visada supranta, kodėl ji tokia ir kiek ja galima pasitikėti skirtingomis rinkos sąlygomis.

Apibendrinant, didieji duomenys finansinėse prognozėse suteikia galimybę praplėsti informacinę bazę ir taikyti pažangius modelius, tačiau kartu išryškina keturias kritines problemų grupes: (1) triukšmo ir „klaidingų dėsningumų“ riziką, (2) koncepto dreifą ir nestacionarumą, (3) duomenų kokybės (užterštumo) poveikį modelių patikimumui, (4) interpretavimo ir sprendimų skaidrumo stoką. Šios problemos sudaro pagrindą tolimesnėse darbo dalyse nagrinėti, kaip prognozavimo procesuose sukurti patikimesnę sistemą, kuri ne tik apdorotų didelius duomenų kiekius, bet ir valdytų duomenų kokybės rizikas, prisitaikytų prie pokyčių bei būtų pakankamai paaiškinama sprendimų priėmėjams.

Ekspertinių žinių vaidmuo finansinėse prognozėse

Finansinių prognozių sudarymo procese, greta statistinių modelių ir istorinių duomenų, svarbią vietą užima ekspertinės žinios – vadovų, direktorių, rinkos specialistų ir analitikų sukaupta patirtis bei kontekstinė informacija, kuri ne visada (arba dar ne) atsispindi duomenyse. Park ir kt. (2023) moksliniame darbe rašo, jog praktikoje tokios žinios gali apimti planuojamus strateginius sprendimus (pvz., kainodaros pakeitimus, investicijas, reorganizaciją), derybų su tiekėjais ar klientais rezultatų tikėtiną poveikį, reguliacinių pokyčių tikimybę, konkurentų veiksmų signalus, rinkos „nuotaikų“ pokyčius ar vienkartinis įvykius, galinčius reikšmingai keisti paklausą, sąnaudas ir finansinius srautus. Šio tipo informacija dažnai yra „šalutinė“ (angl. side information): ji egzistuoja organizacijos viduje arba ekspertų galvose, tačiau nėra formalizuota duomenų bazėse, todėl standartiniai modeliai

jos „nemato“. Tunç (2022) teigia, jog mokslinė ekspertizė turėtų būti suprantama ne tik kaip individualios žinios, bet ir kaip patikimo informanto vaidmuo socialiniame kontekste.

Mokslinėje literatūroje ekspertinės žinios dažnai apibrėžiamos kaip įžvalgos, kurios nėra statistiškai išmokstamos iš turimų mokymo duomenų, tačiau vis tiek turi signalą, reikšmingą prognozei. Pavyzdžiui, Park ir bendraautoriai (2023) nagrinėja situacijas, kai mašininio mokymosi (ML) prognozės konfliktuoja su ekspertų sprendimu, ir siūlo metodiką, kaip ekspertinę nuomonę įtraukti adaptuojant jos svorį pagal tai, ar naujas atvejis yra pakankamai „atstovaujamas“ mokymo duomenyse. Tai tiesiogiai atitinka finansinių prognozių realybę: kai rinka patiria režimų pokyčius ar įvyksta netipiniai įvykiai, istorinių duomenų reprezentatyvumas mažėja, o ekspertinės žinios gali tapti kritiškai svarbios.

Vis dėlto ekspertinių žinių vaidmuo prognozėse nėra vienareikšmis, nes žmogaus sprendimas gali ir pagerinti, ir pabloginti prognozę – priklausomai nuo to, kada ir kaip jis taikomas. Naujesni tyrimai rodo, kad žmonės dažnai gerai „pataiso kryptį“ (pvz., supranta, kad prognozė turi būti mažinama), bet gali klysti nustatydami korekcijos dydį, ypač kai veikia optimizmo, inercijos ar paskatų (pvz., tikslų „pasiekimo“) šališkumai. van der Staak ir kt. (2025), remdamiesi didelės apimties praktiniais duomenimis apie milijonus prognozavimo sprendimų, parodo, kad žmogaus įsitraukimas turi aiškias stiprybes ir silpnybes, todėl siūlomi „lengvo prisilietimo“ (angl. light-touch) integravimo principai: žmogaus indėlį taikyti selektyviai, ten, kur jis kuria didžiausią vertę, ir mažinti ten, kur korekcijos sistemai klaidina.

Finansų kontekste ekspertinės žinios ypatingai ryškios vadovybės prognozėse ir „guidance“, nes vadovai turi prieigą prie informacijos apie būsimus sprendimus ir vidinius rodiklius, kurių rinka ar išoriniai analitikai neturi. Tačiau tyrimai taip pat rodo, kad tokių prognozių kokybę veikia aplinkos veiksniai (pvz., reguliacinė rizika, investuotojų struktūra, viešas spaudimas), ir tai gali mažinti prognozių tikslumą ar informatyvumą. Fu ir kt. (2024) nagrinėja, kaip rinkos liberalizavimo kontekstas paveikia vadovybės prognozių tikslumą ir informacinę turinį: rezultatai rodo, kad keičiasi prognozių preciziškumas ir informatyvumas, o tai patvirtina, jog ekspertinė informacija nėra „grynas“ signalas – ji priklauso nuo paskatų, rizikų ir informacijos atskleidimo kaštų.

Literatūroje taip pat pažymima, kad ekspertinės žinios tampa ypač svarbios situacijose, kai prognozuojami reiškiniai neturi pakankamų istorinių analogų arba kai rinkoje vyksta netipiniai pokyčiai. Goodwin (2021) teigia, kad ekspertiniai sprendimai dažniausiai sukuria didžiausią vertę ne stabiliose situacijose, o tada, kai modeliai susiduria su aukštu neapibrėžtumu ir ribotu istorinių duomenų reprezentatyvumu.

Dar viena aktuali kryptis – ekspertinių žinių derinimas su alternatyviais šaltiniais, ypač nestruktūruotais duomenimis (pvz., socialinių tinklų signalais, naujienomis). Badulescu ir kt. (2024) siūlo struktūruotą metodiką, kaip socialinių tinklų signalus paversti veiksmingomis prognozavimo korekcijomis, pasitelkiant žmogaus sprendimą (pvz., klasifikuojant „staigius lūžius“ ar tendencijų pasikeitimus). Nors tyrimas orientuotas į paklausos prognozavimą, jo logika tiesiogiai perkeliama į finansines prognozes: ekspertas tampa „vertėju“, kuris paaiškina, ką reiškia išoriniai signalai ir kaip jie turėtų paveikti prognozės prielaidas. Empiriniai tyrimai taip pat rodo, kad praktikoje prognozės dažnai nėra naudojamos tiesiogiai, o yra koreguojamos remiantis ekspertiniu vertinimu, kuris leidžia įtraukti papildomą kontekstinę informaciją apie rinkos sąlygas, klientų elgseną ar planuojamus organizacijos sprendimus (Doszyń M., 2021). Tokios žinios papildo modelių generuojamas prognozes, ypač situacijose, kai istoriniai duomenys neatspindi būsimų pokyčių arba kai prognozuojami netipiniai nuokrypiai.

Kita vertus, ekspertinių žinių taikymas nėra vienareikšmiškai teigiamas. Nors jos gali padidinti prognozių tikslumą, jų poveikis priklauso nuo taikymo sistemingumo ir pagrįstumo. Nesistemingi ar pernelyg intuityvūs koregavimai gali iškraipyti modelių rezultatus ir sumažinti prognozių patikimumą. Todėl literatūroje akcentuojamas poreikis struktūruoti ekspertinių žinių integravimą, derinant jas su kiekybiniais metodais ir dirbtinio intelekto sprendimais (Zellner, 2021). Tokia integracija leidžia išnaudoti abiejų požiūrių privalumus – modelių gebėjimą apdoroti didelius duomenų kiekius ir ekspertų gebėjimą interpretuoti kontekstą bei identifikuoti būsimus pokyčius.

Apibendrinant, ekspertinės žinios finansinėse prognozėse yra būtinos, nes leidžia įtraukti kontekstą ir būsimų pokyčių signalus, kurių vien statistiniai duomenys dažnai neapima. Tačiau jos kelia dvi esmines problemas: (1) formalizavimo ir sistemingo integravimo trūkumą (žinios lieka „galvose“ ar neformaliuose susitarimuose), (2) subjektyvumo ir paskatų šališkumą, kuris gali iškreipti prognozes. Dėl to šiame darbe toliau tampa aktualu ieškoti teorinių sprendimų, kaip sukurti integruotą prognozavimo logiką, kurioje ekspertinės žinios būtų įtraukiamos valdomai (selektyviai, su aiškiais taisyklėmis ar svoriais), o statistiniai modeliai užtikrintų kiekybinį pagrindą.

Statistinių duomenų ir ekspertinių žinių integracijos trūkumas

Nors organizacijose finansinės prognozės formaliai grindžiamos statistiniais rodikliais ir vis platesne didžiųjų duomenų analitika, realus sprendimų priėmimas dažnai papildomas vadovų ir direktorių ekspertinėmis įžvalgomis (pvz., apie planuojamus strateginius sprendimus, derybų eigą, reguliavimo pokyčius ar specifinius rinkos signalus). Problema ta, kad šie du informacijos tipai dažniausiai egzistuoja paraleliai, bet nėra sistemiškai sujungiami į vieną nuoseklų prognozavimo procesą (Baecke et al., 2017). Dėl to prognozės tampa „dviejų pasaulių“ rezultatu: vienoje pusėje – modelių sugeneruotos reikšmės, kitoje – neformalūs vadovų koregavimai, kurių logika ne visada dokumentuojama, o poveikis tikslumui vertinamas ribotai.

Mokslinėje literatūroje integracijos trūkumas dažnai apibrėžiamas kaip konfliktas tarp modelio prognozės ir eksperto sprendimo, kylantis tada, kai mokymo duomenys nebeatspindi dabartinės situacijos (pvz., dėl režimų pokyčių, naujų rinkos sąlygų ar vienkartinų įvykių). Park ir kt. (2023) parodo, kad ekspertų nuomonė ypač svarbi, kai duomenys yra nepakankamai reprezentatyvūs, tačiau praktikoje šios žinios dažnai „pridedamos“ intuityviai, be aiškaus mechanizmo, kada ir kiek jomis pasitikėti. Autoriai siūlo formalų sprendimą: ekspertinei nuomonei suteikti didesnę svorį tais atvejais, kai modelio patikimumas mažėja dėl prastai reprezentuotų situacijų (Park et al., 2023).

Vis dėlto vien faktas, kad ekspertinės korekcijos egzistuoja, nereiškia, kad jos visada pagerina prognozes. Naujausi empiriniai tyrimai rodo, kad žmonės dažnai teisingai nustato korekcijos kryptį, bet klysta parinkdami korekcijos dydį, o tai sukuria sisteminę paklaidą. van der Staak ir kt. (2025) didelės apimties tyrime (milijonai prognozavimo sprendimų) nustato, kad planuotojai (žmonės) gana patikimai atlieka korekcijas „žemyn“ (downward adjustments), tačiau „aukštyn“ korekcijų dydžiai dažniau būna netikslūs; todėl autoriai siūlo „light-touch forecasting“ principą – žmogaus įsitraukimą sumažinti ir padaryti selektyvų, paliekant jį ten, kur jis istoriškai sukuria daugiausia vertės (van der Staak et al., 2025). Ši įžvalga tiesiogiai atskleidžia integracijos problemos esmę: be aiškių taisyklių ir kontrolės, ekspertinės korekcijos gali tapti ne sprendimu, o papildomu triukšmo šaltiniu. Papildomai tyrimai rodo, kad organizacijose ekspertinės korekcijos dažnai atliekamos neformalizuotai, todėl tampa sudėtinga vertinti jų poveikį prognozių tikslumui ir sprendimų kokybei. Lawrence, Goodwin, O'Connor ir Önkal (2006) pabrėžia, kad efektyvus žmogaus ir modelio

bendradarbiavimas prognozavime reikalauja aiškių integravimo taisyklių, kurios leistų sumažinti subjektyvumo ir kognityvinių šališkumų poveikį prognozių rezultatams.

Integracijos trūkumas ypač ryškus tada, kai organizacijos pradeda naudoti alternatyvius duomenų šaltinius (pvz., socialinių tinklų signalus, naujienų sentimentą), bet neturi aiškaus proceso, kaip šiuos signalus paversti prognozės prielaidomis ir sprendimais. Badulescu ir kt. (2024) rodo, kad alternatyvių duomenų įtraukimas gali padidinti prognozių tikslumą, tačiau praktinės kliūtys yra būtent integracinės: kaip suklasifikuoti signalų poveikį (trumpalaikis, „šuo“, tendencijos lūžis), kaip jį išversti į korekciją ir kaip užtikrinti duomenų patikimumą. Tai patvirtina, kad problema nėra vien „turėti daugiau duomenų“, bet sukurti metodiką, kuri sujungtų duomenis su ekspertiniu aiškinimu. (Badulescu et al., 2024).

Empirinė literatūra taip pat rodo, kad net ir tada, kai korekcijos taikomos dažnai, jų poveikis priklauso nuo konteksto (pvz., laiko horizonto, specialių įvykių, segmento). Koupriouchina ir kt. (2022) didelės apimties viešbučių prognozių tyrime nustato, kad vartotojų (ekspertų) „override“ dažnis gali pagerinti tikslumą vienais atvejais (pvz., tam tikruose segmentuose ar specialių įvykių laikotarpiais), bet pabloginti kitais. Tai rodo, kad „vienodas“ ekspertinių korekcijų taikymas (be taisyklių, kada jos naudingos) nėra efektyvus, o organizacijoms reikia integruotos logikos: kada leisti korekcijas, kaip jas vertinti ir kaip mokytis iš jų rezultatų (Koupriouchina et al., 2022). Önkal-Atay (1998) taip pat pabrėžia, jog ekspertų sprendimai yra esminė finansinių prognozių dalis, tačiau jų naudojimas yra tiesiogiai susijęs su subjektyvumu, heuristikomis ir integravimo iššūkiais – jei žinios nėra sistemingai integruojamos, gali atsirasti skaidrumo ir tikslumo vertinimo problemų.

Apibendrinant galima teigti, kad nors finansinių prognozių sudaryme vis plačiau taikomi statistiniai ir didžiųjų duomenų analitikos sprendimai, praktikoje išlieka ryškus atotrūkis tarp modelių generuojamų prognozių ir ekspertinių (vadovų, direktorių) žinių panaudojimo. Moksliniai tyrimai rodo, kad ekspertinės korekcijos gali pagerinti prognozių tikslumą, tačiau tik tam tikromis sąlygomis ir tik tada, kai jos taikomos sistemiškai, o ne intuityviai. Integracijos trūkumas lemia situacijas, kai prognozės tampa mažiau stabilios, sunkiau interpretuojamos ir labiau priklausomos nuo individualių sprendimų. Šios išvalgos pagrindžia poreikį tolimesnėse darbo dalyse analizuoti teorinius sprendimus, leidžiančius struktūruotai ir kontroliuojamai sujungti statistinius duomenis ir ekspertines žinias finansinių prognozių sudarymo procese, bei išsiaiškinti, kaip integruoti dirbtinio intelekto metodus, didžiųjų duomenų analitiką ir ekspertines žinias į dirbtinio intelekto finansinių prognozių sprendimus

2. Didžiųjų duomenų ir ekspertinių įžvalgų integravimo į dirbtinio intelekto finansinių prognozių sprendimus teorinė analizė

Šiame skyriuje nagrinėjami teoriniai sprendimai, kurie leidžia pagrįsti pažangesnių finansinių prognozavimo modelių kūrimą. Analizuojami finansinių prognozių sudarymo principai dirbtinio intelekto kontekste, didžiųjų duomenų analitikos taikymo galimybės, pagrindiniai dirbtinio intelekto metodai bei ekspertinių žinių formalizavimo ir integravimo būdai.

2.1. Finansinių prognozių sudarymo teoriniai principai ir vertinimo logika dirbtinio intelekto taikymo kontekste

Finansinės prognozės organizacijose atlieka ne vien informacinę, bet ir sprendimų palaikymo funkciją: jos naudojamos biudžetavimui, pinigų srautų planavimui, investicinių projektų vertinimui, rizikos valdymui ir veiklos rodiklių (KPI) tikslų nustatymui. Teoriškai prognozavimas finansų srityje traktuojamas kaip procesas, kuriame siekiama sumažinti neapibrėžtumą, tačiau kartu pripažįstama, kad prognozės visada kuriamos remiantis ribota informacija, o sprendimų priėmėjai privalo valdyti tiek modelio, tiek duomenų, tiek aplinkos riziką. Todėl šiame darbo skyriuje finansinių prognozių sudarymas konceptualizuojamas per tris tarpusavyje susijusius elementus: (1) prognozavimo modelio pasirinkimą ir prielaidų valdymą, (2) prognozės kokybės (tikslumo ir patikimumo) vertinimą, (3) prognozių pritaikymą sprendimų priėmimo, įskaitant paaiškinamumo ir žmogaus–modelio sąveikos klausimus.

1 lentelė. Finansinių prognozių sudarymo teoriniai principai ir vertinimo logika dirbtinio intelekto taikymo kontekste

Tema	Turinys	Autorius
Prognozavimo metodų ekosistema	Prognozavime pereinama nuo vieno modelio prie kelių metodų derinimo, priklausomai nuo duomenų ir uždavinio.	Tang et al. (2022)
Prognozės kaip sąlyginis teiginys	Prognozės tikslumas priklauso nuo naudojamo informacijos rinkinio ir turi būti vertinamas kartu su stabilumu bei pritaikomumu.	
Prognozės kokybės vertinimas	Prognozių tikslumas turi būti vertinamas ne tik pagal klaidų metrikas, bet ir taikant tinkamą validavimą.	Aziz et al. (2024)
Laiko eilučių validavimo svarba	Laiko eilučių kryžminė patikra leidžia patikimiau įvertinti modelių stabilumą skirtinguose laikotarpiuose.	
Prognozės poveikis sprendimams	Prognozės gali keisti sprendimus ir taip paveikti pačius prognozuojamus rezultatus.	Song & Wu (2023)
Prognozės integracija į valdymą	Prognozės turi būti vertinamos kaip sprendimų priėmimo proceso dalis, o ne izoliuotas rezultatas.	
DI modelių paaiškinamumas	DI prognozės turi būti interpretuojamos, siekiant užtikrinti pasitikėjimą ir sprendimų pagrįstumą.	Giudici et al. (2024)
XAI reikšmė finansuose	Paaiškinamumas yra būtinas veiksnys diegiant DI aukštos rizikos srityse, tokiose kaip finansai.	Arsenault et al. (2024)
Žmogaus ir algoritmo sąveika	Prognozavime svarbus subalansuotas modelių ir ekspertinių korekcijų derinimas.	van der Staak et al. (2025)
Ekspertinių korekcijų valdymas	Žmogaus įsitraukimas turi būti sistemingai valdomas, siekiant išvengti prognozių klaidų didėjimo.	

Naujausi finansinių laiko eilučių tyrimai rodo, kad prognozavime vis rečiau remiamasi vienu „universalium“ metodu; vietoje to formuojama metodų ekosistema, kurioje modelio pasirinkimas

priklauso nuo prognozuojamo rodiklio (pvz., pajamos, kaštai, volatilumas), prognozės horizonto ir duomenų pobūdžio. Tang ir kt. (2022) sisteminėje apžvalgoje pabrėžia, kad finansinės laiko eilutės pasižymi nelineariškumu, triukšmu, nestacionarumu bei režimų kaita, todėl dirbtinis intelektas (ypač gilaus mokymosi ir hibridiniai) metodai dažnai pasirenkami ne „dėl mados“, o dėl teorinio poreikio modeliuoti sudėtingus ryšius ir skirtingas dinamikas (Tang et al., 2022).

Tačiau teoriniu požiūriu svarbu pabrėžti: dirbtinio intelekto metodai nekeičia fundamentalaus principo, kad prognozė yra sąlyginis teiginys apie ateitį, priklausantis nuo informacijos rinkinio, kuriuo remiasi modelis. Todėl DI taikymo inovacijos turi būti vertinamos ne tik „ar padidėjo tikslumas“, bet ir „ar prognozė yra stabili, pagrįsta ir tinkama sprendimams“.

Teorinis prognozavimo kokybės vertinimas remiasi dviem klausimais: (1) kaip matuojamas prognozės nuokrypis nuo faktinės reikšmės, (2) kaip užtikrinama, kad gautas rezultatas nėra atsitiktinis ar „pritaikytas“ konkrečiai imčiai. Praktikoje finansų ir prognozavimo literatūroje plačiai taikomos klaidų metrikos, tokios kaip MAE, RMSE, MAPE ir MASE, tačiau esminis aspektas yra ne vien metrikos parinkimas, o validavimo strategija, kuri atitiktų laiko eilučių pobūdį (t. y. užtikrintų laiko tvarką ir išvengtų informacijos „nutekėjimo“ į ateitį).

Aziz ir kt. (2024) siūlo pakartotinės laiko eilučių kryžminės patikros (Repeated Time-Series Cross-Validation) logiką, kuri sistemingai testuoja modelių stabilumą skirtinguose laiko langų suskaidymuose ir leidžia patikimiau palyginti prognozavimo metodus pagal kelias metrikas (Aziz et al., 2024). Nors tyrimas pateikiamas epidemiologinių prognozių kontekste, metodinis principas yra tiesiogiai perkeliamas į finansines prognozes, nes abiem atvejais aktualus nestacionarumas ir struktūriniai pokyčiai.

Taigi, šiame darbe teoriniams sprendimams svarbu remtis nuostata, kad DI metodų „pranašumas“ turi būti pagrįstas griežtu validavimu (laiko eilučių kryžmine patikra, slenkančiais langais), o prognozės kokybė turi būti vertinama ne vien momentiniu tikslumu, bet ir stabilumu, ypač pasikeitus rinkos režimui.

Finansų srityje prognozės nėra neutralios: jos pačios gali paveikti sprendimus, o sprendimai – pakeisti aplinką, kurią prognozė bandė nuspėti. Ši problema literatūroje siejama su post-prognozavimo (angl. post-forecasting) efektu, kai prognozė keičia elgseną ir taip „pakeičia“ prognozuojamą rezultatą. Song ir Wu (2023) parodo, kad prognozės informacija turi vertę tik tam tikromis sąlygomis ir gali generuoti elgsenos prisitaikymą, kuris mažina pradinės prognozės „instruktyvumą“ (Song & Wu, 2023). Ši įžvalga aktuali įmonių finansams: pavyzdžiui, pajamų prognozė gali paskatinti kainodaros ar kaštų sprendimus, kurie pakeis faktinį rezultatą.

Iš teorinės perspektyvos tai reiškia, kad prognozavimas negali būti traktuojamas kaip izoliuota analitinė užduotis – jis turi būti siejamas su valdymo ciklu, kuriame prognozė yra vienas iš įėjimų į sprendimą. Dėl to didėja poreikis prognozes pateikti ne tik kaip „taškinę“ reikšmę, bet kaip pagrįstą ir aiškinamą sprendimų argumentą.

Finansinės prognozės dažnai naudojamos aukšto lygmens sprendimuose, todėl prognozės priėmimas priklauso nuo pasitikėjimo: organizacijoms svarbu suprasti, kokie veiksniai lėmė prognozė ir kokios prielaidos slypi už rezultato. Giudici ir kt. (2024) pabrėžia, kad finansinėms laiko eilutėms reikalingi XAI sprendimai, kurie atsižvelgtų į laiko priklausomybę ir leistų interpretuoti modelių sprendinius (Giudici et al., 2024). Teoriškai tai reiškia, kad dirbtinio intelekto modelio vertė organizacijoje

priklauso ne tik nuo tikslumo, bet ir nuo paaiškinamumo (audituojamumo), ypač kai prognozė tampa sprendimo pagrindu.

Papildomai, XAI kryptis finansuose siejama su platesne metodine problema: net geras modelis gali būti „nepriimtinas“, jei jo rezultatai nepaaiškinami sprendimų priėmėjams. Šią kryptį apibendrina ir Arsenault ir kt. (2024), pateikdami XAI metodų taksonomiją finansinių laiko eilučių prognozavimui ir akcentuodami, kad aiškinamumas yra kritinis veiksnys diegiant dirbtinį intelektą aukštos rizikos srityse, tokiose kaip finansai (Arsenault et al., 2024).

Atsižvelgiant į pirmosios dalies problematiką, šiame darbe esminis teorinis aspektas yra žmogaus (eksperto) ir algoritmo santykis prognozavime. Nors DI modeliai gali apdoroti didelius duomenų kiekius, praktikoje prognozės dažnai koreguojamos vadovų ar analitikų dėl informacijos, kuri nėra užkoduota duomenyse (pvz., strateginiai sprendimai, specifiniai rinkos pokyčiai). van der Staak ir kt. (2025) siūlo „light-touch forecasting“ metodą, kuris teoriškai pagrindžia selektyvų žmogaus įsitraukimą: nustatoma, kada žmogaus korekcijos yra patikimos, o kada jos sistemingai didina klaidas (van der Staak et al., 2025). Ši kryptis svarbi formuojant teorinius sprendimus: integracija turi būti valdoma, o ne palikta intuityviam „perrašymui“.

Apibendrinant galima teigti, kad finansinių prognozių sudarymo teorinis pagrindas dirbtinio intelekto taikymo kontekste apima ne vien modelių klasifikavimą, bet ir metodinę logiką, kaip prognozė kuriama, validuojama, aiškinama ir integruojama į sprendimų priėmimą. Naujausi tyrimai rodo, kad DI metodai yra perspektyvūs sudėtingų finansinių procesų prognozavime, tačiau jų taikymui būtini griežti validavimo principai, tinkamai parinktos klaidų metrikos, paaiškinamumo užtikrinimas ir žmogaus–algoritmo sąveikos valdymas. Šie principai ypač aktualūs įmonių biudžetavimo ir PnL prognozavimo kontekste, kur prognozės tiesiogiai naudojamos sprendimų priėmime.

2.2. Didžiųjų duomenų analitikos teoriniai sprendimai finansuose

Finansinių prognozių sudarymo kontekste didžiųjų duomenų analitika apibrėžiama kaip metodų, procesų ir technologinių sprendimų visuma, leidžianti rinkti, apjungti ir analizuoti didelės apimties, didelės įvairovės ir didelio atsinaujinimo greičio duomenis tam, kad prognozės būtų tikslesnės, savalaikės ir labiau pagrįstos. Tačiau mokslinė literatūra pabrėžia, kad vien didesnis duomenų kiekis savaime neužtikrina geresnio prognozavimo rezultato – būtini aiškūs teoriniai sprendimai, reglamentuojantys (1) duomenų parengimą, (2) duomenų kokybės valdymą, (3) nestabilumo ir režimų kaitos (koncepto dreifo) kontrolę, (4) informacijos vertės įvertinimą, ypač naudojant alternatyvius duomenis.

2 lentelė. Didžiųjų duomenų analitikos teoriniai sprendimai finansuose

Tema	Turinys	Autorius
Duomenų parengimas ir reprezentacija	Finansinių prognozių tikslumui būtinas sistemingas duomenų parengimas – nuo suvienodinimo ir valymo iki tinkamos reprezentacijos, siekiant išvengti klaidinančių dėsnų.	Tang et al. (2022)
Duomenų kokybė ir patikimumas	Duomenų kokybė (tikslumas, pilnumas, nuoseklumas ir aktualumas) yra kritinis veiksnys, lemiantis finansinių prognozių patikimumą ir stabilumą.	Mohammed et al. (2025)
Koncepto dreifas ir modelių adaptacija	Dėl nuolat kintančių finansinių ryšių modeliai turi būti adaptyvūs, nes statiniai sprendimai laikui bėgant praranda prognozinę vertę.	Bousbaa et al. (2023)

Tema	Turinys	Autorius
Alternatyvūs duomenys ir prognozės horizontas	Alternatyvūs duomenys gali pagerinti trumpalaikes prognozes, tačiau jų poveikis ilgalaikiam informatyvumui turi būti vertinamas atsargiai.	Dessaint, Foucault ir Fresard (2024)
Duomenų vertė ir domeno integracija	Efektyvus didžiųjų duomenų taikymas reikalauja derinti duomenų analizę su finansų srities žiniomis ir konkrečiu sprendimų kontekstu.	Cao, Jiang, Lei ir Zhou (2024)

Didžiųjų duomenų taikyme prognozavimui esminis teorinis principas yra „duomenų gyvavimo ciklo“ (angl. data lifecycle) valdymas: duomenys turi būti ne tik surinkti, bet ir paversti į prognozei tinkamą reprezentaciją. Finansų prognozėms tai reiškia duomenų suvienodinimą laike (skirtingi dažniai: dienos, savaitės, mėnesio), suderinimą tarp šaltinių, trūkstamų reikšmių tvarkymą, išskirčių (outliers) identifikavimą, normalizavimą bei „informacijos nutekėjimo“ (angl. data leakage) prevenciją. Finansinių laiko eilučių prognozavimo apžvalgoje Tang et al. (2022) pabrėžia, kad finansiniai duomenys yra triukšmingi ir nestacionarūs, todėl be sisteminio parengimo net pažangūs metodai gali „išmokti“ netvairius dėsningumus ir prastai generalizuoti.

Didieji duomenys finansuose dažnai yra heterogeniški (skirtingos kilmės ir tikslumo), todėl duomenų kokybė tampa vienu pagrindinių prognozės patikimumo veiksnių. Teoriškai duomenų kokybės valdymas apima tikslumo, pilnumo, konsistentiškumo ir aktualumo dimensijas, kurios turi būti stebimos visame duomenų apdorojimo procese. Mohammed et al. (2025) empiriškai parodo, kad duomenų kokybės pablogėjimas gali ženkliai sumažinti mašininio mokymosi (ML) rezultatų stabilumą ir patikimumą; tai svarbu finansų prognozėms, nes klaidos gali materializuotis kaip neteisingi investiciniai ar likvidumo sprendimai. Ši literatūra leidžia daryti teorinę išvadą, kad didžiųjų duomenų sprendiniai prognozavime turi būti grindžiami ne tik modelio pasirinkimu, bet ir formalizuotais duomenų kokybės kontrolės mechanizmais (pvz., kokybės metrikomis, validavimo taisyklėmis, duomenų kilmės atsekamumu).

Finansų rinkose ir įmonių veiklos aplinkoje ryšiai tarp kintamųjų laikui bėgant keičiasi (pvz., dėl reguliavimo, monetarinės politikos, technologinių pokyčių ar šokų). Ši problema literatūroje apibrėžiama kaip koncepto dreifas (angl. concept drift), kai istoriškai išmoktas ryšys tampa nebeadekvatus dabartinei realybei. Bousbaa et al. (2023) parodo, kad finansinių laiko eilučių prognozavime statiniai (vieną kartą apmokyti) modeliai progresyviai prastėja, o adaptyvūs srautinių duomenų (data stream) sprendimai leidžia geriau reaguoti į pasiskirstymo pokyčius. Tai sukuria svarbų teorinį principą: didžiųjų duomenų prognozavimo sistemos turėtų būti projektuojamos kaip dinaminės (su periodiniu per-mokymu, slenkančiais langais, pokyčių aptikimu), o ne kaip vienkartiniai „modelio įdiegimai“.

Viena reikšmingiausių didžiųjų duomenų inovacijų finansuose – alternatyvių duomenų (pvz., socialinių tinklų, interneto srautų, geolokacijos, mokėjimų, teksto) panaudojimas prognozavimui. Tačiau teorinis iššūkis yra ne vien įtraukti papildomą šaltinį, bet įvertinti jo informacinį turinį ir poveikį prognozės laikotarpiui (trumpam vs. ilgam horizontui). Dessaint, Foucault ir Fresard (2024) teoriškai ir empiriškai pagrindžia vadinamąjį „horizonto efektą“: trumpalaikiai (dažnai alternatyvūs) signalai gali pagerinti trumpalaikių prognozių informatyvumą, bet kartu paskatinti prognozuotojus mažiau dėmesio skirti ilgalaikėms prielaidoms, todėl ilgalaikių prognozių informatyvumas gali mažėti. Ši išvalga svarbi organizacijoms: alternatyvių duomenų integravimas turi būti derinamas su prognozės paskirtimi (ar tikslas – operatyvinis planavimas, ar strateginis horizontas), kad „informatyvumas“ nebūtų perkeliamas vien į trumpą laikotarpį.

Didžiųjų duomenų analitika finansuose yra glaudžiai susijusi su organizacine ir metodine integracija: duomenys turi būti valdoma strateginė priemonė, o modeliavimas – suderintas su domeno logika (rizika, reguliavimas, atskaitomybė). Cao, Jiang, Lei ir Zhou (2024) pabrėžia, kad AI taikymo plėtra finansuose neatsiejama nuo duomenų (įskaitant alternatyvius šaltinius) prieinamumo, tačiau kartu akcentuoja domeno kompetencijos svarbą – be jos didėja rizika kurti „technologškai įspūdingus“, bet menkai pritaikomus sprendinius. Tai leidžia teorinį didžiųjų duomenų sprendinių principą formuluoti taip: duomenų inžinerija ir analitika turi būti projektuojama kartu su sprendimo kontekstu (kokiai prognozei, kokiam horizontui, kokiam sprendimui), o ne atsietai kaip vien technologinis projektas.

Apibendrinant, didžiųjų duomenų analitikos teoriniai sprendimai finansų prognozėse apima ne tik duomenų šaltinių plėtrą, bet ir sistemingą metodinę architektūrą: (1) duomenų parengimą ir reprezentacijos kūrimą, (2) duomenų kokybės valdymą, (3) koncepto dreifo ir srautinės aplinkos kontrolę, (4) alternatyvių duomenų informacijos vertės įvertinimą pagal prognozės horizontą, (5) domeno kompetencijos integravimą. Šie principai sudaro prielaidas tolimesniuose poskyriuose pagrįsti, kaip ši analitika turi būti derinama su DI metodais ir ekspertinėmis žiniomis kuriant patikimesnes finansines prognozes.

2.3. Dirbtinio intelekto metodai finansinių prognozių sudaryme

Dirbtinio intelekto (DI) metodai finansinių prognozių sudaryme paprastai apima dvi dideles grupes: (1) mašininio mokymosi (MM) metodus, kurie dažniausiai taikomi struktūruotiems (lenteliniais) duomenims ir iš anksto suformuotiems požymiams, ir (2) gilaus mokymosi (GM) metodus, kurie geba automatiškai išmokti sudėtingas laiko priklausomybes iš sekų (laiko eilučių) ir integruoti skirtingų tipų signalus. Naujausia literatūra rodo, kad dirbtinio intelekto metodai finansų prognozėse nėra vien „alternatyva“ tradicinei statistikai – jie tampa atskira metodine kryptimi, kurios vertė priklauso nuo (a) duomenų ir požymių inžinerijos, (b) modelio architektūros pasirinkimo, (c) validavimo strategijos (laiko eilučių logikos) ir (d) paaiškinamumo bei patikimumo sprendimų priėmimo kontekste.

3 lentelė. Dirbtinio intelekto metodai finansinių prognozių sudaryme

Metodas	Veikimo esmė	Privalumai	Trūkumai	Autorius
Mašininis mokymasis (Random Forest, XGBoost)	Medžiais grįstas nelinearių ryšių mokymasis	Nelineariškumas, sąveikos, stabilumas	Reikia požymių inžinerijos, ribotas laiko kontekstas	Kılıç (2025); Tang et al. (2022)
Dirbtiniai neuroniniai tinklai (ANN)	Nelineari funkcijų aproksimacija	Universalumas, lankstumas	Perteklinis pritaikymas, interpretacija	Tang et al. (2022)
LSTM / GRU	Ilgalaikių laiko priklausomybių modeliavimas	Atmintis, sekų dinamika	Jautrumas triukšmui, režimų kaitai	Tang et al. (2022); Giantsidi & Tarantola (2025)
CNN–LSTM hibridai	Lokalių + sekų požymių integracija	Geresnė dinamika, tikslumas	Sudėtingumas, hiperparametrai	Giantsidi & Tarantola (2025)
Transformeriai (Attention)	Dėmesio mechanizmas, ilgos sekos	Ilgalaikės priklausomybės, paralelizacija	Dideli duomenų poreikiai	Nayak et al. (2024)

Metodas	Veikimo esmė	Privalumai	Trūkumai	Autorius
Temporal Fusion Transformer (TFT)	Multi-horizonto prognozavimas + XAI	Interpretacija, keli horizontai	Sudėtinga architektūra	Farooq et al. (2024)
Explainable AI (XAI)	Veiksnių indėlio paaiškinimas	Skaidrumas, pasitikėjimas	Paaiškinimų nestabilumas	Giudici et al. (2024)
Ekspertinių žinių integravimas į ML	Eksperto svorio adaptavimas	Kontekstas, režimų kaita	Subjektyvumas	Park et al. (2023)

Finansinių prognozių praktikoje dažnai prognozuojami rodikliai (pvz., pardavimai, marža, pinigų srautai, EPS, rizikos rodikliai) priklauso nuo daugelio paaiškinančių kintamųjų (makroekonominių, finansinių, veiklos, sektoriaus). Tokiuose uždaviniuose ypač paplitę medžiais paremti metodai (pvz., „gradient boosting“, atsitiktiniai miškai), nes jie gerai tvarkosi su nelineariškumu, sąveikomis tarp kintamųjų ir dažnai suteikia konkurencingą tikslumą net tada, kai duomenys nėra idealiai stacionarūs. Kılıç (2025) analizė, lyginanti ekonometrinius modelius ir įvairius ML metodus (įskaitant „Extreme Gradient Boosting“ ir neuroninius tinklus) realizuoto volatilumo prognozėje, parodo, kad ML metodai gali būti labai konkurencingi, tačiau jų pranašumas priklauso nuo duomenų struktūros, režimų kaitos ir pasirinktos validavimo schemos. Ši išvada svarbi teoriniu požiūriu: ML metodai nėra „automatiškai geresni“, bet yra stiprūs, kai prognozavimo sistema sukurta taip, kad valdytų nestacionarumą ir pokyčius.

Finansinių laiko eilučių prognozėse istoriškai dominavo pasikartojantys neuroniniai tinklai (RNN) ir jų variantai (LSTM, GRU), nes jie natūraliai modeliuoja sekų priklausomybes. Sisteminis tyrimų žemėlapis rodo, kad LSTM išlieka viena dažniausių architektūrų finansinėje prognozėje, tačiau jos rezultatai dažnai priklauso nuo duomenų triukšmo, režimų kaitos ir pasirinktų prielaidų (langų dydžio, normalizavimo, požymių rinkinio). Tang ir kt. (2022) apžvalgoje pabrėžiama, kad finansinės laiko eilutės pasižymi triukšmu, nestacionarumu ir sudėtinga dinamika, todėl vien „stipresnė“ architektūra nepanaikina duomenų problemų – būtina metodinė disciplina: tinkamas validavimas, reguliarinimas, stabilumo tikrinimas skirtinguose laikotarpiuose.

Pastarųjų metų inovacijų branduolys finansinėse prognozėse – transformeriais (attention-based) paremti modeliai, kurie geriau nei RNN tvarkosi su ilgomis sekomis, leidžia paralelizuoti skaičiavimus ir dažnai suteikia geresnį „ilgo nuotolio“ priklausomybių modeliavimą. Nayak ir kt. (2024) siūlo transformeriu paremtą architektūrą laiko eilučių prognozavimui ir pabrėžia, kad dėmesio mechanizmas padeda efektyviau apdoroti nelinearias, chaotiškas ir nestacionarias sekas, o tai aktualu finansams, kur trumpalaikiai šokai ir ilgesnio periodo režimai egzistuoja kartu.

Farooq ir kt. (2024), taikydami „Temporal Fusion Transformer“ logiką kriptovaliutų prognozėms, akcentuoja multi-horizonto prognozavimo idėją ir rodo, kad pažangios attention architektūros gali pagerinti prognozavimo rodiklius, ypač kai modelis konfigūruojamas ir testuojamas su skirtingomis normalizavimo strategijomis bei įvairiais rinkos signalais. Teoriškai tai svarbu todėl, kad organizacijoms dažnai reikia ne vien „rytdienos“ prognozės, bet suderintų kelių horizontų prognozių (trumpas/vidutinis/ilgas terminas), kurios yra pagrindas biudžetavimui ir sprendimų planavimui.

Kadangi finansinės prognozės naudojamos sprendimams, vien tik tikslumo nepakanka: reikalingas paaiškinamumas, leidžiantis suprasti prognozės prielaidas, veiksnių svarbą ir modelio jautrumą. Giudici ir kt. (2024) siūlo aiškinamumo metodus, pritaikytus laiko eilučių specifikai, ir pabrėžia, kad finansų srityje interpretavimo aspektas yra esminis pasitikėjimui modeliu ir jo priėmimui organizacijoje. Ši kryptis tiesiogiai siejasi su KTU metodiniu reikalavimu, kad teoriniai sprendimai

turi būti pagrįsti ir pritaikomi praktikoje: prognozė, kurios negalima pagrįsti ar audituoti, organizacijoje dažnai neįgyja sprendimų priėmimo „teisės“.

Naujausi apžvalginiai darbai rodo poslinkį nuo pavienių modelių lyginimo prie dizaino principų: kokią architektūrinį principą rinktis (sekų atmintis, dėmesys, CNN–RNN hibridai, preprocesingas), kaip valdyti ekstremalius įvykius ir kaip standartizuoti vertinimą. Giantsidi ir Tarantola (2025) apžvelgia didelės apimties (Scopus indeksuotų) tyrimus ir pabrėžia, kad DL finansinėse prognozėse dominuoja RNN (ypač LSTM), tačiau daugėja hibridinių architektūrų (pvz., CNN–LSTM), multimodalių signalų (techninių, fundamentalių, sentimentų) integracijos, o didžiausios spragos išlieka būtent patvarumo ekstremaliomis sąlygomis, interpretavimo ir standartizuoto vertinimo srityse. Teoriškai tai pagrindžia, kad DI metodų pasirinkimas turi būti grįstas ne tik „tikslumo reitingu“, bet ir atsparumu (robustness), skaidrumu ir pritaikomumu konkrečiame sprendimų kontekste.

Atsižvelgiant į pirmoje dalyje identifikuotą integracijos problemą, dirbtinio intelekto I metodų teorinis apribojimas yra tai, kad dauguma modelių mokosi tik iš „matomų“ duomenų, o ekspertinės (vadovų/direktorių) žinios dažnai lieka neformalios. Park ir kt. (2023) siūlo metodinę kryptį, kaip ekspertų sprendimą įtraukti į ML prognozė, diferencijuojant eksperto svorį pagal tai, kiek naujas atvejis yra „atstovaujamas“ mokymo duomenyse. Tai svarbu finansinėms prognozėms, nes rinkos režimų kaita, vienkartiniai įvykiai ar strateginiai sprendimai sukuria situacijas, kuriose duomenimis grįstas modelis gali būti mažiau patikimas, o ekspertinė informacija – kritiškai svarbi.

Apibendrinant, DI metodai finansinėms prognozėms apima nuo lentelinių ML sprendimų iki pažangių sekų architektūrų (transformerių, multi-horizonto modelių), tačiau jų taikymo vertė priklauso nuo metodinių principų: validavimo (laiko eilučių logikos), atsparumo režimų kaitai, duomenų kokybės kontrolės, paaiškinamumo ir valdomo ekspertinių žinių integravimo. Ši teorinė bazė sudaro pagrindą kitame poskyryje nagrinėti, kaip ekspertinės žinios formalizuojamos ir įjungiamos į prognozavimo sistemą, kad būtų sprendžiama pirmoje dalyje identifikuota „statistikos ir ekspertinės informacijos atotrūkio“ problema.

2.4. Ekspertinių žinių formalizavimo ir integravimo teoriniai sprendimai dirbtinio intelekto prognozėse

Finansinių prognozių sudarymo praktikoje ekspertinės žinios (vadovų, direktorių, analitikų) dažnai pasireiškia kaip papildoma informacija apie būsimus sprendimus, vienkartinis įvykis, rinkos specifinius pokyčius ar „neužfiksuotus“ signalus, kurių istoriniuose duomenyse dar nėra. Tačiau teoriniu požiūriu ekspertinių žinių vertė organizacijai atsiskleidžia tik tada, kai jos yra formalizuojamos (aprašomos, dokumentuojamos, paverčiamos taikytinomis taisyklėmis ar įvestimis) ir integruojamos į prognozavimo sistemą taip, kad būtų galima įvertinti jų poveikį prognozės tikslumui bei patikimumui. Naujausi tyrimai pabrėžia, kad žmogaus ir algoritmo sinergija gali mažinti prognozės klaidas, ypač kai prognozuojama situacija nėra pakankamai reprezentuota mokymo duomenyse, tačiau kartu išlieka rizika, kad ekspertinės korekcijos taps subjektyvumo ir šališkumą šaltiniu (Park et al., 2023; van der Staak et al., 2025).

Ekspertines žinias prognozavimo teorijoje galima traktuoti kaip kontekstinę informaciją, kurios modelis pats neišmoksta, nes ji nėra užkoduota turimuose duomenyse (pvz., žinomas būsimas kainodaros pokytis, planuojamas kontraktas, numatomas reguliavimo pakeitimas). Park ir kt. (2023) šią problemą apibrėžia kaip konfliktą tarp modelio prognozės ir eksperto sprendimo, kylantį dėl to, kad mokymo duomenys ne visuomet reprezentuoja aktualią situaciją; autoriai siūlo ekspertinę

nuomonę įtraukti kaip koreguojantį signalą, kurio svoris priklauso nuo to, kiek naujas atvejis „panašus“ į mokymo duomenų pasiskirstymą (Park et al., 2023). Ši logika teoriškai suponuoja, kad ekspertinė informacija turi būti pateikiama struktūruotai (pvz., kaip tikėtinas nukrypimas, scenarijus, ribos arba kryptinė korekcija), o ne kaip neapibrėžtas komentaras. Formalizavimo tikslas – paversti ekspertines išvalgas tokiomis, kurias galima (a) taikyti nuosekliai, (b) palyginti tarp periodų, (c) validuoti pagal faktinius rezultatus.

Literaturoje išskiriamos kelios teorinės integracijos kryptys, kurios praktiškai reiškia „kur sistemoje įdedamas ekspertas“. Lentelėje žemiau pateikta klasifikacija apibendrina pagrindines ekspertinių žinių integravimo kryptis, išskiriamas prognozavimo ir dirbtinio intelekto literatūroje, ir parodo, kaip skiriasi žmogaus vaidmuo prognozavimo sistemoje – nuo post hoc koregavimo iki tiesioginio įtraukimo į modelio struktūrą.

4 lentelė. Ekspertinių žinių formalizavimo ir integravimo teoriniai sprendimai dirbtinio intelekto prognozėse

Kryptis	Aprašomoji charakteristika	Autorius
Prognozės koregavimas (Judgmental adjustment)	Ekspertas koreguoja modelio sugeneruotą prognozę po jos sudarymo	van der Staak et al. (2025); Koupriouchina et al. (2022); Franses (2024)
Mechaninis prognozių kombinavimas	Modelio ir eksperto prognozės jungiamos pagal iš anksto nustatytą taisyklę (pvz., lygūs svoriai)	Franses (2024); Nair & Huchzermeier (2024)
Eksperto integravimas į modelį	Ekspertinė informacija įtraukiama į patį DI modelį (svoriai, apribojimai, papildomi signalai)	Park et al. (2023); Nishad et al. (2023)

Franses (2024) pateikia paprastą ir reprodukuojamą integravimo principą krizės sąlygomis: modelio prognozė modifikuojama įtraukiant eksperto prognozę kaip papildomą „stebėjimą“ ir vėliau sujungiama su modelio prognoze (pvz., lygi svoriai), siekiant pagerinti rezultatą tais laikotarpiais, kai istoriniai duomenys tampa mažiau informatyvūs (Franses, 2024). Ši schema svarbi teoriškai, nes ji leidžia ekspertinę informaciją padaryti audituojamą: aišku, kada ir kiek ekspertas pakeitė prognozę, ir galima patikrinti, ar korekcijos buvo naudingos.

Nors ekspertinės korekcijos dažnos, jų nauda nėra universali. van der Staak ir kt. (2025) didelės apimties tyrime siūlo „light-touch forecasting“ principą: žmogaus korekcijas taikyti selektyviai ir riboti ten, kur jos sistemingai didina klaidas. Tyrimas rodo, kad planuotojai (žmonės) dažnai teisingai parenka korekcijos kryptį, tačiau ne visada tiksliai nustato korekcijos dydį, todėl sprendimas – sukurti taisykles, kada žmogus įsikiša ir kokio tipo korekcijos laikomos patikimesnėmis (van der Staak et al., 2025). Teoriškai tai reiškia, kad organizacijai reikia ne tik „leisti ekspertui koreguoti“, bet sukurti kontrolės logiką, kuri mažintų šališkumus ir didintų prognozės stabilumą.

Integracijos vertė ypač išryškėja tada, kai prognozuojami objektai pasižymi ribotu istorinių duomenų informatyvumu (pvz., inovatyvūs produktai, dažni portfelio atnaujinimai, struktūriniai pokyčiai). Nair ir Huchzermeier (2024) parodo, kad mašininio mokymosi prognozė, paremta statistiniais požymiais, gali sumažinti prognozės klaidą lyginant su vien tik ekspertiniu vertinimu, tačiau geriausi rezultatai pasiekiami tada, kai integruojami abu šaltiniai – ekspertinės žinios apie ateitį ir algoritmo gebėjimas išnaudoti istorinius analogus (Nair & Huchzermeier, 2024). Didieji duomenys ir statistika suteikia pagrindą, bet be ekspertinio konteksto prognozė gali būti neadekvati lūžio momentais; tuo tarpu vien ekspertinė intuicija be duomenų gali būti mažiau stabili ir sunkiau patikrinama.

Praktikoje ekspertinės žinios dažnai yra ne „skaičius“, o apytikslės ribos ir lingvistinės kategorijos (pvz., „tikėtinas nuosaikus paklausos kritimas“, „didelė rizika“, „nedidelis teigiamas poveikis“). Tokį neapibrėžtumą galima formalizuoti fuzzy logika, kuri leidžia aprašyti žinias taisyklėmis ir narystės funkcijomis. Nishad ir kt. (2023) fuzzy laiko eilučių prognozavimo sprendimuose demonstruoja, kaip fuzzy ryšiai ir agregavimo logika gali padėti modeliuoti neapibrėžtumą, kai duomenys ar ryšiai nėra tiksliai apibrėžiami, o prognozavimas reikalauja toleruoti „pilkąsias zonas“ (Nishad et al., 2023). Teoriškai tai aktualu finansinėms prognozėms, kai ekspertas gali patikimiau nurodyti kryptį ir intervalą (ribas), o ne vieną taškinę reikšmę.

Apibendrinant galima teigti, kad ekspertinių žinių integravimas į DI prognozavimo sistemas turi būti traktuojamas kaip metodinis dizaino uždavinys: ekspertinė informacija turi būti formalizuota (struktūruota, dokumentuojama), o integracija – realizuota aiškiais mechanizmais (koregavimas, kombinavimas, svorių priskyrimas ar fuzzy taisyklės), leidžiančiais įvertinti poveikį prognozės tikslumui ir stabilumui. Naujausi tyrimai rodo, kad hibridiniai sprendimai yra perspektyvūs, tačiau jų sėkmė priklauso nuo selektyvaus žmogaus įsitraukimo ir integracijos taisyklių, mažinančių subjektyvumo riziką.

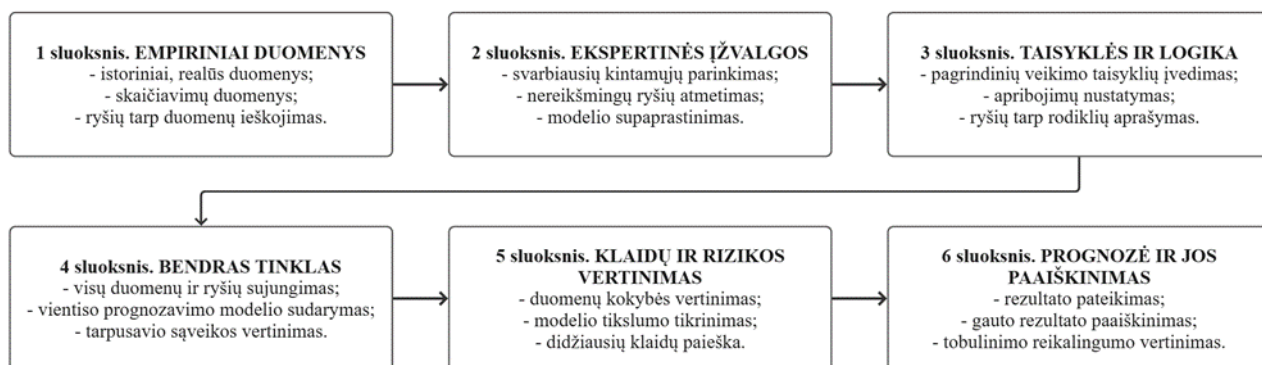
2.5. Didžiųjų duomenų ir ekspertinių išvalgų integravimo į dirbtinio intelekto finansinių prognozių sprendimus modeliai

Mokslinėje literatūroje dirbtinio intelekto ir ekspertinių žinių integracija vystoma keliomis skirtingomis kryptimis, kurios skiriasi tuo, kokį vaidmenį modelyje atlieka ekspertas, koku būdu apdorojami duomenys ir kokiam etape vyksta žmogaus įsitraukimas. Viena kryptis remiasi struktūrine integracija, kai ekspertinės žinios tampa pačios modelio architektūros dalimi. Kita kryptis grindžiama korekcine integracija, kai ekspertas įsiterpia po pirminės modelio prognozės. Trečia kryptis siejama su ansambliniais ar daugiasluoksniais DI modeliais, kuriuose ekspertinės žinios dažniausiai suprantamos kaip papildomas konteksto arba sprendimų palaikymo šaltinis, tačiau nėra iki galo formalizuojamos pačioje modelio logikoje. Ketvirta kryptis yra labiau teorinė ir siūlo bendrą perėjimą nuo vien duomenimis grindžiamų sistemų prie modelių, kuriuose sujungiami duomenys, loginės taisyklės ir žmogaus žinios. Būtent šių kryptių sankirta yra ypač svarbi finansinių prognozių temoje, nes finansiniai duomenys vienu metu yra ir struktūruoti, ir jautrūs kontekstui, o prognozavimo sprendimai retai kada gali būti pagrįsti tik istorine informacija.

2.5.1. Integruoti finansiniai prognozavimo modeliai

Vienas konceptualiai stipriausių integracijos pavyzdžių pateikiamas Feng ir kt. (2020) tyrime, kuriame kuriamas probabilistinių grafinių modelių pagrindu veikiantis dirbtinio intelekto sprendinys, jungiantis duomenis, ekspertines žinias, fizikinius submodelius ir neapibrėžtumo kvantifikavimą. Toks sprendinys suteikia galimybę ne tik generuoti prognozes, bet ir aiškinti jų susidarymo logiką, nustatyti priklausomybių struktūrą bei įvertinti, kuriuose modelio komponentuose atsiranda didžiausia paklaidos rizika. „Probabilistinis“ reiškia, kad modelis dirba su tikimybėmis, o ne su visiškai tikromis reikšmėmis. Vadinasi, jis pripažįsta, kad realybėje duomenys gali būti netikslūs, nepilni arba triukšmingi. „Grafinis“ reiškia, kad ryšiai tarp kintamųjų vaizduojami kaip tinklas arba schema: vieni kintamieji veikia kitus, kai kurie yra tiesiogiai susiję, o kai kurie tik netiesiogiai (Feng ir kt., 2020). Šio modelio pagrindinė idėja yra ta, kad prognozavimo ar vertinimo sistema neturi būti suprantama kaip „juodoji dėžė“, kuri tik priima duomenis ir sugeneruoja rezultatą. Priešingai, autoriai siūlo modelį konstruoti kaip tarpusavyje susijusių kintamųjų tinklą, kuriame aiškiai apibrėžiami

priežastiniai ir koreliaciniai ryšiai. Tai reiškia, kad modelis turi ne vien prognozuoti, bet ir parodyti, iš kokių komponentų ta prognozė susideda, kuriuose sistemos taškuose atsiranda neapibrėžtumas ir kokie ekspertiniai sprendimai nulėmė pačią modelio struktūrą. Ekspertinės žinios čia nėra suprantamos kaip vėlesnė rankinė korekcija. Jos veikia kaip struktūruojantis principas, leidžiantis nuspręsti, kurie kintamieji turi būti laikomi priežastiniais, kokie ryšiai tarp jų yra prasmingi, kokie submodeliai turi būti jungiami ir kokias klaidų ar neapibrėžtumo formas verta modeliuoti. Kitaip tariant, ekspertas ne „taisykles prideda po visko“, bet dalyvauja kuriant pačią modeliavimo ontologiją.

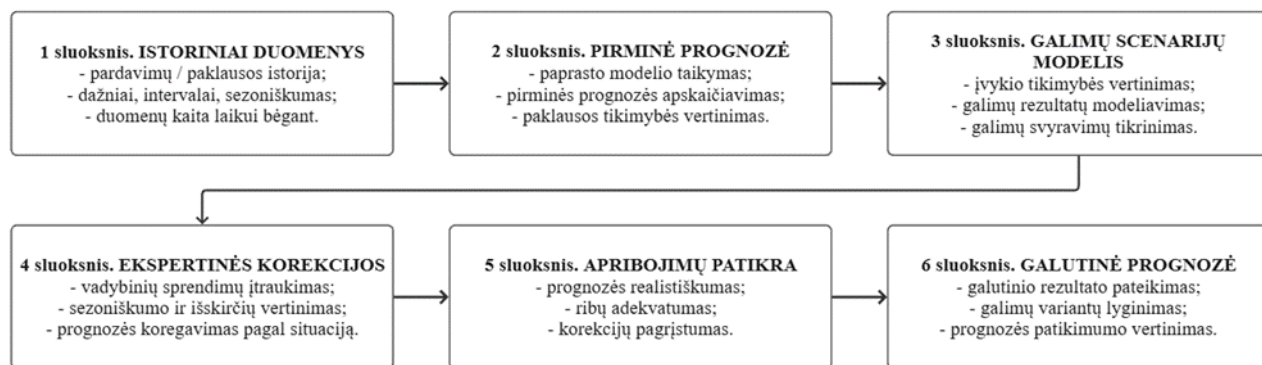


2 pav. Probabilistinis grafinis modelis

Būtent todėl Feng ir kt. modelis gali būti interpretuojamas kaip kelių tarpusavyje priklausomų sluoksnių sistema. Pirmiausia egzistuoja duomenų sluoksnis, kuriame surenkami empiriniai stebėjimai ir nustatomi statistiniai ryšiai. Toliau kuriamas teorinių arba fizikinių submodelių sluoksnis, kuriame duomenys aiškinami per tam tikras priežastines ar mechanistines prielaidas. Trečiasis sluoksnis yra ekspertinių žinių sluoksnis, kuriame apibrėžiami reikšmingi kintamieji, jų tarpusavio kryptys ir modelio struktūriniai apribojimai. Galiausiai viską apjungia neapibrėžtumo sluoksnis, leidžiantis atsekti, ar prognozės paklaida kyla iš duomenų ribotumo, iš submodelio netikslumo, ar iš klaidingų struktūrinių prielaidų. Šio modelio epistemologinė vertė yra ta, kad jis kuria ne tiesiog prognozavimo priemonę, o koreguojamą ir paaiškinamą sprendimų sistemą. Finansinių prognozių kontekste toks požiūris būtų itin vertingas, nes leistų ne tik gauti prognozę, bet ir identifikuoti, ar neapibrėžtumas kyla dėl nepakankamų istorinių duomenų, dėl rinkos lūžio, dėl netinkamo rodiklių susiejimo ar dėl pernelyg siaurai apibrėžto eksperto vertinimo. Kita vertus, šio modelio perkėlimas į finansinį prognozavimą susidurtų su rimtais praktiniais sunkumais. Finansų srityje nėra taip lengva, kaip chemijoje ar inžinerijoje, aiškiai pagrįsti priežastines grandines, nes finansiniai reiškiniai stipriau priklauso nuo organizacinio konteksto, strateginių sprendimų ir išorinių rinkos lūkesčių. Todėl nors modelis teoriškai yra itin stiprus, jo pritaikymas finansams reikalautų gerokai lankstesnės ir mažiau deterministinės struktūros.

Kitokį integracijos tipą pateikia Doszyń (2021) tyrimas, kuriame nagrinėjama ekspertinė sistema epizodinės paklausos prognozavimui. Čia modelis remiasi ne struktūriniu ekspertinių žinių įkomponavimu į patį tikimybinį modelį, bet statistinės prognozės ir ekspertinių korekcijų derinimu praktiniame prognozavimo procese. Straipsnyje siūloma sistema pirmiausia generuoja prognozes naudodama stochastinę simuliaciją ir klasikinius paklausos prognozavimo metodus, o vėliau ta prognozė koreguojama remiantis vadybinėmis taisyklėmis, kurias pateikia organizacijos ekspertai (Doszyn, M. (2021)). Ši sistema ypač įdomi tuo, kad ji aiškiai parodo vieną iš dažniausių realios organizacinės praktikos modelių: algoritmas sugeneruoja pagrindinį rezultatą, o ekspertas jį pakoreguoja atsižvelgdamas į sezoninius nukrypimus, pardavimo ypatumus, rinkos specifiką ar kitas

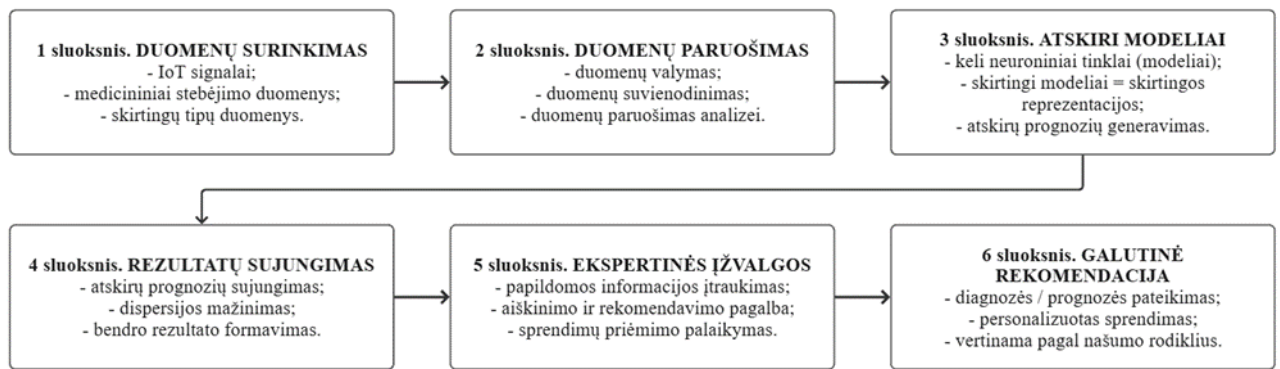
iš anksto neformalizuotas aplinkybes. Šio modelio logika yra dviejų etapų. Pirma, generuojama bazinė prognozė, paremta istorinių duomenų struktūra. Antra, ta prognozė keičiama taikant ekspertines taisykles, kurios dažnai kyla iš patirties, vidinių organizacijos žinių arba verslo intuicijos.



3 pav. Korekcinis modelis

Šio modelio stiprybė yra jo praktinis artumas realiam finansiniam planavimui. Daugelis įmonių finansines prognozes sudaro būtent taip: remiasi istoriniais duomenimis, tačiau vėliau jas koreguoja pagal žinomus būsimos veiklos veiksniai. Tokia logika labai artima balanso ir pelno (nuostolio) ataskaitų prognozavimui, nes organizacijos finansų specialistai dažnai žino apie būsimus kontraktus, planuojamas investicijas, sąnaudų optimizavimo iniciatyvas ar vienkartinus įvykius, kurių dar nėra istoriniuose duomenyse. Vis dėlto būtent čia išryškėja ir silpniausia Doszyń modelio vieta. Ekspertinių žinių integravimas yra korekcinis, bet ne struktūrinis. Tai reiškia, kad ekspertas nėra modelio dalis griežtąja prasme, o veikia kaip išorinė koregavimo jėga. Toks sprendimas padidina lankstumą, tačiau sumažina paaškinamumą ir pakartojamumą. Jei korekcijos nėra standartizuotos, labai sunku nustatyti, kada jos iš tiesų gerina prognozes, o kada tik atspindi subjektyvų šališkumą. Finansinių prognozių kontekste tai ypač problemiška, nes rankiniai koregavimai gali būti paveikti optimizmo, atsargumo, paskatų ar vidinių galios santykių organizacijoje. Taigi, šis modelis būtų tinkamas kaip praktinis pagrindas finansiniam prognozavimui, tačiau jo nepakanka, jei siekiama sukurti konceptualiai stiprią, skaidrią ir vertinimui tinkamą integruotą sistemą.

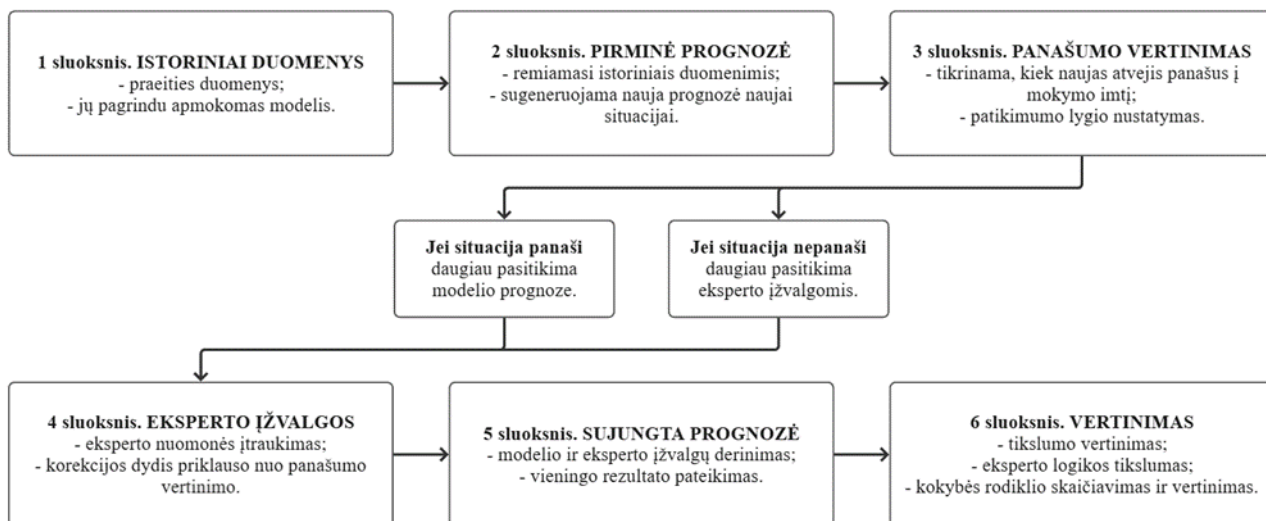
Trečioji kryptis atsiskleidžia Venkatachala Appa Swamy ir kt. (2023) straipsnyje, kuriame aprašomas IoT ir giliojo ansamblinio mokymosi pagrindu sukurtas diagnostinis modelis, gebantis agreguoti kelių modelių prognozes ir įtraukti ekspertinius faktus į sprendimų palaikymo sistemą. Nors šis modelis kurtas medicininei diagnostikai, jo architektūrinė logika svarbi ir finansinių prognozių literatūrai, nes jis rodo, kaip didelių duomenų, skirtingų modelių ir papildomų žinių derinimas gali padidinti sprendimų sistemos tikslumą bei robustiškumą. Šiame modelyje galima išskirti kelis funkcinius sluoksnius. Pirmasis sluoksnis yra didžiųjų duomenų ir jutiklių sluoksnis, kuriame surenkama heterogeniška informacija. Antrasis yra gilus mokymosi sluoksnis, kuriame atskiros architektūros mokosi iš skirtingų duomenų reprezentacijų. Trečiasis sluoksnis yra ansamblinis agregavimo sluoksnis, kuriame kelių modelių prognozės sujungiamos į galutinį rezultatą. Ketvirtasis sluoksnis veikia kaip ekspertinių faktų ir klinikinio sprendimų palaikymo grandis, kuri leidžia galutinę prognozę panaudoti personalizuotam sprendimui (Venkatachala Appa Swamy et al., 2021).



4 pav. Technologinis modelis

Šio modelio stiprybė slypi ne tiek pačiame ekspertinių žinių formalizavime, kiek sistemos robustume. Ansamblinis mokymasis čia suprantamas kaip būdas sumažinti atskirų modelių dispersiją, išvengti perteklinio prisitaikymo ir išgauti stabilesnį sprendimą nei naudojant vieną klasifikatorių. Perkeliant šią logiką į finansinių prognozių sritį, būtų galima teigti, kad finansinių rodiklių prognozėms taip pat tiktų kelių modelių derinimas. Pavyzdžiui, vienas modelis galėtų mokytis iš istorinių finansinių rodiklių, kitas iš makroekonominių kintamųjų, trečias iš tekstinių signalų ar vidinių veiklos duomenų, o galutinė prognozė būtų gauta agreguojant šias dalines išvadas. Tačiau būtent ekspertinių žinių klausimu šis modelis išlieka silpnesnis nei Feng ir kt. siūloma schema. Ekspertinės žinios čia nėra įjaustos į modelio priežastinę logiką, todėl sistema veikia tampa pažangiu daugiamodeliu prognozės generatoriumi, kurį vėliau gali interpretuoti žmogus. Finansų prognozių atveju tai naudinga tik iš dalies. Toks modelis galėtų pagerinti prognozių tikslumą, bet ne iki galo atsakytų į klausimą, kaip sistemiskai spręsti konfliktą tarp modelio rezultato ir ekspertinio vertinimo.

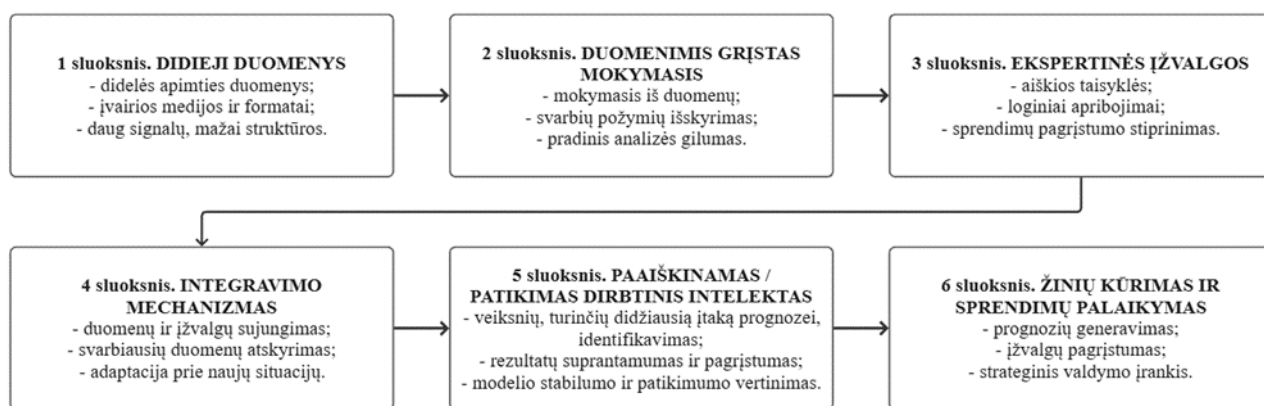
Čia itin svarbus tampa Park ir kt. (2023) straipsnyje pateiktas modelis, kuris yra arčiausiai finansinių prognozių problematikos, nes tiesiogiai sprendžia konfliktą tarp mašininio mokymosi modelių ir ekspertų sprendimų. Šio darbo pagrindinė idėja yra ta, kad ekspertų žinios neturi būti aklaiai priimanos visada, tačiau jos neturi būti ir ignoruojamos, kai modelio prognozė remiasi nepakankamai reprezentatyviais mokymo duomenimis. Mašininio mokymosi modeliai pasižymi aukštu tikslumu tais atvejais, kai prognozuojama situacija yra pakankamai reprezentuota mokymo duomenyse, tačiau jų patikimumas ženkliai mažėja režimų kaitos, struktūrinių lūžių ar naujų, istoriškai nepasitaikiusių situacijų metu. Tuo tarpu ekspertai gali turėti vertingos kontekstinės informacijos apie būsimus pokyčius, tačiau jų sprendimai gali būti veikiami subjektyvių šališkumų. Park ir kt. modelio tikslas – sukurti mechanizmą, kuris leistų adaptuojamai subalansuoti šiuos du informacijos šaltinius. Autoriai siūlo dviejų pakopų metodiką. Pirmiausia, naudojant generatyvinį priešišką tinklą nustatomas naujo stebėjimo reprezentatyvumo laipsnis mokymo imties atžvilgiu. Kitaip tariant, įvertinama, kiek naujas atvejis yra „panašus“ į tai, ką modelis anksčiau matė duomenyse. Antrajame etape pagal šį reprezentatyvumo laipsnį derinama modelio prognozė ir eksperto nuomonė. Jei naujas atvejis gerai reprezentuotas mokymo duomenyse, didesnis svoris tenka mašininio mokymosi modeliui. Jei atvejis nėra pakankamai reprezentuotas, daugiau svorio suteikiama eksperto vertinimui (Park et al., 2023). Svarbu pabrėžti, kad ekspertinė informacija čia nėra naudojama kaip neformalus pataisymas, bet tampa formalia modelio įėjimo dalimi, kurios įtaka yra valdoma pagal aiškiai apibrėžtą taisyklę. Tokiu būdu ekspertinis sprendimas konceptualizuojamas kaip signalas, kurio svoris kinta priklausomai nuo duomenų reprezentatyvumo.



5 pav. Adaptacinis modelis

Šio modelio sprendimų priėmimo principas yra labai stiprus, nes jis pagaliau pateikia principinį atsakymą į vieną esminį prognozavimo klausimą: kada reikia pasitikėti modeliu, o kada žmogui. Tai svarbu todėl, kad dauguma hibridinių modelių tik deklaruoja žmogaus ir algoritmo derinimą, bet nepaaiškina, kokių principu tas derinimas turi vykti. Park ir kt. (2023) siūloma sistema yra būtent konfliktų sprendimo modelis. Ji leidžia ne tik integruoti eksperto žinias, bet ir racionaliai pagrįsti jų svorį. Finansinių prognozių kontekste tai ypač vertinga, nes finansų analitikai dažnai susiduria su situacijomis, kai modelio rezultatas „nesutampa“ su žinoma informacija apie būsimus strateginius sprendimus, reguliacinius pokyčius, sutartis ar rinkos sukrėtimus. Tokiais atvejais nepakanka vien pasakyti, kad ekspertas turėtų pakoreguoti prognozę. Reikia paaiškinti, kodėl jo korekcija yra pagrįsta. Park ir kt. modelis būtent tai ir leidžia padaryti. Jo trūkumas yra tas, kad jis koncentruojasi į konfliktų sprendimo mechanizmą, bet mažiau dėmesio skiria platesnei, daugiasluoksnei sistemos architektūrai. Kitaip tariant, jis labai gerai apibrėžia svorių paskirstymą tarp modelio ir eksperto, tačiau pats nėra pakankamas kaip visas finansinių prognozių modelis, nes neapima nei platesnio duomenų inžinerijos, nei priežastinio rodiklių tinklo, nei neapibrėžtumo sluoksnio.

Galiausiai Zhuang ir kt. (2017) pateikia ne konkretų empirinį modelį, o bendrą AI 2.0 sampratą, pagal kurią ateities dirbtinis intelektas turi judėti nuo vien duomenimis grįsto mokymosi prie sistemų, kurios jungia duomenų analizę, struktūruotas logines taisykles ir žmogaus žinias. Straipsnyje pateikiama itin svarbi teorinė išvalga, kad vien gilusis mokymasis, nors ir pasižymi gebėjimu automatiškai išgauti požymius iš didelių duomenų masyvų, išlieka ribotas, kai reikia paaiškinamumo, semantinio pagrindimo ir mokymosi iš mažesnių ar nepilnai paženklintų imčių.



6 pav. Konceptualus DI 2.0 modelis

Zhuang ir kt. (2017) siūlo matyti pažangų dirbtinį intelektą kaip perėjimą 1) nuo paviršinių skaičiavimų prie gilaus samprotavimo, 2) nuo vien duomenimis grįstų modelių prie sistemų, kuriose integruojamos struktūruotos loginės taisyklės, ir 3) nuo siaurai užduočiai pritaikyto intelekto prie bendresnių, patirtimi besimokančių sistemų. Finansinių prognozių požiūriu ši koncepcija svarbi todėl, kad suteikia teorinį pagrindą pačiai integracijos idėjai. Ji nepasako, kaip tiksliai reikia prognozuoti pajamas ar balansą, tačiau aiškiai nurodo, kad vienas modelis negali būti laikomas pakankamu, jei jis negeba sujungti duomenų, taisyklių ir žmogaus intucijų.

Apibendrinant galima teigti, kad iš analizuotų straipsnių pateiktų modelių nė vienas atskirai nėra visiškai pakankamas finansinių prognozių uždaviniui, tačiau kiekvienas pateikia reikšmingą teorinį komponentą, kuris gali būti panaudotas kuriant stipresnį, daugiasluoksnį hibridinį finansinių prognozių modelį.

2.5.2. Integruotų finansinių prognozavimo modelių analizė

Analizuojami modeliai atskleidžia skirtingas dirbtinio intelekto ir ekspertinių žinių integracijos paradigmas, kurios skiriasi tiek metodologine logika, tiek praktiniu pritaikomumu. Visų modelių bendras tikslas yra spręsti esminę problemą – vien tik duomenimis grįstų modelių ribotumą, kai prognozės tampa nepatikimos dėl duomenų trūkumo, nestabilumo ar nereprezentatyvumo. Tačiau jų siūlomi sprendimai skiriasi integracijos gyliu, formalizavimo lygiu ir orientacija į paaiškinamumą.

5 lentelė. Integruotų finansinių prognozavimo modelių analizė

Modelis	Stiprybės	Silpnybės	Tinkamumas	Autorius
Konceptualus DI 2.0	Jungia duomenis ir žinias; apima visą grandinę nuo duomenų iki sprendimų.	Nėra konkretaus metodo, tik konceptas.	Tinkamas kaip teorinis pagrindas	Zhuang et al. (2017)
Probabilistinis grafinis modelis	Paaiškinamasis DI; neapibrėžtumo vertinimas; lankstumas integruojant skirtingus duomenis.	Dideli reikalavimai ekspertinėms žinioms; sunkiai pritaikomas, kai ryšiai nestabilūs.	Tinkamas kompleksinėms prognozėms.	Feng et al. (2020)
Adaptacinis	Dinamiškas svorių paskirstymas mažina klaidų riziką nestandartinėse situacijose.	Ribotas analizės gilumas, nes keičia modelio struktūros, tik koreguoja rezultata.	Tinkamas esant duomenų trūkumui.	Park et al. (2023)

Modelis	Stiprybės	Silpnybės	Tinkamumas	Autorius
Korekcinis	Lengvai pritaikomas, nereikalauja sudėtingų modelių; leidžia įtraukti praktinę patirtį ir kontekstą.	Mažas sprendimų pagrindumas, nes korekcijos nėra formalizuotos	Tinkamas operaciniam prognozavimui.	Doszyń (2021)
Technologinis	Aukštas tikslumas dėl skirtingų modelių sujungimo; mažima rezultatų svyravimus; gerai veikia su dideliais duomenimis.	„Juodoji dėžė“, nes sunku paaiškinti rezultata; silpnas sprendimų pagrindumas be papildomos interpretacijos.	Tinkamas dideliems duomenims.	Venkatachala Appa Swamy et. Al. (2023)

Pirmiausia, Zhuang ir kt. (2017) modelis reprezentuoja konceptualųjį, aukščiausio lygmens požiūrį į dirbtinio intelekto evoliuciją, kuriame akcentuojama perėjimo nuo duomenų prie žinių logika. Šiame modelyje integracija suvokiama kaip sisteminis procesas, apimantis duomenimis grįstą mokymąsi, žmogaus žinias ir jų sujungimą per integravimo mechanizmus, leidžiančius pasiekti paaiškinamą ir patikimą dirbtinį intelektą (Zhuang et al., 2017). Šio modelio stiprybė yra aukštas teorinis universalumas ir aiški integracijos filosofija, tačiau jo trūkumas – ribotas operacionalizavimas, nes nėra aiškiai apibrėžta, kaip konkrečiai įgyvendinti integraciją praktiniuose modeliuose.

Priešingai, Feng ir kt. (2020) modelis siūlo formalizuotą, matematiškai pagrįstą integracijos struktūrą, paremtą tikimybiniais grafinais modeliais (PGM), kurie leidžia sujungti duomenis, fizinius modelius ir ekspertines žinias į vieningą tikimybinę sistemą. Šiame modelyje integracija vyksta per priežastinių ir koreliacinių ryšių struktūrizavimą, o neapibrėžtumo kvantifikavimas tampa centriniu elementu, leidžiančiu vertinti modelio patikimumą ir identifikuoti klaidų šaltinius. Šio modelio privalumas yra aukštas paaiškinamumo lygis ir sprendimų pagrindumas, tačiau jo trūkumas – sudėtingumas ir dideli reikalavimai ekspertinėms žinioms bei modelio struktūrai.

Tuo tarpu Park ir kt. (2023) modelis orientuojasi į konkrečią praktinę problemą – konfliktą tarp mašininio mokymosi prognozių ir ekspertų sprendimų. Šiame modelyje integracija realizuojama per adaptacinį svorio mechanizmą, kuris priklauso nuo duomenų reprezentatyvumo. Jei naujas atvejis panašus į mokymo duomenis, didesnis svoris skiriamas modeliui, o jei ne – ekspertui. Šio modelio stiprybė yra dinamiškas ir kontekstinis integracijos principas, leidžiantis išvengti aklo pasitikėjimo modelių. Tačiau jo trūkumas – ribotas analizės gilumas, nes modelis daugiausia koreguoja rezultata, o ne integruoja žinias struktūriniu lygmeniu.

Doszyń (2021) modelis atspindi klasikinę ekspertinių sistemų paradigmą, kurioje statistiniai modeliai papildomi ekspertinėmis korekcijomis, ypač prognozuojant nepastovią paklausą. Šiame modelyje integracija vyksta post-prognozavimo etape, kai statistinė prognozė koreguojama remiantis vadybinėmis žiniomis ir patirtimi. Šio modelio privalumas yra paprastumas ir lengvas pritaikomumas praktikoje, tačiau trūkumas – žemas formalizavimo lygis ir didelė subjektyvumo rizika, kas mažina sprendimų pagrindumą.

Galiausiai, Swamy ir kt. (2023) modelis reprezentuoja technologinį, duomenimis intensyvų požiūrį, kuriame integracija realizuojama per deep learning ir ensemble metodus. Šiame modelyje keli neuroniniai tinklai generuoja prognozes, kurios agreguojamos siekiant sumažinti dispersiją ir padidinti tikslumą, o ekspertinės žinios veikia kaip papildomas interpretacinis sluoksnis. Šio modelio stiprybė yra aukštas prognozavimo tikslumas ir robustiškumas, tačiau trūkumas – ribotas paaiškinamumas ir silpnas sprendimų pagrindumas be papildomų interpretavimo mechanizmų.

Palyginus šiuos modelius tarpusavyje, matyti, kad jie skiriasi ne vien taikymo sritimis, bet ir pačia integracijos samprata. Feng ir kt. modelis yra labiausiai struktūrinis ir epistemologiškai gilus, nes ekspertines žinias paverčia modelio architektūros dalimi. Doszyń modelis yra labiausiai pragmatiškas ir artimas realiai verslo praktikai, nes leidžia ekspertui koreguoti statistines prognozes pagal patirtį. Venkatachala Appa Swamy ir kt. modelis akcentuoja tikslumo ir robustumo didinimą per kelių DI modelių ansamblinį sujungimą, tačiau ekspertinės žinios jame atlieka veikiau papildomą nei struktūrinę funkciją. Park ir kt. modelis yra stipriausias tada, kai reikia spręsti konkrečius modelio ir eksperto konflikto atvejus, nes pateikia aiškų kriterijų, kada kuriuo šaltiniu labiau pasitikėti. Zhuang ir kt. koncepcija savo ruožtu veikia kaip teorinis metamodelis, paaiškinantis, kodėl apskritai reikalingas duomenų, taisyklių ir žmogaus žinių junginys.

Nepaisant skirtumų, tarp šių modelių egzistuoja ir reikšmingų panašumų. Visi jie vienaip ar kitaip atsisako minties, kad vien istorinių duomenų pakanka kokybiškam prognozavimui. Visi taip pat pripažįsta, kad žmogaus žinios nėra atsitiktinis triukšmas, bet vertingas informacijos šaltinis, ypač tada, kai duomenys yra riboti, nepakankamai reprezentatyvūs arba neapima būsimų lūžių. Be to, visi modeliai vienaip ar kitaip susiduria su tuo pačiu centriniu klausimu – kaip užtikrinti, kad modelio prognozė būtų ne tik tiksli, bet ir patikima, paaiškinama bei priimtina sprendimų priėmėjui. Skirtumas tas, kad vieni autoriai šį klausimą sprendžia per neapibrėžtumo kvantifikavimą, kiti per taisyklių sistemą, tretį per ekspertinių korekcijų mechanizmą, o ketvirtį per ansamblinį agregavimą.

2.6. Didžiųjų duomenų ir ekspertinių įžvalgų integravimo į dirbtinio intelekto finansinių prognozių sprendimus teorinis modelis

Siekiant sukurti teoriškai pagrįstą ir praktiškai pritaikomą finansinių prognozių modelį, kuris integruotų didžiuosius duomenis ir ekspertines žinias į vieną veikiančią dirbtinio intelekto pagrindu veikiančią modelį, tikslinga integruoti Zhuang ir kt. (2017) siūlomą AI 2.0 koncepcinį pagrindą su Park ir kt. (2023) adaptaciniu sprendimų mechanizmu. Toks modelis leidžia vienu metu išnaudoti didžiųjų duomenų teikiamas galimybes, užtikrinti analizės gilumą ir kartu spręsti vieną esminių prognozavimo problemų – kaip elgtis situacijose, kai istoriniai duomenys nėra pakankamai reprezentatyvūs.

Integruotas modelis remiasi dviejų skirtingų, tačiau viena kitą papildančių teorinių kryptų deriniu. Pirmoji kryptis yra Zhuang ir kt. (2017) AI 2.0 koncepcija, kuri akcentuoja didžiųjų duomenų, duomenimis grįsto mokymosi ir žmogaus žinių integraciją į vieningą sistemą. Šis požiūris suteikia modelio architektūrai struktūrinį pagrindą ir leidžia užtikrinti analizės gilumą, nes prognozavimas suvokiamas kaip daugiapakopis procesas, pereinantis nuo duomenų prie sprendimų.

Antroji kryptis – Park ir kt. (2023) siūlomas adaptacinis modelis, kuris sprendžia vieną esminių praktinių problemų: kaip elgtis, kai nauji duomenys nėra pakankamai panašūs į istorinius. Šiame modelyje įvedamas reprezentatyvumo vertinimo principas, leidžiantis dinamiškai paskirstyti pasitikėjimą tarp modelio prognozės ir eksperto įžvalgų. Šių dviejų požiūrių derinimas leidžia sukurti modelį, kuris yra ne tik struktūriškai pagrįstas, bet ir adaptyvus realioms situacijoms.

Prognozavimo specifika

Modelis remiasi idėja, kad finansinių prognozių tikslumas realiame verslo kontekste negali būti pasiektas vien tik automatizuotu istorinių duomenų apdorojimu arba vien ekspertinėmis įžvalgomis. Modelio esmė – sujungti didžiųjų duomenų analitikos galimybes, dirbtinio intelekto prognozavimo mechanizmus ir ekspertines žinias į vieną integruotą prognozavimo sistemą. Šis modelis remiasi AI

2.0 koncepcija, kuri dirbtinį intelektą suvokia ne kaip autonominių sprendimų priėmėją, bet kaip sistemą, veikiančią kartu su žmogumi ir jo patirtimi. Modelyje taip pat atsispindi adaptacinio prognozavimo logika, kai sprendžiama, kiek konkrečioje situacijoje pasitikėti statistine prognoze, o kiek – ekspertų vertinimu.

Modelio veikimo logika

Modelio veikimas grindžiamas nuosekliu procesu, kuriame pirmiausia iš didžiųjų duomenų formuojamas informacinis pagrindas, vėliau sukuriama pirminė prognozė naudojant duomenimis grįstą modelį, o tuomet atliekamas naujos situacijos panašumo į istorinius duomenis vertinimas. Šis vertinimas tampa pagrindiniu sprendimo kriterijumi, kuris lemia, ar prognozėje dominuos modelio rezultatas, ar ekspertinė nuomonė.



7 pav. Didžiųjų duomenų ir ekspertinių išvalgų integravimo į dirbtinio intelekto finansinių prognozių sprendimus teorinis modelis

Pirmasis modelio sluoksnis – didieji duomenys. Šiame sluoksnyje surenkami ir konsoliduojami dideli kiekiai įvairių tipų duomenų, kurie sudaro pagrindą tolimesnei analizei. Modelyje naudojami tiek vidiniai organizacijos duomenys, tiek išoriniai rinkos ir makroekonominiai rodikliai. Vidiniai duomenys apima istorinius pardavimus, pajamas, sąnaudas, pinigų srautus, biudžetų vykdymo rezultatus, atsargų apyvartumą, klientų elgsenos rodiklius, gamybos efektyvumo duomenis bei ERP sistemose kaupiamą informaciją. Išoriniai duomenys apima infliaciją, palūkanų normas, valiutų kursų, žaliavų kainas, rinkos augimo tempus, konkurentų veiksmus, geopolitinius pokyčius bei kitus išorinius veiksnus, galinčius turėti įtakos prognozėms. Šio sluoksnio paskirtis – sukurti kuo platesnį

organizacijos veiklos ir aplinkos vaizdą. Modelis remiasi prielaida, kad finansinių prognozių tikslumas didėja tada, kai analizuojami ne tik tradiciniai finansiniai rodikliai, bet ir platesnė verslo aplinka.

Antrajame sluoksnyje vyksta duomenų paruošimas ir analizė. Šiame sluoksnyje surinkti duomenys yra valomi, sisteminami ir transformuojami į analizei tinkamą formą. Kadangi didieji duomenys dažnai pasižymi nevienodu formatu, triukšmu, pasikartojimais ar trūkstamomis reikšmėmis, šiame sluoksnyje atliekamas duomenų valymas, normalizavimas, anomalijų identifikavimas bei skirtingų šaltinių suderinimas. Taip pat šiame etape išskiriami svarbiausi prognozavimui reikšmingi rodikliai. Modelis remiasi nuostata, kad ne visi duomenys turi vienodą vertę prognozavimui, todėl dirbtinis intelektas turi identifikuoti tuos veiksnius, kurie labiausiai veikia prognozės tikslumą. Šiame sluoksnyje taip pat vyksta duomenimis grįstas mokymasis – ieškoma pasikartojančių dėšningumų, koreliacijų, cikliškumų bei ryšių tarp skirtingų kintamųjų.

Trečiajame sluoksnyje formuojama pirminė prognozė. Ši prognozė generuojama remiantis tik istoriniais ir statistiniais duomenimis, neįtraukiant žmogaus vertinimo. Šio sluoksnio logika grindžiama prielaida, kad istoriniai duomenys turi pasikartojančių modelių, kuriuos dirbtinis intelektas gali identifikuoti ir panaudoti ateities prognozėms. Priklausomai nuo organizacijos poreikių, šiame etape gali būti naudojami įvairūs mašininio mokymosi, neuroninių tinklų ar laiko eilučių prognozavimo metodai. Pirminė prognozė gali apimti pardavimų prognozes, pinigų srautus, sąnaudų pokyčius, paklausos tendencijas ar investicijų atsiperkamumą. Tačiau ši prognozė laikoma tik baziniu scenarijumi, nes ji remiasi vien statistiniais duomenimis ir nevertina specifinių verslo niuansų, rinkos nuotaikų ar organizacijos viduje vykstančių procesų.

Ketvirtajame sluoksnyje į modelį integruojamos ekspertinės įžvalgos. Šiame sluoksnyje į prognozavimo procesą įtraukiama informacija, kurios nėra istoriniuose duomenyse, tačiau kuri gali turėti reikšmingą poveikį prognozės tikslumui. Ekspertinės įžvalgos gali apimti planuojamus strateginius sprendimus, naujus kontraktus, investicijas, rinkos pokyčius, konkurentų veiksmus, tiekimo grandinės rizikas ar vidinius organizacijos pokyčius. Šis sluoksnis remiasi idėja, kad realiame versle egzistuoja daug implicitinių žinių, kurios nėra formalizuotos sistemose, tačiau turi didelę reikšmę prognozėms. Modelis taip pat numato, kad ekspertinės įžvalgos negali būti priimamos akiai – jos turi būti pagrįstos realiais faktais, rinkos signalais ar praktine patirtimi.

Penktasis sluoksnis yra pagrindinis modelio integracinis vertinimo elementas – situacijos panašumo vertinimas. Šiame etape vertinama, kiek dabartinė organizacijos situacija yra panaši į istorinius scenarijus, kuriais remiantis buvo sudaryta pirminė prognozė. Jei sistema nustato, kad esama situacija yra labai panaši į istorinius duomenis, didesnis pasitikėjimas suteikiamas dirbtinio intelekto sugeneruotai prognozei. Tačiau jei situacija reikšmingai skiriasi nuo anksčiau matytų scenarijų, pavyzdžiui, vyksta rinkos krizė, atsiranda nauji reguliaciniai pokyčiai ar organizacijoje vyksta struktūriniai pokyčiai, didesnė svarba suteikiama ekspertų įžvalgoms. Šis sluoksnis leidžia modeliui tapti adaptaciniu, nes prognozavimo logika prisitaiko prie konkretaus konteksto. Tokiu būdu išvengiama situacijų, kai dirbtinis intelektas pernelyg remiasi praeities duomenimis net tada, kai aplinka iš esmės pasikeitusi.

Šeštajame sluoksnyje formuojama integruota prognozė. Šiame sluoksnyje sujungiami dirbtinio intelekto sugeneruoti rezultatai, ekspertų korekcijos bei situacijos panašumo vertinimo rezultatai. Galutinė prognozė tampa kompromisu tarp statistinio modelio ir žmogaus patirties. Modelis remiasi

prielaida, kad didžiausias prognozių tikslumas pasiekiamas tada, kai dirbtinis intelektas naudojamas dėsningumą identifikavimui, o ekspertai – nestandartinių situacijų interpretavimui. Integruota prognozė laikoma kokybiškai aukštesnio lygio sprendimu nei vien automatizuotas prognozavimas arba vien ekspertinis vertinimas.

Paskutinis, septintasis sluoksnis, yra sprendimų palaikymas. Šiame etape sistema ne tik pateikia galutinę prognozę, bet ir paaiškina, kodėl ji buvo suformuota būtent tokia. Modelis pateikia svarbiausius prognozę nulėmusius veiksnius, rizikų vertinimą, prognozės patikimumo lygį bei galimus alternatyvius scenarijus. Šis sluoksnis ypač svarbus finansų analitikoje, nes vadovams nepakanka vien galutinio skaičiaus – jiems būtina suprasti prognozės logiką, jos pagrindimą bei rizikas. Todėl modelis tampa ne tik prognozavimo sistema, bet ir sprendimų palaikymo įrankiu, padedančiu vadovams greičiau priimti sprendimus, geriau suprasti verslo rizikas bei pagrįsti strateginius veiksmus.

Modelio taikymas

Modelis gali būti taikomas įvairiems finansinių prognozių uždaviniams, ypač tais atvejais, kai svarbu derinti kiekybinius duomenis su kokybinėmis išvalgomis. Pavyzdžiui, jis gali būti naudojamas prognozuojant balanso ar pelno (nuostolio) ataskaitų rodiklius, planuojant pajamų ar sąnaudų pokyčius, taip pat vertinant scenarijus esant neapibrėžtumui. Ypač didelę vertę modelis turi situacijose, kai organizacija susiduria su nestandartinėmis sąlygomis, pavyzdžiui, ekonominėmis krizėmis, reguliaciniais pokyčiais ar strateginėmis transformacijomis. Tokiose situacijose tradiciniai modeliai dažnai praranda tikslumą, o šis modelis leidžia adaptuoti prognozę, įtraukiant ekspertinį vertinimą.

Kritinis vertinimas: privalumai ir trūkumai

Integruotas modelis pasižymi keliomis esminėmis stiprybėmis. Pirmiausia, jis užtikrina analizės gilumą, nes remiasi didžiaisiais duomenimis ir pažangiais mokymosi metodais. Antra, jis didina sprendimų pagrįstumą, nes ekspertinės žinios integruojamos ne atsitiktinai, o remiantis aiškiais kriterijumi – duomenų reprezentatyvumu. Trečia, modelis yra adaptyvus, nes geba keisti sprendimų logiką priklausomai nuo situacijos. Galiausiai, jis prisideda prie paaiškiamo dirbtinio intelekto plėtos, nes leidžia identifikuoti, kada ir kodėl buvo pasirinkta viena ar kita prognozavimo strategija.

Vis dėlto modelis turi ir tam tikrų ribotumų. Jo efektyvumas priklauso nuo reprezentatyvumo vertinimo tikslumo, kuris gali būti sudėtingas realiose finansinėse situacijose. Be to, modelio įgyvendinimas reikalauja aukšto duomenų kokybės lygio ir kompetentingų ekspertų, galinčių pateikti pagrįstas išvalgas. Nepaisant to, toks integruotas požiūris laikytinas perspektyvia kryptimi, siekiant sukurti pažangius finansinių prognozių modelius, kurie būtų ne tik tikslūs, bet ir interpretuojami bei pritaikomi praktikoje.

Teorinė ir praktinė reikšmė

Teoriniu požiūriu šis modelis prisideda prie dirbtinio intelekto ir ekspertinių žinių integracijos problematikos sprendimo, parodydamas, kaip galima sistemingai derinti skirtingus informacijos šaltinius. Jis išplečia tradicinį prognozavimo supratimą, pabrėždamas, kad prognozė turi būti ne tik tiksli, bet ir pagrįsta bei interpretuojama. Praktiniu požiūriu modelis suteikia organizacijoms įrankį, leidžiantį priimti geriau pagrįstus sprendimus sudėtingoje ir neapibrėžtoje aplinkoje. Jo taikymas gali

pagerinti finansinių prognozių kokybę, sumažinti klaidų riziką ir padidinti pasitikėjimą analitiniais sprendimais. Todėl toks modelis gali būti laikomas perspektyvia kryptimi kuriant pažangias finansinės analizės sistemas.

Teorinių sprendimų apibendrinimas ir implikacijos empiriniam tyrimui

Antrojoje darbo dalyje buvo nuosekliai analizuoti teoriniai sprendimai, susiję su dirbtinio intelekto taikymu finansinių prognozių sudaryme, akcentuojant didžiųjų duomenų analitikos, pažangių prognozavimo metodų ir ekspertinių žinių integravimo problematiką. Atlikta mokslinės literatūros analizė leidžia daryti išvadą, kad šiuolaikinės finansinių prognozių inovacijos negali būti redukuojamos vien į techninį prognozavimo algoritmų tobulinimą, nes prognozavimo kokybę lemia platesnė socio-techninė sistema, apimanti duomenis, modelius ir sprendimų kontekstą.

Pirmiausia nustatyta, kad didžiųjų ir alternatyvių duomenų naudojimas finansinėse prognozėse suteikia papildomų galimybių fiksuoti silpnus ir ankstyvus signalus, tačiau pats duomenų kiekis savaime negarantuoja geresnių prognozių. Mokslinėje literatūroje pabrėžiama, kad duomenų vertė prognozavime atsiranda tik tada, kai jie yra prasmingai susieti su prognozavimo horizontu, sprendimo tikslu ir finansiniu kontekstu. Priešingu atveju dideli duomenų kiekiai gali didinti triukšmą ir modelio nestabilumą, ypač struktūrinių pokyčių laikotarpiams.

Antra, analizuoti dirbtinio intelekto ir mašininio mokymosi metodai parodė, kad finansinėse prognozėse vis didesnę reikšmę įgauna ansambliniai ir kombinavimo sprendimai. Vietoje „vieno geriausio modelio“ paieškos teorija ir empirika kryptingai juda link kelių modelių rezultatų derinimo, siekiant sumažinti priklausomybę nuo vienos prielaidos ir padidinti prognozių stabilumą. Tai ypač aktualu finansų srityje, kur laiko eilučių dinamika dažnai keičiasi, o vienas modelis retai geba patikimai aprašyti visus režimus.

Trečia, ekspertinių žinių analizė atskleidė, kad praktikoje egzistuoja reikšmingas atotrūkis tarp statistiniais duomenimis pagrįstų prognozių ir vadovų ar analitikų turimų kontekstinių žinių apie rinkos, reguliavimo ar strateginius pokyčius. Literatūra rodo, kad ekspertinės žinios gali pagerinti prognozių kokybę, ypač tais atvejais, kai istoriniai duomenys tampa mažiau informatyvūs, tačiau nekontroliuojamas ir intuityvus ekspertinis įsikišimas dažnai didina sisteminių klaidų riziką. Todėl teoriniu lygmeniu pagrįstas ne pats ekspertų dalyvavimo faktas, o būtinybė jų žinias integruoti formalizuotai ir valdomai.

Ketvirta, prognozavimo sistemos valdymo ir paaiškinamumo aspektai išryškėjo kaip būtina sąlyga prognozių pritaikomumui sprendimų priėmimo. Net ir statistiškai tikslios prognozės praranda vertę, jei jų negalima paaiškinti, pagrįsti ar atsekti organizacinėje aplinkoje. Paaiškinamojo dirbtinio intelekto (XAI) metodai sudaro prielaidas suprasti veiksnių indėlį, modelių sprendimų logiką ir ekspertinių korekcijų poveikį, taip stiprindami prognozių patikimumą ir jų priėmimą vadybiniu lygmeniu.

Galiausiai, teorinėje analizėje akcentuota neapibrėžtumo svarba finansinėse prognozėse. Finansiniai sprendimai dažnai priklauso ne tik nuo taškinės prognozės, bet ir nuo rizikos įvertinimo, todėl tikimybinis požiūris ir intervalinės prognozės laikytinos reikšminga prognozavimo sistemos dalimi. Tai leidžia geriau derinti statistinę informaciją ir ekspertines prielaidas, ypač situacijose, kuriose ateities raida yra neapibrėžta.

Apibendrinant galima teigti, kad antrojoje darbo dalyje išanalizuoti teoriniai sprendimai formuoja nuoseklų pagrindą empiriniam tyrimui, kuriame finansinių prognozių vertė bus vertinama ne tik

prognozės tikslumo, bet ir stabilumo, paaiškinamumo bei pritaikomumo sprendimų priėmimo aspektais. Tyrimui keliami moksliniai klausimai – kaip praktikoje integruoti didžiuosius duomenis ir ekspertines žvalgas į dirbtinio intelekto finansinių prognozių sprendimus?

3. Didžiųjų duomenų ir ekspertinių įžvalgų integravimo į dirbtinio intelekto finansinių prognozių sprendimus tyrimo metodologija

Šiame skyriuje pristatoma empirinio tyrimo metodologija, apibrėžianti tyrimo strategiją, duomenų rinkimo ir analizės metodus, imties formavimo principus bei tyrimo patikimumo užtikrinimo priemonės. Metodologija grindžiama siekiu nuosekliai ištirti finansų specialistų požiūrį į dirbtinio intelekto taikymą finansinių prognozių sudaryme ir įvertinti ekspertinių žinių, didžiųjų duomenų, bei DI sprendimų sąveiką praktikoje.

Empirinio tyrimo tikslas – išanalizuoti finansų specialistų požiūrį į dirbtinio intelekto taikymą finansinių prognozių sudaryme ir įvertinti ekspertinių žinių bei DI sprendimų sąveiką praktiniame prognozavimo procese.

Siekiant įgyvendinti tyrimo tikslą, keliami šie **uždaviniai**:

- Išsiaiškinti, kaip finansų specialistai praktikoje taiko dirbtinio intelekto sprendimus prognozavime;
- Išsiaiškinti finansų specialistų požiūrį į DI sprendimų patikimumą ir tikslumą;
- Identifikuoti pagrindinius iššūkius ir rizikas, susijusias su DI taikymu finansinėse prognozėse;
- Nustatyti, kokį vaidmenį prognozavimo procese atlieka ekspertinės žinios;
- Išsiaiškinti, kaip ekspertai derina statistinius duomenis, modelių rezultatus ir savo ekspertines žinias prognozavimo procese;
- Nustatyti, ar ekspertai mato potencialą sistemingesniam DI ir ekspertinių žinių integravimui ateityje.

Tyrimo strategija ir metodas

Atsižvelgiant į darbo tikslą ir nagrinėjamos problemos pobūdį, šiame tyrime taikoma kokybinė tyrimo strategija. Kokybiniai tyrimai yra tinkami tuomet, kai siekiama giliau suprasti kompleksinius, kontekstinius ir socialinius reiškinius, kurių negalima adekvačiai išmatuoti vien kiekybiniais rodikliais (Creswell & Creswell, 2018). Tokia metodologija pasirinkta siekiant giliau suprasti, kaip finansinių prognozių sudarymas vyksta praktikoje, kokį vaidmenį jame atlieka dirbtinio intelekto (DI) sprendimai ir kaip finansų specialistai vertina DI bei ekspertinių žinių integravimo galimybes prognozavimo kontekste. Šio darbo kontekste tiriamas reiškinys – dirbtinio intelekto ir ekspertinių žinių sąveika finansinių prognozių procese – yra daugialypis ir priklausomas nuo organizacinio konteksto, individualios patirties bei sprendimų priėmimo logikos. Todėl kokybinė metodologija leidžia atskleisti ne tik faktinius taikymo aspektus, bet ir gilesnius interpretacinius mechanizmus, kurie lemia prognozavimo sprendimus.

Kokybinis tyrimas yra tinkamas šiam darbui dėl kelių priežasčių. Pirma, nagrinėjama problema yra susijusi su praktinėmis patirtimis ir sprendimų priėmimo logika, kurios negalima pilnai atskleisti kiekybiniais metodais. Antra, ekspertinių žinių vaidmuo yra kontekstinis ir dažnai intuicinis, todėl reikalauja interpretacinės analizės. Trečia, dirbtinio intelekto taikymas finansuose vis dar yra besiformuojanti sritis, todėl svarbu identifikuoti ne tik dėsningumus, bet ir naujas įžvalgas. Tai ypač

aktualu analizuojant ekspertines žinias, kurios dažnai yra intuityvios, sunkiai formalizuojamos ir priklausomos nuo individualaus vertinimo.

Tyrimo metodas – pusiau struktūruoti ekspertiniai interviu. Šis metodas plačiai taikomas socialinių mokslų tyrimuose, kai siekiama derinti struktūruotą duomenų rinkimą su lankstumu ir galimybe gilintis į respondentų patirtis (Kvale & Brinkmann, 2009). Pusiau struktūruoti interviu leidžia: 1) užtikrinti, kad visi tyrimo aspektai būtų aptarti; 2) išlaikyti klausimų nuoseklumą tarp respondentų; 3) tuo pačiu suteikti galimybę plėtoti temas, kurios atsiskleidžia interviu metu. Šis metodas leidžia identifikuoti situacijas, kuriose modelių rezultatai ir ekspertų vertinimai nesutampa, bei suprasti sprendimų priėmimo logiką. Tyrimo logika grindžiama interpretatyvistine paradigma, kuri akcentuoja subjektyvios patirties, reikšmių ir konteksto svarbą (Saunders et al., 2019).

Tyrimo imtis ir repondentų atranka

Kokybinio tyrimo imtis laikoma pakankama, kai yra pasiekama duomenų saturacija ir kai nauji interviu nebesuteikia esmingai naujos informacijos (Guest et al., 2006). Tyrimo dalyviais pasirinkti finansų specialistai, dirbantys su įmonių finansine analitika, biudžetavimu, prognozavimu ar finansiniu planavimu. Respondentų atranka grindžiama tiksline (ekspertine) atranka, kai į tyrimą įtraukiami asmenys, turintys praktinės patirties finansinių prognozių sudarymo srityje.

Atrankos kriterijai: 1) darbo patirtis finansų analitikos, planavimo ar prognozavimo srityje; 2) tiesioginis ar netiesioginis dalyvavimas rengiant įmonių finansines prognozes; 3) sąlytis su duomenimis, analitiniais įrankiais ar prognozavimo modeliais.

Atliktame tyrime dalyvavo šeši finansų srities specialistai. Atsižvelgus į tyrimo metu surinktą informaciją, duomenų saturacija buvo pasiekta, matomi aiškūs informacijos pasikartojimai tarp dalyvių, todėl imtis laikoma tinkama. Dalyviai atstovauja skirtingus verslų sektorius ir skirtingas įmones, visi turi bent 5 metus patirties finansų analitikos srityje.

Duomenų rinkimo metodika

Duomenys surinkti naudojant pusiau struktūruotus interviu, kurių trukmė svyruoja nuo 40 minučių iki 80 minučių, priklausomai nuo dalyvių galimybių. Interviu atlikti nuotoliniu būdu (naudojant vaizdo konferencijų platformą „Microsoft Teams“), kuri leidžia pokalbį įrašinėti ir automatiškai jį transkribuoja.

Interviu klausimynas sudarytas remiantis teorinėje dalyje išskirtomis problemų grupėmis ir apima šias temines sritis: 1) finansinių prognozių sudarymo praktika organizacijoje; 2) dirbtinio intelekto ir analitinių įrankių naudojimas; 3) ekspertinių žinių vaidmuo ir jų taikymas; 4) modelių ir ekspertinių sprendimų sąveika; 5) pagrindiniai iššūkiai ir rizikos; 6) požiūris į hibridinius prognozavimo modelius. Tokia struktūra leido užtikrinti, kad surinkti duomenys tiesiogiai atlieptų tyrimo tikslą ir teorinę analizę. Interviu metu siekta skatinti dalyvius pateikti konkrečius pavyzdžius ir refleksijas, kurios leistų giliau suprasti prognozavimo sprendimų logiką.

Klausimynas

Lentelėje žemiau pateikiamas pusiau struktūruoto interviu klausimynas, sudarytas siekiant nuosekliai išanalizuoti finansų specialistų patirtį rengiant finansines prognozes, jų požiūrį į dirbtinio intelekto ir didžiųjų duomenų taikymą bei ekspertinių įžvalgų vaidmenį prognozavimo procese.

6 lentelė. Tyrimo klausimynas

I. Kontekstas
1. Papasakokite apie savo profesinę patirtį finansų srityje. Kokia yra jūsų dabartinė pozicija ir pagrindinės atsakomybės? Kokiame sektoriuje dirbate (pvz., bankininkystė, investicijos, draudimas, fintech ir pan.)?
II. Finansinių prognozių praktika organizacijoje
2. Kokio tipo prognozes dažniausiai atliekate (pvz., pajamų, rizikos, rinkos tendencijų ir pan.)?
3. Kaip atrodo prognozavimo procesas jūsų organizacijoje? Kokie pagrindiniai etapai, kas dalyvauja šiame procese?
4. Ar prognozėms naudojami tik istoriniai duomenys ar ir kiti šaltiniai? Ar duomenų kiekis, ar duomenų kokybė turi didesnę įtaką prognozių tikslumui?
III. Dirbtinio intelekto (DI) taikymas
5. Ar savo darbe naudojate dirbtinio intelekto sprendimus? Jei taip – kokius įrankius ar technologijas naudojate?
6. Kokie, Jūsų nuomone, yra pagrindiniai DI naudojimo privalumai finansinėje analizėje? Kokie yra pagrindiniai trūkumai ar apribojimai?
IV. Didžiųjų duomenų (Big Data) naudojimas
7. Ar jūsų organizacijoje naudojami didieji duomenys (angl. Big Data)? Jei taip – kokio pobūdžio tai duomenys (struktūruoti / nestruktūruoti, vidiniai / išoriniai)?
8. Kokius iššūkius patiriate dirbant su dideliais duomenų kiekiais?
V. Ekspertinių įžvalgų vaidmuo
9. Kiek svarbios ekspertinės įžvalgos prognozavimo procese? Kaip šios įžvalgos yra integruojamos į prognozes?
10. Ar būna atvejų, kai ekspertinė nuomonė (tam tikros papildomos žinios apie konkurentų ar rinkos elgseną, kurios neatsispindi istoriniuose duomenyse) prieštarauja duomenimis pagrįstoms prognozėms? Galbūt prognozuoja skirtingus rezultatus? Kaip tokios situacijos yra sprendžiamos?
VI. Integruotas teorinis modelis
11. Kaip vertinate pateiktą modelį? Ar, jūsų nuomone, toks modelis galėtų būti pritaikytas realioje organizacijoje?
12. Ko, jūsų nuomone, modeliui trūksta? Kokius pakeitimus ar patobulinimus siūlytumėte? Kokiose situacijose ar sektoriuose toks modelis būtų naudingiausias?
VII. Požiūris į DI finansų analitikoje
13. Kaip vertinate DI reikšmę finansų analitiko profesijoje ateityje? Ar DI laikote labiau galimybe ar grėsme? Kodėl?

Klausimynas suskirstytas į teminius blokus, kurie leidžia surinkti informaciją apie respondentų profesinį kontekstą, prognozavimo praktiką organizacijoje, DI naudojimo privalumus ir ribotumus, didžiųjų duomenų taikymo iššūkius, ekspertinių žinių integravimą bei teorinio modelio pritaikomumą realioje organizacinėje aplinkoje.

Duomenų analizės metodai

Surinkti duomenys analizuojami taikant teminę analizę (angl. thematic analysis), kurios metu identifikuojamos pasikartojančios temos, požiūriai ir argumentai. Teminė analizė leidžia struktūruoti ekspertų atsakymus, palyginti skirtingas nuomones ir susieti empirinio tyrimo rezultatus su teorinėje darbo dalyje aptartomis įžvalgomis apie dirbtinio intelekto, didžiųjų duomenų ir ekspertinių žinių integravimą finansinių prognozių sudaryme.

Teminė analizė apima šiuos etapus: 1) duomenų susipažinimas (interview transkribavimas ir skaitymas); 2) pirminių kodų generavimas; 3) temų identifikavimas; 4) temų peržiūra ir sisteminimas; 5) temų interpretavimas ir susiejimas su teorija.

Analizės metu ypatingas dėmesys skiriamas: 1) istorinių (rinkos) duomenų ir ekspertinių žinių santykio suvokimui; 2) situacijoms, kuriose modeliai ir ekspertai „nesutampa“; 3) praktiniams sprendimų priėmimo mechanizams; 4) identifikuotoms problemoms ir jų sprendimo būdams. Teminė analizė pasirinkta dėl jos lankstumo ir gebėjimo sisteminti kompleksinius duomenis. Šis metodas leidžia ne tik identifikuoti pagrindines temas, bet ir analizuoti jų tarpusavio ryšius. Siekiant užtikrinti analizės patikimumą, taikomas nuoseklus kodavimo procesas ir aiškiai dokumentuojami analizės žingsniai.

Tyrimo patikimumas ir validumas

Kokybiniuose tyrimuose patikimumas vertinamas per kredibilumo, perkeliamumo ir nuoseklumo kriterijus (Lincoln & Guba, 1985). Šiame tyrime patikimumas užtikrinamas naudojant aiškią ir nuoseklią tyrimo metodiką, atrenkant patyrusius finansų analitikos srities atstovus. Taikoma sisteminga duomenų analizė, lyginant skirtingų dalyvių atsakymus. Validumas stiprinamas susiejant empirinius duomenis su teorinėmis įžvalgomis, pateiktomis ankstesniuose darbo skyriuose.

Tyrimo etika

Tyrimas atliekamas laikantis pagrindinių mokslinės etikos principų. Visi dalyviai buvo informuoti apie tyrimo tikslą, jų dalyvavimas savanoriškas, o surinkti duomenys naudojami tik moksliniais tikslais. Siekiama užtikrinti anonimiškumą ir konfidencialumą, todėl interviu metu surinkta informacija nebus siejama su konkrečiais asmenimis ar organizacijomis, informacija nuasmeninama.

Metodologijos ir teorijos sąsaja

Parinkta metodologija tiesiogiai siejasi su teorinėje dalyje iškelta problema – integracijos tarp dirbtinio intelekto, didžiųjų duomenų ir ekspertinių žinių trūkumu. Ekspertiniai interviu leidžia empiriškai patikrinti, ar teorijoje identifikuotos problemos pasireiškia praktikoje, kaip realiai vyksta prognozavimo procesas organizacijose ir ar egzistuoja hibridinio modelio prielaidos. Tokiu būdu metodologija ne tik papildo teorinę analizę, bet ir sudaro pagrindą tolimesniam modelio vertinimui.

4. Didžiųjų duomenų ir ekspertinių įžvalgų integravimo į dirbtinio intelekto finansinių prognozių sprendimus empirinis tyrimas

Šiame skyriuje pateikiami empirinio tyrimo rezultatai, gauti analizuojant finansų specialistų interviu apie dirbtinio intelekto, didžiųjų duomenų ir ekspertinių įžvalgų taikymą finansinių prognozių sudaryme. Tyrimo rezultatai leidžia įvertinti, kaip teorinėje darbo dalyje identifikuotos problemos pasireiškia praktikoje ir kokiomis sąlygomis integruotas prognozavimo modelis galėtų būti taikomas organizacijose.

4.1. Tyrimo informantų pristatymas

Tyrimo dalyvavo šeši informantai, dirbantys skirtinguose sektoriuose ir užimantys skirtingas finansų srities pozicijas. Informantai buvo atrinkti siekiant surinkti kuo platesnę praktinę patirtį apie finansinių prognozių sudarymą, biudžetavimą, ekspertinių įžvalgų naudojimą bei dirbtinio intelekto taikymą organizacijose. Tyrimo dalyvavo finansų analitikai, finansų kontrolieriai bei finansų valdymo specialistai, dirbantys transporto, telekomunikacijų, prekybos, gamybos, aviacijos bei kitose verslo srityse. Visi tyrimo dalyviai buvo nuasmeninti ir koduojami kaip Informantas Nr. 1–6.

Analizuojant informantų profesinį kontekstą pastebėta, kad dauguma jų turi ilgametę praktinę patirtį finansų srityje bei tiesiogiai dalyvauja prognozavimo, biudžetavimo ar veiklos kontrolės procesuose. Dėl šios priežasties jų pateikta informacija leido detaliai atskleisti, kaip organizacijose realiai vyksta finansinių prognozių sudarymas ir kokį vaidmenį jame užima istoriniai duomenys, ekspertinės įžvalgos bei dirbtinio intelekto sprendimai.

7 lentelė. Tyrimo informantų pristatymas

Informantas	Sektorius	Pareigos	Patirtis	Pagrindinės atsakomybės
Informantas Nr. 1	Paslaugos, prekyba, gamyba, žemės ūkis	Finansų analizės skyriaus vadovė	Ilgametė finansų analizės patirtis	Finansinės prognozės, biudžetavimas, rinkos analizė, strateginis planavimas
Informantas Nr. 2	Transporto sektorius	Verslo kontrolierius	~8 metų patirtis finansuose	Rolling forecast, KPI analizė, finansinių ataskaitų prognozavimas, biudžetai
Informantas Nr. 3	Prekyba, transportas	Finansų analitikas	>20 metų patirtis	Pinigų srautai, investiciniai projektai, veiklos efektyvumo analizė
Informantas Nr. 4	Telekomunikacijos, gamyba	Finansų kontrolės specialistė	Finansų kontrolės ir projektų priežiūros patirtis	Ketvirtinės prognozės, pajamų prognozavimas, projektų kontrolė
Informantas Nr. 5	Transportas, logistika	Vyr. finansų kontrolierius	Finansų kontrolės patirtis	Pinigų srautų kontrolė, biudžetų sudarymas, prognozės
Informantas Nr. 6	Aviacija	Finansų direktorė	Finansų analitikos ir planavimo patirtis	Planavimas, biudžetavimas, pajėgumų ir klientų prognozės

Informantas Nr. 1 dirba finansų analizės skyriaus vadovės pareigose įmonių grupėje, vykdančioje skirtingo pobūdžio veiklas – nuo paslaugų teikimo iki prekybos bei gamybos. Informantė pabrėžė turinti didelę praktinę patirtį skirtingose organizacijose ir finansų analizės srityje dirbanti nuo karjeros pradžios: „mano kelias prasidėjo nuo finansų analitiko, tai įmonių esu mačiusi nemažai“. Pagrindinės jos atsakomybės susijusios su finansinių prognozių sudarymu, biudžetavimu, rinkos analize bei ilgalaikiu strateginiu planavimu. Informantė taip pat aktyviai dalyvauja rinkos tendencijų vertinime

ir kainų prognozėse, ypač žemės ūkio sektoriuje: „reikia jas stebėti ir žiūrėti kaip keičiasi, maždaug prognozuoti metai į priekį, kokios gali būti kainos“ .

Informantas Nr. 2 šiuo metu dirba verslo kontrolieriaus pozicijoje tarptautinėje transporto sektoriaus įmonėje. Informantas turi apie aštuonerių metų profesinę patirtį finansų srityje ir savo karjerą pradėjo telekomunikacijų bendrovėje nuo buhalterės pareigų. Vėliau dirbo finansinių ataskaitų rengimo srityje, finansų analitiko pozicijoje, o šiuo metu užima verslo kontrolieriaus pareigas. Jis pažymėjo: „dabar dirbu transporto sektoriuje. Tarptautinėje transporto bendrovėje“ . Pagrindinės informanto atsakomybės susijusios su finansinių ataskaitų prognozavimu, rolling forecast procesu, KPI analize bei biudžetų rengimu. Informantas aktyviai dirba su pelno (nuostolių) ataskaitų, balanso ir pinigų srautų prognozėmis bei koordinuoja prognozavimo procesus tarp skirtingų organizacijos padalinių.

Informantas Nr. 3 turi daugiau nei dvidešimties metų patirtį finansų analizės srityje. Tyrimo dalyvis dirbo įvairiose didmeninės prekybos, mažmeninės prekybos bei transporto sektoriaus organizacijose. Interviu metu jis pažymėjo: „esu finansų analitikas daugiau kaip 20 metų“ . Informanto profesinė patirtis apima platų veiklų spektrą – nuo pinigų srautų valdymo, atsargų analizės ir skolų kontrolės iki investicinių projektų vertinimo bei veiklos efektyvumo analizės. Šiuo metu informantas dirba transporto sektoriuje ir aktyviai dalyvauja investicinių projektų, veiklos savikainos bei OEE (Overall Equipment Efficiency) analizėje. Jis taip pat akcentavo poreikį detaliam suprasti verslo procesus ir prognozių dedamąsias.

Informantas Nr. 4 dirba tarptautinėje telekomunikacijų sektoriaus įmonėje finansų kontrolės srityje. Informantė atsakinga už projektų finansinę kontrolę, prognozių priežiūrą bei finansinių rodiklių atitikimo stebėseną. Ji teigė: „dirbu finansų kontrolės srityje (...) atsakinga už projektų finansinę dalį“ . Pagrindinės jos atsakomybės susijusios su trumpalaikių ketvirtinių prognozių rengimu, pajamų prognozavimu bei projektinių kaštų kontrole. Informantė taip pat dirba su naujai įdiegta organizacijos planavimo sistema bei dalyvauja duomenimis grįstų procesų priežiūroje.

Informantas Nr. 5 dirba vyr. finansų kontrolieriaus pareigose ir yra atsakingas už pinigų srautų stebėseną, biudžeto sudarymą, prognozių koregavimą bei finansinių ataskaitų teikimą akcininkams. Informantas pažymėjo: „pagrindinės atsakomybės yra įmonės piniginių srautų stebėseną, biudžeto sudarymas, laikymasis ir koregavimas“ . Informanto veikla susijusi su pajamų ir su jomis susijusių išlaidų prognozavimu, taip pat rinkos tendencijų ir politinių veiksnių vertinimu.

Informantas Nr. 6 atstovauja aviacijos techninės priežiūros sektoriui. Jo organizacija dirba su orlaivių remontu, techniniu aptarnavimu bei komponentų tiekimu. Interviu metu buvo akcentuotas itin aukštas sektoriaus reguliavimo lygis ir sudėtinga techninė aplinka: „aviacijos techninės priežiūros sektorius yra labai specifinis ir griežtai reguliuojamas“ . Informantas aktyviai dalyvauja planavimo, biudžetavimo ir prognozavimo procesuose, kuriuose vertinami klientų remonto ciklai, sezoniskumas, techniniai pajėgumai bei reguliaciniai pokyčiai. Organizacijoje didelė reikšmė skiriama darbuotojų ekspertinėms žinioms ir gebėjimui interpretuoti nestandartines situacijas.

Apibendrinant galima teigti, kad tyrime dalyvavę informantai atstovavo skirtingoms industrijoms ir turėjo įvairialypę profesinę patirtį, tačiau visus juos vienijo tiesioginis dalyvavimas finansinių prognozių, planavimo ar veiklos kontrolės procesuose. Tokia informantų įvairovė leido surinkti plačią praktinę perspektyvą apie tai, kaip skirtinguose sektoriuose organizacijos integruoja istorinius duomenis, ekspertines įžvalgas ir dirbtinio intelekto sprendimus finansinių prognozių procese.

4.2. Teminės analizės rezultatai

Atlikus pusiau struktūruotų interviu analizę buvo identifikuotos devynios pagrindinės temos, atspindinčios finansinių prognozių sudarymo praktiką organizacijose, ekspertinių žinių vaidmenį bei dirbtinio intelekto taikymo galimybes. Analizės metu išskirtos kategorijos ir subkategorijos formuotos remiantis pasikartojančiomis informantų mintimis, praktiniais pavyzdžiais bei bendra prognozavimo logika organizacijose. Gauti rezultatai rodo, kad finansinių prognozių sudarymas praktikoje yra kompleksinis, tarpdisciplininis ir nuolat koreguojamas procesas, kuriame istoriniai duomenys derinami su ekspertinėmis įžvalgomis bei situaciniu organizacijos žinojimu.

1 tema. Finansinių prognozių daugialypiškumas ir skirtingi prognozavimo horizontai

Teminė analizė atskleidė, kad finansinių prognozių procesas organizacijose yra suvokiamas kaip daugialypė ir nuolat kintanti sistema, kuri apima skirtingo laikotarpio bei paskirties prognozes. Informantai nuosekliai pabrėžė, kad organizacijose neegzistuoja viena universali prognozė – praktikoje vienu metu naudojamos trumpalaikės operacinės prognozės, periodiškai atnaujinami „rolling forecast“ modeliai, metiniai biudžetai bei ilgalaikiai strateginiai planai. Tokia prognozių įvairovė rodo, kad organizacijos prognozavimą suvokia ne tik kaip finansinių rezultatų numatymo priemonę, bet ir kaip strateginio valdymo, veiklos kontrolės bei sprendimų priėmimo sistemą.

8 lentelė. Finansinių prognozių daugialypiškumas ir skirtingi prognozavimo horizontai

Kategorija	Subkategorija	Citata
Prognozių tipų įvairovė	Operacinės prognozės	„Pirmas lygis prognozės, tai yra aplamai prognozė į priekį pinigų srautų, kad įmonė galėtų suprasti, kiek jai reikės pinigų vykdyti veiklą“ „Kiekvieną dieną dirbu su trumpalaikėmis prognozėmis, kad matytume ar atitinkame ketvirčio planą ir kaip atrodo einamas mėnuo“ „Yra sudaromi trumpalaikiai pinigų srautų planai, kad būtų galima planuoti darbuotojų užimtumą ir kasdienę veiklą“
	Taktinės prognozės	„Antras lygis prognozės yra atliekamas biudžeto tikslinimas, kai metų eigoje žiūrime kaip sekasi vykdyti planą“ „Mes dirbam rolling forecast‘u principu, tai kiekvieną mėnesį persiskaičiuojam dvylika mėnesių į priekį“ „Prognozes darom kas mėnesį ir žiūrim, kiek realiai pataikom į faktą“
	Strateginės prognozės	„Tada yra atliekama penkių metų prognozė ir sprendžiama ką daryti toliau, kaip įmonė turėtų plėstis“ „Yra sudaromi penkerių metų planai bei metiniai biudžetai, kurie naudojami strateginiams sprendimams“ „Tu investuoji į naują parką ir tada žiūri per kiek metų jis tau atsipirks“
Prognozavimo paskirtis	Veiklos kontrolė	„Kiekvieną mėnesį mes vėl sukam tą patį ratą ir žiūrim, kiek ta mūsų prognozė buvo tiksli“ „Įmonėje nuolat lyginamas planas su faktiniais rezultatais ir vertinama, dėl ko atsirado nukrypimai“ „Mano atsakomybė yra užtikrinti, kad skaičiai ir periodai atitiktų prognozes“
	Sprendimų priėmimas	„Tada yra atliekama penkių metų prognozė ir sprendžiama ką daryti toliau“

Kategorija	Subkategorija	Citata
		„Valdyba pasako savo nuomonę, koks yra jų matymas ir kokie tikslai keliami kitam laikotarpiui“ „Kai vertinam investicijas, skaičiuojam NPV ir žiūrim ar verta investuoti“
	Organizacijos augimo planavimas	„Sprendžiama kaip verslas turėtų plėstis ir kokios kryptys būtų perspektyviausios“ „Akcininkai pasako augimo tikslus ir tada pagal juos dėliojamas visas biudžetas“ „Žiūrima kiek mes turime atnešti pinigų ir kokį rezultatą pasiekti“

Informantas Nr. 1 išskyrė kelis skirtingus prognozavimo lygius ir pabrėžė, kad jų paskirtis priklauso nuo organizacijos poreikio. Jis teigė: „pirmas lygis prognozės, tai yra aplamai prognozė į priekį pinigų srautų. Antras lygis prognozės yra atliekamas biudžeto tikslinimas (...) tada yra atliekama penkių metų prognozė ir sprendžiama ką daryti toliau“ . Šis pasisakymas atskleidžia, kad trumpalaikės prognozės organizacijoje orientuojasi į operacinį stabilumą ir pinigų srautų kontrolę, o ilgalaikės prognozės tampa strateginio planavimo instrumentu, leidžiančiu įvertinti organizacijos augimo galimybes, investicijų poreikį ar net verslo tęstinumo perspektyvas.

Panaši tendencija atsispindėjo ir Informanto Nr. 2 pasakojime. Jis apibūdino prognozavimo procesą kaip nuolatinį ciklą, kuriame organizacija kiekvieną mėnesį peržiūri ir tikslina prognozes pagal naują informaciją. Informantas pažymėjo: „kiekvieną mėnesį mes vėl sukam tą patį ratą ir žiūrim, kiek ta mūsų prognozė buvo tiksli“ . Tokia praktika rodo, kad prognozės organizacijose nėra laikomos statišku dokumentu – jos nuolat atnaujinamos, koreguojamos ir pritaikomos prie besikeičiančių aplinkos sąlygų.

Tyrimo metu taip pat išryškėjo, kad prognozių pobūdis stipriai priklauso nuo sektoriaus specifikos. Aviacijos sektoriaus atstovė pažymėjo, kad jų organizacijoje planuojant vertinami ne tik finansiniai rodikliai, bet ir techniniai bei sezoniniai veiksniai: „planuojant vertinami konkretūs klientai, jų turimi orlaiviai, remonto ciklai, sezoniškumas bei turimi pajėgumai“ . Tai rodo, kad ilgalaikis planavimas tampa glaudžiai susijęs su specifiniais veiklos procesais ir rinkos ciklais.

Beveik visi informantai akcentavo, kad prognozavimas organizacijose suvokiamas kaip nuolatinis procesas, kuriame svarbus ne tik rezultatas, bet ir gebėjimas stebėti pokyčius bei laiku reaguoti į nukrypimus. Informantas Nr. 1 ypatingą dėmesį skyrė planavimo disciplinai ir proceso valdymui, teigdamas: „jeigu neturim planerio, tai neturim taško A, B, C, D (...) ir tada yra nukrypstama į kairę į dešinę“ . Ši mintis atskleidžia, kad prognozės organizacijose atlieka ne tik analitinę, bet ir koordinavimo funkciją.

Apskritai ši tema parodė, kad prognozės praktikoje yra daug daugiau nei vien matematinis ateities rezultatų apskaičiavimas. Organizacijose jos tampa nuolatinio strateginio proceso, jungiančiu finansinę kontrolę, veiklos koordinavimą, rizikų vertinimą ir organizacijos krypties formavimą.

2 tema. Prognozavimas kaip kolektyvinis ir tarpdisciplininis procesas

Interviu analizė atskleidė, kad finansinių prognozių sudarymas organizacijose yra stipriai kolektyvinis procesas, kuriame dalyvauja įvairių sričių specialistai. Nors finansų analitikai dažniausiai koordinuoja prognozių rengimą ir apjungia informaciją į galutinius finansinius modelius, tačiau praktiškai nei vienas informantas prognozavimo neįvardijo kaip išskirtinai finansų departamento atsakomybės. Priešingai – tyrimo dalyviai nuolat pabrėžė, kad realistiška prognozė gali

būti sudaryta tik tada, kai procese dalyvauja darbuotojai, kurie tiesiogiai dirba su klientais, pardavimais, logistika, pirkimais ar kitais operaciniais procesais.

9 lentelė. Prognozavimas kaip kolektyvinis ir tarpdisciplininis procesas

Kategorija	Subkategorija	Citata
Organizacinis įsitraukimas	Skirtingų departamentų dalyvavimas	„Pasijungia praktiškai visi skyriai. Ir pirkimai, ir pardavimai, ir logistika“ „Biudžeto rengime dalyvauja daug skirtingų komandų – pardavimų vadybininkai, finansų analitikai, verslo kontrolieriai ir vadovai“ „Kiekviena finansų komanda dirba su tuo kiekvienu departamentu aiškinantis, kas gali būti kitaip“
	Vadovybės įsitraukimas	„Susidarę tas prognozes mes jas aptarinėjame su aukščiausiu finansų vadovu“ „Valdyba pasako savo nuomonę ir kokį mato kitų metų rezultatą“ „Akcininkai pasako gaires, kokio augimo jie tikisi iš verslo“
	Finansų koordinacinis vaidmuo	„Yra finansų analitikų ofisas, kuris apjungia informaciją iš visų skyrių“ „Centrinė finansų kontrolės komanda prižiūri visas prognozes“ „Dirbu verslo kontrolieriaus pozicijoje ir koordinuoju prognozių procesą“
Praktinių žinių integracija	Vadybininkų išvalgos	„Reikia to vadybininko, kuris su tuo žmogum dirba, žinojimo“ „Ką matom iš klientų ir ką girdim iš rinkos, tą dedam į prognozes“ „Tie žmonės, kurie dirba su klientais, geriausiai žino realią situaciją“
	Rinkos informacija	„Analizuojama užsienio rinka ir jos tendencijos“ „Mes daug konsultuojamės su žmonėmis, kurie yra toje srityje kompetentingi“ „Rinkos pokyčiai labai stipriai įtakoja prognozes“
	Procesinis žinojimas	„Čia reikia tokio žinojimo, kaip savo namuose“ „Dėl sektoriaus specifikos reikia nemažai laiko suprasti procesus“ „Žino tik klientai ir žmonės, kurie su jais dirba“
Iteracinis derinimas	Nuolatinės korekcijos	„Šimtas versijų, vis prasižiūrim iteraciją ir vėl persiskaičiuojam“ „Planai yra koreguojami, jeigu pasikeičia klientų poreikiai ar atsiranda papildomi kaštai“ „Kiekvieną mėnesį persidėliojam prognozes pagal naują informaciją“
	Diskusijų procesas	„Susidarę tas prognozes mes jas aptarinėjame“ „Vyksta susirinkimai ir aptarimai tarp skyrių“ „Vadovai užduoda klausimus ir tikrina prielaidas“
	Scenarijų modeliavimas	„Gyvai modeliuojam įvairias situacijas ir žiūrim kaip pasikeistų rezultatas“ „Visas biudžetas persiskaičiuoja pasikeitus vienam faktoriui“ „Žiūrim dvylika mėnesių į priekį ir vertinam skirtingus scenarijus“

Informantas Nr. 1 pasakojo, kad ilgalaikėse prognozėse „pasijungia praktiškai visi skyriai. Ir pirkimai, ir pardavimai, ir logistika“. Jo teigimu, finansų skyrius vienas negali pilnai suprasti visų verslo niuansų, todėl prognozavime būtina integruoti skirtingų sričių žinias ir patirtis. Toks požiūris rodo, kad organizacijose prognozavimas suvokiamas kaip bendras organizacinis procesas, o ne izoliuota finansų funkcija.

Panašiai situaciją apibūdino ir Informantas Nr. 2. Jis detaliai aiškino, kaip finansų komandos nuolat bendradarbiauja su verslo padaliniais ir kartu ieško galimų pokyčių ar rizikų: „kiekviena finansų komanda dirba su tuo kiekvienu departamentu, aiškinantis, kas gali būti kitaip“. Šis pasisakymas atskleidžia, kad prognozavimas organizacijose yra stipriai paremtas komunikacija tarp skirtingų organizacijos grandžių.

Ypatingai ryškus ekspertinių žinių vaidmuo atsiskleidė Informanto Nr. 3 interviu. Jis teigė, kad prognozuojant būtinas „to vadybininko, kuris su tuo žmogum dirba, žinojimas“. Informantas akcentavo, kad statistiniai modeliai negali pilnai atspindėti realių klientų santykių, derybų eigos ar neformalios rinkos informacijos. Tai rodo, kad organizacijos prognozavimo procese remiasi ne tik formalizuotais duomenimis, bet ir darbuotojų sukaupta praktine patirtimi.

Tyrimo metu taip pat išryškėjo, kad prognozavimo procesas organizacijose yra labai iteracinis ir grindžiamas nuolatiniu derinimu tarp skirtingų interesų grupių. Informantas Nr. 3 biudžetavimo eigą apibūdino kaip „šimtas versijų, vis prasižiūrim iteraciją“. Tai rodo, kad prognozės nėra sukuriamos vienu sprendimu – jos formuojamos per ilgą diskusijų, korekcijų ir kompromisų procesą.

Teminė analizė leidžia teigti, kad finansinių prognozių sudarymas organizacijose yra socialus ir tarpdisciplininis procesas, kuriame finansiniai modeliai nuolat papildomi organizaciniu žinojimu, ekspertinėmis įžvalgomis ir praktiniu rinkos supratimu.

3 tema. Istoriniai duomenys kaip bazė, bet ne galutinė prognozės tiesa

Vienas ryškiausių pasikartojančių motyvų interviu medžiagoje buvo kritiškas požiūris į prognozes, paremtas vien istoriniais duomenimis. Nors visi informantai pripažino, kad istoriniai duomenys yra būtinas prognozės pagrindas, tačiau jie buvo suvokiami tik kaip atskaitos taškas, kuris turi būti papildomas papildoma kontekstine informacija ir ekspertinėmis įžvalgomis.

10 lentelė. Istoriniai duomenys kaip bazė, bet ne galutinė prognozės tiesa

Kategorija	Subkategorija	Citata
Istorinių duomenų vaidmuo	Bazinis atskaitos taškas	„Istorija tau gali duoti tikrai atskirtį – čia yra mano bazė“ „Visą laiką atsiremia į faktą ir tada jau dėlioja toliau“ „Pirmiausia pasižiūrim faktinius duomenis apie tai, kaip atrodė pirmas ketvirtis“
	Ankstesnių rezultatų analizė	„Analizuojama ankstesnių remontų istorija, orlaivių amžius ir klientų elgsena“ „Žiūrime į istorinius duomenis ir kaip atrodė ankstesni periodai“ „Praėjusių metų statistika vis tiek yra pagrindas“
	KPI pagrindas	„Prognozės remiasi KPI rodikliais, tokiais kaip pajamos per kilometrą“ „Žiūrim kuro normas ir transporto efektyvumą“ „Vertinam remonto sąnaudas per dieną“
Istorinių duomenų ribotumas	Nepakankamumas ateičiai	„Naudoti tik istorinius duomenis, mano asmenine nuomone, yra nerealistiška“ „Vien tik istoriniais duomenimis remtis tikrai neužtenka“ „Jis tiesiog statistiškai duomenimis gali paprognozuoti į priekį“
	Nestandartinės situacijos	„Tokie dalykai kaip geopolitinė situacija labai stipriai keičia prognozes“ „Rusijos atvejis parodė, kad viskas gali apsiversti labai greitai“

Kategorija	Subkategorija	Citata
		„Reguliaciniai pokyčiai labai stipriai įtakoja veiklą“
	Pokyčių neprognozuojamumas	„Aiškinamės kas gali būti kitaip negu buvo istorijoje“ „Svarbiausia suprasti kas pasikeis ateityje“ „Aplinkos pokyčiai dabar vyksta nuolat“

Informantas Nr. 2 labai aiškiai įvardijo šią problemą teigdamas: „naudoti tik istorinius duomenis, mano asmenine nuomone, yra nerealistiška“ . Jo nuomone, istoriniai duomenys leidžia nustatyti bazinę situaciją, tačiau prognozuojant būtina vertinti tai, kas gali pasikeisti ateityje. Informantas pažymėjo, kad organizacijos turi nuolat reaguoti į rinkos pokyčius, infliaciją, naujus reguliacinius sprendimus ir besikeičiančią klientų elgseną.

Panaši mintis atsispindėjo ir Informanto Nr. 1 interviu. Jis pasakojo, kad organizacijoje daug dėmesio skiriama rinkos analizei bei išorinių veiksnių stebėjimui: „reikia jas stebėti ir žiūrėti kaip keičiasi, maždaug prognozuoti metai į priekį, kokios gali būti kainos“ . Tai rodo, kad organizacijos prognozuodamos remiasi ne tik vidine istorine informacija, bet ir išoriniais ekonominiais bei geopolitiniais signalais.

Aviacijos sektoriaus atstovė taip pat akcentavo išorinių veiksnių svarbą ir pažymėjo, kad „vien tik istoriniais duomenimis remtis tikrai neužtenka“ . Jos teigimu, aviacijoje prognozes stipriai veikia reguliaciniai pokyčiai, auditai, klientų sprendimai ir geopolitinė situacija.

Tyrimo rezultatai rodo, kad organizacijos prognozavimą suvokia ne kaip praeities pratęsimą į ateitį, o kaip

4 tema. Ekspertinių žinių vaidmuo prognozavimo procese

Teminė analizė atskleidė, kad ekspertinės žinios organizacijose yra suvokiamos kaip vienas svarbiausių finansinių prognozių tikslumą lemiančių veiksnių. Nors organizacijos aktyviai naudoja istorinius duomenis, KPI rodiklius bei įvairias analitines sistemas, tačiau beveik visi informantai akcentavo, kad vien duomenų nepakanka norint realistiškai įvertinti ateities situaciją. Tyrimo dalyviai nuolat pabrėžė, kad prognozavimo procese būtina integruoti darbuotojų patirtį, praktinį rinkos suvokimą ir neformalų žinojimą apie klientus, konkurentus ar organizacijos vidinius procesus.

11 lentelė. Ekspertinių žinių vaidmuo prognozavimo procese

Kategorija	Subkategorija	Citata
Ekspertinių žinių reikšmė	Praktinis („ūkiškas“) supratimas	„Čia reikia tokio žinojimo, kaip savo namuose. Statistika gali parodyti skaičių, bet ji nepasakys, kodėl realiai taip vyksta“ „Labai daug ateina iš patirties, iš supratimo apie klientą, rinką, procesus“ „Vien skaičių neužtenka, reikia suprasti kaip realiai veikia pats verslas“
	Situacijos interpretavimas	„Didelę reikšmę turi darbuotojų patirtis ir gebėjimas įvertinti specifines situacijas“ „Mes vertinam ne tik skaičius, bet ir ką matom iš rinkos, ką girdim iš klientų“ „Labai daug sprendimų ateina iš supratimo, kas realiai vyksta versle tuo momentu“

Kategorija	Subkategorija	Citata
	Neformalios informacijos svarba	„Reikia to vadybininko, kuris su tuo žmogum dirba, žinojimo, nes sistemos tokių dalykų neparodo“ „Yra dalykų, kuriuos žino tik klientai ir žmonės, kurie su jais dirba kasdien“ „Labai daug informacijos ateina iš santykių su klientais ir rinkos nuotaikų“
Ekspertų įtraukimo formos	Konsultacijos su specialistais	„Mes jų neišburiam iš galvos, mes daug konsultuojamės su žmonėmis, kurie yra toje srityje kompetentingi“ „Biudžeto procese vyksta daug aptarimų tarp skyrių ir specialistų“ „Kiekviena finansų komanda dirba su tuo departamentu aiškinantis, kas gali būti kitaip“
	Vadovų įžvalgos	„Valdyba pasako savo nuomonę, kokį mato kitų metų rezultatą ir kokius tikslus kelia“ „Vadovai nori prajausti ir pračiupinėti kiekvieną dalyką, ne tik matyti skaičius“ „Akcininkai pasako gaires ir tada visas biudžetas dëllojamas pagal jas“
	Pardavimų ir klientų informacija	„Ką matom iš klientų ir ką girdim iš rinkos, tą dedam į prognozes“ „Jeigu keičiasi klientų poreikiai ar planai, mes iškart koreguojam prognozes“ „Pardavimų žmonės dažnai pirmi pamato rinkos pokyčius“
Ekspertinių žinių ribotumai	Subjektyvumo problema	„Pastebėjome, kad ekspertinės įžvalgos dažnai nepasiteisina, nes žmonės linkę vertinti subjektyviai“ „Subjektyvumas dažniausiai atsiranda tada, kai žmogus remiasi nuojauta“ „Kartais ekspertinė nuomonė prieštarauja tam, ką rodo realūs skaičiai“
	Skirtingos nuomonės organizacijoje	„Valdyba pasako savo nuomonę, finansai savo, ir tada vyksta ilgos diskusijos“ „Vadovai užduoda klausimus ir tikrina visas prielaidas“ „Biudžeto viduje vyksta labai daug derinimo“
	Patirties priklausomybė nuo žmogaus	„Labai priklauso nuo žmogaus patirties ir kiek jis pažįsta klientą“ „Didelę reikšmę turi darbuotojų patirtis ir jų gebėjimas įvertinti situaciją“ „Vieni žmonės daug geriau jaučia rinką negu kiti“

Ypač stipriai ši tema atsiskleidė Informanto Nr. 3 interviu. Jis prognozavimą apibūdino kaip procesą, kuriame labai svarbus tampa „ūkiškas“ verslo supratimas. Informantas teigė: „čia reikia tokio žinojimo, kaip savo namuose“. Jo nuomone, statistiniai metodai negali pilnai įvertinti realios rinkos situacijos, nes didelė dalis svarbios informacijos egzistuoja ne duomenų bazėse, o darbuotojų sukauptoje patirtyje ir kasdienėje komunikacijoje su klientais. Informantas taip pat akcentavo, kad prognozuojant itin svarbios tampa vadybininkų įžvalgos apie klientų elgseną, galimas derybas ar rinkos pokyčius: „reikia to vadybininko, kuris su tuo žmogum dirba, žinojimo“.

Panaši tendencija atsispindėjo ir Informanto Nr. 2 pasisakymuose. Jis pabrėžė, kad prognozės organizacijoje formuojamos per nuolatinę konsultavimąsi su skirtingų sričių specialistais. Informantas teigė: „mes jų neišburiam iš galvos, mes daug konsultuojamės su žmonėmis, kurie yra toje srityje kompetentingi“. Šis pasisakymas rodo, kad prognozių sudaryme ekspertinės žinios tampa ne papildomu, o esminiu sprendimų priėmimo elementu. Finansų analitikai prognozėse remiasi ne tik

skaičiais, bet ir specialistų pateikiamomis prielaidomis apie draudimo kainas, klientų rizikingumą, rinkos pokyčius ar naujus reguliacinius sprendimus.

Aviacijos sektoriaus atstovė taip pat pabrėžė darbuotojų patirties svarbą prognozėse. Informantas Nr. 5 pažymėjo, kad „didelę reikšmę turi darbuotojų patirtis ir gebėjimas įvertinti specifines situacijas“. Jos teigimu, aviacijos sektoriuje egzistuoja labai daug išorinių veiksnių, kurių neįmanoma pilnai įvertinti vien istoriniais duomenimis. Tokie aspektai kaip audita, sertifikatai, klientų sprendimai ar geopolitiniai įvykiai dažnai reikalauja žmogaus interpretacijos ir praktinio vertinimo.

Vis dėlto tyrime atsiskleidė ir alternatyvus požiūris į ekspertinių žinių naudojimą. Informantas Nr. 4 teigė, kad jų organizacijoje ekspertinės išvalgos praktiškai nebenaudojamos, nes „pastebėjome, kad jos dažnai nepasiteisina“. Šis atvejis parodė, kad organizacijose egzistuoja ir skeptiškas požiūris į subjektyvų vertinimą, ypač tada, kai ekspertinės nuomonės prieštarauja realiems rinkos rezultatams.

Nepaisant šios išimties, bendra tyrimo tendencija išliko labai aiški – dauguma organizacijų ekspertines žinias vertina kaip būtinas norint interpretuoti rinkos pokyčius, įvertinti nestandartines situacijas ir priimti realistiškus prognozavimo sprendimus. Tyrimo rezultatai leidžia teigti, kad praktikoje prognozės dažnai formuojamos ne vien matematiniais modeliais, o nuolat derinant istorinius duomenis su žmonių sukaupta patirtimi bei situaciniu suvokimu.

5 tema. Skepticizmas autonominio dirbtinio intelekto atžvilgiu

Analizuojant interviu medžiagą išryškėjo itin stiprus skepticizmas visiškai autonominio dirbtinio intelekto naudojimo finansinių prognozių procese atžvilgiu. Nors dauguma informantų pripažino, kad dirbtinis intelektas gali būti naudingas pagalbinėse ar techninėse užduotyse, tačiau praktiškai visi tyrimo dalyviai akcentavo, kad dabartiniai DI sprendimai negali pilnai pakeisti žmogaus sprendimų priėmimo, ypač prognozuojant sudėtingas ar nestandartines situacijas.

12 lentelė. Skepticizmas autonominio dirbtinio intelekto atžvilgiu

Kategorija	Subkategorija	Citata
Nepasitikėjimas DI sprendimais	Didelė klaidų kaina	„Kol kas mes neturime tokio pasitikėjimo, kad jis už mus teisingai padarys, nes jo kaina klaidos yra per didelė“ „Finansuose viena klaida gali labai daug kainuoti, todėl negali akiai pasitikėti sistema“ „Negali sau leisti, kad sistema suklystų milijoninėse prognozėse“
	Ribotas pasitikėjimas technologija	„Vien DI nepasitikėčiau, nes vis tiek reikia žmogaus, kuris suprastų kontekstą“ „Vis tiek reikia žmogaus patvirtinimo prieš priimant sprendimą“ „Kol kas pasitikėjimo technologija dar nėra tiek daug“
	Žmogaus kontrolės poreikis	„Žmogus turi pasižiūrėti ir suprasti, ar prognozė logiška“ „Vadovai nori prajausti ir pračiupinėt kiekvieną dalyką“ „Vis tiek turi būti žmogaus kontrolė ir atsakomybė“
DI ribotumai	Konteksto nesupratimas	„Jis nežino niuansų kiekvieno verslo, jis negali visko apgalvoti pats“ „Sistema nesupranta realios situacijos ir verslo konteksto“ „Dirbtinis intelektas nežino kas vyksta rinkoje šiandien“
	Neformalios informacijos nebuvimas	„Sistema nežino klientų santykių ar vykstančių derybų“ „Nežino ką vadovas planuoja daryti kitais metais“ „Negali pilnai įvertinti geopolitinių dalykų ar rinkos nuotaikų“

Kategorija	Subkategorija	Citata
	Nestandardinių situacijų problema	„Jeigu aplinka labai dinamiška, ekspertinės žinios vis tiek lieka labai svarbios“ „Rusijos atvejis parodė, kad modeliai ne viską gali numatyti“ „Reguliaciniai pokyčiai labai stipriai keičia situaciją“
Paaškinamumo poreikis	Rezultatų pagrindimas	„Vadovai nori prajaust, pračiupinėt kiekvieną dalyką, o ne tiesiog gauti skaičių“ „Visada atsiranda klausimas – iš kur tas skaičius atsirado?“ „Reikia suprasti pačią logiką, kodėl modelis taip paskaičiavo“
	Skaidrumo poreikis	„Neužtenka, kad sistema tiesiog pasakė rezultatą“ „Vadovai nori žinoti dėl ko kažkas pasikeitė“ „Reikia paaiškinimo, o ne tik skaičiaus“
	Atsakomybės klausimas	„Kas atsakys už klaidą, jei sistema suklys?“ „Atsakomybė vis tiek lieka žmogaus pusėje“ „Galutinį sprendimą vis tiek priima vadovas“

Informantas Nr. 1 pabrėžė, kad pagrindinė problema yra tai, jog dirbtinis intelektas nesupranta specifinių organizacijos niuansų. Jis teigė: „jis nežino niuansų kiekvieno verslo, jis negali visko apgalvoti pats“. Informanto nuomone, DI gali statistiškai prognozuoti remdamasis istoriniais duomenimis, tačiau nesupranta realių veiklos procesų, rinkos subtilybių ar organizacijos vidinių problemų. Dėl šios priežasties organizacijose vis dar išlieka didelis nepasitikėjimas visiškai automatizuotais sprendimais.

Ypač ryškus skepticizmas atsiskleidė Informanto Nr. 3 interviu. Jis labai aiškiai kritikavo situacijas, kai prognozė pateikiama be paaiškinimo ar logikos pagrindimo. Informantas teigė, kad vadovams nepakanka vien galutinio rezultato – jie nori suprasti, iš kokių dedamųjų jis susideda: „vadovai nori prajaust, pračiupinėt kiekvieną dalyką“. Informantas taip pat pažymėjo, kad organizacijoje nepriimtina situacija, kai į klausimą apie prognozės pagrindimą būtų atsakoma „dirbtinis intelektas taip padarė“. Šis pasisakymas labai aiškiai atskleidžia pasitikėjimo problemą – organizacijoms svarbus ne tik rezultatas, bet ir galimybė suprasti bei paaiškinti prognozės logiką.

Dalis informantų taip pat akcentavo didelę klaidų kainą finansinių prognozių procese. Informantas Nr. 1 pažymėjo: „kol kas mes neturime tokio pasitikėjimo, kad jis už mus teisingai padarys, nes jo kaina klaidos yra per didelė“. Ši mintis kartojosi ir kituose interviu – organizacijos yra linkusios naudoti DI tik tose srityse, kuriose klaidos rizika yra mažesnė arba rezultatus gali papildomai patikrinti žmogus.

Tyrimo rezultatai taip pat parodė, kad skeptišką požiūrį į DI stiprina jo nesugebėjimas interpretuoti konteksto. Informantai nuolat akcentavo, kad realiame gyvenime egzistuoja daug neformalios informacijos, kurios nėra duomenų bazėse: klientų nuotaikos, derybų eiga, rinkos lūkesčiai ar organizacinė situacija. Informantas Nr. 3 tai apibūdino kaip „realaus gyvenimo“ aspektą, kurio statistiniai modeliai negali pilnai suprasti.

Apibendrinant galima teigti, kad organizacijos dirbtinį intelektą vertina atsargiai. Nors matomas jo potencialas automatizuoti tam tikrus procesus, tačiau prognozavime vis dar dominuoja žmogaus sprendimų priėmimas ir ekspertinės interpretacijos poreikis. Tyrimo rezultatai labai aiškiai atskleidžia paaškinamumo (XAI) svarbą – organizacijoms nepakanka vien prognozės rezultato, jos nori suprasti, kaip ir kodėl tas rezultatas buvo gautas.

6 tema. Dirbtinis intelektas kaip pagalbinė, o ne strateginė priemonė

Nors interviu metu buvo jaučiamas stiprus skepticizmas autonominio dirbtinio intelekto atžvilgiu, tačiau beveik visi informantai pripažino, kad DI jau dabar aktyviai naudojamas įvairiose pagalbinėse organizacijų funkcijose. Tyrimo rezultatai parodė, kad organizacijos DI dažniausiai suvokia ne kaip pilnavertį sprendimų priėmėją, o kaip įrankį, padedantį automatizuoti rutininius procesus, sisteminti informaciją ar sumažinti darbuotojų administracinę krūvį.

13 lentelė. Dirbtinis intelektas kaip pagalbinė, o ne strateginė priemonė

Kategorija	Subkategorija	Citata
DI naudojimo sritis	Informacijos sisteminimas	„Jeigu rašymas naujienų ar rinkos analizė, tai čia numeris vienas įrankis yra“ „Visus mūsų failus archyvuoja ir tvarko DI pilnai“ „Informacijos perdavimas tarp sistemų dabar jau vyksta automatiškai“
	Techninės užduotys	„Dirbtinis intelektas naudojamas tik siekiant pasikonsultuoti kaip geriausia parašyti SQL užklausą“ „Automatizuojami sąskaitų apdorojimo procesai“ „Didelė dalis techninių veiksmų jau vyksta automatiškai“
	Analitinė pagalba	„DI naudojamas rinkos analizėm ir duomenų sisteminimui“ „Jis padeda dirbti su labai dideliais duomenų kiekiais“ „Naudojamas klaidų identifikavimui ir analizei“
DI vertinamos stiprybės	Greitis	„Jis padeda daug greičiau atlikti rutininius darbus“ „Sutaupo labai daug laiko techninėse užduotyse“ „Tikslas yra kuo daugiau automatizuoti procesus“
	Didelių duomenų apdorojimas	„Padeda ten, kur yra labai dideli duomenų kiekiai“ „Turim milžiniškus kiekius informacijos ir žmogui būtų sunku tai apdoroti“ „Sistema gali daug greičiau susisteminti duomenis“
	Pasikartojančių procesų automatizavimas	„Pasikartojančios užduotys yra geriausia vieta DI“ „Dalis procesų jau pilnai automatizuojami“ „Tikslas yra pamažinti darbuotojų kaštus automatizuojant rutiną“
Strateginiai ribojimai	Netinkamas strateginiams sprendimams	„Vien tik skaičių neužtenka, labai daug ateina iš žmogaus patirties“ „Žmogus vis tiek reikalingas galutiniam sprendimui“ „DI nepakeis žmogaus prognozavimo procese“
	Ribotas kūrybinis mąstymas	„Sistema negali sugalvoti naujų sprendimų ar strategijų“ „Jis remiasi tuo, kas buvo istorijoje“ „Neįvertina verslo niuansų“
	Žmogaus sprendimų prioritetas	„Galutinį sprendimą vis tiek priima vadovas“ „Ekspertinės žinios vis tiek lieka labai svarbios“ „Žmogaus interpretacija yra būtina“

Informantas Nr. 1 pasakojo, kad jų organizacijoje DI naudojamas rinkos analizėms, naujienų sisteminimui ir dokumentų valdymui. Jis pažymėjo: „jeigu rašymas naujienų ar rinkos analizė, tai čia numeris vienas įrankis yra“ . Taip pat organizacijoje naudojami automatizuoti dokumentų archyvavimo sprendimai: „visus mūsų failus archyvuoja ir tvarko DI pilnai“ . Šie pavyzdžiai rodo,

kad DI daugiausia taikomas ten, kur procesai yra standartizuoti, pasikartojantys ir nereikalaujantys sudėtingos interpretacijos.

Panašios tendencijos atsispindėjo ir Informanto Nr. 4 pasisakymuose. Jis teigė, kad jų organizacijoje dirbtinis intelektas naudojamas kaip pagalbiniė priemonė techninėms užduotims atlikti: „dirbtinis intelektas naudojamas tik siekiant pasikonsultuoti kaip geriausia parašyti SQL užklausą“. Tai rodo, kad DI organizacijose dažnai naudojamas kaip darbuotojo produktyvumą didinantis įrankis, o ne kaip savarankiškas sprendimų priėmimo mechanizmas.

Informantas Nr. 2 taip pat akcentavo, kad dirbtinis intelektas efektyviausias ten, kur egzistuoja aiškios taisyklės ir dideli duomenų kiekiai. Jis teigė: „jisai padeda ten, kur yra labai dideli duomenų kiekiai ir yra kažkokios aiškios taisyklės“. Informantas pažymėjo, kad tokios sritys kaip buhalterinės operacijos ar pasikartojančių klaidų identifikavimas gali būti sėkmingai automatizuojamos, nes jose egzistuoja standartizuoti procesai ir aiškūs kontrolės kriterijai.

Tyrimo metu taip pat išryškėjo, kad organizacijos DI aktyviausiai diegia operacinėse srityse. Informantas Nr. 1 pasakojo apie gamybos planavimo sistemų diegimą ir automatizuotą pirkimų planavimą. Jo teigimu, organizacijos ilgalaikis tikslas yra mažinti administracinį darbą ir automatizuoti kuo daugiau rutininių procesų: „tikslas yra apamai, kad jisai pamažintų kaštus darbuotojų“.

Vis dėlto tyrimo rezultatai parodė, kad organizacijos aiškiai atskiria technines ir strategines DI funkcijas. Nors dirbtinis intelektas vertinamas kaip efektyvus pagalbiniškas standartizuotuose procesuose, tačiau strateginis prognozavimas, sprendimų interpretavimas ir sudėtingų situacijų vertinimas vis dar laikomi žmogaus kompetencijos sritimi. Tai leidžia teigti, kad dabartinėje praktikoje DI dažniausiai suvokiamas kaip darbuotoją papildanti, o ne pakeičianti technologija.

7 tema. Duomenų kokybės svarba prognozių tikslumui

Teminė analizė parodė, kad organizacijose duomenų kokybė yra suvokiama kaip vienas svarbiausių prognozių tikslumą lemiančių veiksnių. Nors šiuolaikinės organizacijos dirba su dideliais informacijos kiekiais ir naudoja įvairias analitines sistemas, tačiau interviu metu nuolat kartojosi mintis, kad didelis duomenų kiekis savaime negarantuoja geresnių prognozių. Priešingai – nekokybiški, nepilni ar neteisingai apdoroti duomenys gali iš esmės iškreipti prognozavimo rezultatus ir sukurti klaidingą organizacijos situacijos suvokimą.

14 lentelė. Duomenų kokybės svarba prognozių tikslumui

Kategorija	Subkategorija	Citata
Duomenų kokybės reikšmė	Kokybė svarbiau už kiekį	„Man atrodo, kad didesnę įtaką turi kokybė, nes jeigu turi labai daug netvarkingų duomenų, tai jie neduoda jokios naudos“ „Kuo didesnis kiekis duomenų, tuo yra didesnė galimybė turėti blogus duomenis arba klaidas sistemose“ „Prognozėms reikia labai geros kokybės duomenų, nes kitaip modeliai tampa nepatikimi“
	Tikslumo svarba prognozėms	„Viena klaida gali labai daug kainuoti, nes tada visa prognozė pasidaro neteisinga“ „Jeigu bazė neteisinga, tai iš esmės išsikraipo visas planavimas“ „Finansuose klaidos labai greitai pasimato ir turi realią įtaką rezultatams“

Kategorija	Subkategorija	Citata
	Duomenų patikimumas	„Visada reikia tikrinti informaciją, nes sistema pati savaime negarantuoja, kad duomenys teisingi“ „Svarbu ne tik kiek duomenų turi, bet ar tie duomenys iš tikrųjų yra korektiški“ „Reikia validuoti duomenis prieš juos naudojant prognozėms“
Duomenų problemos	Sisteminiai trikdžiai	„Metų eigoje aiškėja, kad kažkoks buvo trikdys ir dalis duomenų tiesiog nebuvo įtraukta“ „Kartais ne viskas suvaikščioja tarp sistemų ir tada atsiranda neatitikimų“ „Problemos tarp sistemų labai apsunkina prognozių sudarymą“
	Netikslūs įrašai	„Kuo daugiau duomenų, tuo daugiau atsiranda neteisingų formatų ar klaidingų įrašų“ „Blogi duomenys labai greitai sugadina analizės rezultatą“ „Kartais žmonės neteisingai suveda informaciją ir tada išsikraipo visa statistika“
	Nepilna informacija	„Kai kurių išlaidų mes tiesiog nematėm duomenyse ir tai iškreipė prognozę“ „Trūksta informacijos apie kai kuriuos procesus arba klientus“ „Ne viskas atsispindi sistemose, dalis informacijos lieka tik žmonių galvose“
Duomenų valdymo sprendimai	Automatizacija	„Mes dabar dirbam su informacija, kuri maksimaliai pateikta vienoje sistemoje, automatizuota ir suskaidyta smulkiai“ „Automatizuoti procesai leidžia sumažinti klaidų tikimybę“ „Kuo daugiau automatizacijos, tuo mažiau rankinių klaidų“
	Sistemų integracija	„Informacijos perdavimas tarp sistemų dabar vyksta automatiškai“ „Dirbam vienoje sistemoje, kad visi matytų tuos pačius skaičius“ „Buvo įdiegta nauja planavimo sistema, kuri padėjo geriau suvaldyti duomenis“
	Kontrolės mechanizmai	„Nuolat lyginamas planas su faktiniais rezultatais ir ieškoma neatitikimų“ „Mes žiūrim nukrypimus ir aiškinamės kodėl jie atsirado“ „Tikrinam ar visi skaičiai ir periodai atitinka prognozes“

Ypač aiškiai šią problemą įvardijo Informantas Nr. 2. Paklaustas, kas prognozių tikslumui turi didesnę įtaką – duomenų kiekis ar kokybė – jis nedvejodamas atsakė: „didesnę įtaką turi kokybė“ . Informantas taip pat pateikė konkretų praktinį pavyzdį, kaip net ir nedidelės duomenų klaidos gali turėti reikšmingų pasekmių organizacijai. Jis pasakojo apie situacijas, kai dėl sisteminių trikdžių organizacija nematydavo tam tikrų išlaidų istoriniuose duomenyse: „paimam bazę dar pamąstome kaip efektyvinsi ir tada metų eigoje aiškėja, kad uoj atsirado dar (...) kažkoks buvo trikdys“ . Šis pasisakymas atskleidžia, kad net ir nedidelės informacijos spragos gali suformuoti klaidingą biudžeto bazę, o vėliau sukelti reikšmingus nukrypimus tarp plano ir faktinių rezultatų.

Panaši problema buvo minima ir Informanto Nr. 4 interviu. Jis pažymėjo, kad kuo didesnis duomenų kiekis, tuo didesnė tikimybė susidurti su nekokybiška informacija: „kuo didesnis kiekis duomenų tuo yra didesnė galimybė turėti blogus duomenis“ . Informantas išskyrė neteisingus formatus, klaidingus įrašus bei nekorektiškai užpildytus duomenis kaip vienus pagrindinių iššūkių organizacijose dirbant su dideliais informacijos kiekiais.

Tyrimo metu taip pat paaiškėjo, kad duomenų kokybės problema glaudžiai susijusi su sistemų integracija ir technologine infrastruktūra. Informantai dažnai kalbėjo apie būtinybę naudoti centralizuotas sistemas, automatizuotus duomenų surinkimo procesus bei standartizuotas duomenų struktūras. Informantas Nr. 1 pažymėjo, kad organizacijos stengiasi maksimaliai automatizuoti informacijos surinkimą ir konsolidavimą: „mes ir dabar iš esmės jau tam tikruose lygiuose dirbam su informacija, kuri maksimaliai pateikta vienoje sistemoje, automatizuota ir suskaidyta smulkiai“ .

Interviu analizė taip pat atskleidė, kad duomenų kokybę organizacijose suvokiama ne tik kaip techninis, bet ir kaip vadybinis klausimas. Prognozių tikslumas priklauso ne vien nuo technologijų, bet ir nuo darbuotojų gebėjimo tinkamai interpretuoti informaciją, identifikuoti anomalijas bei suprasti, kokie duomenys iš tikrųjų atspindi realią situaciją. Dėl šios priežasties organizacijos didelį dėmesį skiria duomenų validavimui, kontrolės procedūroms ir nuolatiniam rezultatų tikrinimui.

Apibendrinant galima teigti, kad organizacijose duomenų kokybė yra laikoma kritiniu prognozavimo veiksniumi. Tyrimo rezultatai rodo, kad net pažangūs analitiniai modeliai ar dideli duomenų kiekiai negali užtikrinti tikslių prognozių, jei pradinė informacija yra netiksli arba nepilna. Tai dar kartą sustiprina praktinę išvalgą, kad finansinių prognozių procese itin svarbi tampa ne vien duomenų apimtis, bet ir jų patikimumas bei interpretavimo kokybė.

8 tema. Prognozavimas kaip nuolatinis tikslinimo ir kontrolės procesas

Teminė analizė atskleidė, kad organizacijose finansinės prognozės nėra suvokiamos kaip vienkartinis rezultatas ar galutinis dokumentas. Priešingai – prognozavimas buvo apibūdinamas kaip nuolatinis, cikliškas ir iteracinis procesas, kuriame organizacijos nuolat stebi faktinius rezultatus, lygina juos su planu ir koreguoja prognozes pagal naujai atsirandančią informaciją. Tokia praktika rodo, kad organizacijos prognozavimą suvokia ne kaip statinį modelį, o kaip nuolatinį prisitaikymo prie aplinkos procesą.

15 lentelė. Prognozavimas kaip nuolatinis tikslinimo ir kontrolės procesas

Kategorija	Subkategorija	Citata
Nuolatinis prognozių tikslinimas	„Rolling forecast“ principas	„Kiekvieną mėnesį mes vėl sukam tą patį ratą ir persiskaičiuojam dvylika mėnesių į priekį“ „Mes dirbam rolling forecast‘u principu, todėl prognozės nuolat atsinaujina“ „Prognozės darom kas mėnesį ir žiūrim, kiek pataikom į faktą“
	Prognozių koregavimas	„Jeigu keičiasi klientų poreikiai ar atsiranda papildomi kaštai, planai yra koreguojami“ „Vėl grįžtam ir persiskaičiuojam pagal naują informaciją“ „Pasikeitus situacijai viskas labai greitai persidėlioja“
	Prisitaikymas prie pokyčių	„Aplinkos pokyčiai dabar vyksta labai greitai, todėl prognozes reikia nuolat atnaujinti“ „Jeigu pasikeičia rinkos situacija, iškart keičiasi ir planai“ „Prognozės nėra statiškos, jos nuolat gyvena“
Kontrolės procesai	Plano ir fakto analizė	„Nuolat lyginamas planas su faktiniais rezultatais ir vertinama, dėl ko atsirado nukrypimai“ „Žiūrim kiek ta mūsų prognozė buvo tiksli ir kur suklydom“ „Analizuojam nukrypimus tarp plano ir realaus rezultato“
	KPI stebėseną	„Prognozės remiasi KPI rodikliais, tokiais kaip pajamos per kilometrą“

Kategorija	Subkategorija	Citata
		„Žiūrim kuro normas ir kiek efektyviai dirba transportas“ „Vertinam remonto sąnaudas per dieną ir kitus veiklos rodiklius“
	Nukrypimų priežasčių analizė	„Svarbiausia suprasti ne tik kad nukrypimas atsirado, bet ir kodėl jis atsirado“ „Tu gali matyti, kad mano prielaida buvo tokia, o pasikeitė dėl kažkokio faktoriaus“ „Aiškinamės kas pasikeitė ir kaip tai paveikė rezultatą“
Scenarijų modeliavimas	Alternatyvūs scenarijai	„Gyvai modeliuojam įvairias situacijas ir žiūrim kaip pasikeistų rezultatai“ „Pasikeitus vienam faktoriui visas biudžetas persiskaičiuoja“ „Žiūrim dvylika mėnesių į priekį ir vertinam skirtingus scenarijus“
	Rizikų vertinimas	„Prognozuojant labai svarbu vertinti visas galimas rizikas“ „Mes nuolat galvojame kas gali būti kitaip negu planavom“ „Nestandartinės situacijos dabar tampa labai dažnos“
	Operatyvus reagavimas	„Jeigu kažkas pasikeičia, labai greitai persidėliojame visą planą“ „Reaguojame į pokyčius praktiškai realiu laiku“ „Procesai turi būti lankstūs, nes situacija nuolat keičiasi“

Ypač ryškiai ši tema atsiskleidė Informanto Nr. 2 interviu. Jis prognozavimo procesą apibūdino kaip nuolat pasikartojantį ciklą: „kiekvieną mėnesį mes vėl sukam tą patį ratą ir žiūrim, kiek ta mūsų prognozė buvo tiksli“. Informantas paaikšino, kad organizacija kiekvieną mėnesį analizuoja faktinius rezultatus, vertina nukrypimus nuo prognozės ir pagal tai atnaujina ateities planus. Toks požiūris rodo, kad prognozės organizacijose yra laikomos „gyvu“ procesu, kuris nuolat adaptuojamas prie realios situacijos.

Panašios tendencijos atsispindėjo ir Informanto Nr. 5 pasisakymuose. Aviacijos sektoriaus atstovė pažymėjo, kad organizacijoje planai nuolat koreguojami pagal naują informaciją: „jeigu keičiasi klientų poreikiai, vėluoja sertifikatai ar atsiranda papildomi kaštai, planai yra koreguojami“. Šis pasisakymas atskleidžia, kad organizacijos nuolat susiduria su neapibrėžtumu, todėl prognozavimo procesas negali būti užbaigtas vienu sprendimu.

Tyrimo metu taip pat išryškėjo, kad organizacijos daug dėmesio skiria plano ir fakto analizei. Informantai nuolat kalbėjo apie KPI stebėjimą, nukrypimų analizę bei poreikį suprasti, kodėl faktiniai rezultatai skiriasi nuo prognozuotų. Informantas Nr. 2 pažymėjo, kad organizacijoje svarbu ne tik matyti nukrypimą, bet ir suprasti jo priežastį: „tu gali žiūrėti, kad mano prielaida buvo tokia, o pasikeitė tas dėl to“. Tai rodo, kad prognozių tikslinimas organizacijose glaudžiai susijęs su priežasčių analizavimu ir nuolatinio prielaidų peržiūrėjimu.

Labai svarbus aspektas buvo ir scenarijų modeliavimo praktika. Informantai pasakojo, kad organizacijose prognozės dažnai koreguojamos realiu laiku, vertinant skirtingus galimus scenarijus. Informantas Nr. 3 akcentavo, kad finansų analitikams svarbu gebėti „gyvai modeliuoti įvairias situacijas“. Tokia praktika leidžia organizacijoms greičiau reaguoti į rinkos pokyčius ir įvertinti galimą skirtingų sprendimų poveikį rezultatams.

Apibendrinant galima teigti, kad organizacijose prognozavimas yra suvokiamas kaip nuolatinis kontrolės ir prisitaikymo procesas. Prognozės nėra laikomos galutine tiesa – jos nuolat peržiūrimos, tikslinamos ir koreguojamos pagal besikeičiančią situaciją. Tyrimo rezultatai labai aiškiai atspindi dinamiškos aplinkos poveikį finansinių prognozių praktikai.

9 tema. Sektoriaus specifikos įtaka prognozavimo logikai

Teminė analizė atskleidė, kad prognozavimo logika organizacijose stipriai priklauso nuo sektoriaus specifikos. Nors visos organizacijos naudoja finansinius rodiklius, istorinius duomenis ir biudžetavimo procesus, tačiau tyrimo rezultatai parodė, kad skirtinguose sektoriuose prognozavimo struktūra, naudojami rodikliai ir svarbiausi rizikos veiksniai reikšmingai skiriasi. Tai leidžia teigti, kad praktikoje neegzistuoja vienas universalus prognozavimo modelis, tinkantis visoms organizacijoms.

16 lentelė. Sektoriaus specifikos įtaka prognozavimo logikai

Kategorija	Subkategorija	Citata
Transporto sektoriaus specifika	KPI orientacija	„Prognozės remiasi KPI rodikliais, tokiais kaip pajamos per kilometrą ar remonto sąnaudos per dieną“ „Žiūrime kuro normas ir kiek efektyviai dirba transportas“ „Transporto sektoriuje labai svarbūs veiklos efektyvumo rodikliai“
	Veiklos efektyvumo analizė	„Mes labai daug naudojame OEE analizę ir žiūrime kiek realiai technika dirba efektyviai“ „Analizuojame kiek vilkikas kilometrų nuvažiavo ir kiek stovėjo be darbo“ „Kiekviena neefektyvi valanda labai greitai matosi rezultatuose“
	Savikainos kontrolė	„Labai daug dėmesio skiriama savikainos dedamosioms“ „Žiūrime draudimų kaštus, kuro kainas ir transporto išlaidas“ „Transporto sektoriuje kaštų kontrolė yra vienas svarbiausių dalykų“
Aviacijos sektoriaus specifika	Reguliacinė aplinka	„Aviacijos techninės priežiūros sektorius yra labai specifinis ir griežtai reguliuojamas“ „Didelę įtaką daro sertifikatai ir auditai“ „Reguliaciniai pokyčiai labai stipriai paveikia planavimą“
	Techninis sudėtingumas	„Dirbam su orlaivių remontu ir technine priežiūra, todėl labai daug priklauso nuo techninių pajėgumų“ „Labai svarbus tampa komponentų tiekimas ir jų prieinamumas“ „Tai labai specifinis sektorius, kuriam reikia daug techninių žinių“
	Sezoniškumas ir pajėgumai	„Prognozuojant vertinami remonto ciklai, sezoniškumas ir klientų poreikiai“ „Labai svarbu įvertinti turimus pajėgumus ir darbuotojų užimtumą“ „Kai kuriais periodais apkrovos būna ženkliai didesnės“
Prekybos ir gamybos specifika	Atsargų valdymas	„Didelę reikšmę turi atsargų apyvartumo optimalumo valdymas“ „Labai svarbu stebėti sandėlio likučius ir užsakymų srautus“ „Pardavimų ir užsakymų procesai tiesiogiai veikia prognozes“
	Klientų elgsena	„Ką matom iš klientų ir ką girdim iš rinkos, tą dedam į prognozes“ „Klientų poreikiai labai greitai keičiasi“ „Santykiai su klientu labai stipriai įtakoja pardavimus“
	Investiciniai sprendimai	„Kai vertinam investicijas, skaičiuojame NPV ir žiūrime per kiek metų atsipirks“ „Tu investuoji į naują parką ir tada modeliuoji atsiperkamumą“ „Investicijų planavimas yra labai svarbi prognozavimo dalis“

Prekybos sektoriuje dirbę informantai daugiausia dėmesio skyrė klientų elgsenai, atsargų valdymui bei rinkos kainų pokyčiams. Informantas Nr. 3 pažymėjo, kad didmeninėje prekyboje prognozavimo pagrindą sudaro „pinigų srautai, visas skolų valdymas, atsargų apyvartumo optimalumo valdymas“. Šiame sektoriuje itin svarbus tampa santykių su klientais supratimas ir gebėjimas vertinti rinkos pokyčius.

Transporto sektoriuje prognozavimas buvo glaudžiai susijęs su veiklos KPI ir savikainos analize. Informantas Nr. 2 pasakojo, kad organizacijoje daug dėmesio skiriama tokiems rodikliams kaip „pajamos per kilometrą“, „remonto sąnaudos per dieną“ ar „draudimų kaštai“. Tuo tarpu Informantas Nr. 3 itin detalai apibūdino transporto bei gamybos sektoriuje naudojamą OEE analizę ir procesų skaidymą į mažas dedamąsias. Jis teigė, kad organizacijose analizuojama „kiek konkretus vilkikas kilometrų nuvažiavo, kiek stovėjo be darbo, kokia jo kuro norma“. Tai rodo, kad šiame sektoriuje prognozavimas stipriai orientuotas į veiklos efektyvumo ir savikainos kontrolę.

Aviacijos sektoriaus specifika tyrime taip pat išsiskyrė. Informantas Nr. 5 pažymėjo, kad jų organizacijoje prognozėms didelę įtaką daro „sertifikatai, auditai, klientų sprendimai ar net geopolitiniai dalykai“. Aviacijoje planavimo procesas glaudžiai susijęs su techniniais pajėgumais, reguliacine aplinka ir sezoniškumu, todėl prognozės tampa daug sudėtingesnės nei vien finansinių rodiklių analizė.

Telekomunikacijų sektoriaus atstovė taip pat akcentavo didelį procesų sudėtingumą ir informacijos ribojimą tarp skirtingų organizacijos lygių. Informantas Nr. 4 pažymėjo, kad organizacijoje „yra labai aiškios ribos kiek kas kokios info gauna“. Tai rodo, kad didelėse tarptautinėse organizacijose prognozavimas tampa stipriai decentralizuotu procesu, kuriame darbuotojai dirba tik su jiems aktualia informacija.

Apibendrinant galima teigti, kad sektoriaus specifika stipriai formuoja prognozavimo logiką organizacijose. Skirtingose industrijose skiriasi ne tik naudojami rodikliai ar prognozavimo metodai, bet ir tai, kokie veiksniai laikomi svarbiausiais prognozės tikslumui. Tyrimo rezultatai leidžia daryti išvadą, kad praktikoje prognozavimo modeliai turi būti pritaikomi prie konkretaus sektoriaus veiklos pobūdžio, rizikų ir organizacinių procesų.

4.3. Didžiųjų duomenų ir ekspertinių įžvalgų integravimo į dirbtinio intelekto finansinių prognozių sprendimus modeliai vertinimas

Interviu metu informantams buvo pristatyta teorinio modelio idėja, paremta didžiųjų duomenų, dirbtinio intelekto ir ekspertinių įžvalgų integracija finansinių prognozių sudaryme. Analizuojant informantų atsakymus paaiškėjo, kad bendra modelio kryptis buvo vertinama pozityviai ir suvokiama kaip artima realiai organizacijų praktikai.

17 lentelė. Didžiųjų duomenų ir ekspertinių įžvalgų integravimo į dirbtinio intelekto finansinių prognozių sprendimus modeliai vertinimas

Kategorija	Subkategorija	Citata
Teorinio modelio stiprybės	Duomenų ir ekspertinių žinių integracija	„Naudoti tik istorinius duomenis, mano asmenine nuomone, yra nerealistiška, nes vis tiek reikia žiūrėti kas vyksta rinkoje ir ką sako žmonės, kurie toj srity dirba“ „Reikia to vadybininko, kuris su tuo žmogum dirba, žinojimo, nes sistemos tokių dalykų neparodo“

Kategorija	Subkategorija	Citata
	Prisitaikymas prie pokyčių	„Jeigu keičiasi klientų poreikiai ar atsiranda papildomi kaštai, planai yra koreguojami“ „Kiekvieną mėnesį mes vėl sukam tą patį ratą ir persiskaičiuojam dvylika mėnesių į priekį“
	Didžiųjų duomenų panaudojimas	„Jis padeda ten, kur yra labai dideli duomenų kiekiai ir yra kažkokios aiškios taisyklės“ „Jeigu rašymas naujienų ar rinkos analizė, tai čia numeris vienas įrankis yra“
	Praktinis pritaikomumas	„Mes daug konsultuojamės su žmonėmis, kurie yra toje srityje kompetentingi“ „Labai daug ateina iš patirties, iš supratimo apie klientą, rinką, procesus“
Teorinio modelio silpnybės	Ekspertinių žinių formalizavimo problema	„Čia reikia tokio žinojimo, kaip savo namuose. Statistika gali parodyti skaičius, bet ji nepasakys, kodėl realiai taip vyksta“ „Labai daug informacijos lieka žmonių galvose“
	Subjektyvumo rizika	„Pastebėjome, kad ekspertinės išvalgos dažnai nepasiteisina, nes žmonės linkę vertinti subjektyviai“ „Subjektyvumas dažniausiai atsiranda tada, kai žmogus remiasi nuojauta“
	Paaškinamumo problema	„Vadovai nori prajausti, pračiupinėt kiekvieną dalyką, o ne tiesiog gauti skaičius“ „Visada atsiranda klausimas – iš kur tas skaičius atsirado?“
	Pasitikėjimo DI trūkumas	„Kol kas mes neturime tokio pasitikėjimo, kad jis už mus teisingai padarys, nes jo kaina klaidos yra per didelė“ „Finansuose viena klaida gali labai daug kainuoti“
Siūlomi modelio patobulinimai	Žmogaus kontrolės stiprinimas	„Žmogus turi pasižiūrėti ir suprasti, ar prognozė logiška“ „Galutinį sprendimą vis tiek priima vadovas“
	Ekspertinių žinių dokumentavimas	„Labai daug informacijos ateina iš santykių su klientais ir rinkos nuotaikų“ „Ką matom iš klientų ir ką girdim iš rinkos, tą dedam į prognozes“
	Paaškinamumo sluoksnio poreikis	„Reikia suprasti pačią logiką, kodėl modelis taip paskaičiavo“ „Neužtenka, kad sistema tiesiog pasakė rezultatą“
	Modelio pritaikymas sektoriui	„Transporto sektoriuje labai svarbūs veiklos efektyvumo rodikliai“ „Aviacijos techninės priežiūros sektorius yra labai specifinis ir griežtai reguliuojamas“

Dauguma tyrimo dalyvių pripažino, kad finansinių prognozių procesas praktikoje jau dabar remiasi mišria logika, kai istoriniai duomenys, KPI rodikliai bei analitinės sistemos derinamos su darbuotojų patirtimi, vadovų vertinimais ir situaciniu rinkos suvokimu. Vis dėlto informantai taip pat išskyrė nemažai iššūkių, susijusių su tokio modelio praktiniu įgyvendinimu, duomenų kokybe, ekspertinių žinių formalizavimu bei paaškinamumo problema.

Teorinio modelio stiprybės

Vienas dažniausiai pasikartojusių aspektų buvo modelio gebėjimas sujungti du skirtingus prognozavimo pasaulius – duomenimis grįstą analizę ir žmogaus ekspertinį vertinimą. Informantai teigė, kad realiose organizacijose vien statistinių modelių nepakanka, nes didelė dalis svarbios informacijos neegzistuoja struktūruotuose duomenyse. Dėl šios priežasties modelio idėja integruoti ekspertines išvalgas buvo vertinama kaip praktiškai reikalinga. Informantas Nr. 2 pažymėjo:

„Naudoti tik istorinius duomenis, mano asmenine nuomone, yra nerealistiška, nes vis tiek reikia žiūrėti kas vyksta rinkoje ir ką sako žmonės, kurie toje srityje dirba“. Ši citata atspindi vieną pagrindinių teorinio modelio stiprybių – gebėjimą įtraukti informaciją, kuri nėra tiesiogiai matoma duomenų bazėse. Informantai ne kartą akcentavo, kad rinkos pokyčiai, klientų santykiai, derybos ar geopolitiniai įvykiai dažnai tampa svarbesni už istorinius statistinius dėsningumus.

Labai teigiamai buvo vertinamas ir adaptacinis modelio principas, pagal kurį prognozės turėtų būti koreguojamos priklausomai nuo situacijos specifikos. Informantas Nr. 5 pabrėžė: *„Jeigu keičiasi klientų poreikiai ar atsiranda papildomi kaštai, planai yra koreguojami“.* Tyrimo dalyviai akcentavo, kad praktikoje prognozavimas yra nuolatinis procesas, todėl modelio lankstumas ir gebėjimas prisitaikyti prie naujos informacijos buvo laikomas viena svarbiausių jo stiprybių.

Kita reikšminga stiprybė buvo didžiųjų duomenų integravimo galimybė. Informantai pripažino, kad organizacijos šiandien susiduria su itin dideliais informacijos kiekiais, kurių žmogus fiziškai nebegali pilnai apdoroti. Dėl šios priežasties DI sluoksnis modelyje buvo vertinamas kaip svarbi priemonė automatizuoti duomenų analizę ir pagreitinti sprendimų priėmimą. Informantas Nr. 1 teigė: *„Jeigu rašymas naujienų ar rinkos analizė, tai čia numeris vienas įrankis yra“.* Tuo tarpu Informantas Nr. 2 akcentavo: *„Jis padeda ten, kur yra labai dideli duomenų kiekiai ir yra kažkokios aiškios taisyklės“.* Šie pasisakymai rodo, kad modelio DI komponentas praktikoje būtų naudingas pirmiausia kaip analitinis ir pagalbinis sluoksnis.

Teorinio modelio silpnybės

Nepaisant teigiamo bendro vertinimo, interviu metu atsiskleidė ir nemažai modelio silpnybių bei praktinių rizikų. Viena svarbiausių problemų informantai įvardijo ekspertinių žinių formalizavimą. Tyrimo dalyviai pabrėžė, kad ekspertinės įžvalgos dažnai yra labai intuityvios, paremtos asmenine patirtimi ir sunkiai perkeliamos į struktūruotą sistemą. Informantas Nr. 3 teigė: *„Čia reikia tokio žinojimo, kaip savo namuose. Statistika gali parodyti skaičių, bet ji nepasakys, kodėl realiai taip vyksta“.* Šis pasisakymas atskleidžia vieną pagrindinių modelio silpnybių – labai sudėtinga standartizuoti žmogišką intuiciją ir kontekstinį supratimą.

Kita reikšminga problema buvo susijusi su subjektyvumu. Informantai pažymėjo, kad ekspertinės nuomonės organizacijose ne visada pasiteisina, o skirtingi darbuotojai tą pačią situaciją gali vertinti labai skirtingai. Informantas Nr. 4 teigė: *„Pastebėjome, kad ekspertinės įžvalgos dažnai nepasiteisina, nes žmonės linkę vertinti subjektyviai“.* Tai rodo, kad modelyje egzistuoja rizika pernelyg stipriai remtis žmogišku vertinimu, kuris gali būti paveiktas emocijų, asmeninės patirties ar organizacinių interesų.

Dar viena labai ryški silpnybė buvo paaiškinamumo problema. Informantai nuolat akcentavo, kad organizacijose nepakanka vien gauti prognozės rezultatą – būtina suprasti, kaip tas rezultatas buvo pasiektas. Informantas Nr. 3 pažymėjo: *„Vadovai nori prajausti, pračiupinėt kiekvieną dalyką, o ne tiesiog gauti skaičių“.* Šis aspektas ypač svarbus kalbant apie sudėtingesnius DI modelius, kurie organizacijose gali būti suvokiami kaip „juodosios dėžės“. Informantai teigė, kad be aiškios sprendimų logikos organizacijose būtų sunku pasitikėti pilnai automatizuotomis prognozėmis.

Informantų siūlomi modelio patobulinimai

Analizuojant interviu medžiagą paaiškėjo, kad informantai modelį labiau matytų kaip žmogaus ir dirbtinio intelekto bendradarbiavimo sistemą, o ne pilnai autonominių sprendimų priėmimo mechanizmą. Dauguma tyrimo dalyvių akcentavo, kad žmogaus vaidmuo turėtų išlikti centrinis. Informantas Nr. 1 teigė: „*Kol kas mes neturime tokio pasitikėjimo, kad jis už mus teisingai padarys*“.

Todėl vienas svarbiausių siūlomų patobulinimų buvo žmogaus kontrolės sluoksnio stiprinimas modelyje. Informantai siūlė, kad: 1) galutinį sprendimą visada priimtų žmogus; 2) DI veiktų kaip rekomendacinė sistema; 3) ekspertinės korekcijos būtų aiškiai dokumentuojamos; 4) sistema gebėtų parodyti, kodėl priėmė konkretų sprendimą.

Taip pat buvo akcentuojamas poreikis aiškesniam ekspertinių žinių struktūravimui. Informantai pažymėjo, kad organizacijose labai daug kritinės informacijos egzistuoja neformalia forma, todėl modelyje reikėtų mechanizmo, leidžiančio sistemingai rinkti ir dokumentuoti ekspertines įžvalgas. Informantas Nr. 5 teigė: „*Labai daug informacijos ateina iš santykių su klientais ir rinkos nuotaikų*“. Tai rodo poreikį modelyje integruoti ne tik kiekybinius, bet ir kokybinius duomenų šaltinius.

Galiausiai informantai akcentavo, kad modelis turėtų būti adaptyvus skirtingiems sektoriams. Tyrimo metu paaiškėjo, kad transporto, aviacijos, prekybos ar telekomunikacijų sektoriuose prognozavimo logika labai skiriasi, todėl universalus modelio taikymas visoms organizacijoms galėtų būti ribotas.

Apibendrinimas

Apibendrinant galima teigti, kad informantai teorinį modelį vertino kaip aktualų ir atitinkantį realias finansinių prognozių praktikos problemas. Didžiausiomis modelio stiprybėmis buvo laikomas gebėjimas integruoti didžiuosius duomenis, dirbtinį intelektą ir ekspertines žinias bei adaptyviai reaguoti į aplinkos pokyčius. Vis dėlto tyrimo rezultatai taip pat atskleidė svarbius praktinius iššūkius: ekspertinių žinių formalizavimo sudėtingumą, subjektyvumo riziką, paaiškinamumo poreikį bei būtinybę išlaikyti žmogaus kontrolę sprendimų priėmimo procese. Informantų įžvalgos leidžia teigti, kad efektyviausias modelio taikymas būtų pasiekiamas ne pilnai automatizuojant prognozavimą, o kuriant hibridinę žmogaus ir dirbtinio intelekto bendradarbiavimo sistemą.

4.4. Didžiųjų duomenų ir ekspertinių įžvalgų integravimo į dirbtinio intelekto finansinių prognozių sprendimus koreguotas modelis

Įvertinus empirinio tyrimo rezultatus ir informantų pateiktas įžvalgas, paaiškėjo, kad pradinis teorinis modelis atitinka bendrą organizacijų finansinių prognozių praktiką, tačiau realiose organizacijose prognozavimo procesas yra dar labiau dinamiškas, iteracinis ir priklausomas nuo žmogaus interpretacijos, nei buvo numatyta pradiniam modelyje.

1 korekcija. Atskiro „Duomenų kokybės ir validavimo“ sluoksnio įtraukimas

Empirinio tyrimo rezultatai labai stipriai atskleidė, kad viena didžiausių prognozavimo problemų organizacijose yra ne pats DI modelis, o netikslūs, nepilni arba nekokybiški duomenys. Todėl tarp 1 ir 2 sluoksnių įtraukiamas papildomas sluoksnis: „Duomenų kokybės vertinimas ir validavimas“.

Šis sluoksnį sudaro: duomenų kokybės vertinimas; anomalijų identifikavimas; trūkstamų duomenų aptikimas; skirtingų sistemų duomenų suderinimas; duomenų patikimumo indeksas; automatizuotas klaidų aptikimas.

Šio sluoksnio poreikį pagrindžia informantų mintys:

„Viena klaida gali labai daug kainuoti, nes tada visa prognozė pasidaro neteisinga.“

„Kuo didesnis kiekis duomenų, tuo yra didesnė galimybė turėti blogus duomenis.“

Tokiu būdu modelis tampa praktiškai realesnis ir sumažina riziką, kad DI mokosi iš nekokybiškų duomenų.

2 korekcija. Ekspertinių įžvalgų sluoksnio perkėlimas iš pavienio etapo į visą modelį

Pradiniame modelyje ekspertinės įžvalgos pateikiamos kaip atskiras 4 sluoksnis po pirminės prognozės sugeneravimo. Tačiau tyrimo rezultatai parodė, kad realybėje ekspertinės žinios organizacijose dalyvauja visuose prognozavimo etapuose.

Informantai akcentavo, kad, ekspertai padeda interpretuoti duomenis, formuoja pradines prielaidas, koreguoja modelio rezultatus, identifikuoja nestandartines situacijas, vertina rizikas, bei interpretuoja nukrypimus.

Todėl ekspertinės žinios modelyje vaizduojamos ne kaip vienas atskiras blokas, o kaip horizontalus sluoksnis, jungianti duomenų paruošimą, prognozės generavimą, situacijos panašumo vertinimą, bei galutinį sprendimų palaikymą.

Remiantis tyrimo rezultatais, tai geriau atspindi realų organizacijų veikimo principą.

3 korekcija. Situacijos panašumo sluoksnio išplėtimas į „Dinaminio konteksto vertinimą“

Pradinis modelio 5 sluoksnis yra viena stipriausių modelio dalių, nes labai gerai atspindi adaptacinę prognozavimo logiką, tačiau tyrimo rezultatai parodė, kad praktikoje organizacijos vertina ne tik istorinį panašumą, bet ir geopolitinius pokyčius, reguliacinę aplinką, klientų elgseną, rinkos nuotaikas, sezoniškumą, tiekimo grandinės pokyčius, bei konkurentų veiksmus.

Siūloma 5 sluoksnį pervadinti į: „Dinaminio konteksto ir situacijos panašumo vertinimas“

Šis sluoksnis turėtų vertinti istorinių duomenų reprezentatyvumą, išorinės aplinkos stabilumą, rizikos lygį, prognozės neapibrėžtumą, situacijos nestandartiškumą.

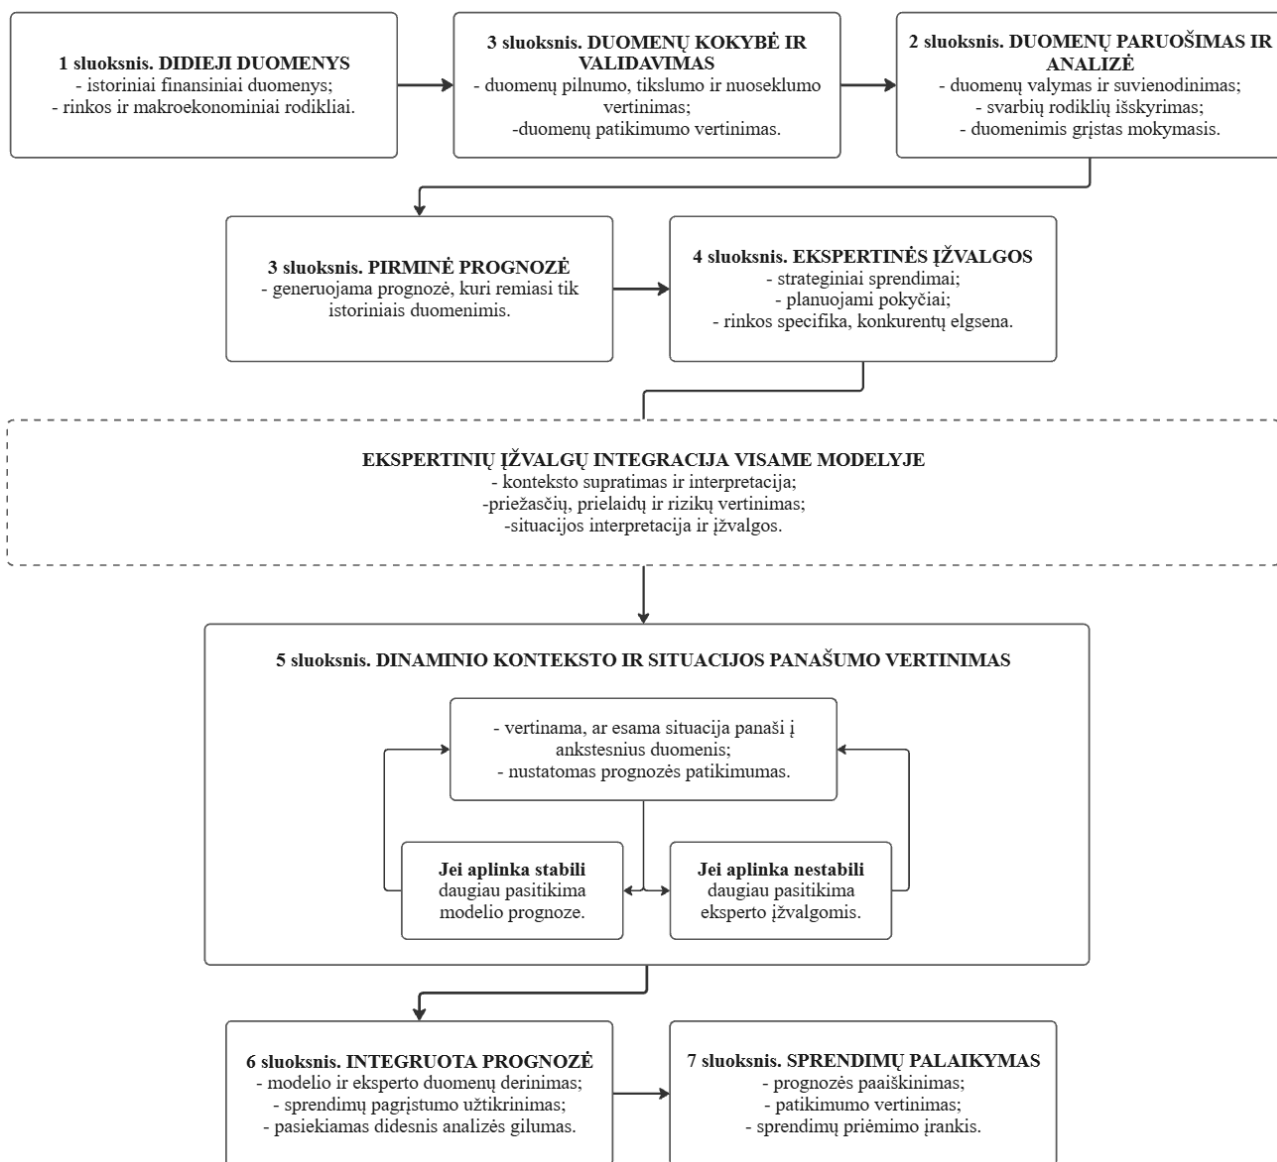
Jeigu:

aplinka stabili → daugiau pasitikima modeliu;

aplinka nestabili → daugiau svorio suteikiama ekspertinėms įžvalgoms.

Koreguoto didžiųjų duomenų ir ekspertinių įžvalgų integravimo į dirbtinio intelekto finansinių prognozių sprendimus teorinio modelio logika

Pagrindinis pokytis lyginant su pradiniu modeliu yra tas, kad DI šiame modelyje nebėra suvokiamas kaip autonominis sprendimų priėmėjas. Tyrimo rezultatai rodo, kad praktiškai efektyviausias tampa hibridinis modelis, kuriame: DI analizuoja didelius duomenų kiekius, o ekspertai interpretuoja kontekstą. Pati sistema adaptuojasi prie aplinkos pokyčių, na o žmogus išlaiko galutinę sprendimų kontrolę. Tokiu būdu modelis geriau atitinka realią organizacijų finansinių prognozių praktiką ir empirinio tyrimo metu identifikuotus poreikius. Modelio logika paremta prielaida, kad finansinių prognozių tikslumas negali būti pasiektas vien statistiniais modeliais arba vien žmogaus intuicija. Dėl šios priežasties modelyje derinami tiek automatizuoti duomenų analizės metodai, tiek ekspertinis situacijos interpretavimas ir žmogaus kontrolė.



8 pav. Koreguotas modelis

Pateiktas modelis vaizduoja integruotą finansinių prognozių sistemą, kurioje didieji duomenys, dirbtinio intelekto metodai ir ekspertinės žinios sujungiami į vieną adaptyvų prognozavimo mechanizmą. Modelio struktūra paremta nuoseklia daugiapakopio prognozavimo logika, kuri leidžia ne tik generuoti statistiškai pagrįstas prognozes, bet ir prisitaikyti prie dinamiškų bei nestandartinių verslo situacijų.

Pirmasis sluoksnis – didieji duomenys – sudaro visos prognozavimo sistemos informacinį pagrindą. Šiame etape surenkami ir konsoliduojami vidiniai bei išoriniai organizacijos duomenys. Vidiniai duomenys apima istorinius finansinius rodiklius, tokius kaip pardavimai, pajamos, sąnaudos, pinigų srautai ar biudžetų vykdymo rezultatai, o išoriniai duomenys apima rinkos ir makroekonominis rodiklius, galinčius paveikti organizacijos veiklą. Šio sluoksnio tikslas yra sukurti kuo platesnį organizacijos veiklos ir išorinės aplinkos vaizdą. Modelis remiasi nuostata, kad finansinių prognozių tikslumas didėja tada, kai vertinami ne tik tradiciniai finansiniai duomenys, bet ir platesnis ekonominis bei rinkos kontekstas.

Antrasis sluoksnis – duomenų kokybė ir validavimas – buvo įtrauktas remiantis empirinio tyrimo rezultatais. Tyrimo metu informantai pabrėžė, kad viena didžiausių finansinių prognozių problemų

praktikoje yra nekokybiški, netikslūs arba nepilni duomenys. Dėl šios priežasties šiame sluoksnyje atliekamas duomenų pilnumo, tikslumo ir nuoseklumo vertinimas. Taip pat tikrinamas duomenų patikimumas ir suderinamumas tarp skirtingų sistemų. Šio sluoksnio paskirtis yra užtikrinti, kad tolimesniuose prognozavimo etapuose būtų naudojami tik validuoti ir patikimi duomenys. Modelis remiasi prielaida, kad net pažangiausi dirbtinio intelekto metodai negali generuoti kokybiškų prognozių, jei mokomi iš neteisingų arba iškraipytų duomenų.

Trečiajame sluoksnyje vyksta duomenų paruošimas ir analizė. Šiame etape validuoti duomenys transformuojami į dirbtinio intelekto modeliams tinkamą formą. Atliekamas duomenų valymas, suvienodinimas ir reikšmingų rodiklių išskyrimas. Taip pat šiame sluoksnyje vyksta duomenimis grįstas mokymasis, kai dirbtinis intelektas analizuoja istorinius duomenis, ieško dėsningumų, koreliacijų bei pasikartojančių ciklų. Šio sluoksnio paskirtis yra identifikuoti prognozavimui reikšmingus veiksnius ir paruošti pagrindą tolimesniam prognozės generavimui.

Ketvirtajame sluoksnyje formuojama pirminė prognozė. Ši prognozė generuojama remiantis tik istoriniais duomenimis ir statistiniais ryšiais, neįtraukiant žmogaus vertinimo. Modelis remiasi prielaida, kad istoriniuose duomenyse egzistuoja pasikartojantys dėsningumai, kuriuos dirbtinis intelektas gali identifikuoti ir panaudoti ateities prognozėms. Šiame etape gali būti taikomi įvairūs mašininio mokymosi, neuroninių tinklų ar laiko eilučių prognozavimo metodai. Pirminė prognozė laikoma baziniu scenarijumi, nes ji remiasi vien statistiniais duomenimis ir nevertina platesnio konteksto ar organizacijos vidinių pokyčių.

Šalia pagrindinio proceso modelyje išskirtas atskiras ekspertinių įžvalgų sluoksnis. Šiame etape į prognozavimo sistemą įtraukiamos strateginės, organizacinės ir rinkos žinios, kurios nėra tiesiogiai matomos istoriniuose duomenyse. Ekspertinės įžvalgos gali apimti planuojamus strateginius sprendimus, investicijas, reorganizacijas, klientų elgsenos pokyčius, konkurentų veiksmus ar rinkos tendencijas. Šis sluoksnis rodo, kad ekspertinės žinios modelyje egzistuoja ne tik kaip vienkartinis prognozės pataisymas, bet kaip formalus papildomos informacijos integravimo etapas.

Tuo pačiu modelyje pabrėžiama, kad ekspertinės žinios veikia ne tik viename etape, bet visame prognozavimo procese. Dėl šios priežasties modelyje įtrauktas horizontalus „Ekspertinių įžvalgų integracijos visame modelyje“ mechanizmas. Šis mechanizmas reiškia, kad ekspertai dalyvauja ne tik koreguodami galutinę prognozę, bet ir interpretuodami duomenis, vertindami jų kokybę, analizuodami rizikas, aiškindami nukrypimus bei interpretuodami kontekstą. Tokiu būdu modelis tampa socio-technine sistema, kurioje dirbtinis intelektas ir žmogaus patirtis veikia kartu.

Penktasis sluoksnis – dinaminio konteksto ir situacijos panašumo vertinimas – yra pagrindinis modelio adaptacinis mechanizmas. Šiame etape vertinama, kiek dabartinė situacija yra panaši į istorinius scenarijus, kuriais remiantis buvo sugeneruota pirminė prognozė. Jei sistema nustato, kad aplinka yra stabili ir panaši į istorinius duomenis, didesnis pasitikėjimas suteikiamas dirbtinio intelekto prognozei. Tačiau jei aplinka tampa nestabili, vyksta ekonominiai ar geopolitiniai pokyčiai arba organizacija susiduria su nestandartinėmis situacijomis, didesnė svarba suteikiama ekspertinėms įžvalgoms. Šis sluoksnis leidžia modeliui tapti adaptyviu ir prisitaikančiu prie besikeičiančios aplinkos.

Šeštajame sluoksnyje formuojama integruota prognozė. Šiame etape sujungiami dirbtinio intelekto sugeneruoti rezultatai ir ekspertinės įžvalgos. Integruota prognozė tampa kompromisu tarp statistinio modelio ir žmogaus patirties. Modelis remiasi prielaida, kad didžiausias prognozių tikslumas pasiekiamas tada, kai dirbtinis intelektas naudojamas didelių duomenų kiekių analizei ir dėsningumų

identifikavimui, o ekspertai interpretuoja nestandartines situacijas bei įvertina papildomus kontekstinius signalus. Šiame sluoksnyje taip pat užtikrinamas sprendimų pagrįstumas ir didesnis analizės gilumas.

Paskutinis, septintasis sluoksnis, yra sprendimų palaikymas. Šiame etape sistema ne tik pateikia galutinę prognozę, bet ir paaiškina jos formavimo logiką, prognozės patikimumą bei pagrindinius ją nulėmusius veiksnius. Šis sluoksnis ypač svarbus finansų analitikoje, nes organizacijų vadovams nepakanka vien galutinio rezultato – būtina suprasti, kaip prognozė buvo suformuota ir kokiomis prielaidomis ji remiasi. Todėl modelis tampa ne tik prognozavimo sistema, bet ir sprendimų palaikymo priemone, leidžiančia geriau pagrįsti strateginius sprendimus ir įvertinti galimas rizikas.

Modelio veikimą papildomai papildo žmogaus kontrolės mechanizmas, kuris integruojamas į visą prognozavimo procesą. Šis mechanizmas reiškia, kad žmogus dalyvauja duomenų validavimo, modelio tinkamumo vertinimo, prognozių interpretavimo ir galutinio sprendimų patvirtinimo procesuose. Tokiu būdu modelis nėra suvokiamas kaip visiškai autonominė dirbtinio intelekto sistema. Priešingai, jis remiasi human-in-the-loop principu, pagal kurį dirbtinis intelektas veikia kaip analitinis ir pagalbinis įrankis, o galutinė atsakomybė už sprendimus išlieka žmogui.

4.5. Diskusija

Atliktas empirinis tyrimas iš esmės patvirtino pirmojoje ir antrojoje darbo dalyse identifikuotas teorines prielaidas bei problemas, susijusias su didžiųjų duomenų, dirbtinio intelekto ir ekspertinių žinių integravimu finansinių prognozių sudaryme.

Empirinio tyrimo ir teorinių išvalgų sąsajos

Tyrimo rezultatai parodė, kad praktikoje finansinių prognozių procesas išlieka hibridinis – organizacijos remiasi istoriniais duomenimis, statistiniais modeliais ir duomenų analitika, tačiau galutinės prognozės dažniausiai papildomos ekspertinėmis korekcijomis bei vadovų sprendimais. Tokie rezultatai tiesiogiai siejasi su teorinėje darbo dalyje analizuotais Park ir kt. (2023), van der Staak ir kt. (2025), Goodwin (2021) bei Franses (2024) tyrimais, kuriuose akcentuojama, kad vien statistiniai ar dirbtinio intelekto modeliai ne visuomet geba tinkamai reaguoti į netipines situacijas, todėl prognozavimo procese išlieka reikšmingas žmogaus vaidmuo.

Tyrimo metu išryškėjo, kad organizacijose prognozės nėra suvokiamos kaip vienkartinis „skaičius“ ar techninis rezultatas. Praktikoje jos tampa nuolat koreguojamu ir organizacijos sprendimų priėmimo procese integruotu mechanizmu. Informantai prognozes apibūdino kaip sistemą, kuri nuolat atnaujinama priklausomai nuo rinkos pokyčių, naujai gaunamos informacijos ar strateginių organizacijos sprendimų. Ši išvalga tiesiogiai siejasi su teorinėje darbo dalyje aptartu post-prognozavimo efektu, kurį analizavo Song ir Wu (2023). Autoriai teigia, kad prognozės finansų srityje nėra neutralios – jos pačios daro įtaką sprendimams, kurie vėliau pakeičia prognozuojamą rezultatą. Empirinis tyrimas šią teorinę logiką patvirtino praktiškai, nes informantai ne kartą pabrėžė, kad prognozės organizacijose tampa pagrindu tolimesniems veiksams: kaštų mažinimui, investicijų planavimui, darbuotojų poreikio vertinimui ar kainodaros sprendimams.

Svarbu pažymėti, kad tyrimo rezultatai sustiprino teorinėje darbo dalyje iškeltą argumentą, jog finansinių prognozių procesas organizacijose tampa vis labiau tarpdisciplininis. Informantai akcentavo, kad prognozėse dalyvauja ne tik finansų specialistai, bet ir pardavimų, tiekimo,

komercijos, gamybos bei aukščiausio lygmens vadovai. Tai leidžia teigti, kad prognozavimas organizacijose nebėra izoliuota finansų departamento funkcija – jis tampa kolektyviniu organizacijos žinojimo ir sprendimų koordinavimo procesu. Ši išvalga iš esmės sutampa su Fildes, Ma ir Kolassa (2019) pozicija, kad prognozės organizacijose veikia kaip koordinavimo mechanizmas tarp skirtingų funkcinių sričių.

Tradicinių prognozavimo metodų ribotumų patvirtinimas

Empirinis tyrimas patvirtino pirmojoje darbo dalyje aptartą tradicinių finansinių prognozavimo metodų ribotumo problemą. Informantai nuosekliai pabrėžė, kad istoriniai duomenys organizacijose išlieka pagrindiniu prognozių sudarymo šaltiniu, tačiau praktikoje jų nepakanka. Tyrimo metu paaiškėjo, kad organizacijos reguliariai susiduria su situacijomis, kai istorinės tendencijos tampa nebeaktualios dėl rinkos pokyčių, ekonominio neapibrėžtumo, vartotojų elgsenos kaitos ar specifinių vienkartinų įvykių.

Šios išvalgos tiesiogiai siejasi su Tang ir kt. (2022) tyrimais apie finansinių laiko eilučių nestacionarumą bei režimų kaitą. Empirinio tyrimo rezultatai parodė, kad praktikoje finansų specialistai iš tiesų susiduria su problema, kai istoriniai modeliai praranda reprezentatyvumą naujose situacijose. Informantai akcentavo, kad net ir tiksliai veikiantys modeliai tampa mažiau naudingi, kai organizacija patiria nestandartinius pokyčius – įgyvendina reorganizaciją, keičia strategiją, susiduria su tiekimo grandinės sutrikimais ar staigiais rinkos pokyčiais. Tokie rezultatai patvirtina Chung ir kt. (2025) bei Makridakis ir kt. (2020) teorines išvalgas, kad finansiniai procesai pasižymi sudėtinga ir sunkiai prognozuojama dinamika.

Kita vertus, tyrimas atskleidė ir tam tikrą skirtumą tarp teorinių modelių bei realios organizacijų praktikos. Mokslinėje literatūroje dažnai akcentuojamas pažangių DI modelių gebėjimas prisitaikyti prie sudėtingų duomenų struktūrų, tačiau empirinio tyrimo metu paaiškėjo, kad organizacijos praktikoje dažnai vis dar remiasi santykinai paprastais prognozavimo metodais – „rolling forecast“, biudžetais, ankstesnių laikotarpių tendencijomis bei ekspertiniais vertinimais. Tai leidžia teigti, kad egzistuoja tam tikras atotrūkis tarp teorinių technologinių galimybių ir jų realaus pritaikymo organizacijose.

Tokį skirtumą galima aiškinti ne tik technologiniais, bet ir organizaciniais veiksniais. Tyrimo metu paaiškėjo, kad organizacijoms svarbus ne vien modelio tikslumas, bet ir jo suprantamumas, aiškumas bei galimybė pagrįsti sprendimus vadovybei. Dėl šios priežasties organizacijos ne visuomet linkusios naudoti itin sudėtingus „juodosios dėžės“ modelius, net jei teoriškai jie galėtų generuoti tikslesnes prognozes.

Ekspertinių žinių vaidmuo prognozavimo procese

Vienas svarbiausių empirinio tyrimo rezultatų buvo aiškiai išreikštas ekspertinių žinių poreikis finansinių prognozių procese. Tyrimas parodė, kad organizacijose prognozės retai priimamos vien remiantis modelio sugeneruotu rezultatu. Informantai akcentavo, kad prognozės dažniausiai papildomos vadovų, rinkos specialistų ar kitų ekspertų išvalgomis apie būsimus rinkos pokyčius, klientų elgseną, konkurentų veiksmus ar strateginius organizacijos planus.

Ši tyrimo išvada stipriai siejasi su Park ir kt. (2023) adaptacinio ekspertinių žinių integravimo mechanizmo logika. Tyrimo metu paaiškėjo, kad praktikoje ekspertinės žinios tampa ypač svarbios

tada, kai organizacijos susiduria su nestandartinėmis situacijomis arba kai istoriniai duomenys nebeatspindi realios aplinkos. Tokios situacijos visiškai atitinka teorinėje darbo dalyje analizuotą reprezentatyvumo problemą – kuo mažiau dabartinė situacija panaši į istorinius duomenis, tuo didesnė tampa ekspertinių žinių svarba.

Kita vertus, tyrimas taip pat patvirtino teorinėje literatūroje iškeltą problemą, kad ekspertinės žinios organizacijose dažnai nėra formalizuotos. Informantai pabrėžė, kad korekcijos dažniausiai atliekamos remiantis intuicija, patirtimi ar vadovų „pojūčiu“, tačiau šių sprendimų logika retai dokumentuojama ar sistemingai vertinama. Tai tiesiogiai siejasi su Lawrence ir kt. (2006) bei Zellner (2021) išvalgomis, kad neformalios ekspertinės korekcijos gali sukurti papildomą subjektyvumo ir šališkumo riziką.

Empirinis tyrimas taip pat papildė teorinę literatūrą tuo, kad išryškino organizacinio pasitikėjimo aspektą. Informantai akcentavo, kad vadovai dažniau pasitiki prognozėmis, kurios yra koreguotos žmogaus, nei visiškai automatizuotais sprendimais. Tai leidžia teigti, kad ekspertinių žinių funkcija organizacijose nėra vien informacinė – jos taip pat atlieka pasitikėjimo ir sprendimų legitimizavimo vaidmenį.

Dirbtinio intelekto vertinimas praktikoje

Empirinis tyrimas atskleidė gana ryškų finansų specialistų skepticizmą autonominio dirbtinio intelekto atžvilgiu. Nors teorinėje literatūroje DI dažnai pristatomas kaip pažangus finansinių prognozių sprendimas, tyrimo metu paaiškėjo, kad praktikoje finansų specialistai DI suvokia pirmiausia kaip pagalbinių analizės instrumentą.

Informantai pabrėžė, kad DI gali būti naudingas automatizuojant rutines užduotis, identifikuojant sudėtingus dėsningumus ar pagreitinant duomenų analizę, tačiau galutinė sprendimų kontrolė vis tiek turi išlikti žmogaus rankose. Tokie rezultatai tiesiogiai siejasi su Giudici ir kt. (2024) bei Arsenault ir kt. (2024) tyrimais apie paaiškinamo dirbtinio intelekto svarbą finansų sektoriuje.

Vis dėlto atliktas tyrimas papildė ankstesnius tyrimus tuo, kad atskleidė ne tik techninio paaiškinamumo, bet ir psichologinio pasitikėjimo svarbą. Praktikoje organizacijoms nepakanka vien „tikslis“ prognozės – svarbu suprasti, kodėl sistema pateikė konkretų rezultatą, kokie veiksniai jį lėmė ir kiek galima pasitikėti prognoze skirtingomis rinkos sąlygomis. Tai leidžia teigti, kad finansinių prognozių kontekste paaiškinamumas tampa ne papildoma funkcija, o būtina sąlyga efektyviam DI taikymui.

Tyrimo metu taip pat paaiškėjo, kad organizacijose egzistuoja tam tikra baimė prarasti žmogaus kontrolę priimant finansinius sprendimus. Informantai ne kartą pabrėžė, kad finansinės prognozės turi tiesiogines pasekmes organizacijos veiklai, todėl visiškai automatizuoti sprendimai vertinami atsargiai. Ši išvalga leidžia manyti, kad artimiausiu metu finansų srityje labiausiai plėsis ne autonominiai DI modeliai, o žmogaus ir dirbtinio intelekto bendradarbiavimu paremti sprendimai.

Sukurto modelio sąsajos su ankstesniais tyrimais

Autoriaus suformuotas teorinis modelis ir jo koreguota versija turi aiškias sąsajas su ankstesniais integruotais prognozavimo modeliais, tačiau kartu išsiskiria platesniu požiūriu į prognozavimo procesą. Ankstesniuose tyrimuose dažniausiai dėmesys buvo skiriamas arba modelių tikslumo didinimui, arba ekspertinių korekcijų poveikio analizei. Tuo tarpu šiame darbe prognozavimas

nagrinėjamas kaip kompleksinė organizacinė sistema, kurioje svarbus ne tik prognozės tikslumas, bet ir jos interpretavimas, pritaikomumas sprendimų priėmimui bei organizacinis pasitikėjimas.

Tyrimo rezultatai parodė, kad efektyviausias prognozavimo modelis praktikoje turėtų būti adaptyvus. Tai reiškia, kad sistema turi gebėti ne tik generuoti prognozes remiantis dideliais duomenų kiekiais, bet ir prisitaikyti prie nestandartinių situacijų, vertinti dabartinės situacijos reprezentatyvumą bei lanksčiai paskirstyti pasitikėjimą tarp modelio ir eksperto.

Tokiu būdu sukurtas modelis tiesiogiai siejasi su Park ir kt. (2023) adaptacinio ekspertinių žinių integravimo logika bei van der Staak ir kt. (2025) „light-touch forecasting“ principais. Tačiau šiame darbe modelis papildomai išplėstas įtraukiant duomenų kokybės, paaiškinamumo ir žmogaus kontrolės dimensijas. Empirinis tyrimas parodė, kad būtent šie aspektai praktikoje tampa kritiškai svarbūs organizacijoms.

Taigi galima teigti, kad atliktas tyrimas ne tik patvirtino teorinėje literatūroje identifikuotas problemas, bet ir papildė jas praktinėmis įžvalgomis apie realų organizacijų prognozavimo procesą. Tyrimo rezultatai leidžia manyti, kad ateities finansinių prognozių sistemos turėtų būti grindžiamos ne žmogaus pakeitimu dirbtiniu intelektu, o adaptyviu žmogaus ir technologijų bendradarbiavimu.

Tyrimo ribotumai

Nepaisant tyrimo rezultatų aktualumo, atliktas tyrimas turi tam tikrų ribotumų. Pirmiausia, tyrimas buvo atliktas taikant kokybinę metodologiją ir remiantis ribotu informantų skaičiumi, todėl rezultatai negali būti statistiškai apibendrinami visoms organizacijoms ar sektoriams. Tyrimo rezultatai labiau atspindi finansų specialistų patirtis, suvokimą ir praktinį požiūrį į prognozavimo procesą.

Antra, tyrimo rezultatai gali priklausyti nuo informantų profesinės patirties, organizacijos dydžio, veiklos specifikos bei technologinio brandumo. Skirtingose organizacijose DI taikymo lygis ir prognozavimo procesų formalizavimas gali reikšmingai skirtis.

Trečia, tyrime nebuvo atliekamas kiekybinis siūlomo modelio testavimas realiais finansiniais duomenimis. Dėl šios priežasties nebuvo galimybės empiriškai įvertinti, kiek integruotas modelis praktiškai pagerintų prognozių tikslumą lyginant su tradiciniais ekonometriniais ar autonominiais DI modeliais.

Ketvirta, tyrime daugiausia buvo analizuojamas organizacinis ir vadybinis prognozavimo aspektas, todėl mažiau dėmesio skirta konkrečių technologinių sprendimų ar algoritmų techniniam efektyvumui.

Rekomendacijos tolimesniems tyrimams

Atsižvelgiant į nustatytus ribotumus, tolimesniuose tyrimuose būtų tikslinga atlikti kiekybinį integruoto modelio testavimą naudojant realius organizacijų finansinius duomenis. Tokie tyrimai leistų objektyviai įvertinti, kaip siūlomas modelis veikia praktikoje bei ar adaptyvus ekspertinių žinių integravimas iš tiesų pagerina prognozių tikslumą.

Taip pat aktualu atlikti platesnės apimties tyrimus skirtinguose sektoriuose, siekiant nustatyti, kaip sektoriaus specifika veikia ekspertinių žinių poreikį bei DI taikymo galimybes. Tyrimo metu išryškėjo, kad skirtingos organizacijos prognozavimo procesus organizuoja nevienodai, todėl ateities tyrimuose būtų naudinga palyginti skirtingų sektorių prognozavimo logiką.

Tolimesniuose tyrimuose taip pat būtų naudinga giliau analizuoti paaškinamo dirbtinio intelekto sprendimus finansinių prognozių srityje. Atsižvelgiant į tai, kad organizacijoms svarbus ne tik prognozės tikslumas, bet ir jos paaškinamumas, aktualu ieškoti metodų, kurie leistų užtikrinti didesnę skaidrumą bei pasitikėjimą DI sistemomis.

Be to, ateities tyrimuose būtų tikslinga giliau nagrinėti ekspertinių žinių formalizavimo galimybes. Praktikoje ekspertinės korekcijos dažnai išlieka neformalios ir sunkiai dokumentuojamos, todėl aktualu ieškoti metodų, kurie leistų sistemingai integruoti ekspertines žinias į prognozavimo sistemas.

Galiausiai, perspektyvia tyrimų kryptimi galėtų tapti adaptyvių prognozavimo sistemų kūrimas, kurios automatiškai vertintų dabartinės situacijos reprezentatyvumą ir dinamiškai paskirstytų pasitikėjimą tarp dirbtinio intelekto modelio bei eksperto sprendimo. Tokie sprendimai leistų sukurti lankstesnes, patikimesnes ir realioms organizacijų sąlygoms geriau pritaikytas finansinių prognozių sistemas.

Diskusijos rezultatai parodė, kad finansinių prognozių sudarymas organizacijose išlieka hibridinis procesas, kuriame statistiniai modeliai ir dirbtinio intelekto sprendimai derinami su ekspertinėmis įžvalgomis bei žmogaus sprendimais. Atliktas tyrimas patvirtino teorinėje dalyje identifikuotas problemas bei atskleidė, kad efektyviausias prognozavimo modelis praktikoje turėtų būti adaptyvus, paaškinamas ir grindžiamas žmogaus bei dirbtinio intelekto bendradarbiavimu.

Išvados

1. Atlikus mokslinės literatūros analizę nustatyta, kad tradiciniai finansinių prognozių metodai susiduria su reikšmingais ribotumais dėl finansinių duomenų nestacionarumo, režimų kaitos, nelineariųjų ryšių ir riboto gebėjimo integruoti kontekstinę informaciją. Taip pat nustatyta, kad nors didieji duomenys ir dirbtinio intelekto metodai suteikia galimybę efektyviau analizuoti sudėtingus duomenų srautus, praktikoje išlieka duomenų kokybės, prognozių paaiškinamumo bei ekspertinių žinių sistemingo integravimo problemos. Literatūros analizė parodė, kad organizacijose vis dar egzistuoja atotrūkis tarp statistinių modelių generuojamų prognozių ir ekspertinių sprendimų priėmimo logikos.
2. Teorinėje darbo dalyje pagrįstas integruotas didžiųjų duomenų ir ekspertinių įžvalgų integravimo į dirbtinio intelekto finansinių prognozių sprendimus modelis, jungiantis Zhuang ir kt. (2017) AI 2.0 koncepcinį pagrindą bei Park ir kt. (2023) adaptyvų ekspertinių žinių integravimo mechanizmą. Modelis grindžiamas logika, kad dirbtinis intelektas generuoja bazinę prognozę, o ekspertinių žinių svoris priklauso nuo situacijos reprezentatyvumo istoriniuose duomenyse. Teorinė analizė parodė, kad efektyviausias prognozavimo sprendimas finansų srityje turėtų būti grindžiamas hibrinine žmogaus ir dirbtinio intelekto sąveika, užtikrinančia tiek duomenų analizės gilumą, tiek kontekstinį sprendimų pagrįstumą.
3. Tyrimo metodologijoje pagrįsta kokybinio empirinio tyrimo logika leido suformuoti metodinį pagrindą finansų specialistų požiūrio į dirbtinio intelekto, didžiųjų duomenų ir ekspertinių žinių integravimą analizei. Pasirinktas pusiau struktūruoto ekspertinio interviu metodas sudarė galimybę identifikuoti realias organizacijų prognozavimo praktikas, ekspertinių korekcijų taikymo logiką bei pagrindinius dirbtinio intelekto taikymo ribotumus. Teminės analizės metodas leido sistemaiškai susieti empirinius rezultatus su teorinėje darbo dalyje išskirtomis problematikomis ir integruotų prognozavimo modelių koncepcijomis.
4. Empirinis tyrimas parodė, kad finansinių prognozių sudarymas organizacijose išlieka hibridinis procesas, kuriame statistiniai modeliai ir dirbtinio intelekto sprendimai derinami su ekspertinėmis įžvalgomis bei vadovų sprendimais. Tyrimo rezultatai patvirtino, kad dirbtinis intelektas praktikoje dažniausiai suvokiamas kaip pagalbinių analizės priemonė, o ne autonominis sprendimų priėmėjas, nes finansų specialistams svarbus prognozių paaiškinamumas, konteksto interpretavimas ir žmogaus kontrolė. Empirinio tyrimo pagrindu koreguotas teorinis modelis atskleidė, kad efektyviausias finansinių prognozių sprendimas turėtų būti adaptyvus, integruojantis didžiuosius duomenis, dirbtinio intelekto metodus ir struktūruotai valdomas ekspertines žinias į vieną prognozavimo sistemą.

Literatūros sąrašas

1. Arsenault, P.-D., Wang, S., & Patenande, J.-M. (2024). A survey of explainable artificial intelligence (XAI) in financial time series forecasting. arXiv. <https://doi.org/10.48550/arXiv.2407.15909>
2. Aziz, A. A., Yusoff, M., Wan Yaacob, W. F., & Mustaffa, Z. (2024). Repeated time-series cross-validation: A new method to improved COVID-19 forecast accuracy in Malaysia. *MethodsX*, 13, 103013. <https://doi.org/10.1016/j.mex.2024.103013>
3. Badulescu, Y., Cañas, F., & Cheikhrouhou, N. (2024). Judgmental adjustment of demand forecasting models using social media data and sentiment analysis within industry 5.0 ecosystems. *International Journal of Information Management Data Insights*, 4(2), 100272. <https://doi.org/10.1016/j.ijime.2024.100272>
4. Baecke, P., De Baets, S., & Vanderheyden, K. (2017). Investigating the added value of integrating human judgement into statistical demand forecasting systems. *International Journal of Production Economics*, 191, 85-96.
5. Bousbaa, Z., Sanchez-Medina, J., & Bencharef, O. (2023). Financial time series forecasting: A data stream mining-based system. *Electronics*, 12(9), 2039. <https://doi.org/10.3390/electronics12092039>
6. Cao, S. S., Jiang, W., Lei, L., & Zhou, Q. (2024). Applied AI for finance and accounting: Alternative data and opportunities. *Pacific-Basin Finance Journal*, 84, 102307. <https://doi.org/10.1016/j.pacfin.2024.102307>
7. Cheng, Y., Yi, J., Yang, X., Lai, K. K., & Seco, L. (2022). A CEEMD-ARIMA-SVM model with structural breaks to forecast the crude oil prices linked with extreme events. *Soft Computing*, 26, 8537–8551. <https://doi.org/10.1007/s00500-022-07276-5>
8. Chung, V., Espinoza, J., & Quispe, R. (2025). Forecasting financial volatility under structural breaks: A comparative study of GARCH models and deep learning techniques. *Journal of Risk and Financial Management*, 18(9), 494. <https://doi.org/10.3390/jrfm18090494>
9. Creswell, J. W., & Creswell, J. D. (2018). *Research design: Qualitative, quantitative, and mixed methods approaches* (5th ed.). Sage.
10. Dessaint, O., Foucault, T., & Fresard, L. (2024). Does alternative data improve financial forecasting? The horizon effect. *The Journal of Finance*, 79(3), 2237–2287. <https://doi.org/10.1111/jofi.13323>
11. Doszyń, M. (2021). Expert systems in intermittent demand forecasting. *Procedia Computer Science*, 192, 3598-3606
12. Farooq, A., Uddin, M. I., Adnan, M., Alarood, A. A., Alsolami, E., & Habibullah, S. (2024). Interpretable multi-horizon time series forecasting of cryptocurrencies by leverage temporal fusion transformer. *Heliyon*, 10(22), e40142. <https://doi.org/10.1016/j.heliyon.2024.e40142>
13. Fildes, R., Ma, S., & Kolassa, S. (2019). Retail forecasting: Research and practice. *Forecasting International Journal of Forecasting*, 35(1), 1–9. <https://doi.org/10.1016/j.ijforecast.2019.01.001>
14. Franses, P. H. (2024). Incorporating judgment in forecasting models in times of crisis. *Futures and Foresight Science*, 6(4), e193. <https://doi.org/10.1002/ffo2.193>
15. Fu, R. (2024). The impact of stock market liberalization on management forecast precision—Evidence from Mainland-Hong Kong Stock Connect Programs in China. *Journal of Accounting and Public Policy*. <https://www.sciencedirect.com/science/article/abs/pii/S0278425424000668>

16. Giantsidi, S., & Tarantola, C. (2025). Deep learning for financial forecasting: A review of recent trends. *International Review of Economics & Finance*, 104, 104719. <https://doi.org/10.1016/j.iref.2025.104719>
17. Giudici, P., Piergallini, A., Recchioni, M. C., & Raffinetti, E. (2024). Explainable Artificial Intelligence methods for financial time series. *Physica A: Statistical Mechanics and its Applications*, 655, 130176. <https://doi.org/10.1016/j.physa.2024.130176>
18. Goodwin, P. (2021). Researching judgmental forecasting. *International Journal of Forecasting*, 37(2), 658–671. <https://doi.org/10.1016/j.ijforecast.2020.01.004>
19. Guest, G., Bunce, A., & Johnson, L. (2006). How many interviews are enough? *Field Methods*, 18(1), 59–82.
20. Hashem, I. A. T., Yaqoob, I., Anuar, N. B., Mokhtar, S., Gani, A., & Khan, S. U. (2015). The rise of “Big Data” on cloud computing: Review and open research issues. *Information Systems*, 47, 98–115. <https://doi.org/10.1016/j.is.2014.07.006>
21. Ishwarappa, ir Anuradha, J. (2015). A brief introduction on big data 5Vs characteristics and Hadoop technology. *Procedia Computer Science*, 48, 319–324. <https://doi.org/10.1016/j.procs.2015.04.188>
22. Kılıç, R. (2025). Linear and nonlinear econometric models against machine learning models: Realized volatility prediction (Finance and Economics Discussion Series 2025-061). Board of Governors of the Federal Reserve System. <https://doi.org/10.17016/FEDS.2025.061>
23. Kontopoulou, V. I., Panagopoulos, A. D., Kakkos, I., & Matsopoulos, G. K. (2023). A review of ARIMA vs. machine learning approaches for time series forecasting in data driven networks. *Future Internet*, 15(8), 255. <https://doi.org/10.3390/fi15080255>
24. Koupriouchina, L., van der Rest, J.-P., & Schwartz, Z. (2022). Judgmental adjustments of algorithmic hotel occupancy forecasts: Does user override frequency impact accuracy at different time horizons? *Tourism Economics*, 29(8), 2143–2164. <https://doi.org/10.1177/13548166221126572>
25. Kvale, S., & Brinkmann, S. (2009). *InterViews: Learning the craft of qualitative research interviewing* (2nd ed.). Sage
26. Lawrence, M., Goodwin, P., O’Connor, M., & Önkal, D. (2006). Judgmental forecasting: A review of progress over the last 25 years. *International Journal of Forecasting*, 22(3), 493–518. <https://doi.org/10.1016/j.ijforecast.2006.03.007>
27. Lincoln, Y. S., & Guba, E. G. (1985). *Naturalistic inquiry*. Sage.
28. Lipelis, M. (2025). Bridging financial forecasting and budget management: New approaches for modern enterprises. *Scientific Journal of Bielsko-Biala School of Finance and Law*, 29(1). <https://doi.org/10.19192/wsfip.sj1.2025.5>
29. Makridakis, S., Spiliotis, E., & Assimakopoulos, V. (2020). The M4 Competition: 100,000 time series and 61 forecasting methods. *International Journal of Forecasting*, 36(1), 54–74. <https://doi.org/10.1016/j.ijforecast.2019.04.014>
30. Martin, G. M., Frazier, D. T., Maneesoonthorn, W., Loaiza-Maya, R., Huber, F., Koop, G., Maheu, J., Nibbering, D., & Panagiotelis, A. (2024). Bayesian forecasting in economics and finance: A modern review. *International Journal of Forecasting*, 40(2), 811–839. <https://doi.org/10.1016/j.ijforecast.2023.05.002>
31. Mohammed, S., Budach, L., Feuerpfeil, M., Ihde, N., Nathansen, A., Noack, N., Patzlaff, H., Naumann, F., & Harmouch, H. (2025). The effects of data quality on machine learning

- performance on tabular data. *Information Systems*, 132, 102549. <https://doi.org/10.1016/j.is.2025.102549>
32. Nair, D., & Huchzermeier, A. (2024). Predictably unpredictable? How judgmental and machine learning forecasts complement each other. *Production and Operations Management*, 33(5), 1214–1234. <https://doi.org/10.1177/10591478241245138>
 33. Nayak, G. H. H., Alam, M. W., Avinash, G., Kumar, R. R., Ray, M., Barman, S., Singh, K. N., Naik, B. S., Alam, N. M., Pal, P., Rathod, S., & Bisen, J. (2024). Transformer-based deep learning architecture for time series forecasting. *Software Impacts*, 22, 100716. <https://doi.org/10.1016/j.simpa.2024.100716>
 34. Nishad, A. K., Aggarwal, G., & Abhishekh. (2023). Hesitant fuzzy time series forecasting model of higher order based on one and two-factor aggregate logical relationship. *Engineering Applications of Artificial Intelligence*, 106897. <https://doi.org/10.1016/j.engappai.2023.106897>
 35. Önkâl-Atay, D. (1998). Financial forecasting with judgment. In G. Wright & P. Goodwin (Eds.), *Forecasting with judgment* (pp. 139–168). John Wiley & Sons. <https://onlinelibrary.wiley.com/doi/book/10.1002/9780470759040>
 36. Olaniyan, J., Olaniyan, D., Obagbuwa, I. C., Esiefarienrhe, B. M., Adebisi, A. A., & Bernard, O. P. (2024). Intelligent financial forecasting with Granger causality and correlation analysis using Bayesian optimization and long short-term memory. *Electronics*, 13(4408). <https://doi.org/10.3390/electronics13224408>
 37. Park, H., Megahed, A., Yin, P., Ong, Y., Mahajan, P., & Guo, P. (2023). Incorporating experts' judgment into machine learning models. *Expert Systems with Applications*, 228, 120118. <https://doi.org/10.1016/j.eswa.2023.120118>
 38. Rubio, L., Palacio Pinedo, A., Mejía Castaño, A., & Ramos, F. (2023). Forecasting volatility by using wavelet transform, ARIMA and GARCH models. *Eurasian Economic Review*, 13, 803–830. <https://doi.org/10.1007/s40822-023-00243-x>
 39. Saunders, M., Lewis, P., & Thornhill, A. (2019). *Research methods for business students* (8th ed.). Pearson.
 40. Simon, M., & Shrader, R. C. (2022). Financial forecasting, risk-taking and venture performance. *European Journal of Business and Management Research*, 7(6), 1–6. <https://doi.org/10.24018/ejbmr.2022.7.6.1693>
 41. Song, Z., & Wu, S. (2023). Post financial forecasting game theory and decision making. *Finance Research Letters*, 58, 104288. <https://doi.org/10.1016/j.frl.2023.104288>
 42. Tang, Y., Song, Z., Zhu, Y., Yuan, H., Hou, M., Ji, J., Tang, C., & Li, J. (2022). A survey on machine learning models for financial time series forecasting. *Neurocomputing*, 512, 363–380. <https://doi.org/10.1016/j.neucom.2022.09.003>
 43. Tunç, D. U. (2022). We should redefine scientific expertise: An extended virtue account. *European Journal for Philosophy of Science*, 12, 71. <https://doi.org/10.1007/s13194-022-00498-2>
 44. van der Staak, B. B. J. P. J., Basten, R. J. I., van de Calseyde, P. P. F. M., Demerouti, E., & Kok, A. G. (2025). Light-touch forecasting: A novel method to combine human judgment with statistical algorithms. *International Journal of Forecasting*, 41(2), 440–451. <https://doi.org/10.1016/j.ijforecast.2024.04.003>

45. Wang, X., Hyndman, R. J., Li, F., & Kang, Y. (2023). Forecast combinations: An over 50-year review. *International Journal of Forecasting*, 39(4), 1518–1547. <https://doi.org/10.1016/j.ijforecast.2022.11.005>
46. Zellner, M., Abbas, A. E., Budescu, D. V., & Galstyan, A. (2021). A survey of human judgement and quantitative forecasting methods. *Royal Society open science*, 8(2), 201187.
47. Zopounidis, C., & Lemonakis, C. (2024). The company of the future: Integrating sustainability, growth, and profitability in contemporary business models. *Development and Sustainability in Economics and Finance*, 1, 100003. <https://doi.org/10.1016/j.dsef.2024.100003>
48. Zhuang, Y. T., Wu, F., Chen, C., & Pan, Y. H. (2017). Challenges and opportunities: from big data to knowledge in AI 2.0. *Frontiers of Information Technology & Electronic Engineering*, 18(1), 3-14. <https://ieeexplore.ieee.org/stamp/stamp.jsp?arnumber=11289634>
49. Feng, J., Lansford, J. L., Katsoulakis, M. A., & Vlachos, D. G. (2020). Explainable and trustworthy artificial intelligence for correctable modeling in chemical sciences. *Science advances*, 6(42), eabc3204.
50. Venkatachala Appa Swamy, M., Periyasamy, J., Thangavel, M., Khan, S. B., Almusharraf, A., Santhanam, P., ... & Elsis, M. (2023). Design and development of IoT and deep ensemble learning based model for disease monitoring and prediction. *Diagnostics*, 13(11), 1942.

Priedai

1 priedas. Interviu transkriptas Nr. 1

Informantas: Asmuo nr. 1

Interviu trukmė: 42 min.

Labas, šiuo metu rašau baigiamojo darbo tyrimą ir siekiu išsiaiškinti, kaip realiame gyvenime yra integruojamos ekspertinės įžvalgos ir istoriniai duomenys, sudarant finansines prognozes. Pradžioje paprašysiu papasakoti apie save, kokiam sektoriuje dirbi, kokios tavo atsakomybės ir panašiai.

Dirbu finansų analizės skyriaus vadovės pareigose, grupėje, kuri turi ganėtinai skirtingą spektrą veiklų, nuo paslaugų teikimo iki prekybos ir gamybinių įmonių. Iš esmės nuo pat pradžių mano kelias prasidėjo nuo finansų analitiko, tai įmonių esu mačiusi nemažai. Patirties ir valdymo būdų irgi mačius gan daug ir įvairių, tai visi taiko labai skirtingai, priklausomai.

Kokio tipo prognozės dažniausiai yra sudarinėjamos? Ar tai gali būti pajamų prognozės, biudžetas kaip prognozė, rinkos ir panašiai.

Tai mes iš esmės įvairias prognozes, tik jų lygiai yra skirtingi. Tada gaunasi, kad pirmas lygis prognozės, tai yra aplamai prognozė į priekį pinigų srautų. Antras lygis prognozės yra atliekamas biudžeto tikslinimas. Tai reiškias prognozėje pusmetis į priekį startuojant iki metų galo, kaip sekasi biudžetas ir tada stambusis tai kai skaičiuojame į priekį. Tai biudžetas atliekamas metams ir dar yra dar platesnio spektro. Tai yra, kai mes atliekam įmonei, kai matom, kad prieinam, sakykim tašką, nuo kurio neišlendam iš situacijos, reiškias reikia papildomo sprendimo, nes pasiekiam butelio kakliuką. Tada yra atliekama penkių metų prognozė ir sprendžiama aą daryti toliau. Nes iš esmės tikslas yra toks, kad verslas nuolat plėstųsi, jeigu jisai nesiplečia, tai mes matom arba ir nematom kodėl. Tai tada ir darom ta penkių metų prognozę. Tada mes matom būdus, kaip tą verslą plėsti. Vienas iš variantų gali būti verslo pardavimas, jeigu jisai neneša pelno. Jeigu, sakykim, jisai negali toliau plėtotis, tai jisai iš esmės didelės vertės iš savęs neturi, o kas dar? Mano specifika gal yra dar tokia, kad man tenka atlikti ir rinkos analizes. Tai daug maž stebėti, kadangi yra žemės ūkis ir skirtingos ir kainos, tai biržos, tai rinkos, tai reikia jas stebėti ir žiūrėti kaip keičiasi, maždaug prognozuoti metai į priekį, okios gali būti kainos. Šiais metais priėmėm sprendimą žiūrėti du metus į priekį, nes sakykim pinigų srautai leidžia fiksuotis dviem metams į priekį kainas. Tai tikriausiai tokie lygiai.

O kas dalyvauja pačiame procese prognozės? Na, tai yra vis tiek ne vien tik analitikas, tai yra tam tikri departamentų vadovai, kaip maždaug atrodo pats procesas, sakykim, nuo ko prasideda ir kuo baigiasi.

Tai čia iš esmės irgi tada priklauso nuo ko. Jeigu mes imsime apie tą penkių metų ilgalaikę prognozę kalbėti, tai čia pasijungia praktiškai visi skyriai. Ir pirkimai ir pardavimai ir logistika, ir logistika, nes dažniausiai yra vertinami keli variantai. Aišku, labiausiai dirba tai finansų analitikų ofisas ir visas sakykim finansų departamentas, plius to analizuojamo verslo vadovybę. Dažniau aukštesnio lygio vadovybė tiktais tam tikriems klausimams atsakyti pajungiami, tam tikrų skyrių atstovai.

Jeigu kalbame apie pinigų srautų prognozę, tai dalyvauja dažniausiai vienas du žmonės max. Tai yra irgi finansų departamento atsakomybė pagrinde, kam tas funkcija yra priskirta.

Tada, jeigu mes kalbam apie biudžetavimą, tai dažniausiai vėlgi yra pajungiamoji visa įmonė, nes kiekvieną grandinę liečia biudžetas, kiekvieną departamentą.

Kas dar, rinkos analizė irgi yra dažniausiai priskiriama tam tikram vienam asmeniui. Jisai tikrai teikia informaciją aukštesnio lygio vadovams, kuriems ji reikalinga.

Bet taip sakykim mechanizmas vienaip ar kitaip jis yra pajudinamas visos, nes vienas visko nežinosi ir tada gaunasi, kad pajungiamos įvairios patirtys.

Kokie įrankiai yra naudojami darbe, kaip suvaldomas informacijos srautas?

Kur viskas atliekama, tai aišku pačiame Excelyje, nes jis yra lanksčiausias ir mes kol kas iš esmės tą įrankį turim. Iš kur traukiam duomenis, aišku, traukiam iš savo istorinių duomenų, tai tie patys Exceliai arba mūsų naudojama ERP sistema tai Navision'as. Tada toliau aišku yra pajungiamos patirtys, kas ką žino šitoj srity.

Ir plus be ko neapsieinama. Tai darbų planeris. Pirmiausia yra nustatomas taškas atskaitos. Nesvarbu, ar tai pinigų srautai, ar tai yra prognozė, ar tai yra biudžetas, ar tai ir penkių metų prognozė, nustatomas pradinis taškas A ir tada yra išsiaiškinama, koks yra galutinis taškas, ką mes turim pasiekti, jeigu neturim planerio, tai neturim taško a, b, c, d, e, f, g ir tada yra nukrypstama iš esmės į kairę į dešinę, tai šiuo atveju iš esmės yra vienas pagrindinių įrankių, kuris nuolat yra stebimas, tai planeris, ar mes judame iš taško A į tašką B galutinį. Ir yra visiems tiems darbams galutinė data, kas irgi yra vienas iš pagrindinių įrankių. Neturėsi datos pabaigimo, neturėsi ir pabaigto darbo.

Sakykit ar naudojate dirbtinį intelektą savo darbe?

Naudojam kuo toliau, tuo labiau. Dabar galvoju. Naudojam pasitarimams sakykim, ar pats nenukrypti nuo to, ką žinai. Bet šiaip daugumoje atvejų tai būna naudojama labiau tokiom rinkos analizėm ar ten, kur reikia greitai susisteminti informaciją naujienų. Pavyzdžiui, jeigu rašymas naujienų ar rinkos analizė tai čia numeris vienas įrankis yra.

Jeigu tai yra biudžetas, nenaudojant praktiškai išvis. Bet, kuo toliau tuo labiau einama vis tiek tai į ateitį ir einama link to, kad netgi buhalterija turėtų dirbti su DI pagalba teikiant ir pildant visą dokumentaciją. Tai, pavyzdžiui, tas pats DI yra naudojamas Fitekinas, tai yra skaitmenizuotas dokumentų suvedimo procesas arba, pavyzdžiui, bet tai yra, sakau, tai yra pagalbinės priemonės, tai tikrai nėra tas, su kuo mes įvykdome savo kažkokius tai vat tuos planus. Tai yra pagalbinės priemonės atlaisvinti rankas tam savo planui pasiekti.

Kas pas mus dabar DI tvarko archyvą, mes prie to patys mechaniškai nesiliečiam, visus mūsų failus archyvuoja ir tvarko DI pilnai. Nu tai taikymas DI yra kažkoks, bet tai yra dar tokiam lygyje, kad kol kas mes neturime tokio pasitikėjimo, kad jis už mus teisingai padarys, nes jo kaina klaidos yra per didelė.

Ar buvo galvota galimybė, sakykim, čia, dirbtinį intelektą integruoti į prognozių procesą, jį naudoti kaip įrankį, ne tik kaip pagalbininką? Ar tai yra realu, sakykim, šiandieniniam verslui, ar dar laikoma ta technologija nepakankamai patikima, kad būtų ją galima integruoti į patį jau procesą?

Tai yra labai realu iš esmės, nes jis ir tobulėja gan stipriai ir greitai, bet čia reikia atskirti, ką, pavyzdžiui, norime prognozuoti. Nes jam ir dabar galima duoti užduotį ir sakyti, nu va, čia yra istoriniai duomenys, man reikia kitų metų biudžeto. Tai ką jisai gali, jis tiesiog statistiškai

duomenimis gali paprognozuoti į priekį, bet jis nežino niuansų kiekvieno verslo, jis negali visko apgalvoti pat.

Bet jeigu mes, pavyzdžiui, kalbėsime apie gamybos planavimą, užpildyti jis gali teisingai pagal taisykles. Sakykim, yra pardavimų planai ir taip toliau, kokie yra užimtumai linijų ir panašiai. Prie to mes jau einam, diegiam Agzpto sistemą, kuri iš esmės bus kaip pagalbininkas, kuris planuos gamybą, tai čia bus didelė pagalba analitikams. Pavyzdžiui, pirkimų planavimas tai nuo gamybos priklausomai, visi užsakymai, logistika. Tai eina jau prie to, kad pati sistema formuos gamybos užsakymams pirkimus. Tikslas yra aplanuoti, kad jisai pamažintų kaštus darbuotojų, tai kol kas mes dar nematom, kad, sakykim, trumpuoju metu, dviejų laikotarpių, kad jis pamažins darbuotojų kaštus, galbūt netgi darbuotojų laikinai reikės dar daugiau, tam, kad testuoti ir išvengtų sistemos klaidų.

Tai nes viena yra kaip tu pats darai padarai ir žinai viską, kita yra, kai turi pats padaryti ir dar žiūrėti ir testuoti, tikrintis ar viskas veikia. Bet ateities ilgalaikė perspektyva trijų penkių metų yra tai, kad buhalteriai, tai apskaitos skyrius turėtų per pusę sumažėti, pirkimų skyrius turėtų trauktis, gamybos planavimas ir taip toliau, turėtų būti atliekama DI, nes mes ir Excelius kūrėme taip, kad planavimas daug maž būtų automatizuotas, tai čia jisai (Agzptas) turės visus įrankius. Mes ir dabar iš esmės jau tam tikruose lygiuose dirbam su informacija, kuri maksimaliai pateikta vienoje sistemoje, automatizuota ir suskaidyta smulkiai, tai iš esmės viską turim taip, kad gali analitikas suprognozuoti. Bet vis tiek, DI nežino tiksliai kas dega gamyboje šiuo metu, kas įvyksta ir taip toliau, tai dėl pačio integravimo DI, vis tiek už to stovės žmogus, bet galbūt ne penki, o du, kurie turės tą sistemą prižiūrėti pastoviai, bet taip gal tai yra ateitis.

Kiek svarbios yra ekspertinės įžvalgos prognozavimo procese? Kaip šios įžvalgos yra integruojamos į prognozes ir kokia yra reali jų įtaka procesui ir prognozės tikslumui?

Pavyzdžiui, jeigu imant kaip pavyzdį biudžetą. Tikslumas stipriai nenukentėtų, atrodo, bet čia mes galim kaip pavyzdį paimti, naujas darbuotojas atlieka biudžeto prognozę ir senas darbuotojas atlieka biudžetavimą, kur tikimybė, kad biudžetas bus efektyvesnis ir kokybiškesnis, tai pas seną darbuotoją, nes pas jį mintyse yra penkių metų klaidos. Kur užlipom ant kokios grėsmės, tai iš esmės pas jį jau yra visi taškai ir aspektai galvoje, kur mes prasileidžiam, kur mes nepagalvojom ir kur mes, sakykim, neįsivertinom kažko papildomai, tai naujas žmogus, kuris visiškai pilnai atsistoja į analitiko poziciją ir visiškai nežino istorijos, kas ten vyksta, nesupranta proceso ir remiasi tik istoriniais duomenimis, tai nėra tikslu, nes istoriniuose duomenyse nėra visko, nėra praeities klaidų. Tai, sakykim, darbas būtų atliktas bet kokybė vien su istorinėm įžvalgom, jinai visada bus visiškai kitokia ir tikrai ne tokia kokybiška, kaip su papildoma žinoma informacija. Tai ir klaidų tikimybė yra visiškai kitokia, apie viską pagalvot, ar ne apie viską pagalvot.

Tai čia toks, o jeigu kalbant apie ilgalaikę prognozę, penki metai į priekį, tai čia jau yra visiškai kito lygio, nes čia pasijungia visai kitos patirtys, nes tai, kas buvo atgal, mes žinom, bet tai, kas bus ateity mums reikia patirčių realių. Mums reikia pavyzdžių, nes mes galim ten planuoti, kad mes papildomai pastatysim gamybinę liniją ir parduosim tiek ir tiek, bet tai nėra visiškai tikslu. Reikia čia jau tų žmonių, kurie pažįsta tą rinką, kurie gali pasakyti kaip kas bus. Nes gal nors statykit jus ir šešias linijas, vis tiek neturėsite kur parduoti arba kur tada reikia plėstis arba kokios klaidos buvo padarytos, kodėl ta įmonei nesiseka. Tos pačios skirtingos technologijos buvo taikomos, kad šita gal tikrai nebeveiks arba gal reikia iš naujo apgalvoti investicijas, pasiskaičiuoti, bet žmogus niekada su tuo nėra dirbęs ir nežino, kad va šitoj vietoj mes priėjom butelio kakliuką, kad gal jam reikės dar šimto

tūkstančių investicijų papildomų. Tai čia įsijungia visai kito lygio įžvalgos - tai yra jau patirtys tų darbuotojų, kurie ilgą laiką dirba tam tikrame sektoriuje arba kad ir toje įmonėje. Svarbu turėti ir žmonių, kurie turi skirtingų patirčių, skirtingų rizikos toleravimo lygių, kad maštant į priekį jie būtų skirtingų lygių saugikliai apsaugos. Tai, pavyzdžiui, vienas, kuris išvis bijo rizikos, stabdys ant kiekvieno taško, kitas, kuris mėgsta rizikuoti, labai aštriai mato, ką mes galim, ko negalim, bet jis jau jaučia ir žino kada reikia stabdyti, o kada dar galima veikti. Tai čia yra diskusijos, diskusijos, diskusijos. Ir čia jau visas toksai menas verslo iš esmės, kiek verslų užsilenkia, o kiek verslų toliau gyvuoja, tai čia tikrai vat ir pasiseka, jeigu tu turi patirtį, kuri jau yra susiformavusi per laiką, ten nukentėjo tas, ten tau pasisekė rizikos išvengti.

Dabar norėčiau tau parodyti prognozavimo modelį ir tavo nuomonės, ar tai yra pritaikoma realiaame šiandieniniame versle. Modelio veikimo principas, tai pirmiausia dirbtinis intelektas, naudodamas didelius istorinių ir kitų duomenų kiekius, pateikia pirminę prognozę, grįstą tik istoriniais duomenimis. Į modelį integruojamos ir papildomos ekspertinės įžvalgos, kurių pasitikėjimo lygį prognozėje sprendžia situacijos panašumo vertinimo rodiklis, kuris lygina esamą organizacijos situaciją su prognozuojama. Jei prognozė panaši į esamą situaciją, didesnis pasitikėjimas skiriamas pirminei modelio prognozei, jei ne – eksperto įžvalgų korekcijoms. Galiausiai modelis pateikia galutinę integruotą prognozę, bei prognozės paaiškinimą (dėl ko, kaip ir kas kito).

Manau, kad toks modelis yra realiai pritaikomas šiandieniniame versle ir iš esmės tai yra kryptis, link kurios vis tiek einama. Pats principas logiškas, nes dirbtinis intelektas labai gerai gali apdoroti didelius istorinių duomenų kiekius ir pateikti pirminę prognozę, bet vien istorinių duomenų versle dažnai neužtenka. Yra daug niuansų, kurių sistema nežino – rinkos situacija, vidiniai procesai, klaidos iš praeities, tam tikri „butelio kakliukai“, emocinis rinkos fonas ar tiesiog praktinė darbuotojų patirtis.

Labai svarbu, kad modelis nenumato aklo pasitikėjimo DI. Tas situacijos panašumo vertinimas, kur sprendžiama kada labiau pasitikėti modeliu, o kada ekspertų korekcijomis, man atrodo labai realistiškas. Nes jeigu situacija standartinė ir panaši į ankstesnius laikotarpius, tada DI tikrai gali prognozuoti labai gerai. Bet jeigu atsiranda nestandartinės situacijos, pokyčiai rinkoje ar naujos aplinkybės, tada žmogaus įžvalgos tampa daug svarbesnės.

Manau, kad trumpuoju laikotarpiu toks modelis veiktų daugiau kaip pagalbininkas analitikams, o ne pilnai savarankiškas sprendimų priėmėjas. Už jo vis tiek turėtų stovėti žmonės, kurie tikrina, interpretuoja ir vertina rizikas. Bet ilgalaikėje perspektyvoje tai tikrai atrodo kaip labai reali ateities kryptis finansų prognozavime.

Tai ir pabaigai tokį bendresnį klausimą būtent dėl finansų analitikų. Dirbtinį intelektą vertini kaip grėsmę labiau ar kaip galimybę?

Galimybę. Jinai visada kiek gąsdina, nes bet koku atveju su tuo reikia būti atsargiam.

Ir analitikoje, jo pagalba jau nereikia pačiam naršyti ieškoti informacijos, gali prašyti ir netgi įmesti formulę jei ten skaičiavimam specifiniam reikia. Tai čia jau yra galimybės ir mes jau daugumoje tai naudojame, bet tik kaip pagalbininką, kaip agentą papildomą. Aišku, yra ir tokių ir neįvertintų galimybių, kaip, pavyzdžiui, mums atima laiko kai kurie dalykai paprasti, skaidrių darymas raportavimo, kia galbūt galėtume tą laiką išnaudoti kitur, nes dabar mums pakeitus vieną skaičiuką kažkokį analitikoje, reikia iškart padaryti ir naują pristatymą, o DI čia galėtų tą patį padaryti, tik aišku reikėtų jį išmokyti, tada ištestuoti, patikrinti, bet tai analitikams sutaupytų daug laiko.

Nes pati finansų analitika jinau yra labai plati. Tai jeigu mes bent jau pradžioje pradėsime ją (DI) naudoti paviršutinišku lygiu paprastiems darbams, mes patys turėsime daugiau laiko lysti giliau į kitas analitikas, tai čia labai didelis plusas manau yra. Tai iš esmės yra ne grėsmė, tai yra ateitis, kurios tu neišvengsi. Jeigu mes dabar kažko neįsivaizduojam, kaip jisai dirbs, tai po penkių metų mes neįsivaizduosime, kaip tas galėjo nedirbt, tai bus jau kasdienybė.

Iš esmės ir duomenų kiekiai pas mus yra labai dideli, ir mes kraunam juos dabar dalinai rankom, juos ten susitvarkom, ateityje mes to jau nebedarysim. Techninį darbą jis (DI) atliks už mus. Kiek mes suvalgysim laiko testuodami, tai čia jau kitas dalykas.

Bet yra ir labai įdomu, kaip kita karta analitikų dirbs, kuri nemokės dirbti be DI, tai čia įdomu, kaip jiems seksis. Kokios bus klaidos ir kokios jų bus kainos ir kas tada toliau nueis? Nes, sakykim, mūsų karta moka dirbti dviem būdais, mokėsime ir senuoju, bet privalome ir tuo naujuoju išmolti. Mums bus sunkiau persilaužti antruoju, bet mes persilaušim ir mokėsime ją testuoti, tikrinti ar jis gerai veikia, kaip ir ką jis ten daro. Kai ateis nauja karta, jie jau iškart su DI dirbs, jiems nereikės jo kurti ir testuoti, tai labai įdomu, kaip tuo metu veiks visa sistema. Aišku, jie irgi tobulės, bet niekada neturės, pagal mane, to tokio loginio mąstymo, kurį dabar analitikai turi ir privalo turėti.

Nes dirbtinis intelektas jis nuojautos neturi, emocijų nesupranta, o planavimui tas yra reikalinga, tas rinkos pajautimas, emocijos, numatymas kas gali būti. Tai aš manau, kad jis bus labai didelis pagalbininkas ir atlaisvins daugiau rankas eiti verslams į priekį, greičiau priiminėti sprendimus, nes dabartiniam pasaulyje jei dirbti lėčiau, tai tas pats, kas stovi vietoj.

2 priedas. Interviu transkriptas Nr. 2

Informantas: Asmuo nr. 2

Interviu trukmė: 76 min.

Papasakokite apie savo profesinę patirtį finansų srityje. Kokia yra jūsų dabartinė pozicija ir pagrindinės atsakomybės? Kokiame sektoriuje dirbate?

Okey, tai jo, tai pradėjau aš finansuose dirbti kažkur prieš aštuonis gal metus, pradėjau nuo praktikos telekomunikacijų bendrovėje, po mėnesio įsidarbinau buhalterė. Ir tada dar po mėnesio toj pačioj įmonėj pakilau ir tapau reportingo ataskaitų teikimo specialistu. Tai buvo darbas, susijęs su finansinių ataskaitų rengimu įmonės lygmeniu. Po to tai pradirbau toj įmonėj tris metus ir tada perėjau į kitą įmonę į finansų analitiko poziciją. Tai toj pozicijoj dirbau gal tris metus ir tada dabar peršokau į verslo kontrolieriaus poziciją. Tai dabar dirbu transporto sektoriuje. Tarptautinėje transporto bendrovėje galima sakyti taip.

Toliau, kokio tipo prognozes dažniausiai atliekate?

Jo tai mes turim turbūt keletą tokių prognozių, tai dalis jų yra tokios, kurias darom, sakykim, vieną kartą metuose, o dalis yra tokios, kurias mes darom. kas mėnesį, tikslinam remiantis besikeičiančia situacija, tai, ką prognozuojam, tai pagrinde kur su kuo aš dirbu, tai mes prognozuojam absoliučiai visą finansų dalį, visas finansines ataskaitas. Tai pelno nuostolio ataskaita, balanso, pinigų srautų, realiai viską viską, kas yra susiję su finansiniais įmonės rezultatais ir iš to prognozuojami ir kokie bus mūsų finansiniai rodikliai, kuriuos vėliau mes teikiame sakykim iš išorės kažkokioms organizacijoms,

pavyzdžiui, bankams, kad jie įsivertintų, sakykim, kokie mes esame, ar esame patikimi, ar nekeliamo rizikos ir panašiai. Tai jo, tai realiai taip pat prognozuojamos rizikos ir rinkos tendencijos. Tiesiogiai aš pati nedirbu, bet kompanijoje dirbantys kiti analitikai tai žiūri, tikrai prognozes daro ir rinkos tendencijų. Tai, pavyzdžiui, ten kažkokių kylančių kainų, šiaip paklausos rinkoje tarp klientų pagal tai, kaip keičiasi rinka, pavyzdžiui, ten, kokios kuro kainos ir panašiai. O rizikos turbūt irgi vertinasi ten jau labiau, draudimo rizikų analitikai įvairius tokius dalykus, bet šiaip pagrindas taip pas mane yra su finansiniais duomenimis, kas susiję su įmonės finansinėmis ataskaitomis.

Kaip atrodo prognozavimo procesas jūsų organizacijoje? Kokie pagrindiniai etapai, kas dalyvauja šiame procese?

Nu tai vat sakykim, mes prognozuojam kiekvieną mėnesį, tikslinam savo prognozę, tai vadinam ją Rolling Forecast'u, tai mes prognozuojame, kiek mes uždirbsime pelno iš savo pagrindinės veiklos. Tai mes prognozuojam įvairius rodiklius remiantis sutartais KPI rodikliais. Pavyzdžiui, KPI galėtų būti pajamos per kilometrą, sakykim, arba ten koks nors kažkoks. Tai nėra, kad mes prognozuojame totalinę sumą, kažkokią tai nu vat bus tiek pinigų. Mes labiau prognozuojam, kaip mes pasieksim ir kas kaip įtakos kažkokį tai rodiklį, kurį turint tu gali realiai susidėlioti galutinę pelno (nuostolių) ataskaitą. Tai, pavyzdžiui, ar ne? Koks bus mano įkainis, sakykim, draudimų ir kaštų per dieną, kas gali pasikeisti, koks bus ten mano, kadangi transporto įmonė, koks bus ten koks nors remonto sąnaudos per dieną, tai mes tokius įsivertinam rodiklius ir po to iš tų rodiklių, ki žinom, kiek ten tų dienų, ir tada tiesiog susidauginam ir gaunam žodžiu rezultata. Tai kaip tas visas procesas vyksta, tai mes turim faktinius duomenis apie tai, kaip atrodė, sakykim, jau praėjusių metų, vat pavyzdžiui, dabar pirmas ketvirtis, tai mes žinom, kaip atrodė pirmas ketvirtis. Tada yra, sakykim, įmonėj ten, kaip pavyzdys penki departamentai, tai kiekvienam departamente yra žmogus, kuris dirba iš esmės su finansais, ir tuomet eina kalbėtis su verslu, būtent to departamento atstovais, apie tai, tai kokios yra jų įžvalgos? Ar planuojam kažką tai daryti kitaip, negu darom dabar, ką matom iš rinkos, ką matom iš klientų? Ar yra kažkokių galimybių užmegzti, kažkokius naujus santykius, pritraukti kažkokį naują klientą, pakelti kainą. Gal kažkas mums labai išbrangsta, nes atsirado kažkoks naujas dalykas, mokestis koks nors papildomas, kad kažkokie gali būti, nežinau, atsiranda nauji reguliaciniai ar mokestiniai pokyčiai, ar ne, kuris įtakoja mums tą veiklą ir kiekviena finansų komanda dirba su tuo kiekvienu departamentu, aiškinantis, kas gali būti kitaip. Kas kaip čia pasikeis, ir tada jie susirenka informaciją, susiskaičiuoja tuos finansinius rodiklius ir taip gimsta toksai dvylikos mėnesių į priekį planas, kaip mes matom, kaip atrodys mūsų uždarbis. Tai va tada susidarę tas prognozes mes jas aptarinėjam, pristatom mūsų aukščiausiam finansų vadovui, kuris, užduoda kažkokius klausimus, ir galiausiai jis patvirtina tą prognozę, tai mes sakom na va, čia yra mūsų dabar einamojo periodo prognozė ir kiekvieną mėnesį mes vėl sukam tą patį ratą ir žiūrim, tai kiek ta mūsų prognozė buvo tiksli, nes nu, pavyzdžiui, dabar yra balandžio mėnuo. Tai balandžio mėnesio prognozę mes darėm praeitą mėnesį, tai dabar vat mes turėsime jau faktinius rezultatus už balandį ir mes žiūrėsime, tai kiek mes į tą prognozę pataikėm ir vėl tada pažiūrėsime dvylika mėnesių į priekį, ar mūsų prognozė, ką dabar prognozavome, išlieka tokia pati, ar mes kažką keičiame, nes atsirado kažkokių dar papildomų veiksmų. Tai vat tas turbūt taip atrodo procesas.

Tai iš esmės dalyviai, tai yra vis tiek labai arti, na vat finansų analitikai yra prie verslo tai prie žmonių, kurie realiai daro, sakykim, pardavimus, kurie ieško klientų nu vat tas, kas tiesiogiai su įmone, sakykim, pelno generavimu ir vat būtent jų tos įžvalgos padeda tą prognozę padaryti labiausiai realistinę, gal taip pasakyčiau.

O, pavyzdžiui, dar dėl biudžetavimo pačio proceso. Man irgi truputėlį įdomu, kaip tai vyksta, kokie etapai yra?

Mhm, tai čia tu apie tą biudžetavimą, kurių vieną kartą metuose darom ir biudžetą pasiruošiam, okei. Šiaip mes esam linkę procesą peržiūrėti nuolatos ir jį tobulinti, ir įvairių esamų metodų taikę, bet jau dabar antri metai darom tokį metodą. Tai aš, pavyzdžiui, dirbu toj komandoj, kur yra centrinė finansų kontrolės komanda, tai realiai mes formuojam taisykles ir politiką, kaip turėtų atrodyti visas biudžetas ir įtraukiam tada jau visas finansų komandas ir visų departamentų. Trumpai taip apibūdinant, koks yra tas procesas, tai mes iš pradžių nusistatom savo pagrindines eilutes, iš ko susideda mūsų pelno nuostolio ataskaita. Tai yra, sakykime, ten tos pajamų visokie vat rodikliai, kurie mums padeda uždirbt ir yra sąnaudų rodikliai. Nu tai, pavyzdžiui, ten tų pačių administracinių darbuotojų išlaidos. Tas pats draudimas, ką minėjau, ten lizingas, visi tie dalykai, kurie yra kaštų dedamosios, tai kaip atrodo iš pradžių, tai vat mūsų ta centrinė komanda susirenka tokias prielaidas kiekvieną iš tų eilučių, kas galėtų būti kitaip negu buvo šiais metais, nu vat remiantis istorija. Tai mes vat sakom, pavyzdžiui, draudimo vat išleidome tiek vat tokį įkainį, bet kitais metais ten kažkokioj jau šalį dėl kažkokių pasikeitusių įstatymų dešimt procentų pakyla ten kažkokia įmokos kaina, tai mes sakom, okey tai mūsų priešai yra tokia, kad kaštai išlieka vat tokiam lygyje, bet mes įsivertiname tai, kad nuo kažkurio čia periodo keisis va tiek procento ir išsiskaičiuojam, kiek čia ta įtaka yra. Tada mes susidedame visus metus visus visus tuos rodiklius (KPI), gaunam kažkokį tai rezultatą, tai į kokį su tom prielaidomis pelną mes išeinam. Tada mes sakom, tai va, čia yra mūsų toksai vat pasiūlymas. Mes tą rezultatą dar pasiderinam kartu su įmonės atsakingiausiu asmeniu, ten direktorium, sakykim, kad koks jo yra matymas, koks valdybos yra matymas, kiek mes turime atnešti pinigų, ir tada tuos atsiformuotus tikslus mes pasidalinam su visų finansų komandų atsakingais asmenimis, kad va žiūrėkit, yra jūsų toks rodiklis, jūs gausit į x tiek pinigų išleisti, tiek pinigų uždirbti. Dabar jūs turite eiti pas verslą ir verslas turi patikėti, kad tai yra įmanoma. Tai nėra, kad einam dabar viską detalai ir planuojam, bet vat kalbama apie tai, kad vat yra tokios prielaidos. Tada duodame jiems laiko, jie grįžta pas mus sakydami, kad, žiūrėk, dar yra kažkas tokio.

Tai mes susidėliojam kažkokias naujas prielaidas ir tada jau ten aišku daug tų etapų, žinai, ten pasitikrini, grįžti atgal, vėl taip toliau, bet bendrai įsidirbi į kažkokį tai totalinį pelno nuostolio ataskaitos, sakykim, skaičių ir pagrindinius rodiklius, kurie yra paremti kažkokiomis sutartom prielaidom, kur visi žino, kodėl vat skiriasi, nes, pavyzdžiui, nuo šių metų nes vat tas dėl to ir panašiai. Kai mes jau tokį maždaug susidėliojam vaizdą ir jau tikim, kad įmanoma tokius skaičius pasiekti, keliaujame į valdybą, kur valdyba pasako savo nuomonę, jie gali žinai pasakyti, sutaupykite dar dešimt procentų, noriu daugiau, tada mes vėl grįžtam, pasižiūrim, ką galim padaryt, ir galiausiai, kai sakom, kad va turim tokį rezultatą pasiekti, pradedam kažką biudžetuoti. Tai vat vadinasi pas mus toks biudžetavimo procesas, kai jau viską išsidetalizuojam labai labai detalai. Ten jau žmonių atlyginimus, žmonių galvų lygiu, kiek uždirbs vienas asmuo, kiek uždirbs kitas asmuo, tai va čia taip pas mus dabar porą metų jau buvo.

Tai realiai prielaidos nusileidžia iš jūsų to pagrindinio branduolio, pagrindinės kontrolės komandos?

Jo tai yra iš mūsų, bet kaip jos atsiranda, tai nu mes jų irgi žinai neišburiam iš galvos, mes irgi dėliodami jas daug konsultuojamės su žmonėm, kurie yra toj srity kompetentingi. Nu, pavyzdžiui, yra pas mus kažkokia analitikų komanda, kuri dirbo su draudimu, tai vat. Aš gal, pavyzdžiui, vat einu, pas tą komandą ir sakau, žiūrėk, kokios įžvalgos kitiems metams, ar kas nors rinkoje keičiasi, ar yra kažkokių naujų įstatymų, gal kažką jau esam persidengę su savo esamais tiekėjais. Ką jie siūlo, gal

ten vat, pavyzdžiui, jie vertinasi mūsų žalingumus, sakykim, kiek ten prisidaro visokių žalų ir kiek mums reikės draudimo pagalbos. Gal labai kils, nes esam žalingi, tai jie tokias irgi pateikia savo išvalgas iš to, ką jie turi, ir pagal tai tada mes nusprendžiam, kokia ta prielaida keliauja į biudžetą. Ir po to faktas, kai mes pasidarom biudžetą, jis yra paremtas prielaidomis, tai kai mes analizuojame, po to jau lyginam su biudžetu, tai tu gali žiūrėt, kad vat mano prielaida buvo tokia, o pasikeitė vat tas dėl to, uždarbis mano pasikeitė irgi dėl kažko tiek tiek tiek.

Tai jūs realiai naudojate tiek istorinius vidinius duomenis, tiek ir rinkos kažkokius duomenis išorinius?

Tai naudoti tik istorinius duomenis, mano asmenine nuomone, yra nerealistiška, pagal juos pasidaryti biudžetą, nes tu visą laiką turi vertinti, kas pasikeis. Istorija tau gali duoti tikrai atskirtį, nu ta prasme, kad va čia yra mano bazė. Ir tai net ne visą laiką ta bazė reiškia, kad nu vat taip vat vertiname, kaip finansų analitikai labai pažengę, kad jeigu šiomet išleidau, sakykim tūkstantį, tai nereiškia, kad kitais metais išleisti tūkstantį plius infliacija. Tai gautųsi žinai ten tūkstantis ten nežinau dvidešimt eurų, tai tu turi sugalvoti kažkokį metodą, kaip tu padengtum tą infliaciją, nes tu turi visą laiką ieškoti efektyvumo kaštuose, kad ne tik žinai, kaip dauguma mėgsta tokį cost plus metodą, kad nu vat užsidedu kažkokį procentą ir vat mano biudžetas, tai tuo negali remtis, nes nu tu turi visą laiką ieškot. O gal man kažkur pavyks sutaupyti? Gal man pavyks persiderėti? Gal aš kažko atsisakysiu ir taip iš tos pusės perėjus į geresnį rezultatą.

Ar duomenų kiekis, ar duomenų kokybė turi didesnę įtaką prognozių tikslumui?

Turi didesnę įtaką kokybė, nes nuo nekokybiškų duomenų tai tu gali tą pačią bazę pasiimti klaidingą ir tada jau kažko netekti tai vat. Pavyzdžiui, irgi būna praktikoje, kad, sakykim istoriniuose duomenyse dėl kažkokių trikdžių mes nematom, sakykim, kažkokių išlaidų ir tada paimam kaip bazę. Sakykim pametam du milijonus tai ką tai reiškia, kad mes paimam bazę dar pamastome kaip efektyvinsi ir tada metų eigoje aiškėja, kad uoj atsirado dar, nes buvome nematę, kažkoks buvo trikdys tai, ką tu sakai? Nu tai jau toj savo biudžeto eilutėj esi pagalvę sau negerą įsitaisę, perviršį, nes tu tiesiog neturėjai to momento gerų teisingų duomenų. Tai va čia labai išsiplėčiau apie šitą mano tema.

Ar savo darbe naudojate dirbtinio intelekto sprendimus? Jei taip – kokius įrankius ar technologijas naudojate?

Tai aš pati nenaudoju. Nu, tiksliau, mes dabar turim tokį tikslą pradėti naudoti iš tikro tai, pavyzdžiui, dabar visi mes turim tokį metinį tikslą, kad turim sugalvoti, kaip dirbtinis intelektas vieną iš mūsų darbų galėtų, sakykim, palengvinti, pakeisti ir taip toliau. Tai nežinau, kokį ten tikslą, bet kažkurį tai ten iš tų CoPilot'o cloud'ų, tiksliai neįvardinsiu, koks ten tikslus jis

Kaip vertinate DI tikslumą, lyginant su tradiciniais paieškos ar prognozių metodais?

Tai kodėl aš skeptiškai žiūriu į tą DI tikslumą ir pritaikomumą. Kur aš matau tik privalumus, tai, kad jisai padeda ten, kur yra labai dideli duomenų kiekiai ir yra kažkokios aiškios taisyklės, kaip pastebėti ką nors, ką tu nori pastebėti, padeda ten, kur turi pasikartojančias užduotis, kurios yra labai aiškios. Tai mano tokioj, kaip verslo kontrolėj, tokių užduočių nėra. Aš neturiu kažkokių periodinių darbų, kur viskas pasikartoja, pas mane darbai labai priklauso nuo situacijos. Tai privalumas yra ten, kur tos užduotys pasikartoja ir ten, kur yra labai dideli duomenų kiekiai. Pavyzdžiui, gali būti bet kur mes dabar bandom, sakykim, pasinaudoti tai vat, sakykim, turim buhalterines operacijas ir, sakykim, yra kažkokios konkrečios taisyklės, kur mes matom, kad buhalterija nuolatos padaro klaidas

registruojant, tai apmokius tą agentą konkrečių taisyklių jis gali vietoj tavęs tiesiog paimti duomenis, prasukti ir patikrinti, ar pasitaikė kažkokios klaidos pagal tai, ką tu jam nurodei. Pavyzdžiui, surask, kad ten DK sąskaita tokia, karštų centras turi būti toks, patikrink, ar taip yra, na ir jis tada prasuka ir tau pačiam kaip ir nereikia to daryti. Tai vat tokius dalykus turbūt jis gali padaryti.

Kas man asmeniškai, kodėl aš jo nemėgstu, naudoti, tai dėl to, nes jis pats negalvoja. Ta prasme, tu jam turi viską pasakyti. Tai iš vienos pusės jis yra turbūt kaip naujas darbuotojas, kur tu su juo pusę metų dirbtum, apmokintum jį visų įmanomų situacijų. Tuomet turbūt jis būtų naudingas, jeigu tu į jį labai daug laiko investuotum, bet dažniausiai, šiaip ką duoda žmogus, tai, kad jis pats dar pagalvoja, o kas jeigu vat taip, arba jeigu anaip būtų. Tai aš bandžiau irgi naudoti kaip įrankį suprognozuoti man kaupinius. Pavyzdžiui, sakau, yra sausis, vasaris, kovas, balandis, sakykim, nepilnas mėnuo, nori užsidaryti mėnesį ir man trūksta sąnaudų ir vat sakau, pažiūrėk, čia yra istoriniai duomenys, padaryk man prognozę, kur man reiktų kažko dasikaupti, pasidaryti papildomai, tai jisai ką, nu tai jis paima, padaro vidurkį, išveda iš trijų mėnesių. Tada sakau, okei, žiūrėk į išlaidų tipus kažkokius specifinius. Pavyzdžiui, žinai ten užrašyta amortizacija, nu tai jis paskaičiuoja vidurkį. Tai jau yra neteisinga, nes modernizacija neveikia taip, kad būna tiek, kiek vidutiniškai yra, tiek. Turbūt jeigu nieko papildomo nepaleidai į nusidėvėjimą, nu tai tiek pat, kiek ir buvo praeitą mėnesį. Tai nu ta prasme viską jam reikia paaiškinti ir jam paaiškinus, vis tiek padaro taip, kaip tu jam ir pasakei. Bet nu tu realiai kiekvieną žingsnį turi papasakoti, tai, jeigu yra kažkoks modelis, kuris būtų visiškai kažkoks, kurį tu gali nusakyti visą taisyklėmis, be kažkokio tai dar papildomo pamąstymo, tai turbūt jis tiktų, bet praktikoje visą laiką atsiranda kažkas, kas naujai nutinka pirmą kartą arba išsikeičia iš vėžių, ir tada tu jau pats turi pagalvoti, kokį sprendimą priimti. Tai mano toks požiūris, man jis nelabai prilipo, nors vat, pavyzdžiui, mano kolega, kuris labiau dirba su duomenų analitika, tai jis DI naudoja, nes jis turi tokių gan apibrėžtų užduočių, kur DI gali didelius duomenų kiekius apdoroti ir vat būtent kažkokią informaciją susisteminti, parašyti aprašus ir panašiai. Tai man prognozuojantis nepadėjo, bet nu turbūt priklausytų nuo to, kokio kompleksškumo yra tavo prognoze, kurią tu darai. Mes dabar pradedam mokytį ir naudoti, nu vadovai mūsų sakykim, kaip asistentą naudoti, tai mes turim dirbtinį intelektą. Jisai žodžiu savyje turi visą duombazę failų, kurie ir pas mus yra. Mes iš pradžių norėjome prastestuoti tokį įrankį ir aš paėmiau savo duomenis iš ataskaitos, bet juos visiškai nuasmeninau, ten žinai tiekėjus pakeičiau random numeriais, ir daviau kolegai, sakau, pratestuok. Tai tas asistentas, jisai iškasė tą failą vis tiek iš mūsų duombazės ir parašė, žiūrėk, čia gal pilni duomenys, sako panašu, kad vat ten vat yra pilnesni duomenys jau, gal šituos naudokime ir mes tokie okey labai keista.

Ar jūsų organizacijoje naudojami didieji duomenys (angl. Big Data)? Jei taip – kokio pobūdžio tai duomenys?

Jo gerai toliau didžiųjų duomenų naudojimas. Šiaip logika ta, kad mes tai nenaudojam pas save pačioje komandoje didžiųjų duomenų. Tai realiai šiaip pas mus turbūt organizacijų finansų analitikai, verslo kontrolieriai nenaudoja pačių didžiųjų duomenų, su jais labiau dirba, sakykim, programuotojai arba duomenų inžinieriai, arba architektai, kurie tuos duomenis jau taip apdirba, kad mes gautume juos tokius, kad galėtume juos vartyti per įrankius, ir su kuriais jau gebėtume kažką atlikti. Mes patys su jais nedirbam.

Kokius iššūkius patiriate dirbant su dideliais duomenų kiekiais?

Tai pavyzdžiui, kažkoks įrenginys siunčia nuolat informaciją apie ten nuvažiuotus kilometrus, ten sakykim, arba apie nežinau, išnaudotą kurą, jie yra kažkur nuolat siunčiami. Tai vat ir kas atsitinka,

kokios gali įvykti problemos su tuo, tai, kad jeigu tame siuntime kažkas nutrūksta, įvyksta kažkoks duomenų lūžis arba nesuveikė integracija tarp skirtingų sistemų, sakykim, arba sistemos tarpusavyje susipyksta, nes kažkas atsitinka, tai tuomet kaip ir dingsta duomenų tęstinumas, nes tas duomuo, dažniausiai, nebūna taip, kad atsikuria po to su visa istorija. Tai turbūt būna taip, kad nuolat įvyksta kažkoks lūžis ir tu kažkiek duomenų netinki. Ir nu, kadangi jie ten yra baisiai sunkūs ir kažkokia loginė klaida gali labai daug po to pakenkti prognozėms, jos klaidingos automatiškai darosi. Nežinau, nelogiškumas tada atsiranda, išsikraipo informacija. Pavyzdžiui, gali būti, kad vienas šaltinis naudoja vienus duomenis, kitas kitus, tada jau žinai, susitinka du verslai, pradeda kalbėti apie tą patį skaičių, bet skirtingom reikšmėm, tai va čia tokia problema. Šiaip bendrai esam susidūrę, bet patys mes nenaudojam, nes nu šiaip nežinau, ar finansų analitikai dirba su Big data. Pas mus jau tie skaičiai sutvarkyti ateina, inžinieriai juos jau formuoja mum, kad patogiai dirbt galėtumėm.

Kiek svarbios ekspertinės įžvalgos prognozavimo procese? Kaip šios įžvalgos yra integruojamos į prognozes?

Kiek svarbios ekspertinės įžvalgos tai čia vat ką kalbėjom, kad negalim pasitikėti tik istorija., turime remtis ir kažkokiais patyrimais žmonių, kurie jau tuo klausimu kažkokį bagažą yra sukaupe. Praktiškai be kažkokių ekspertinių įžvalgų analizės pasidarytos iš kintamųjų tik istorinių turi tikrai labai sumažintą vertę. Nes nu dažniausiai iš istorijos turbūt gali kažkokį pastebėt sezoniškumą, kas vis nuolatos kartojasi ir tuo remtis, bet, nesiremdamas tuo, ką žino jau patyrę žmonės ir vilkai, nu tu savo prognozėm gali nuvažiuoti labai ne ten, kur reikia, ir susikurti per didelį rezervą. Tai vat turbūt vienas iš tų dalykų kas kiša koją dažnai biudžeto prognozavimo metu tai, kad žmonės yra linkę bijoti nepasiekti tikslų ir to pasekoje, jie labai išpučia savo išlaidų biudžetą. Pavyzdžiui, va, kokia galėtų būti mano įžvalga, remiantis tuo, ką aš matau, kaip viskas vyksta, tai vat, sakykim, kiekvienais metais duodi vadovams susiplanuoti savo komandos narių skaičių ir jų atlyginimus. Kaskart aš vis liepiu susimąžinti ir visi kiekvienais metais sako, kad nu niekaip neišeis. Čia jau visiškai mano visa komanda sudėta ir nu aš nebegaliu niekur nieko pamažinti. Ir kas tuo atveju nutinka realiai ir ką esu vat jau pastebėjusi, kad ir kiek žmonės sako, kad jau nebegali, kiekvienais metais, kažkokiu būdu sugeba nemažai sutaupyti. Nors vat ką sako istorija, ką sako patys faktai, kad vat žmonių yra tiek, atlyginimų yra tiek ir čia nieko nepakeisi, faktas toks, istorija tokia, bet ką pastebi ir ką matai tokį paterną, kad nu visą laiką yra kur.

Ir kažkaip vat atsiranda tų dalykų, kaip kažkokių sprendimų ū planų, kaip kažką padaryti. Tai vat, sakykim, vat ką pastebėjom, bet per kažkiek metų, kad galbūt mes galim netgi kaip tik susiplanuoti tiek, kad jau kur visi verkia, kad jaučia riba ir nuo tos ribos dar numažinti, įsidėti kaip efektyvumo kažkokių target a. Ir tada jau tas biudžetas tampa labiau challenging nes, vat stai faktais remiantis ir viską vertinantis, kad va čia tai išleisiu tave išleisiu tai visą laiką prisi biudžeto uoju, tų vadinamų pagalvį.

Tai jo, labai yra svarbu čia tos ekspertinės įžvalgos. Tai čia turbūt kaip ir kiekvieną dalyką prognozuojant svarbu įtraukti žmones, kurie yra ekspertai tos srities. Nu tai vat, kaip ir su tuo pačiu draudimu, minėjau, kad istorija gali būti vienokia, o vat ekspertas, kuris analizuoja, stebi, gali suprognozuoti remiantis savo patirtim, žiniom, nes jis žino kažkokį tai tikslesnį rezultatą. Tas pats, kas tam tikros žinios apie konkurentų rinkos elgseną.

Ar gali būti, kad ekspertinė nuomonė prieštarauja duomenims?

Nu tai aišku, kad gali. Tai čia tikrai dažnai būna, kad ta istorinė informacija, jeigu ypatingai keičiasi tam tikri aspektai, jina gali būti mažiau naudinga, negu tai, ką tau gali ekspertiškai papasakoti, ypač jeigu rinkoje labai kažkas keičiasi, pavyzdžiui, buvo kovidas, pandemija, istorijos jokios nebuvo skaičių, tai realiai turi statyti viską ant kažkokio scenarijaus. Čia gal dar irgi ką duoda tas ekspertiškumas, tai, kai tu vat susiplanuoji, sakykim, vat ką mes dar prognozuojam kažkokią įmonę, strategiją, kad mes pasakom, bet mes uždirbsim ten pinigų per metus ir tada, ką ką daro į ekspertai, tai sako, jo čia tu viską labai gražiai susidėjai, bet what if, kad mes susikūrėme sau papildomus scenarijus nuolat. Pavyzdžiui, sako va, dabar kuro kaina baisiai yra išaugusi, tai o koks būtų scenarijus, jeigu ji tokia laikytųsi visus metus, tai kas tada būtų. Nu tai čia nukris po dviejų mėnesių ta kaina. Tai nu, tai vat jau iš tų visokių ekspertiškumo, gimsta papildomi kažkokie dalykai ir mes juos taip ir vadinam. Iš tikrųjų scenarijais, scenarijus A, scenarijus B ir dar būna vos keli scenarijai, kas būtų, jeigu jau labai blogai būtų.

O kaip vertinate subjektyvumo įtaką?

Tai šiaip tokie dalykai turbūt yra visada su aukštesnio lygio vadovais, nes nori nenori ir mums pasako kažkokią tai žinai nuomonę, kad va turi būti tiek, o ne iki tiek, bet čia žinai, kaip yra akcininko noras, ko jisai tikisi iš organizacijos, tai mes šitą turim priimti bet koku atveju tik tiek, kad mes prieš tai esam labai stipriai pasiruošę paaiškinti, koks yra mūsų tas pats scenarijus, iš ko jis susideda, kodėl jisai toks ir kodėl jis negali būti kitoks. Jeigu akcininkas, sakykim, sugalvojo, kad vat bus vat tiek pajamų, tai ką mes tada darome? Tai mes irgi einam į analizę ir sakom, va, žiūrėkit, turime nuleistą tokį tikslą, pavyzdžiui, uždirbti tiek pajamų daugiau, tai ką mes galim padaryti, tai mes tą problemą gautą išskaidome į konkrečius veiksmus. Mums pasakė uždirbk, nežinau, šimtų milijonų daugiau pajamų, tai mes sakom, kad čia galim uždirbti dvidešimt, čia galim dvidešimt, gal iš šito čia gal kažkokį naują klientą atsivesiu čia, gal pakelsiu kainą čia gal vat kažkokias sutarties sąlygas persidirbęs ir taip toliau ir paliekam kažkokią pilką zoną, kur sakoma va šitą penkiasdešimt aš nežinau, kaip aš uždirbsiu, bet šitam metų eigoje reikės Action plano Ūveiksmo plano). Ir tada vat irgi metų eigoje mes sakom, okey, mes turim jau po dešimt sakykim milijonų, mums pasakė, va, turim valdybai nori nenori, bet parodyti, iš kur mes taupysime, tai mes sakom, okey pradėsim į kiekvieną detalę ir vis tiek galbūt ne per metus laiko, bet per kažkokį tęstinį periodą mes išeisim į kažkokį tai įkainį, kurį mato tas vadovas, imantis kažkokių tikslų ir planų, ko mes atsisakysime arba ką darysim kitaip.

Nes darant taip pat nu tai niekas nesikeis, bet čia yra viskas per griežtą kontrolę, kad nusistatai va, darysiu taip, o ne kitaip. Pavyzdžiui, nevažiuosiu šituo mokamu keliu niekada ir tada tavo tikslas yra toks. Subjektyvūs aukšti tikslai nebūtinai pasiekiami per vieną periodą, gal reikia ilgesnio laiko. Bet na, turbūt tai duoda gaires iki kur eiti, nes nu jeigu tau nieks nepasakys, kad tu turi uždirbti daugiau pajamų, tai tu gal ir neuždirbsi daugiau pajamų. Tai čia yra kaip tai nu taisyklė, nes tu pasakyk, kad darbuotojai reikia uždirbti daugiau, negu jina uždirba dabar, tai jina ir dės pastangas ir uždirbs daugiau. Jei nieko nesakysi, tai ji pati per daug nesistengs nieko ten papildomai uždirbti, nebus suinteresuota.

Dabar norėčiau tavo nuomonės apie tam tikrą teorinį modelį ir jo pritaikomumą realiame versle. Modelio veikimo principas: pirmiausia dirbtinis intelektas, naudodamas didelius istorinių ir kitų duomenų kiekius, pateikia pirminę prognozę, grįstą tik istoriniais duomenimis. Į modelį integruojamos ir papildomos ekspertinės išvalgos, kurių pasitikėjimo lygį prognozėje sprendžia situacijos panašumo vertinimo rodiklis, kuris lygina esamą organizacijos situaciją su

prognozuojama. Jei prognozė panaši į esamą situaciją, didesnis pasitikėjimas skiriamas pirminei modelio prognozei, jei ne – eksperto įžvalgų korekcijoms. Galiausiai modelis pateikia galutinę integruotą prognozę, bei prognozės paaiškinimą (dėl ko, kaip ir kas kito).

Jo tai nu šiaip iš praktikos, ar ne, tai nu čia šitas modelis yra realiai panašu į tai, kas ir vyksta praktikoje. Nes ką ir darom, istoriniai duomenys duoda kažkokią bazę, atspirties taškas kažkoks tai tada tos ekspertinė žinios, jos duoda kažkokias papildomas prielaidas, kas skiriasi nuo to, kas buvo šiemet. Nu tai čia realiai ant tų bazinių duomenų užmauna kažkokias ekspertinis prielaidas ir tada daro nu tai jo tai nu čia turbūt taip ir vyksta visą laiką. Tai tiktai prie tų ekspertinių prielaidų dar turbūt atsiranda naujos, turbūt turėtų būti kažkokios tai išplėstos gana, nes vienas yra prielaida dėl pokyčių, o kitas dar yra kažkokie prielaida ar tu ieškai efektyvumo toje prognozėje, nu čia žiūrint, ką prognozuoja aišku, bet jeigu sakai, pavyzdžiui, prognozuoji išlaidas, nu tai tu jo ir įsidėsi prielaidas dėl augimo, bet ir dėl kažkokio efektyvumo, nes negali sakyti, kad visą laiką augsiu. Tai nes sakykim, žiūrėtum istoriją ir galvotum, kad viskas auga, bet nebūtinai viskas turi visą laiką augti. Tai turbūt viskas čia gerai su tuo modeliu. Aš manau, ar jis gali būti pritaikytas, gali, nes yra įtraukta ekspertinės įžvalgos, kas yra svarbu, negali pasitikėti tik istoriniais duomenimis.

Kalbėjau su kitu analitiku, ir jisai man išskyrė, kad, sakykim modelis okey, bet tas, kad yra dirbtinio intelekto, sakykim pagrindu daromas modelis ir realiai mes matom tik tais pirminę prognozę, galutinius skaičius integruota prognozę ir kažkokius paaiškinimus, bet tas, kad nesimato tų tarpinių skaičius, sakykim, kaip kito viduje, jisai man tai išskyrė kaip problematiką. Kas versle realiai neveiktų, nes dažniausiai vadovai, akcininkai, jie nori žinoti labai iki smulkių eilučių, o tai kas vyko, o tai kodėl taip buvo padaryta ir jam galbūt ta galutinė tiktais prognozė nesuteikia užtektinai informacijos.

Jo tai šitas yra tiesa. Vat kam jisai turbūt būtų tinkamos nusistatyti kažkokį pirminį atspirties tašką. Sustato kažkokias prielaidas, ir tada susigeneruoja tai, koks čia gali būti mūsų tas, sakykim, pelnas. Tai turbūt va šitam dalykui sumesti kažkokį tai pirminį tikslą, kad va tokia istorija, turim tokias prielaidas įsivertinti, įsivertinam, akumuliuojam ir išeinam į kažkokį tikslą, kurį paskui jau galima kvestionuoti ir koreguoti. Tai galėtų būti kaip įrankis pirminei prognozei sudaryti, ant kurio tada statytumėm toliau rezultata. Nes verslui reikia tokio detalumo iš kur kuris skaičius ateina, kad mes negalim pateikti tik rezultatus galutinius. Nes ir kol mes prieinam iki tos pirminės prognozės, tai procesas yra gana ilgas, nes tikrai reikia daug duomenų išanalizuoti, pažiūrėt, kas čia istorijai buvo. Tai jeigu jis kaip įrankis apdorotų iškart tuos duomenis, tai būtų galima greitai ateiti iki pirminio rezultato, o jau po to ant jo statom toliau skaičius ir naujas prielaidas.

Na ir pabaigai, kaip vertinate DI reikšmę finansų analitiko profesijoje ateityje? Ar DI laikote labiau galimybe ar grėsme?

Aš manau, kad nu, kaip ir jau minėjau, kad man atrodo, kad jis yra tinkamas, jeigu turi kažkokias užduotis, kurios yra pasikartojančios, konkrečios ir aiškios. Bet kalbant, pavyzdžiui, iš mano perspektyvos nuo finansų analitiko, kai reikia daugiau visokių įžvalgų ir ekspertizmo, tai nu man jisai nėra, sakykim prie pagrindinių įrankių, ką aš naudočiau, tai aš asmeniškai vertinu, kaip kažkokią pagalbą užduotyse, kurios yra labai aiškios ir apibrėžtos, ir su taisyklėmis, ir yra baigtinės. Tai jisai kaip galimybė, bet ta galimybė kaip asistento, o ne to, kas pakeis patį analitiką.

Kokie įgūdžiai taps svarbiausi ateities analitikams?

Reikia pasidaryti viską taip, kad nereiktų dirbti, o ką tai reiškia. O ką tai reiškia, kad viską, ką įmanoma, reikia optimizuoti, tai, kas yra labai svarbu ir vat kuo irgi vadovaujosi net ir su tuo pačiu Excel'iu. Kad jeigu aš jau kažką darau ilgiau nei minutę laiko, tai reiškia, kad kažkas jau yra sukūręs formulę, nes aš nesu pirma, kuri darau tą, ir vadinasi, kad aš galiu kažką optimizuoti ir padaryti kitaip, nes kai tu viską optimizuoti, turi daugiau laiko daryti įžvalgas, o ne dirbti ties duomenimis ir jų apdirbimu. Kas yra problema didelė finansų analitiko darbe, kad tu daug laiko užsiimi su duomenų kokybe, su kažkokios ataskaitos sudėjimu, bet tu nespėji būtent tų analitinių įžvalgų pasidaryti ir pasižiūrėti iš aukščiau į viską, nes labai įsigilinę detalės.

Dėl įdomumo, kokius įrankius naudojat?

Pagrindas tai yra tikrai Excel'is, mes jų tikrai kietų esam prisidarę. Dirbam ir su SAP'u, su Power BI ataskaitų turim, kur jie ten inžinieriai duomenų didelius duomenis apdoroja į kažkokias ataskaitas. Bet nu faktas reikia suprasti tai, kad tie įrankiai yra palaikomi kažkokios komandos. Nu vat pavyzdžiui, aš susiformavau kažkokį poreikį, man reikia va tokios ataskaitos, tai jie man per tą įrankį suprogramuoja tą ataskaitą, bet kažkas pasikeičia. Nu, pavyzdžiui, vat aš noriu dar prisidėti kažką tai ir tada jau to lankstumo nebelieka, nes lauki, kol kažkas ten sutvarkys, kažką pridės, tai čia gali ir mėnesio, ir poros, klausimas būt. Tai turbūt Excel'is pats lanksčiausias yra ką mes naudojames, nes viską galim realiu laiku.

3 priedas. Interviu transkriptas Nr. 3

Priedas. Interviu nr. 1

Informantas: Asmuo nr. 1

Interviu trukmė: 44 min.

Taip, pradžiai norėčiau paprašyti, papasakoti truputėlį apie savo profesinę patirtį, kokia yra Jūsų dabartinė pozicija, atsakomybės ir kokiame sektoriuje dirbate?

Tai esu finansų analitikas daugiau kaip 20 metų ir daugelį metų dirbau tokiose įmonėse kaip įmonė X, įmonė Y, žinoma dabar čia įmonėje H. Įmonė X yra grynai mažmeninė prekyba, yra kita specifiška, tenai daugiau už Latviją Estiją buvau atsakingas, tarptautinio verslo ir sakykime, tai iš principo, prieš tais dar vienos didelės didmeninės prekybos įmonėje dirbau 16 metų žodžių.

Va, tai dabar kalbant prie, sakykime, tokių core dalykų, kas kiekvienoje įmonėje, kur analitiko akcentas. Labai priklauso viskas nuo to, kokia tai įmonė, nes vienoje įmonėje finansų analitiko kasdienybė gali labai skirtis nuo kitos. Tai, kai sakykime, yra didmeninė prekyba, vat konkrečiai kiekvienoje įmonėje, kad suprastum, kaip atrodo, jeigu vat yra didmeninė prekyba, vat ten yra nedaug žmonių, bet yra labai didžiulės apyvartos, stambū verslo klientai, tai tenai yra tokios įmonės, jos savo apimtim, personalu, ir operacijų skaičium nėra didelės, bet labai didžiuliai pinigai.

Žodžio ir tenai pagrindas yra praktiškai pilnas spektras, tai reiškia pinigų srautai, visas skolų valdymas, atsargų apyvartumo optimalumo valdymas, ten ir debiutinių apyvartumas, yra visa pardavimo analitika, ten rinkos segmentais, visa kita. Žodžio darai viską per visą spektrą. Darai viską, bet ten kažkokio labai ypatingo gylio nėra, yra perku, parduodu ir tenai praktiškai prognozavimas, kalbant apie visas įmonėes, kaip aš dirbu, sakykim, dirbtinis intelektas, aš bent jau nenaudojau, viskas

vyksta realiai Excelyje tiesiai, ir viskas yra daroma labai detaliai ir kiekviena detalė, sakykim, jeigu prognozuojami pardavimai, tai imama to kliento statistika, kalbama su tuo vadybininku, kokias ten perspektyvas, kokios ten galimos derybos dėl kainos, ta prasme, tai reikia čia gyvo, ko reikia prognozavimui, reikia labai patogia sudėliotos statistikos, ir reikia to vadybininko, kuris su tuo žmogum dirba, žinojimo. Tai intelektas to nepasakys šitoje vietoje joks, sakykim, tai va, nes čia, matai, yra, kaip sakyti, realus gyvenimas, realiai įmonė ir čia reikia tokio priėjimo, daugiau yra, žinai, čia ne tai, kad makro kažkokių, žinai, tendencijų prognozavimas, makro rodiklių, kur vat yra grina ant statistinių metodų, vat galima pakabinti ant dirbtinio intelekto, sakykim dar kažko. Čia yra reikia vat to tokio, kaip sakyti, žinojimo, kaip savo namuose, ūkiškai situacijos, nes statistika gali, tu negali prabraukt, žinai, statistiškai, vat taip buvo, tai vat ten, žinai, vat taip išspratrendint, kaip sakant, tai toks dalykas. Kas liečia įmonę X, tai, sakykime, čia daugiau ta, tai yra lygiai tas pats, tik tai buvo, sakykime, buvo labai didžiulis momentas, tai yra ant tų investicinių projektų skaičiavimo, nu tai, žinai, tas variantas tu turėtum žinoti, sakykime, kur susideda investicijos, pelno nuostolio ataskaitą ir išeinama į NPV, net present value, diskontuotis srautai ir per kiek metų atsipirks ir vėlgi labai kiekviena prielaida labai detalai tikrinama ir žiūrima ūkiškai, ta prasme, realiai, žinai, ten, sakykime, iš, tai jeigu vat tuos investicinius projektų skaičiavimo, žinai, tai maždaug tai, čia labai irgi būtų ilgas pasakojimas ir jau atskira labai sfera, žinai.

Lygiai tas pats vat ir įmonėje H, vat perka, perka, sakykime, investuoja va praeitais metais, žinai, ten labai daug milijonų į naują parką, į naują viską ir vėlgi valdybai yra medžiaga, kur tu turi paruošti prezentaciją su visais atsipirkimais, irgi kiekvieną prielaidą atskirai, kokie bus pardavimų kitimai, kokios bus kainos, kokios bus ten išlaidos, labai detalai paremtos ir statistika, ir ūkišku žinojimu, kaip mažės kuro norma, tos kuro normos turi būti vėlgi paremtos ne iš lempos, o kažkokia realiai technine dokumentacija, visa kita, žinai, tai toks dalykas.

Pagrindinis skirtumas tarp bet kurios prekybinės ir gamybinės įmonės, sakykime, yra vadinama OEE analizė, tai yra Overall Equipment Efficiency, jeigu nežinai, kas tai yra, ar žinai?

Esu girdėjęs, bet pati darbe nesu susidūręs.

Nu tai pagoogleinsi, pamatysi tenais. Tai reiškiasi, kai gamybinis procesas yra skaldomas į mažiukus etapėlius, ir kiekvienas iš jų yra analizuojamas atskirai. Paėmus tuos pačius įmonę H, nėra tik taip, kad va perku parduodu, čionai nėra parduotų kilometrų savikainos, va tai, aš juos nenuperku, man susirenka iš nusidėvėjimo, aš nieko neperku, aš perku kurą, aš neperku kilometrų, aš perku kurą, moku atlyginimus vairuotojams, nusidėvėjimas mano vilkikams skaičiuojasi, va čia yra mano savikaina, žinai, ir visi ten kiti dalykai.

Tai atskirai yra sekama, kiek yra pardavimo įkainis, kiek konkretus vilkikas, koks jo buvo įkainis, kiek jisai kilometrų nuvažiavo, kiek jisai tarp užsakymų dienų stovėjo be darbo, toliau kas ten dar, kokias jo kuro norma, koks jų kelių mokės, žodžiu, yra labai skaldoma, žinai, į gabaliukus visas tas jo visas procesas, žinai. O tai tas įneša, tai yra bet kurioj gamybinėj įmonėj, tai yra absoliučiai esminis dalykas, žinai, tai va, bet vėlgi, vėlgi, bent jau aš nesusidūręs, žinok, su jokio, netaikom jokio dirbtinio intelekto, sakykim, šitoj vietoj, šitoj vietoj viskas vyksta, viską, kitaip tariant, viską vadovai nori prajaust, pračiupinėt, kaip sakyti, kiekvienas dalykas turi būt parodytas, analitikas turi parodyti ir bendrą skaičių, ir per dedamasias. Ir ta prasme, ir per dedamasias, ta kiekvieną elementą, kuris tenai yra, nu kaip sakyti, nori vadovai matyti atskirai ir jį pračiupinėt, jausti, kad jis yra realūs, žinai, nėra nieko taip, kad, žinai, atnešu ataskaitą, ten kažkokie skaičiai, arba kažkokia va prognozė, klausia, iš

kur, ant ko pastatytas šitas skaičius, ai, dirbtinės intelektas taip padarė, žinai, nežinau, jo klausk. Nu, supranti, tokių dalykų, žinai, gyvenime, gamtoje taip nebūna.

Ta prasme, tu turi žinot labai aiškiai prielaidas ir tos prielaidos būna sutartos, suderintos ant ko ką statom, iš ko, pagal kokią logiką remiantis, kuo prognozuojam, kas yra mūsų gyvenimo konkrečiai atveju realiausia prielaida. Nu, ta prasme, nuo ko daugiausia kažkas priklauso ir žodžiu būtent taip. Tai va, nežinau, ar aš šiaip, šiaip, žinai, biški chaotiškai pasakoju, bet maždaug taip. Tai didmeninė prekyba yra, kaip sakiau, skolos atsargos tas, o gamyboje prisideda ta overall equipment efficiency. Kas tai yra teoriškai ir ta, tai ten viską, žodžiu, rasi. Tikrai, nebe problemų, nes tai yra, nu, absoliučiai svarbiausias.

Labai ačiū, tikrai, labai įdomu buvo. Tik aš dar pasitikslinti norėčiau, o kaip, pavyzdžiui, atrodo pats biudžetavimo procesas? Ar yra kažkokie etapai?

Biudžetavimo procesas. Biudžetavimo procesas yra toks, kaip čia pasakyti, suformuluosiu, kad būtų aiškiau.

Procesas prasideda nuo to, tai akcininkai pasako daugiau, mažiau, gaires kokio augimo jie nori. Kitais žodžiais tariant yra galioja dažniausiai, ne visada taip, bet dažniausiai galioja, kaip pasakyt, tas principas, kad aukščiausio lygio vadovas iškelia kažkokį stambų tikslą, pavyzdžiui, grynasis pelnas koks turi būti, arba bent jau lygį, režius.

Tada tas keliauja vykdančiajam direktoriui, vykduojantis direktorius tą dalyką išskaido tą tikslą ant padalinių vadovų, ant padalinių vadovų, nuskaido, jeigu iš jų kiekvienas pasieks tą tikslą, tai ir bus pasiektas tas bendras įmonės tikslas. Ir tada, ir tada jau tas eina, vyksta biudžetavimas.

Iš finansų analitikos rolės yra toks dalykas. Jis žinodamas tuos esminius KPI'jus, vadinkime, į kuriuos reikia orientuotis, ir turėdamas statistiką, jis paskaičiuoja tai, kas vadinasi „pin limit'ai“. Tai realiai preliminarus toks biudžetas, toks labai juodraštinis, išeinant iš statistikos ir išeinant iš tų tikslinių KPI'jų, maždaug tiems vadinamams stakeholderiams, tiems padalinių vadovų, į kokius ties kiekviena, sakykim, sąskaita buhalterine arba ties kiekviena sakykim, nu kaip čia pasakyti, kaip tas vadinasi, apskaitinis objektas, tai kaip, nu pavyzdžiui automobilių kuras.

Yra didžiosios knygos sąskaita, bet ten yra labai daug automobilių, tai vat kiekvienas tas automobilis, žinai, tas atvadinama, kur detalizacija sąskaitos, į kokį dydį, nu, kad jis orientuotųsi, kad nusipieštų dešimt kartų daugiau, dešimt kartų mažiau ir taip toliau. Ir paruošia, sakykim, tas biudžetavimo formas ar kažkokią vieną formą labai didelę, kur, sakykim, yra praėjusių metų statistika, yra tas rekomendacinės biudžetas, yra, surašo, kokiam prielaidom mes turim remtis, ane, ten yra kažkokie esminiai skaičiai, kažkokio ten, pavyzdžiui, ties kiekvieno automobilių kuro norma, ten kuro kaina, į kurią mes, nu, kiek jis kilometrų turės nuvažiuoti, kokia kaina turės būti parduoti tie kilometrai, taip toliau, žodžiu, labai, va, taip detalčiai ir paskui prasideda, kaip sakyt, susirinkimai ir tiuninimas ir aptarimai ir ta, ir būna šimtas versijų, vis prasižiūrim interaciją, ane, sakykim, susirenkam, prasižiūrim, ten, sakykim, kaip čia pasakyt, vis, vyksta to biudžeto viduj įmonėj derinimas, tol, kol visiems jisai tinka, ir grynasis pelnas, ir tos visos dedamosios yra realinės, tiek išeinantys statistikos, tiek iš tų prielaidų į ateitį, nes kas yra biudžetas? Biudžetas tai yra faktas, plus struktūriniai pokyčiai ateinančiais metais, tai reiškia, jis yra faktas, plus ką mes keisim organizacijos viduje, plus kas keisis iš išorės, nu čia toks grubus žinai. Jisai visą laiką atsiremia į faktą, bet yra pakeitimai tiek viduj, tiek iš rinkos pusės ateinantys ir taip toliau, žinai, plus augimo tikslai, tai sakykime, negali

įmonė augti, jeigu ji visą laiką tik prognozuoja tai, kas buvo pernai, tai yra ta ambicija, kuri nusileidžia iš viršaus, nes gal apačios niekada jom nepatogu turėti tų ambicijų, nes paskui jas reikia įgyvendinti, žinai, tai visą laiką yra tas kažkoks įtempimas daromas, kad būtų kur augt, kur stengtis, kažko siekt. Tai va, tai maždaug atrodo taip, realiai tai ten, žinai, čia finansų analitiko yra, žinai, lygis ir techninis, kad padaryti visokius gyvus modelius, kad realiai galėtų ten, sakykime, pačių susirinkimų metu gyvai modeliuoti įvairias situacijas. Žinai, sakau, ai, kainas darom 5 procentais didesns ir iškart ten poro mygtukų paspaudžiu, visas biudžetas persiskaičiuoja, žinai, nu toks labai, kaip sakyti, interaktyvus, ne tai, kad, žinai, kažkokia mažytė detalė išeina, žinai, savaitę vėl ten nuo nulio renka, žinai, ten skaičius, žinai.

Tai čia tokio, va, žodžiu, techninių gebėjimų, tai reikia gerų, nes jisai yra daromas labai, labai detaliai, ta prasme, iki, jeigu atlyginimai, tai kiekvienos žmogaus lygiai kiekvieną mėnesį, jeigu tenai kuras, tai kiekvieno automobilio kiekvieną mėnesį, jeigu remontai, tai irgi kiekvieno automobilio kiekvieną mėnesį, žodžiu, yra ne tai, kad, žinai, ten 5 eilutės, tai yra milžiniškas failas, kitais žožiais tariant.

Taip, ir kiekvienas vadovas yra atsakingas už savo padalinį, kaip suprantu.

Jisai atsakingas už tą biudžeto vykdymą, kuris tenai bus patvirtintas valdyboj. Jisai atsakingas už to biudžeto vykdymą. Ir jis, aišku, betarpiškai dalyvauja tam biudžetavime. Bet kalbant iš to pačio biudžetavimo proceso, tai visą tą darbą su skaičiais atlieka analitikas, o vadovas, jisai, žinai, kaip pasakyti, jie ne analitikai. Jis gali net Excel'io nemokėti atsidaryti, jisai šneka kaip ūkininkas, čia tokį klientą pasiimsim, čia tokią kainą. O tu turi visą tai paversti skaičiais, pelno nuostolio ataskaitą, efektyvumais ir taip toliau.

Taip, supratau, o dabar sakykit, kaip suprantu, dirbat su labai dideliu kiekiu domenu, kokie dažniausiai iššūkiai kykla dirbant?

Taip, šiaip, tai dažniausiai būna tas, kad Excel'is vis tiek yra gana ribotas, jisai gana, ta, bet jisai, kaip čia pasakyti, būtent kad Excel'is pasidaro labai sunkiasvoris, tie failai dažnai ir tiesiog vartotojams darosi jau nekomfortiška, kai ten, žinai, minutę laiko tas failas atsidarinėja iš lieto, nu, ta prasme, tvarkoj, ten, kai atsidaro, ten viskas yra, viskas matosi ten ir galima žiūrėti detaliai ir visi suvestiniai, žinai, bet, kaip pasakyti, tikrai tie failai tokie gremėzdi ir, sakykim, kur yra alternatyva gera, bent jau mano praktikoj tokiose situacijose, tai yra Power BI'us.

Jeigu ten, kaip praeitoj įmonėje, ten pavyksta, jeigu tas duomenų šaltinio programa, tais žodžiais tarint, jinai leidžia iš duomenų bazės tiesiai, kaip sakyti, transliuoti į power BI'ų, tada yra viskas gerai. Tada viskas gerai, galima padaryti tas ataskaitas power BI'ų ir tada bet kur, bet kada telefoniuky visi online'ų matys. Bet yra programos, kurios yra senos, kurios, arba kur ten tų programų pardavėjai iš principo, nu, nesutinka, kad jie sako, pasakykit, kokių grafikų reikia, kokių ataskaitų reikia, mes pačioj programoj įprogramuosim, nu, jie iš principo nesutinka. Nesutinka, kad kažkas turėtų prisijungimą tiesiogiai nugręžinėti tuos duomenis iš tiesiai iš duomenų bazės. Tai čia yra tada, tada jau, kaip sakyti, jeigu tu nori kažkokio custom analizės, o ne to, kas ten nenumatyta ir nori greitai, tada yra Excel'iai ir tada jeigu ten eilučių yra, nu, sakykim, virš šimto tūkstančių, nu, tai tas Excel'is jau vargsta.

Dabar grįžtant prie pačių prognozių, labai pabrėžėte, kad yra svarbesnė vadovo nuomonė, nei galbūt istoriniai skaičiai...

Ir tas ir tas yra svarbu, ir abudu šitie dalykai jie nėra taip, žinai, kaip pasakyt, ar kairė ar dešinė koja svarbesnė, žinai, čia nėra taip, žinai, kad tas svarbu ar anas nesvarbu supranti. Čia, kaip sakyti, visą laiką yra tas, įsivaizduok, kad realiai situacija. Visokių tų vadovų yra ir, sakykim, kalbant, nes įmonė nėra vienas žmogus.

Yra daug žmonių ir žmonės yra žmonės, žinai. Tau gali ateiti koks nors pardavimų, čia teoriškai kalbu, ne įmonės H atveju, bet ateit gali, pavyzdžiui, pardavimų vadovas pasakyt, čia prikarkseti kosminių skaičių, žinai, čia siaubas, žinai. Bet jeigu mes matom, kad pagal statistiką, tai yra visiška lempa, kad tai yra ant nieko nepastatyta, ten pažiūrį kainų dvigubas augimas ar dar kažką.

Tai yra, tai mes tada jau generalinis direktorius, jo remiantis atotrūkiu tarp jo pasisakymų apie ateitį ir praeities statistikos, klausimų šaltinis, tai jau jo klaus, kokiais kontraktais, kokio realumo čia yra visas tas ir labai konkrečiai. Ar čia mes turime jau tokias sutartis, ar čia šiaip fantazija kažkokia. Tai toks dalykas, tam, kad išvengti visokio manipuliatyvių manevrų, tikrai turi būti ir statistika, ir tam, kad statistika konvertuoti į biudžetą, prie jos reikia ir to ateities žinojimo.

Bet jis neturi būti, žinai, aš kalbu apie ateities žinojimo, tai neturi būti šūkliai, kažkokie, žinai, supranti motyvacinės kalbos, o turi būti kažkas labai labai konkretaus ir realaus. Tai reiškia oficiali informacija, kas yra, pavyzdžiui, konkreto ir realu, pavyzdžiui, turim pasirašę naują kontraktą su klientu, kuris dar neturi už praeitį jokios statistikos, tai ką, mes ne nuliūs dėsim, toliau, pavyzdžiui, oficiali infliacijos prognozė, arba minimalių atlyginimų didinimas jau yra nuspręsta, kad mes jau žinom, kad, pavyzdžiui, koks Seimas nubalsavo, kad kitais metais čia teoriškai kalbu, žodžiu, didins minimalią algą, tai mes jau tą vertinsim, nors statistika kitokia.

Bet tai yra realūs, konkretūs faktai, kurie nėra šiaip, žinai, oi, pavarysim maždaug.

Taip, suprantau, ačiū Jums. Dabar norėčiau pasidalinti ekranu ir paprašyti Jūsų nuomonės apie tam tikrą teorinį integracinį modelį. Modelio veikimo principas: pirmiausia dirbtinis intelektas, naudodamas didelius istorinių ir kitų duomenų kiekius, pateikia pirminę prognozę, grįstą tik istoriniais duomenimis. Į modelį integruojamos ir papildomos ekspertinės išvalgos, kurių pasitikėjimo lygį prognozėje sprendžia situacijos panašumo vertinimo rodiklis, kuris lygina esamą organizacijos situaciją su prognozuojama. Jei prognozė panaši į esamą situaciją, didesnis pasitikėjimas skiriamas pirminei modelio prognozei, jei ne – eksperto išvalgų korekcijoms. Galiausiai modelis pateikia galutinę integruotą prognozę, bei prognozės paaiškinimą (dėl ko, kaip ir kas kito).

Taip, tai žinoma, ta prasme tai vat, taip ir vyksta tas biudžetų gynimas. Visi tie nuokrypiai nuo praeitų metų, juos turi iškommentuoti grupei, akcininkams, savininkams, bent jau didesni skaičiai būtina. Tai ir yra biudžeto gyvenimo esmė. Iš principo taip, taip gyvenime ir vyksta tik tai tiek, kad nu sakau, aš nesusidūręs, kad šitame procese, kažkaip nu mano gyvenime nesu matęs, kad šitame reikale dalyvauti kažkaip dirbtinis intelektas. Nes va čia atsiranda, kad tu turi labai žinoti visą analitiką. Ką iš kur paėmei, ką kur pridėjai, ką kaip apgrupavai, turi visą procesą žinoti, koks yra prognozės modelis, kokia yra logika, tai aš nežinau, man nelabai tas dirbtinis intelektas čia.

Tai ar gerai suprantu, kad realiai dirbtinio intelekto kol kas taikyti realiose situacijose nėra labai pravartu, nes trūksta paaiškinamumo? Ką jis ten ėmė, ką jis skaičiavo?

Matai, dalykas yra, realiam gyvenime kiekviena įmonė turi santykinai labai daug unikalumo.

Labai, kaip sakyti, žinai, čia kaip ir žmonės, žinai, yra rasės, bet kiekvienas žmogus yra nu labai asmenybė. Įmonė kiekviena yra unikali, tu negali paimti bendros klasės kažkokios modelio ir taikyti visoms vienodai. Nes, dirbtinis intelektas, bent jau kiek aš jį naudoju kitiems dalykams, ne darbui, tai jisai praskenuoja viską, visokius žinių portalus, Redit'us, viską viską, kas ką apie tą klausimą yra pasakęs, ir jisai tau iššauna tokį kaip ekstraktą.

Bet kiekviena įmonė tai nėra kažkoks vat panašių įmonių vidurkis.

Jinai turi labai daug, sakykim, tų visokių, „ifų“ ir taip brūkštelt viską tai nežinau ar gerai. Aišku, gal tai būtų daug greičiau, bet nu žinai.

Tada galbūt labai daug apribojimų reikia tam dalykui, taisyklių.

Jo jo jo, galbūt dirbtinis intelektas gali padėti ir jis, aš manau, padėtų tokiam dalyke, kaip rinkos talpos skaičiavimai.

Rinkos talpos skaičiavimai tai realiai, kai yra klausimas, pavyzdžiui, nu gerai.

Įmonė uždirba, tarkim, dešimt milijonų ir akcininkui įdomu, ar čia gerai, ar blogai.

Va čia gerai ar blogai, nežinau, ta prasme ir gerai, ir blogai, priklauso nuo to, ar ta įmonė, jeigu ta įmonė tarp konkurentų ir tų produktų rinkoje užima, sakykim, trisdešimt procentų ir daugiau rinkos, tai yra gerai. Jeigu jinai užima tris procentus, tai yra blogai.

Jeigu jinai uždirbo praeitais metais trisdešimt milijonų, šiais metais vėl trisdešimt milijonų, bet rinkos talpa apamai pati rinka išaugo dešimt procentų, tai yra blogai.

Nes nes realiai tą visą prieaugį pasiėmė konkurentai.

O rinkos talpa gali augti dėl atlyginimų augimo.

Tai va tokiem dalykam arba sakykim, aš matyčiau, daugiau realiai gyvenime, kur reikia tokios daugiau makro rodiklių analizės, kur reikia surinkti informaciją apie makro situaciją, tai dirbtinis intelektas tikrai išnaršys visą internetą labai greitai paduos kompaktiškai informaciją ne tai, kad ten reikės labai ilgai ir nuobodžiai kuistis. Bet kur kalbama apie įmonės vidinį gyvenimą, tai nu, tai nežinos, nu tai aš tas pats, kas paklausčiau interneto, kaip aš šiandien jaučiuosi, pasakyk tu man.

Arba ką man šiandien skauda? Taip ir įmonei gali skaudėti vieną sferą ar vienu laikotarpiu viena tema gali būti aktualiausia, kitu laikotarpiu kita tema. Aš manau, kad tai yra nelabai įmanoma, jis gali padaryti du dalykus: jis gali surinkti informaciją iš interneto apie makro rodiklius, jis gali padėti finansų analitikui, kaip gauti reikiamą atsakymą, kokį metodą naudoti, kokiais kampais užėti ir kaip tą atsakymą gauti galutinį gerą.

Jis daugiau toks va kaip mentorius, patarėjas, bet jis tikrai nebus taip, kad aš supyliau - iššovė, nebent tas dirbtinis intelektas yra įmonei kažkoks dirbtinio intelekto inžinierius, kuris padarė asistentą dirbtinio intelekto, kuris yra labai specifinis tai įmonei.

Nu ta prasme, nes kiek aš girdėjau, jis gali būt labai custom'izuotas, adaptuotas tai įmonei, bet aš kol kas su tuo nesusidūręs.

Aš kiek girdžiu tą dirbtinį intelektą, tai jį naudoja daugiau tokie kreatyviniai žmonės, visokie reklamistai, kurie kuria video klipus, bet kurie dirba su skaičiais su prielaidom, kai nuo tų skaičių priklauso milijonų likimas, tai tikrai niekas tau nepraleis kažkokio žinai autopiloto.

Tiesiog trūksta pasitikėjimo tuo dalyku.

Taip, joks vadovas, tau nesutiks su procesu, kad va įeities duomenys, išeities duomenys, viskas vyksta po vandeniu. Visi skaičiavimai, visa kita žinai, aš kažkur suvedžiau, jis man iššovė, kaip jis tą gavo - nežinau.

Ta prasme tokio atsakymo niekas nepraleis, turi būti labai aišku iki niuansų kiekvienam žingsneliui, kas kaip ir kodėl.

Nes nuo to priklauso labai dideli pinigai ir čia tikrai jokioj įmonėj taip nepraleis.

Nebent kažkokią siaurą sritį, pavyzdžiui, mažmeninėje prekyboje, kur yra labai dideli skaičiavimai, kur nėra vardų pavardžių, žinai, kur jisai gal būtent kažkokios va tendencijas ar pardavimus pagal kategorijas prognozuoti, tokius gali leisti.

Bet kol aš dirbau mažmeninėje prekyboje, tai buvo prieš kokius penkis šešis metus tikrai dar to nebuvo.

Šita schema kur tu man rodei, jina realiai ir atspindi realybę, kaip viskas vyksta, arba bent jau labai labai panašiai.

Tik tiek, kad visą procesą daro žmonės, jie daug diskutuoja tarpusavy, žiūri ir į tą statistiką, bet tikrai pagrinde gyvas ūkiškas pokalbis vyksta.

O dirbtinis intelektas, tai aš nežinau, vat jeigu man reikėtų surinkti apie, pavyzdžiui, kažkokią rinką, tai galbūt taip. Vat rinkos talpų skaičiavimui reikalingos informacijos surinkimui super, manau super.

Toks daugiau kaip padėjėjas susirinkti informaciją, bet ne prognozuoti ją?

Taip jo. Dirbtinis intelektas, aš daugiau jį matyčiau kaip instrumentą, kaip Excel'is, kaip vat pilotas.

Realiai visą sudėtinga į darbą, ir visus kritinius sprendimus, ir visose kritinėse fazėse, ir visą atsakomybę neša finansų analitikas, įmonės vadovai.

Dirbtinis intelektas gali būti pajungiamas maždaug ten, kur kai jau pakyla, kai viskas be incidentų ir kai ten tiesia linija skristi virš debesų, tada jį ten laikinai įjungia.

Ir jisai tą padaro, bet vis tiek visą laiką tie lakūnai pridėję ranką laiko ir bet kada jį gali išjungti. Tai daugiau požiūris į jį, kaip į tokį asistentą, kaip į Excel'į, kaip į darbo priemonę. Aš tai žiūrėčiau kaip į darbo priemonę, bet ne kaip į virtualų finansų analitiką.

Jis gali kažką padaryti greičiau, tuos blogus darbus, fizinį darbą, ten žinai kažką surinkti informaciją, bet tikrai ne paimta taip pokšt žinai įmonėje, kur dirba vienas dirbtinis intelektas finansų analitiku, kitas dirbtinis intelektas direktoriumi, trečias vadybininku. Čia gal kažkienu ir fantazija, bet toli gražu dar ne realybė.

Vat dar kur galėtų, tai dokumentų, sąskaitų suvedimas į programą automatinis, kuris sąskaitą skenuotą internetu man automatiškai suvestų į programą. Labai mechaninis veiksmas.

Kol kas niekas dar to įmonėje nepadarė, yra kažkokios automatizuotos sistemos, kurios nu labai daug brangiai pinigų ima už kiekvienos eilutės automatinį va tokį įvedimą.

Tai jis kaip instrumentas, kaip padėjėjas, kaip tas pats Excel'is, virtualus asistentas bet ne analitikas.

4 priedas. Interviu transkriptas Nr. 4

Priedas. Interviu nr. 1

Informantas: Asmuo nr. 1

Interviu trukmė: 43 min.

Ačiū, kad sutikai dalyvauti mano apklausoje. Pradžioje norėčiau pradėti nuo pačio konteksto, gal gali papasakoti apie savo darbinę patirtį. Kokios tavo dabartinės atsakomybės, kokiam sektoriui dirbi ir panašiai?

Tai aš tikriausiai, galima sakyti, dirbu telekomunikacijų sektoriuje tarptautinėje įmonėje, dirbu finansų kontrolės srityje. Esu reguliavimo prižiūrėjimas, tikrinu, kad skaičiai ir periodai atitiktų prognozes ir kad viskas būtų pagal reikalavimus atlikta. Žodžiu, atsakinga už projektų finansinę dalį.

Su kokiomis prognozėmis susiduri savo darbe?

Kiekvieną dieną dirbu su trumpalaikėmis prognozėmis, tai ketvirčio. Aišku mes turime ir metines, bet aš labiausiai esu įsitraukusi į trumpalaikes ketvirtines. Pagrindė į pajamų prognozavimą, pardavimų ir tas visas specifines pajamų pripažinimo dalis. Nu ir kaštų priežiūra, bet daugiau trumpalaikės prognozės, o ne gamybos.

Gal gali papasakoti, kaip atrodo prognozavimas, procesas tavo įmonėje, kokie žmonės tame dalyvauja, kokios jų atsakomybės?

Pirmines formas kas daro aš tau visiškai neatsakysiu, nes aš visiškai neturiu jokio inputo, kas yra susijęs su pačia gamyba, kuri yra absoliučiai viskas atskirai, kas yra susijęs su pardavimais ir panašiai tai. Su mano dalim tai, kas yra atsakingas, tai yra verslo kontrolierius, kuris prižiūri šitą visą procesą. Kas yra atsakingas už pajamų pačių tarkim mėnesio ir ketvirčio tai yra Project Delivery Manager, AM'ai atsakingi už užsakymų priėmimų procesą, iš kaštam mes turim Cost Project Manager, kuria atsakingi už tai, kad iš esmės kas vyksta įmonėje, jeigu tau tokį lengvesnį procesą, kaip mes dirbame, tai būtent toje verslo grupėje, kurioje aš dirbu, mes turime dabar naujai įdiegta sistema, kurioje yra įdiegti duomenų pagrindu veikiantys procesai, kurie leidžia mums naudoti quantities ir jų vidutinius kaštus, bet kadangi kaip žinom, kaštai yra, ypač kas yra susiję su gamyba yra, svarbi informacija, kuri yra saugoma įmonėje, tai mes teoriškai su tikrais kaštais nelabai dirbame ir tai ateina per visus raportavimo įrankius ir automatiškai priklausomai nuo pardavimų. Tai, jeigu mes žiūrime į savikainą, tai realiai su šita dalim visiškai aš nedirbu šiuo metu. Visa kita kas eina po to, tai atsakingas Business Manager'is kuris atsakingas už komandas projektų. Virš jo yra Marketingo unit with controller, kuris yra atsakingas už market unit'ą, ir dar viršuj turim kontrolierius, kurie irgi yra atsakingi už įmonę.

Ką girdžiu, kad pas jus dalyvauja labai daug skirtingų, sakykim, departamentų su labai daug skirtingų žmonių, kaip suvaldote procesus ir kokius įrankius naudojate?

Bendru įmonės mastu aš tau neatsakysiu, bet su kuo mes asmeniškai dirbame, tai čia yra visiškai naujai įdiegtas sistema PlanUp, kur kiekvienas, kuris turi ribotą prieigą prie tam tikrų jam aktualių aksesuarų ir kuris kiekvienas yra atsakingas už tą tuos dalykus. Nu, tarkim, kaip ir dėl gerai menedžeris yra atsakingas, tarkim, už paravimus, tis atsakingas už procesų priežiūrą, kad būtų teisingai viskas atlikta ir atitiktų reikalavimus.

Ar prognozėms naudojami tik istoriniai duomenys ar ir kiti šaltiniai? Ar duomenų kiekis, ar duomenų kokybė turi didesnę įtaką prognozių tikslumui?

Jeigu mes žiūrėsime kompanijos mastu, kai yra daromos prognozės, tai yra analitikai, kurie atsižvelgia tikrai į visus tuos dalykus ir rodiklius, daro prognozes, kurios yra daromos, remiantis visais taip tiek išoriniais, tiek vidiniais duomenimis, klientų info. Vidiniuose trumpalaikių projektų prognozės proceso, kur turim klientus specifinius, projektus, užsakymus, tai mes žiūrime kas vyksta dabar įmonėje, vertiname rizikas, kas gali nutikti su tuo klientu. Būna pasibaigia biudžetas ar užtrunka, nežinau, tarkim Rusijos atvejis ir panašiai. Aišku yra dalykai, kurie utinka ir į kuriuos reikia atsižvelgti. Kadangi yra labai didelė įmonė, daug biurokratijos, tai mes prieinam tik prie tos informacijos, kuri mum duota, tai jinau jau susisteminta ir tik būtina pateikiama. Toliau visą info konsoliduojama ir toliau eina sekantys procesai.

Okey, dėkui ar naudojate dirbtinį intelektą savo darbe?

Turim naudoti bet ar yra naudojama dabartiniai prognozei daryti? Tai yra testuojama, bet mes turime įmonės viduje DI, kuris yra kaip įmonės ChatGPT, tai ar aš asmeniškai naudoju, tai ne, nes tai specifine info, o platesniu spektru, įmonės lygiu, tai aš manau, kad tikrai žmonės naudoja iki tam tikro lygio kaip agentą, bet viskas atsimuša į duomenų saugą.

Ar naudojate didžiuosius duomenis?

Tai yra naudojama, bet aš tiesiog su tuo nedirbu. Tai aš tau negalėčiau prasiplėsti ir kažką pasakyti, kad aš tau aš žinau ir naudoju. Aš tiesiog nedirbu su ja. Analitikai, kiek žinau, gauna jau apdirbtą info ir tik tą, kuri jiems būtina darbui. Kadangi yra daug departamentų, daug žmonių skirtingų, rinkų net iš tikro, tai labai aiškios ribos yra kiek kas kokios info gauna, niekas neleidžia bet kam prieiti prie didelių kiekių informacijos. Tai taip, analitikai ją gauna, bet jau susistemintą. Inžinieriai duomenų su ta raw informacija dirba ir ja tvarko.

Dabar vėl grįžtant prie pačio prognozavimo proceso ar dalyvauja tame procese kažkokio ekspertinės įžvalgos. Tai papildoma informacija, kuri neatsispindi, sakykim, istoriniuose šaltiniuose, įmonės rodikliuose, bet yra papildoma informacija, ką žino o vadovas, ką žino team lead'as, ką reikia įvertinti toje prognozėje? Gal gali truputėlį pakomentuoti?

Su tuo ką mes dirbam, tai yra info, kuri ateina tiesiai pas žmones, kurie dirba su klientais tiesiogiai, ir ją žino tik klientai ir jie. Ir tuomet, kur vyksta derybos ir kas yra daroma, tai jie patys tiesiog įdeda į prognozes. Tai yra nuolatinis procesas, kuris yra džasmin tai ir visa kita daroma bei standartų. Įmonės mastu irgi tikrai yra ekspertinės žinios, kurios koreguoja prognozes.

Norėčiau dabar tavo nuomonės, apie integruotą teorinį modelį. Modelio veikimo principas: pirmiausia dirbtinis intelektas, naudodamas didelius istorinių ir kitų duomenų kiekius, pateikia pirminę prognozę, grįstą tik istoriniais duomenimis. Į modelį integruojamos ir papildomos ekspertinės išvalgos, kurių pasitikėjimo lygį prognozėje sprendžia situacijos panašumo vertinimo rodiklis, kuris lygina esamą organizacijos situaciją su prognozuojama. Jei prognozė panaši į esamą situaciją, didesnis pasitikėjimas skiriamas pirminei modelio prognozei, jei ne – eksperto išvalgų korekcijoms. Galiausiai modelis pateikia galutinę integruotą prognozę, bei prognozės paaiškinimą (dėl ko, kaip ir kas kito).

Tai probably galbūt ir veiktų, bet čia tiesiog tikriausiai atsimuša į tai, kaip kiekviena įmonė yra susidėliojus savo prognozės procesą, nes kai kas jau turi pokyčių stebėjimą kas mėnesinį, galiausiai kai ateini iki metinės prognozės, tu jau turi matymą, kas buvo kitaip, lyginant su prognoze. Jeigu žiūri į ateitį ir jeigu tu žiūri ne į smulkią prognozę, žiūri į didesnę, tai tas patikimumo vertinimas ateityje, remiantis praeities duomenimis, dar tikriausiai labai priklauso nuo rinkos ir sektoriaus, kuriam tu dirbi. Jo, nes, jeigu mes dirbam sektoriuje, kuriame jau yra labai viskas stebima, tai aišku, kad tu gali pasiremti tais praeities duomenimis. Bet jeigu mes žiūrim, kur yra labai didelė konkurencija ir pastoviai juda ir keičiasi dalykai ir turi augti pačios įmonės ir produktai, ir technologija, tai tikrai pritaikoma. Tai tuomet tos ekspertų išvalgos ir visa kita gaunasi vos ne neišskiriami dalykai nuo prognozės ir kad mes turim tuos nuokrypius didesnius ar mažesnius, tai man tiesiog atrodo tai savaime suprantama. Tai eksperto išvengti neįmanoma. Niekada prognozėnebus centas į centą, niekada neatitiks šimtu procentų, nes visą laiką kažkas nutinka, visą laiką būna kažkas nenumatyta. Aš tiesiog negaliu įsivaizduoti prognozės be eksperto išvalgos, jeigu mes žiūrim į ateitį. Ir ypač jeigu mes žiūrim į pardavimus. Iš kitos pusės, jeigu įmonė dirba labai ilgai, ateityje mes matom tą cikliškumą istoriniuose duomenyse, tai tas irgi gali padėti ir tada mes galim galbūt išvengti tos ekspertinės išvalgos. Kas tada būtų tikrai naudinga, bet tikriausiai tai reikalautų daug testavimo. Bet tai vis tiek liktų tik kaip papildomas įrankis, nes nu viso proceso pakeisti vienas modelis negali.

Kur dar būtų gerai modelis šitas, tai ten, kur labai dideli egzistuoja duomenų svyravimai, ir kur turim technologines įmones, kur labai daug kaupia duomenų, kur Big data gali jau tikrai prognozuoti trendus pagal turimą sukauptą info.

Ir dar, man atrodo, kad mes galėtumėm integruoti ekspertinę žinias ir aplamai naudoti tokį modelį, tai kokio galingumo įrenginio ar kompiuterio reikėtų, nes tai yra labai labai didelio masto duomenys ir procesas, ko šiandieninis verslas ne kiekvienas gali sau leisti ir turi laiko ir kaštų diegti. Dirbtinis intelektas aplamai dar neturi to loginio mąstymo, ir jam interpretuoti žmogaus mintis, tai šiuo atveju ekspertinė žinias, yra realiai neįmanoma. Nebent ta sudėta info labai tiksli ir jau sukiekybinta, bet šiaip perteikti mintis ar jausmus DI yra neįmanoma, nes jis nesupranta. Visa tai yra matematika, formulės, ir jeigu mes neturime labai aiškių duomenų, kurie parodytų tam tikrą nuokrypį, tiesiog yra neįmanoma išvengti tų ekspertinių išvalgų ir korekcijų darymo, tai yra būtina dalis prognozei. Nes dirbtinis intelektas jis pats nenuspręs ir nepajaus. Ir šiaip, versle analitikoje daug ir įtakos turi pajautimas, kaip tu jauti rinką, kuom jinai kvėpuoja. Rinka kuo toliau, tuo labiau yra nebeįsėjama, išskirtys labai didelės atsiranda, tai papildomą korekciją būtina integruoti į prognozes.

Kaip vertini patį dirbtinio intelekto naudojimą, sakykim finansų sritį, tiek kontrolei, tiek analitikoje. Ir ar tai yra daugiau kaip galimybė ar grėsmė ateityje?

Kur yra DI problema, kad jis vis dar negali logiškai mąstyti, jis neturi loginio mąstymo. Jisai tau gali patarti, bet pats sugalvoti negali. Tai, jo naudojimas darbe yra geras dalykas, nes jis gali pastebėti išimtis, išskirtis, pasikartojančius dalykus, kurio žmogaus akis gali jau nebepagauti. Kol kas mūsų dirbtinis intelektas vis dar negali pakeisti, bet jis yra galimybė įmonėms žiūrėti smulkiau ir matyti daugiau ir turėti tikslesnes prognozes, arba tiesiog įvertinti situaciją realiau. Dirbtinis intelektas yra dar gerai tuo, kad tu gali jį patį kažkiek mokyti ir prisitaikyti iš savo įmonės pusės kažką, tai man tai tiesiog yra galimybė. Pačio analitiko, žmogaus smegenų kol kas jisai dar negali pakeisti, jeigu mes žiūrim iš tos grėsmės, tai ji nelabai egzistuoja. Duomenų analizę gali pakeisti, tą techninę sritį, formulių sudarymą, bet pačio analitinio mąstymo tai niekaip. Jis tinka sferai, kur reikia daug apribojimų, kur egzistuoja taisyklės, nes jam tada nereikia pačiam mąstyti, tik daryti. Tai mano toks, nežinau, pas mus jau įmonės labai kalba apie tą integravimą DI, tai čia jau yra ateitis, tai galvoti kažkaip kitaip, kad DI nebus kasdeinybės dalis, yra labai keista tiesiog. Tai nebūtų nei kliūtis, nei trukdis ar kažkas blogo, tai tiesiog taps gyvenimo dalis ir viskas, bus integruota į procesus.

5 priedas. Interviu transkriptas Nr. 5

Priedas. Interviu nr. 1

Informantas: Asmuo nr. 1

Interviu trukmė: 41 min.

Papasakokite apie savo profesinę patirtį finansų srityje. Kokia yra jūsų dabartinė pozicija ir pagrindinės atsakomybės? Kokiame sektoriuje dirbate (pvz., bankininkystė, investicijos, draudimas, fintech ir pan.)?

Šiuo metu dribu vyr finansų kontrolieriumi. Pagrindinės atsakomybės yra įmonės piniginių srautų stebėsina, biudžeto sudarymas, laikimasis ir koregavimas, ataskaitų teikimas akcininkams bei specifinių užklausų arba užduočių atlikimas akcininkų arba kitų prašymu.

Kokio tipo prognozes dažniausiai atliekate (pvz., pajamų, rizikos, rinkos tendencijų ir pan.)?

Atlieku pajamų ir su jais susijusių išlaidų prognozę

Kaip atrodo prognozavimo procesas jūsų organizacijoje? Kokie pagrindiniai etapai, kas dalyvauja šiame procese?

Analizuojama užsienio rinka ir jos tendencijos, politiniai pokyčiai, įvertinami įspėjimai apie kainų pokyčius užsienio šalyse bei žiūrima į istorinius duomenis siekiant įvertinti įvairių situacijų poveikį įmonės rezultatams. Pagal tai nustatomas yra įmonės tikslas (ar siekiama didinti pajams ar mažinti sąnaudas arba išlaikyti dabartinę poziciją) ir pagal tai yra sudaroma reali, logiška prognozė.

Ar prognozėms naudojami tik istoriniai duomenys ar ir kiti šaltiniai? Ar duomenų kiekis, ar duomenų kokybė turi didesnę įtaką prognozių tikslumui?

Prognozėms naudojami ne tik istoriniai duomenys bet ir vertinami politiniai faktoriai, kurie galėtų turėti įtaka savikainai bei kainų svyravimams.

Ar savo darbe naudojate dirbtinio intelekto sprendimus? Jei taip – kokius įrankius ar technologijas naudojate?

Šiuo metu dirbtinis intelektas naudojamas tik siekiant pasikonsultuoti kaip geriausia parašyti SQL užklausą, kad mažiau naudotų kasdieninių resursų

Kaip vertinate DI tikslumą, lyginant su tradiciniais paieškos ar prognozių metodais?

Priklauso nuo to kaip yra pateikiama užklausa. Jeigu užklausa pateikiama tiksli ir aiški tada DI yra labai tikslūs mano nuomone

Kokie, Jūsų nuomone, yra pagrindiniai DI naudojimo privalumai finansinėje analizėje? Kokie yra pagrindiniai trūkumai ar apribojimai?

Didžiausias trūkumas yra sudėtinga aprašyti tiksliai kas yra norima iš DI bei Dirbtinis intelektas negali žinoti visų įmonėje atliekamų procesų reiškius jis negali paaiškinti priežastčių kodėl susidaro būtent toks rezultatas , o ne kitoks

Ar jūsų organizacijoje naudojami didieji duomenys (angl. Big Data)? Jei taip – kokio pobūdžio tai duomenys (struktūruoti / nestruktūruoti, vidiniai / išoriniai)?

Nenaudojame Big Data

Kokius iššūkius patiriate dirbant su dideliais duomenų kiekiais?

Negalima tiesiog „parsisiųsti“ duomenys iš programos ir jas nagrinėti , reikia pateikti tikslinga užklausa siekiant neužstrigdinti serverių ir kompiuterio. Taip pat kuo didesnis kiekis duomenų tuo yra didesnė galimybę turėti blogus duomenis (kurie neteisingu formatu užpildyti, neteisingai užrašyti arba klaidingai užrašyti)

Kiek svarbios ekspertinės įžvalgos prognozavimo procese? Kaip šios įžvalgos yra integruojamos į prognozes?

Ekspertinės įžvalgas prognozavimo procese nenaudojame, nes pastebėjome, kad jos dažnai nepasiteisina

Kaip vertinate subjektyvumo įtaką prognozių tikslumui?

Subjektyvumas dažniausiai atsiranda interpretuojant politinius pareiškimus prognozės procese, tačiau subjektyvumas yra išgryninamas einant laikui ir tobulinimas iki objektyvumo naudojant patirtį ir istorinius duomenis

Modelio veikimo principas: pirmiausia dirbtinis intelektas, naudodamas didelius istorinių ir kitų duomenų kiekius, pateikia pirminę prognozę, grįstą tik istoriniais duomenimis. Į modelį integruojamos ir papildomos ekspertinės įžvalgos, kurių pasitikėjimo lygį prognozėje sprendžia situacijos panašumo vertinimo rodiklis, kuris lygina esamą organizacijos situaciją su prognozuojama. Jei prognozė panaši į esamą situaciją, didesnis pasitikėjimas skiriamas pirminei modelio prognozei, jei ne – eksperto įžvalgų korekcijoms. Galiausiai modelis pateikia galutinę integruotą prognozę, bei prognozės paaiškinimą (dėl ko, kaip ir kas kito). Kaip vertinate pateiktą modelį? Ar, jūsų nuomone, toks modelis galėtų būti pritaikytas realioje organizacijoje?

Šitas modelis beveik atitinka tai, kuri naudoja beveik visos organizacijos. Vienintelis skirtumas, kad mano organizacijoje nenaudojame ekspertinės nuomonės.

Kokios modelio stipriosios pusės? Kokie galimi trūkumai ar silpnosios vietos?

Stipriausios pusės, kad prognozė turi būti pagrįsta duomenimis o ne subjektyvu spėjimu. Taip pat yra gerai, kad gilinamasi į pačius duomenis ir koks jų yra poveikis įmonės potencialiems rezultatams. Silpnosios pusės kaip ir visose prognozės modeliuose yra, kad nepriklausomai nuo to ar jei yra istoriniai duomenys – rezultatas gali neplanuotai pasikeisti dėl kažkokių specifinių faktorių grupės, kurių yra itin sudėtinga nuspėti.

Ko, jūsų nuomone, modeliui trūksta? Kokius pakeitimus ar patobulinimus siūlytumėte? Kokiose situacijose ar sektoriuose toks modelis būtų naudingiausias?

Šis modulis yra naudojamas beveik visose organizacijose, kurios yra ne finansinio pobūdžio (kaip logistika, pramonė ir t.t.). Modulyje trūksta įmonės tikslo dalies, kur įmonė planuoja turėti tam tikrus pokyčius savo rezultatuose dėl planuojamos plėtros/naujos veiklos/naujos įrangos ir t.t.

6 priedas. Interviu transkriptas Nr. 6

Priedas. Interviu nr. 1

Informantas: Asmuo nr. 1

Interviu trukmė: 38 min.

Gal galite trumpai papasakoti apie įmonės veiklą ir sektoriaus specifiką?

Aviacijos techninės priežiūros sektorius yra labai specifinis ir griežtai reguliuojamas. Įmonė dirba su orlaivių remontu, techniniu aptarnavimu ir komponentų tiekimu. Didelė dalis veiklos priklauso nuo įvairių sertifikatų, licencijų ir tarptautinių reguliavimo reikalavimų. Kiekviena detalė – net ir mažiausias komponentas – turi atitikti tam tikrus standartus. Dėl to darbuotojams reikia nemažai laiko suprasti procesus, klientų poreikius ir techninę specifiką.

Kaip jūsų įmonėje atrodo prognozavimo ir planavimo procesas?

Įmonėje daugiau dirbama ne su teorinėmis prognozėmis, o su detalizuotu planavimu ir biudžetavimu. Yra sudaromi penkerių metų planai, metiniai biudžetai bei trumpalaikiai pinigų srautų planai. Biudžetų rengime dalyvauja daug skirtingų komandų – pardavimų vadybininkai, finansų analitikai, verslo kontrolieriai ir vadovai. Planuojant vertinami konkretūs klientai, jų turimi orlaiviai, remonto ciklai, sezoniškumas bei turimi pajėgumai.

Kokie duomenys naudojami planuojant veiklą ir pajamas?

Naudojami tiek istoriniai duomenys, tiek ekspertinės darbuotojų žinios. Analizuojama ankstesnių remontų istorija, orlaivių amžius, skraidymo regionai, techniniai gedimai ir klientų elgsena. Taip pat svarbus sezoniškumas – dauguma orlaivių aktyviausiai remontuojami ne vasaros sezono metu. Pagal tai planuojamas darbuotojų užimtumas, angarų pajėgumai ir reikalingų komponentų kiekiai.

Kiek prognozavimo procese svarbios ekspertinės žinios?

Ekspertinės žinios yra labai svarbios, nes vien tik istoriniais duomenimis remtis nepakanka. Aviacijos sektoriuje daug įtakos turi išoriniai veiksniai – reguliaciniai pokyčiai, audita, klientų sprendimai ar geopolitinė situacija. Dėl to prognozės ir planai nuolat koreguojami pagal naujai atsirandančią informaciją. Didelę reikšmę turi darbuotojų patirtis ir gebėjimas įvertinti specifines situacijas.

Kaip vyksta biudžeto kontrolė ir planų tikslinimas?

Įmonėje nuolat lyginamas planas su faktiniais rezultatais. Kiekvieną savaitę ar mėnesį vertinama, kokie nukrypimai atsirado ir dėl kokių priežasčių jie susiformavo. Jeigu keičiasi klientų poreikiai, vėluoja sertifikatai ar atsiranda papildomi kaštai, planai yra koreguojami. Procesas vyksta nuolat ir yra glaudžiai susijęs su kasdieniu veiklos valdymu.

Kaip įmonė valdo tokį didelį kiekį procesų ir informacijos?

Procesų valdymui naudojamos įvairios IT sistemos bei automatizavimo sprendimai. Dalis procesų yra automatizuojami – pavyzdžiui, sąskaitų apdorojimas, logistinių duomenų suvedimas ar informacijos perdavimas tarp sistemų. Tačiau dėl sektoriaus specifikos pilnai automatizuoti visų procesų neįmanoma, todėl labai svarbi išlieka darbuotojų kompetencija ir bendradarbiavimas tarp padalinių.

Kaip vertinate sektoriaus dinamiką ir pokyčius?

Aviacijos sektorius yra labai dinamiškas ir nuolat besikeičiantis. Kiekvieni metai atneša naujų klientų, skirtingų situacijų ir naujų iššūkių. Dėl to planavimo ir prognozavimo procesai turi būti lankstūs, o darbuotojai nuolat prisitaikyti prie besikeičiančios aplinkos.

Dabar norėčiau paprašyti Jūsų pakomentuoti šį teorinį modelį. Modelio veikimo principas: pirmiausia dirbtinis intelektas, naudodamas didelius istorinių ir kitų duomenų kiekius, pateikia pirminę prognozę, grįstą tik istoriniais duomenimis. Į modelį integruojamos ir papildomos ekspertinės įžvalgos, kurių pasitikėjimo lygį prognozėje sprendžia situacijos panašumo vertinimo rodiklis, kuris lygina esamą organizacijos situaciją su prognozuojama. Jei prognozė panaši į esamą situaciją, didesnis pasitikėjimas skiriamas pirminei modelio prognozei, jei ne – eksperto įžvalgų korekcijoms. Galiausiai modelis pateikia galutinę integruotą prognozę, bei prognozės paaiškinimą (dėl ko, kaip ir kas kito).

Šiaip pats modelis man atrodo logiškas, nes realybėje vien tik istoriniais duomenimis remtis tikrai neužtenka. Ypač tokiuose sektoriuose kaip aviacija, kur labai daug kas priklauso nuo reguliavimo, sertifikatų, auditų, klientų sprendimų ar net geopolitinių dalykų. Tai tas ekspertinių įžvalgų įtraukimas man atrodo labai svarbus ir praktiškai reikalingas. Man iš tikrųjų įdomiausia vieta yra tas situacijos panašumo vertinimas. Nes mes ir dabar praktiškai nuolat lyginam planą su faktu, žiūrime, kur buvo nukrypimai, kodėl jie atsirado, kas pasikeitė. Tai pats principas nėra svetimas. Tik man atrodo, kad labai priklauso nuo sektoriaus, kiek galima pasitikėti vien istoriniu modeliu. Jeigu rinka stabili, cikliška, mažai pokyčių – tada tikrai galima labiau remtis praeities duomenimis. Bet jeigu aplinka labai dinamiška, kaip pas mus, tai ekspertinės žinios vis tiek lieka labai svarbios. Patinka ir tai, kad modelis nebando eliminuoti žmogaus. Nes bent jau mano akimis, prognozavime vien tik skaičių neužtenka. Labai daug ateina iš patirties, iš supratimo apie klientą, rinką, procesus. Kartais yra dalykų, kurių tiesiog nesimato duomenyse, bet žmonės jau žino, kad jie turės įtakos rezultatui. Dar

man atrodo naudinga tai, kad modelis ne tik sugeneruoja prognozę, bet ir paaiškina, kodėl toks rezultatas gautas. Nes praktikoje labai svarbu suprasti ne tik skaičių, bet ir priežastį – kodėl pasikeitė pajamos, kodėl atsirado nuokrypis, kokia rizika atsirado. Tada jau galima priimti sprendimus. Aišku, man atrodo, kad toks modelis labiau tiktų planavimui, biudžetavimui ar ilgesnio laikotarpio prognozėms, o ne labai operaciniams kasdieniams sprendimams. Ir dar tikriausiai reikėtų labai daug testavimo skirtinguose sektoriuose, nes kiekviena įmonė turi savo specifiką ir savo procesus. Bet kaip sprendimų palaikymo įrankis, kuris padeda susisteminti informaciją ir įvertinti, kiek galima pasitikėti prognoze, man jis atrodo tikrai prasmingas.