

VILNIAUS UNIVERSITETO

KAUNO FAKULTETAS

**SOCIALINIŲ MOKSLŲ IR TAIKOMOSIOS INFORMATIKOS
INSTITUTAS**

Finansų technologijų studijų programa

Kodas 6211BX022

AKVILĖ RIBIKAUSKAITĖ

MAGISTRO BAIGIAMASIS DARBAS

**DIRBTINIO INTELEKTO METODŲ INTEGRACIJA FINANSINĖS
RIZIKOS VERTINIMUI NAUDOJANT VIRTUALIUOSIUS
ASISTENTUS**

Kaunas 2024

VILNIAUS UNIVERSITETO

KAUNO FAKULTETAS

**SOCIALINIŲ MOKSLŲ IR TAIKOMOSIOS INFORMATIKOS
INSTITUTAS**

AKVILĖ RIBIKAUSKAITĖ

MAGISTRO BAIGIAMASIS DARBAS

**DIRBTINIO INTELEKTO METODŲ INTEGRACIJA FINANSINĖS
RIZIKOS VERTINIMUI NAUDOJANT VIRTUALIUOSIUS
ASISTENTUS**

**INTEGRATION OF ARTIFICIAL INTELLIGENCE METHODS FOR
FINANCIAL RISK ASSESMENT USING VIRTUAL ASSISTANTS**

Leidžiama ginti

Magistrantas_____
(parašas)

Darbo vadovas_____
(parašas)

____Dalia Krikščiūnienė, Prof., Dr._
(darbo vadovo mokslo laipsnis, mokslo
pedagoginis vardas, vardas ir pavardė)

Darbo įteikimo data

Registracijos Nr.

Kaunas 2024

TURINYS

PAVEIKSLŲ SĄRAŠAS	5
LENTELIŲ SĄRAŠAS	6
ĮVADAS.....	7
1. VIRTUALŪS ASISTENTAI FINANSINIŲ PASLAUGŲ RIZIKAI VERTINTI	10
1.1. Pokalbių robotų tipai, techninė struktūra ir funkcionavimas	10
1.1.1. Taisyklėmis pagrįstų pokalbių robotų techninė struktūra, kūrimo etapai	12
1.1.2. Dirbtinio intelekto pokalbių robotų techninė struktūra (mašininis mokymas ir natūralios kalbos apdorojimas)	15
1.1.3. Matematinų modelių integravimas į pokalbių robotus ir jų poveikis veikimo procesams bei naudojimo scenarijams	17
1.2. Finansinių paslaugų funkcijų integravimas verslo ir individualių vartotojų poreikių bei UX (angl. user experience) kriterijų atžvilgiu	20
1.2.1. Pagrindinės finansinių paslaugų rūšys ir jų reikšmė verslui ir individualiems vartotojams ..	21
1.2.2. Fintech inovacijos ir jų poveikis įvairių verslo sektorių ir individualių vartotojų sąveikos sistemose	23
1.2.3. Vartotojų poreikiai ir kaip virtualūs asistentai gali būti naudojami efektyviam asmeniniam aptarnavimui, patirties gerinimui ir našumo didinimui, atsižvelgiant į vartotojų patirtį.....	26
1.3. Virtualių asistentų naudojimo galimybės finansų sektoriuje	27
1.3.1. Taisyklėmis pagrįstų ir dirbtinio intelekto pokalbių robotų palyginimas: lankstumas ir adaptacija į vartotojų poreikius	27
1.3.2. Virtualių asistentų funkcijos, reikalingos teikti finansines paslaugas.....	29
1.3.3. Finansinės rizikos vertinimo metodų integracija į virtualius asistentus.....	31
2. DIRBTINIO INTELEKTO SPRENDIMAI - MATEMATINIAI MODELIAI SKOLŲ GRAŽINIMO IR RIZIKOS VERTINIMO ANALIZĖJE	33
2.1. Duomenų paruošimo metodai	33
2.1.1. Standartizacija ir normalizacija.....	34
2.1.2. Duomenų balansavimo metodai	34
2.2. Mašininio mokymosi metodai paskolų rizikos analizėje	35
2.2.1. Logistinės regresijos metodas	35
2.2.2. Atsitiktinių miškų metodas	36
2.2.3. XGBoost metodas	38
2.3. Giliojo mokymosi metodai.....	38
2.3.1. Daugiapakopis perceptronas (MLP)	38
2.3.2. Ilgalaiškės atminties modelis (LSTM).....	40
2.3.3. Modelio mokymosi ir testavimo žingsniai giluminiame mokyme.....	42
2.4. Dirbtinio intelekto modelių integracija virtualiuose asistentuose	44
2.4.1. Kūrimo aplinkos, jų galimybės ir privalumai	44
2.4.2. API svarba virtualių asistentų kūrime	45
3. MAŠININIO MOKYMOSI IR VIRTUALAUS ASISTENTO INTEGRUOTO MODELIO EKSPERIMENTINIS TYRIMAS PASKOLŲ GRAŽINIMO IR FINANSINIŲ RIZIKŲ VERTINIMUI.....	47
3.1. Duomenų analizė ir pasiskirstymas.....	48
3.2. Duomenų klasifikavimas ir klasterizacija	51
3.3. Rizikos veiksnių sąryšio ir koreliacijos analizė	54
3.4. Dirbtinio intelekto sprendimas: mašininio mokymosi modeliai	56
3.4.1. Duomenų apdorojimo ir modelių treniravimo etapai.....	57
3.4.2. Mašininio mokymosi modelių optimizacijos ir tobulinimo procesai.....	58

3.4.3. Eksperimentų rezultatai ir palyginimas.....	59
3.4.4. Mašininio mokymo modelių pritaikymas virtualiuose asistentuose	61
3.5. Dirbtinio intelekto sprendimas: giliojo mokymosi modeliai	62
3.5.1. Duomenų apdorojimo ir modelio paruošimo žingsniai.....	62
3.5.2. Giliojo mokymosi modelių kūrimas ir algoritmų naudojimas	64
3.5.3. Modelių rezultatai ir lyginamoji analizė	65
3.5.4. Mašininio mokymo ir giliojo mokymo modelių palyginimas.....	66
3.6. Dirbtinio intelekto modelių integracija į virtualų asistentą: realizacija	67
3.6.1. Virtualaus asistento integracija Gradio aplinkoje naudojant Open AI.....	68
3.6.2. Virtualaus asistento veikimo demonstracija.....	71
IŠVADOS IR PASIŪLYMAI	76
LITERATŪRA	77
PRIEDAI.....	81

PAVEIKSLŲ SĄRAŠAS

1 pav. Pokalbių roboto veikimo principas.....	12
2 pav. Mašininio mokymosi ir giliojo mokymosi padėties dirbtinio intelekto srityje iliustracija	16
3 pav. Atsitiktinių miškų metodo veikimo principas	37
4 pav. MLP veikimo principas	40
5 pav. LSTM veikimo principas.....	41
6 pav. Eksperimentinė tyrimo eiga.....	47
7 pav. Segmentas iš duomenų bazės, naudojamos tyrime.....	48
8 pav. Duomenų bazė: išmokėtos ir neišmokėtos paskolos	49
9 pav. Nemokėjimo tikimybė pagal paskolos paskirtį	50
10 pav. Kredito grąžinimo tendencijos	51
11 pav. GMM klasterizacijos pasiskirstymas.....	52
12 pav. K-means klasterizacijos pasiskirstymas	52
13 pav. Anomalijų aptikimas naudojant Z-score	53
14 pav. Paskolos palūkanų norma pagal paskirtį	54
15 pav. Nemokėjimas pagal palūkanų normos kategoriją.....	55
16 pav. Paskolos duomenų ypatybių koreliacinė matrica	56
17 pav. Pradinis klasių pasiskirstymas	63
18 pav. Klasių pasiskirstymas po SMOTE.....	64
19 pav. Open AI API raktas	69
20 pav. Open AI nustatymai panaudoti virtualiame asistente	70
21 pav. Finansinių rizikų asistentas.....	70
22 pav. Virtualaus asistento veikimo schema	71
23 pav. Vartotojas per virtualaus asistento sąsają pateikia tekstinę užklausą.....	72
24 pav. Ištrauka iš kodo, kurioje virtualus asistentas supažindinamas su kokiomis užklausomis dirbs	72
25 pav. Ištrauka iš kodo, kuri išrenka iš užklauso, skaičiavimams reikalingus duomenis	73
26 pav. Virtualaus asistento atsakymas į vartotojo užklausą	73
27 pav. Sukurto virtualaus asistento veikimo pavyzdys	74

LENTELIŲ SĄRAŠAS

Lentelė 1. Dirbtinio intelekto pokalbių robotų techninė struktūra, taikymo pavyzdžiai ir aprašymas	15
Lentelė 2. Matematinis aspektas ir jo panaudojimas dirbtinio intelekto	17
Lentelė 3. Matematinų modelių integravimas į pokalbių robotus fintech sektoriuje	19
Lentelė 4. Finansinių paslaugų svarba privatiems ir verslo klientams	22
Lentelė 5. Autentifikacijos ir autorizacijos priemonės	30
Lentelė 6. Specifinės konsultacijos ir funkcijos fintech sektoriuje, kurias gali atlikti pokalbių robotai	30
Lentelė 7. Mašininio mokymo metodų, 1 bandymo, rezultatai	60
Lentelė 8. Mašininio mokymo metodų, 2 bandymo, rezultatai	60
Lentelė 9. 1 bandymo klaidų matrica	61
Lentelė 10. 2 bandymo klaidų matrica	61
Lentelė 11. MLP ir LSTM modelių rezultatai	66

SUMARRY

In recent years, the integration of technological advancements and the increasing reliance on artificial intelligence have highlighted the importance of automated solutions in improving operational efficiency and user experience. This paper focuses on integrating artificial intelligence models into intelligent virtual assistants, especially in the financial services sector, to address the challenge of automating loan risk assessment.

The main problem is how artificial intelligence models can be effectively integrated into virtual assistants to automate and optimize the financial risk assessment of loan applicants. Current research reveals significant progress in AI-based customer service tools, but applying these technologies to financial risk assessment using virtual assistants is still unexplored. Reliance on traditional, often manual, risk assessment methods limit efficiency and scalability. This study explores the potential of AI models to improve risk assessment processes by designing and integrating them into a prototype virtual assistant. By analyzing the existing literature and methodologies, the paper identifies key challenges, including the need for accurate, secure, and personalized financial assessments. The study explores mathematical models and machine learning methods for debt repayment and loan risk assessment scenarios.

The result of this research is a prototype of a virtual assistant that can use artificial intelligence to assess financial risks and provide actionable recommendations. By integrating these capabilities, the prototype ensures more efficient and reliable risk assessment, thereby improving decision-making processes for both service providers and customers. This approach contributes to the growing application of artificial intelligence in financial services, highlighting the innovation and practical benefits of virtual assistants in solving complex financial challenges.

IVADAS

Greitėjant gyvenimo tempui bei vykstant nuolatinei technologijų plėtrai vis dažniau dėmesys krypta į dirbtinį intelektą bei jo sprendimus, kurie tobulinami, vardan efektyvesnio kasdienių užduočių automatizavimo, darbo našumo didinimo ir geresnės vartotojų patirties užtikrinimo. Ypatingai svarbūs tampa virtualūs asistentai, dar kitaip vadinami pokalbių robotai, kurie leidžia gerinti aptarnavimo kokybę, greičiau ir efektyviau įgyvendinti paslaugos tiekėjo ir kliento poreikius, o kartu ir vertinti įvairias rizikas. Šiame magistro baigiamajame darbe nagrinėjami dirbtinio intelekto modeliai, skirti finansinių rizikų vertinimui per išmaniuosius virtualius asistentus.

Temos aktualumas

Technologijos greitai keičiasi, taip tobulindamos finansinių paslaugų sektorių, o išmanieji virtualūs asistentai ir dirbtinis intelektas tampa kasdienio gyvenimo dalimi. Šie įrankiai atveria naujas galimybes finansinių paslaugų įmonėms padeda ne tik greičiau ir paprasčiau gerinti vartotojų patirtį, bet ir vertinti įvairias finansines rizikas. Virtualūs asistentai ir dirbtinis intelektas supaprastina ir optimizuoja finansinius procesus, kartu ir keičia vartotojų įpročius bei lūkesčius, užtikrindami nuolatinį dialogą, teikdami reikiamą informaciją, sprenddami problemas ir net vykdydami transakcijas.

Finansinės paslaugos, kurios anksčiau buvo standartizuotos, dabar vis labiau tampa orientuotos į personalizuotas paslaugas, lankstumą ir pokyčius, pagrįstus rinkos ir vartotojų duomenų analitika, algoritmais bei matematiniais modeliais. Nepaisant šių paslaugų svarbos, vartotojai dažnai susiduria su informacijos ir žinių trūkumu. Dėl patirties ir konsultantų stokos jie nepriima ir renkasi nenaudoti tokio tipo finansinių produktų ir paslaugų. Kartais, dėl žinių trūkumo, vartotojai, patys to nežinodami, pasirenka rizikingus ir jiems netinkamus finansinius pasiūlymus. Virtualių sistemų ir dirbtinio intelekto robotų augantis populiarumas skatina tyrinėti jų taikymo svarbą ir galimybes fintech srityje.

Šiame kontekste magistro darbas bus skirtas dirbtinio intelekto metodų analizei, bei jų pritaikymas išmaniesiems virtualiems asistentams finansinių paslaugų srityje – rizikos vertinime.

Problemų ištyrimo lygis

Nors tema apie dirbtinio intelekto sprendimai finansinių rizikų vertime išmaniems virtualiems asistentams (pokalbių robotams) moksliniuose darbuose dar nėra plačiai nagrinėta, yra nemažai tyrimų, kurie yra susiję su panašiomis problemomis bendresniame lygmenyje.

Plačiausiai moksliniuose šaltiniuose aptariamas dirbtinio intelekto taikymas klientų aptarnavimo srityje, įskaitant natūralios kalbos apdorojimą (NLP), pokalbių robotų kūrimą ir optimizavimą, bei jų pritaikymą įvairiose industrijose, įskaitant finansų sektorių (Pham, 2024). Tyrimai rodo, kaip pokalbių robotai gali automatizuoti dažniausiai užduodamus klausimus, spręsti paprastas problemas

ir nukreipti sudėtingesnius klausimus specialistams (Saleem, 2024). Moksliniuose straipsniuose ypatingas dėmesys skiriamas AI sprendimų saugumui ir privatumo klausimams, kadangi itin svarbu apsaugoti klientų duomenis (Sablah ir Mak, 2024). Techniniai aspektai, kaip mašininio mokymosi modelių kūrimas ir integravimas į esamas informacines sistemas, taip pat yra plačiai nagrinėjami dirbtinio intelekto kontekste (Malhotra, 2023).

Atsižvelgiant į tai, kad konkrečios literatūros mano pasirinkta tema nėra daug, esami tyrimai ir metodikos gali būti pritaikyti kuriant virtualų asistentą, finansinių rizikų vertintoją. Tai leidžia apjungti matematinių modelių ir dirbtinio intelekto sprendimus, skirtus išmaniems virtualiems asistentams finansinių paslaugų srityje.

Darbo problema – kaip dirbtinio intelekto modeliai gali būti integruojami į virtualius asistentus, siekiant patenkinti poreikį automatizuotai vertinti paskolos gavėjų finansines rizikas?

Darbo objektas – dirbtinio intelekto modeliai, jų integracija virtualiuose asistentuose finansinės rizikos vertinimui.

Darbo tikslas – ištirti dirbtinio intelekto modelius, pritaikomus virtualių asistentų sistemose ir juos integruoti į virtualų asistentą, siekiant įvertinti paskolos gavėjų finansines rizikas bei teikti rekomendacijas.

Darbo uždaviniai:

Norint pasiekti išsikeltą tikslą, turėtų būti įvykdyti šie uždaviniai:

1. Išnagrinėti virtualių asistentų tipus, jų techninę struktūrą ir vaidmenį finansinių paslaugų sektoriuje.
2. Išanalizuoti matematinių modelių taikymo galimybes finansinės rizikos vertinimui ir virtualių asistentų naudojimą finansų sektoriuje.
3. Aptarti dirbtinio intelekto modelius, naudojamus finansų sektoriuje ir skolų grąžinimo rizikos vertinimams atlikti.
4. Parengti eksperimentinį tyrimą – dirbtinio intelekto modelių tinkamumą paskolų grąžinimo rizikos vertinimams.
5. Sukurti virtualaus asistento prototipą, kuriame integruotas eksperimento metu tirtas dirbtinio intelekto modelis.

1. VIRTUALŪS ASISTENTAI FINANSINIŲ PASLAUGŲ RIZIKAI VERTINTI

1.1. Pokalbių robotų tipai, techninė struktūra ir funkcionavimas

Atliekant literatūros analizę, buvo pastebėta, kad daugelis šaltinių pokalbių robotų apibrėžimą pateikia panašiai, akcentuodami jų gebėjimą automatiškai atsakyti į vartotojų klausimus, vykdyti užduotis ir palaikyti dialogą natūralia kalba, taip gerinant vartotojo patirtį ir efektyvumą įvairiose paslaugų srityse. Pokalbių robotai yra kompiuterinė programa, kuri simuliuoja pokalbį su vartotoju, siekiant perduoti informaciją ar atlikti tam tikrą užduotį (Gillis et al., 2024). Pokalbių robotai apibrėžiami kaip dialogo sistemos, kurios naudoja natūralios kalbos apdorojimo (NLP) technologijas, kad galėtų sąveikauti su vartotojais, teikdami informaciją arba atlikdami specifines užduotis (Wollny et al., 2021). Virtualių asistentų techninė architektūra susideda iš keturių pagrindinių ir kelių papildomų modulių, įskaitant įvesties apdorojimą, dialogo valdymą, atsakymų generavimą ir vartotojo sąsajos modulių (Karyotaki et al., 2022).

Pastaraisiais metais, sparčiai vystantis technologijoms ir tobulėjant dirbtiniam intelektui, pokalbių robotai (angl. chatbot) tapo ypač populiarūs, o pagrindinis veiksnys, lemiantis jų paplitimą, yra technologijų pažanga kartu ir visuomenės susidomėjimas. Dirbtinio intelekto, mašininio mokymosi ir natūralios kalbos apdorojimo technologijos pasiekė aukštą lygį ir tai leidžia kurti sudėtingesnius ir veiksmingesnius pokalbių robotus, be kurių įmonėms ir organizacijoms būtų sudėtingiau patenkinti vartotojų poreikius ir užtikrinti greitą ir efektyvią komunikaciją. Atliktų tyrimų rezultatai įžvelgia ryšį tarp pokalbių robotų ir klientų lojalumo, atskleidžiant pokalbių robotų veiksmingumą didinant klientų lojalumą įvairiose pramonės šakose ir programose. Tai rodo didėjančią visuomenės pasitikėjimą virtualiais asistentais (Jenneboer, Herrando, ir Constantinides, 2022). Technologijų pažanga leidžia pokalbių robotams suprasti ir interpretuoti vartotojų užklausas, atlikti sudėtingesnes užduotis, tobulinti savo veiklą ir adaptuotis prie vartotojų poreikių ir taip vis didinti savo funkcionalumą. Tai ypatingai svarbu verslo aplinkoje, kurioje svarbu pasiūlyti greitą ir efektyvų klientų aptarnavimą bei užtikrinti geriausią vartotojų patirtį. Tyrimai rodo, kad net 88 proc. interneto vartotojų turėjo bent 1 pokalbį su virtualiu asistentu per 2022 metus (Fokina, 2024). Iš to galime daryti išvadą, kad šiandien pokalbių robotų populiarumas ir naudojimas toliau sparčiai auga.

Pokalbių robotų istorija prasideda nuo dvidešimto amžiaus vidurio. Bėgant metams jie buvo integruojami į įvairias pramonės šakas, įskaitant finansus, dėl padarytos didžiulės pažangos. Kaip aiškina Ashfaq, M. W. (2022) pokalbių robotai išsivystė nuo paprastų teksto sąsajų iki sudėtingų pokalbių platformų. Ankstyvieji pokalbių robotai, tokie kaip ELIZA, PARRY ir Jabberwacky, kurių kiekvienas turi unikalių techninių detalių, padėjo pagrindus šiuolaikinėms pokalbių robotų technologijoms. 1966 m. sukurta Joseph Weizenbaum, ELIZA veikė pagal taisyklių rinkinį ir modelių


suderinimo metodiką, kad imituotų žmonių pokalbį. Veikimo principas buvo sudarytas iš vartotojo įvesties ir galimų atsakymų sąrašo pagal iš anksto nustatytas taisykles. ELIZA scenarijus imitavo psichoterapeutą, atspindėdamas klausimus ir teiginius, kad sukurtų supratimo iliuziją. Tai buvo inovatyvus pokalbių robotas, turėjęs įtakos natūralios kalbos apdorojimui ir dirbtinio intelekto plėtrai. 1972 m. sukurtas kitas pokalbių robotas – PARRY, buvo laikomas pažangesniu nei ELIZA ir parodė, kad pokalbių roboto technologija gali imituoti į žmogų panašią sąveiką. Adamopoulou ir Moussiades, (2020) aprašė, kad PARRY robotą sukūręs psichiatras Kenneth Colby siekė imituoti pacientą, sergantį šizofrenija. Jis panaudojo sudėtingą prielaidų, priskyrimų ir emocinių reakcijų sistemą, tačiau jo veikimo procesas taip pat, kaip ir ELIZA, buvo pagrįstas taisyklių rinkiniu ir modelių suderinimu. Autoriaus darbe pabrėžiama, kad vis tik PARRY kalbos supratimas ir gebėjimas reikšti emocijas buvo žemas, turėjo mažą reagavimo greitį ir negalėjo pasimokyti iš pokalbio. Taip pat minėtas autorius, kad virtualus asistentas Jabberwocky, sukurtas 1988 m. Rollo Carpenterio, buvo vienas pirmųjų bandymų sukurti dirbtinį intelektą per žmonių kontaktą. Šis robotas daugiausia buvo skirtas pramogai, jis buvo sukurtas taip, kad būtų išskirtinė asmenybė ir įtrauktų vartotojus į interaktyvius ir humoristinius pokalbius. Jabberwocky projekto tikslas – sukurti dirbtinį intelektą, galintį išlaikyti Turingo testą, kuris apima žmonių sąveikos imitavimą ir pokalbius su vartotojais. Veikimo principas taip pat buvo pagrįstas taisyklėmis, tačiau jis buvo kuriamas su didesniu dėmesiu į asmenybę ir interaktyvumą, tad Jabberwocky veikė kaip „žodžių žaidinimas“.

Pokalbių robotų istorija rodo greitą technologijų evoliuciją, kuri prasidėjo nuo taisyklėmis pagrįstų sistemų iki pažangių dirbtinio intelekto modelių, galinčių suprasti vartotojo užklaudas, emocijas ir teikti pritaikytas paslaugas. Su dirbtinio intelekto tobulėjimu, pokalbių robotai tampa svarbia priemone finansinių organizacijų arsenalu, padedančia didinti klientų pasitenkinimą, darbo operatyvumą ir efektyvumą. Kaip skelbia Hvozdyk (2024) yra numatoma, kad „pasaulinė dirbtinio intelekto rinka iki 2028 m. viršys 521,3 mlrd. USD“, kas leidžia suprasti, kad virtualių asistentų naudojimas ir poreikis laikui bėgant vis didelės. Virtualūs asistentai, vis labiau populiarėjantys finansų sektoriuje, siekia gerinti klientų patirtį, supaprastinti operacijas ir kovoti su sukčiavimu. Šie dirbtinio intelekto įrankiai gali užtikrinti nepriekaištingą klientų aptarnavimą 24/7, teikti asmenišką rekomendacijas ir net vykdyti bankines operacijas ar atlikti sandorius klientų vardu, siekiant maksimaliai didinti investicijų grąžą. Pagal autorius Han, Chen, Dou, Wang, ir Feng (2023), tyrimai parodė, kad „virtualūs asistentai, apimantys dirbtinį intelektą, nuspėjamąją analizę ir natūralios kalbos apdorojimą, gali teikti asmenines rekomendacijas, vykdyti sandorius ir teikti finansines konsultacijas, pagrįstas vartotojų duomenų analize“. Be to, tie patys tyrimai parodė, kad „virtualūs bankininkystės padėjėjai gali sutaupyti bankams iki 7,3 mlrd. USD klientų aptarnavimo išlaidų, palyginti su tradiciniais skambučių centrais“, todėl sutaupoma daug lėšų.

Apibendrinant atliktą literatūros analizę, galima teigti, kas pastaraisiais metais technologijų plėtra, ypač dirbtinio intelekto srityje, iššaukė pokyčius verslo aplinkoje, ypač finansų sektoriuje. Ši plėtra sparčiai didina pokalbių robotų populiarumą, nes jie tampa svarbia priemone organizacijoms teikti greitą, efektyvų klientų aptarnavimą ir pagerinti vartotojų patirtį. Prognozės rodo, kad dirbtinio intelekto rinka toliau augs, o tai reiškia, kad pokalbių robotų naudojimas tik didės ateityje. Ypač finansų sektoriuje, virtualūs asistentai tampa neatsiejama klientų aptarnavimo dalimi, teikdami asmenines rekomendacijas, vykdydami operacijas ir kovodami su sukčiavimu. Tyrimai tvirtina, kad šie virtualūs finansinių paslaugų asistentai gali sutaupyti klientų aptarnavimo išlaidas. Tai įrodo, kad pokalbių robotai ne tik pagerina klientų patirtį, bet ir sutaupo organizacijoms didelius pinigus. Visa tai patvirtina, kad pokalbių robotai tampa ne tik technologijos stebuklu, bet ir realiai naudinga priemone verslui. Su tolesne technologijų pažanga, galime tikėtis, kad jų svarba ir naudojimas tik augs ateityje.

1.1.1. Taisyklėmis pagrįstų pokalbių robotų techninė struktūra, kūrimo etapai

Taisyklėmis pagrįsti pokalbių robotai naudoja iš anksto nustatytą atsakymų duomenų bazę ir laikosi nustatytų taisyklių, kad nustatytų tinkamus atsakymus. Nors jie negali savarankiškai generuoti atsakymų, jų veiksmingumas priklauso nuo atsakymų duomenų bazės gylgio ir taisyklių efektyvumo. Taisyklėmis pagrįsti virtualūs asistentai yra labai riboti ir gali atsakyti į užklausas tik tuo atveju, jei tiksliai sutampa su jų duomenų bazėje apibrėžtomis įvestimis ir labai paprastomis taisyklėmis pagrįstas pokalbių robotas veiks ieškodamas konkrečių raktinių žodžių vartotojo įvestyje. Raktažodžiai padės nustatyti norimą vartotojo veiksmą. Nustačius užklausos tikslą, robotas parinks tinkamą atsakymą (Saleem, 2024).



Šaltinis: Saleem, (2024)

1 pav. Pokalbių roboto veikimo principas

Svarbu suprasti du, vienus iš pagrindinių, terminų, naudojamų taisyklėmis pagrįstų virtualių asistentų kūrime, tai pokalbių robotų *kūrimo sistemas* (angl. Chatbot Framework) ir *kūrimo platformos* (angl. Chatbot Platforms). Thorat ir Jadhav (2020) savo straipsnyje išskiria šias dvi

terminologijas ir pabrėžia kaip svarbu suprasti jas. Pokalbių robotų kūrimo sistemos yra programinės įrangos rinkiniai, kurie supaprastina pokalbių robotų kūrimo procesą, teikdamos iš anksto paruoštų funkcijų ir klasių rinkinį, leidžiantį kūrėjams rašyti kodą efektyviau ir greičiau. Pavyzdžiui, "Facebook Bot Engine", "Microsoft Bot Framework" ir API.ai yra populiarios kūrimo sistemos. Kita vertus, pokalbių robotų kūrimo platformos yra internetinės aplinkos, kuriose galima diegti ir sąveikauti su pokalbių robotais, atliekant veiksmus vartotojų vardu ir sąveikaudamos su kitomis platformomis (Desirable features of a chatbot-building platform., 2020). Pavyzdžiai tokios robotų kūrimo platformos yra "Slack", "Facebook Messenger", "Telegram", "Skype" ir kt. Kitaip tariant, pokalbių robotų platformos yra skirtos pradedantiems ar netechniniams vartotojams, leidžiančios kurti robotus be programavimo žinių, o pokalbių robotų kūrimo sistemos yra skirtos programuotojams, kuriems reikia kurti robotus nuo pradžių, naudojant programavimo kalbas. Taigi virtualių asistentų kūrimas gali būti atliekamas tiek kūrimo sistemoje, tiek kūrimo platformoje.

Minėtas autorius, Saleem (2024) taip pat detaliai išdėsto galimą procesą, siekiant sukurti taisyklėmis pagrįstą virtualų asistentą kūrimo sistemoje, kurioje programuotojai gali naudoti programavimo kalbų funkcijas ir kodo kūrimo aplinkas, kad sukurtų algoritmus, generuoja atitinkamus atsakymus pagal vartotojų užduotas užklausas:

1. *Importuojamos reikiamos priklausomybės.* Pirmiausia yra importuojami reikalingi paketai ir bibliotekas. Priklausomybės gali būti importuojamos įvairiais būdais priklausomai nuo programavimo kalbos ir naudojamos plėtinio tvarkyklės. Pavyzdžiui, Python kalboje dažnai naudojamas *import* komanda, o JavaScript kalboje naudojamas *require()* funkcija. Taip atsiranda galimybė naudoti ir įvairias leksines duomenų bazines. Tai naudinga tuo, kad išplečia raktinių žodžių sąrašą nevedant visų įmanomų žodžių ranka, o sukuriamas raktinių žodžių sinonimų žodynas, kuriuos vartotojas galėtų naudoti. Importuoti reikiamas priklausomybes reiškia įtraukti į savo projektą bibliotekas ar kitas išorines programas, kurių reikia, kad kodas veiktų tinkamai. Tai gali būti specialios funkcijos ar moduliai, kurie suteikia tam tikras savybes ar funkcionalumą. Kur importuoti priklausomybes priklauso nuo projekto struktūros ir programavimo kalbos standartų, paprastai, priklausomybes importuoja projektą viršuje, prieš bet koki kitą kodą.
2. *Sukuriamas raktažodžių sąrašas.* Raktažodžių sąrašas yra kuriamas tam, kad pokalbių robotas galėtų atpažinti vartotojų užklausas ir gebėtų į jas tinkamai reaguoti. Į šį sąrašą įtraukiami žodžiai ar frazės, kurias tikėtina, kad vartotojai naudosis bendraudami su virtualiu asistentu. Kuo šis sąrašas yra platesnis, tuo veiksmingiau gali veikti pokalbių robotas.
3. *Sukuriamas intencijų, galimų užklausų žodynas.* Intencijų žodynas kuriamas siekiant atitikti raktinius žodžius su konkrečiais tikslais, galimomis vartotojo užklausomis. Tai

padeda taisyklėmis paremtam pokalbių robotui suprasti, ką vartotojas nori pasakyti arba ką jis siekia padaryti ar sužinoti, kai naudojasi virtualiu asistentu. Kiekvienas raktinis žodis turi būti susietas su tam tikra intencija arba tikslu. Galima suformuoti žodyną, kuriame kiekviena intencija yra atskirta ir kuri nurodo paieškos funkcijai ieškoti bet kurio žodžio iš paminėtų raktinių žodžių. Intencijų žodyne galima įtraukti tiek raktų ir reikšmių porų, kiek norime, kad padidintumėme pokalbių roboto funkcionalumą ir supratimą apie vartotojo paklausimą. Tai leis robotui geriau atpažinti vartotojo užklausas ir teikti tinkamus atsakymus.

4. *Apibrėžiamas atsakymų žodynas.* Atsakymų žodynas kuriamas siekiant suteikti pokalbių robotui galimybę reaguoti į vartotojų užklausas tinkamais atsakymais. Šis žodynas yra esminis, kad robotas galėtų atlikti savo funkciją ir užtikrinti sėkmingą bendravimą su vartotojais. Kiekvienam ketinimo tipui arba intencijai apibrėžiame atitinkamus atsakymus. Tai gali būti tekstas, kuris bus rodomas vartotojui, arba veiksmai, kuriuos atliks robotas. Pavyzdžiui, jei vartotojas kreipiasi dėl pagalbos su sąskaita, reikia apibrėžti vieną arba keletą atsakymų, kurie gali būti kažkas tokie kaip "Aš padėsiu jums su jūsų sąskaita" arba "Prašome palaukti, kol perduosiu jus klientų aptarnavimo specialistui". Be to, svarbu įtraukti atsarginį tikslą ir atsakymą. Tai yra atsakymas, kuris bus naudojamas, jei pokalbių robotas negalės iš vartotojo įvesties išgauti jokių susijusių raktinių žodžių. Tai suteikia patikimą atsakymą, užtikrinantį, kad robotas visada turės kažką atsakyti, net jei vartotojo užklausa yra netikėta, neįprasta ar neaprašyta galimų užklausų žodyne.
5. *Intencijų atitikimas ir atsakymų generavimas.* Intencijų atitikimas ir atsakymų generavimas yra procesas, kuris vyksta, kai vartotojas pateikia užklausą virtualiam asistentui, o robotas siekia interpretuoti šią užklausą pagal sukurtą intencijų žodyną. Tai svarbiausias virtualaus asistento kūrimo etapas, kuomet ištestuojama, ar yra teisingai įvykdyti anksčiau minėti žingsniai. Kai intencija yra nustatyta, robotas generuoja tinkamą atsakymą, kuris atitinka vartotojo paklausimą. Šis procesas yra labai svarbus, nes pokalbių robotas gali veiksmingai bendrauti su vartotojais ir teikti jiems reikalingą informaciją arba atlikti reikalingus veiksmus.

Taigi, taisyklėmis pagrįsto virtualaus asistento kūrimo procesas paaiškina kas leidžia robotui veikti efektyviai ir sėkmingai bendrauti su vartotojais, teikiant jiems reikalingą informaciją arba pagalbą. Įvykdžius šiuos žingsnius, dalinai užtikrinama, kad virtualus asistentas galėtų suprasti vartotojų užklausas ir teikti jiems tinkamus atsakymus. Tačiau, akivaizdu, kad sudėtingoms situacijoms ir komplikuotoms vartotojų užklausoms taisyklių sudarymas yra labai ilgas ir varginantis darbas, yra sunku numatyti ir aprašyti taisykles kiekvienai galimai situacijai. Taisyklėmis paremtos

pokalbių robotų sistemos gali susidoroti su tiesioginiais, paprastais ir šabloniniais klausimais, tačiau taip pat svarbu yra valdyti sudėtingesnius klausimus, kuriems išspręsti yra reikalinga arba darbuotojo specialisto pagalba, arba dirbtinio intelekto virtualaus asistento įsikišimas.

1.1.2. Dirbtinio intelekto pokalbių robotų techninė struktūra (mašininis mokymas ir natūralios kalbos apdorojimas)

Kalbant apie pokalbių robotus ir jų tipus, būtina detaliau apžvelgti dirbtiniu intelektu grįstus virtualius asistentus, kurių populiarumas ir naudojimas vis didėja įvairiose srityse, siekiant pateikti informaciją arba atlikti užduotis. Dirbtiniu intelektu grįsti pokalbių robotai padeda sumažinti klientų skambučių skaičių ir sumažinti klientų aptarnavimo laiką bei išlaidas. Šiandien jie plačiai naudojami populiariose programose, tokiose kaip Telegram, Cortana, Slack, WeChat, Facebook Messenger, Google Assistant ir Siri. Literatūroje neretai apžvelgia mašininio mokymo (ML) ir natūralios kalbos apdorojimo (NLP) pažangą, kuri leido sukurti sudėtingus pokalbių robotus. Lentelėje nr. 1 žemiau matomi pagrindiniai pažangos aspektai:

Lentelė 1

Dirbtinio intelekto pokalbių robotų techninė struktūra, taikymo pavyzdžiai ir aprašymas


Aspektas	Techninė struktūra	Taikymo pavyzdys	Aprašymas
Natūralios kalbos apdorojimo (NLP)			
Kalbos modeliai	Modeliai: BERT, GPT-3	Iš konteksto, nuoseklių atsakymų generavimas	Pažangūs kalbos modeliai padeda pokalbių robotams suprasti kontekstą ir generuoti natūralesnius atsakymus
Sekos į seką (Seq2Seq) modeliai	Modeliai: LSTM, GRU	Vertimas, dialogo kūrimas	Seq2Seq modeliai leidžia generuoti atsakymus, kurie yra nuoseklūs su ankstesnėmis užklausomis
Transformeriai	Architektūra: BERT, GPT-3	Ilgalaikio konteksto išlaikymas pokalbiuose	Transformeriai leidžia pokalbių robotams geriau suprasti kontekstą ir atlikti sudėtingesnes kalbos užduotis

Šaltinis: Maher, S., Kayte, S., & Nimbhore, S. (2020)

Mašininis Mokymas (ML)			
Intencijų atpažinimas	Algoritmai: SVM, sprendimų medžiai	Klientų užklausų supratimas ir atsakymų generavimas	Naudojami klasifikavimo algoritmai intencijų atpažinimui
Vartotojų suskirtymas	Algoritmai: klasterizacija	Personalizuotų atsakymų generavimas pagal vartotojų grupes	Naudojama klasterizacija vartotojų segmentavimui ir personalizuotų atsakymų generavimui

Šaltinis: Maher, S., Kayte, S., & Nimbhore, S. (2020)

Svarbu ne tik gebėjimas apdoroti ir analizuoti duomenis, bet ir savarankiškas mokymosi procesas, leidžiantis DI adaptuotis prie naujų situacijų bei užduočių. Tai reiškia, kad DI turėtų turėti savybę nuolat tobulėti, remiantis savo patirtimi, ir gebėti veikti ne tik pagal iš anksto nustatytas taisykles, bet ir kūrybiškai spręsti naujus iššūkius. Mokslininkai pabrėžia, kad svarbiausia yra tai, kad DI gebėtų jausti, interpretuoti, mokytis, planuoti ir veikti savarankiškai. Kitaip pasakius, dirbtinis intelektas turėtų pats sugebėti tinkamai interpretuoti iš aplinkos gaunamus duomenis ir mokytis iš jų, o ne būti griežtai suprogramuotas konkrečioms užduotims ar užklausoms vykdyti. (Eriksson, Bigi, ir Bonera, 2020). Paveikslėlis apačioje atvaizduoja, kas dalyvauja procese link dirbtinio intelekto pokalbių roboto veikimo, kuris sugeba atkartoti žmogaus elgesį:



Šaltinis: Sarker, (2022)

2 pav. Mašininio mokymosi ir giliojo mokymosi padėties dirbtinio intelekto srityje iliustracija

Apžvelgtoje literatūroje aprašomas dirbtinio intelekto efektyvumas, kuris padeda sumažinti klientų skambučių skaičių ir kliento aptarnavimo laiką, naudojant NLP ir ML technologijas. Tokie virtualūs asistentai sugeba ne tik apdoroti ir analizuoti duomenis, bet ir mokytis iš savo patirties, prisitaikyti

prie naujų situacijų ir užduočių, veikti kūrybiškai, nuosekliai ir savarankiškai interpretuoti gaunamą informaciją.

1.1.3. Matematinų modelių integravimas į pokalbių robotus ir jų poveikis veikimo procesams bei naudojimo scenarijams

Dirbtinio intelekto asistentai yra pagrįsti matematiniais modeliais ir metodais. Šie modeliai apima įvairias matematines ir statistines technikas, kurios yra naudojamos sprendimų priėmimo procese, optimizavimo ir prognozavimo procesuose bei duomenų analizėje (Dr. Revathi, 2023). Pavyzdžiui, generatyvinis iš anksto apmokytas transformatorius 4 (GPT-4) yra ketvirtos kartos kalbos modelis, sukurtas OpenAI, kuris buvo išleistas 2023 m. kovo 14 d. ir sukurtas tam, kad taptų vis labiau sudėtingas ir pajėgus kaip kalbos modelis. Buvo atliktas tyrimas, kurio metu, pats DI virtualus asistentas paaiškino matematinius aspektus ir jų panaudojimą DI kalbos modelyje:

Lentelė 2

Matematinis aspektas ir jo panaudojimas dirbtinio intelekto

Matematinis aspektas	Paaiškinimas	Naudojimo būdas	Paaiškinimas
Tiesinė algebra	Daugeliui mašininio mokymosi algoritmų, įskaitant neuroninius tinklus, kurių pagrindą sudaro mano architektūra, reikalingos linijinės algebros sąvokos, pvz., vektoriai, matricos.	Teksto apdorojimas	Norint suprasti ir generuoti tekstą, naudojami matematiniai pagrindai sukurti žodžių įdėjimai (vektorinės reprezentacijos), kurie atspindi žodžių tarpusavio ryšius.
Tikimybių teorija ir statistika	Žmonių kalbos supratimas ir generavimas apima žodžių sekų ir šablonų tikimybių modeliavimą. Tikimybių teorija ir statistika atlieka esminį vaidmenį priimant sprendimus remiantis stebimais duomenimis.	Kalbos generavimas	Žmonių kalbos generavimui naudojami tikimybių modeliai, kurie įvertina žodžių sekų ir šablonų tikimybes. Statistiniai matavimai naudojami vertinant teksto kokybę ir priimant informuotus sprendimus.
Matematinė analizė	Gradientinio optimizavimo metodai, tokie kaip stochastinis gradientinis nuolydis (SGD), naudojami neuroninio tinklo parametrams tobulinti. Šis procesas apima matematikos sąvokas, tokias kaip išvestinės ir dalinės išvestinės.	Optimizavimas	Mokymo proceso metu naudojami optimizavimo algoritmai, kaip stochastinis gradientinis nuolydis, kad sumažintų nuostolių funkciją. Tai apima išvestinių skaičiavimus ir neuroninio tinklo parametrų (svorių ir šališkumų) atnaujinimą.

Šaltinis: sudaryta autoriaus pagal Ray Knight (2023)

Neuroniniai tinkai ir jų ryšys su matematika yra dirbtinio intelekto pagrindas, nes neuroniniai tinkai remiasi įvairiomis matematinėmis sąvokomis ir algoritmais, kad galėtų identifikuoti vartotojų natūralią kalbą, apdoroti informaciją ir generuoti atsakymus. Neuroninių tinklų tipų yra gausi įvairovė, tačiau literatūroje plačiausiai aptariami šie:

1. Konvoliuciniai neuroniniai tinklai (CNN): Šie tinklai yra skirti vaizdo apdorojimui ir objektų aptikimui. CNN tinklai susideda iš konvoliucinių sluoksnių, aktyvacijos sluoksnių, telkimo sluoksnių ir visiškai sujungtų sluoksnių. Konvoliucija yra pagrindinė operacija, kuri padeda išgauti vaizdo ypatybes. Aktyvacijos funkcijos, tokios kaip ReLU, suteikia tinklui netiesiškumą. Tinklui suteikiant netiesiškumą, tai reiškia, kad tinklas tampa pajėgus atpažinti ir modeliuoti sudėtingesnes, ne tiesines funkcijas arba ryšius tarp duomenų. Netiesiškumo suteikimas yra svarbus, nes dauguma realių duomenų ir jų sąryšių yra sudėtingesni nei tiesiniai. CNN mokymui naudojami optimizavimo metodai, pvz., gradiento nusileidimas, kuris padeda tinklui mokytis iš duomenų. Pavyzdžiui, tiesinė funkcija yra tiesioginis santykis tarp kintamųjų, kuris būtų panašus į tiesią liniją. Tačiau dauguma realių pasaulio sąryšių yra sudėtingesni ir dažnai negali būti tiesiškai išreikšti. Todėl, naudojant netiesines funkcijas, tinklas gali išmokti ir modeliuoti šiuos sudėtingesnius ryšius, leidžiant jį geriau prisitaikyti prie duomenų ir atlikti efektyvesnį sprendimų priėmimą, kas yra ypatingai svarbu aptarnaujant vartotojus.
2. Pasikartojantys neuroniniai tinklai (RNN): Šie tinklai naudojami nuosekliam duomenų apdorojimui, pvz., kalbos vertimui ar teksto apibendrinimui, kurie naudoja tiesinę algebrą, skaičiavimo metodus ir statistiką bei tikimybių teoriją, taip pat klasifikavimą ir regresiją. RNN tinklai turi sąryšį tarp savo būsenų, kuris leidžia jiems naudoti ankstesnių įėjimų informaciją. Taip tinklas turi atmintį arba gebėjimą saugoti informaciją apie ankstesnius įėjimus ir jų poveikį. Tai leidžia tinklui naudoti ankstesnių žingsnių arba užklausų informaciją, kuri gali būti svarbi sprendžiant dabartinę, paskutinę užduotį. Tai ypač naudinga užduotims, kuriose svarbus laiko kontekstas arba nuoseklumas,
3. Tikimybiniai neuroniniai tinklai (PNN): Šie tinklai yra skirti klasifikavimui ir regresijai. Jie yra pagrįsti radialinių bazinių funkcijų (RBF) teorija ir naudoja tikimybių teoriją, kad apskaičiuotų sąlyginės klasės tikimybes. RBF funkcijos yra naudojamos tam, kad duotų duomenų taškus būtų transformuojami į aukšto dimensijos erdvę, kurioje duomenys tampa lengviau klasifikuojami. RBF funkcijos taip pat padeda PNN tinklams modeliuoti ir identifikuoti sudėtingus duomenų sąryšius, kurie gali būti tiesiškai neaprepiami. Taip pat, PNN modelis skaičiuoja tikimybes, kad duotas įvesties taškas priklauso kiekvienai galimai

- klasei, pagal turimus duomenis. Šios sąlyginės tikimybės tada naudojamos sprendžiant, kuriai klasei priskirti naujas duomenis arba klasifikuoti duomenis pagal jų įvesties reikšmes.
4. Sprendimų medžiai: Šie metodai taip pat naudojami klasifikavimui ir regresijai, remiantis tiesine algebra, skaičiavimo metodais, statistika bei tikimybių teorija. Pagrindinis sprendimų medžių veikimo principas apima kelis žingsnius:
- Duomenų skaidymas: Pradžioje sprendimų medžio modelis yra mokomas pagal turimus duomenis. Medžio konstravimo metu jie skaidomi į vis mažesnius ir mažesnius poaibius, kiekvieną kartą pasirenkant optimalų kriterijų, pagal kurį duomenys yra skirstomi.
 - Kriterijų pasirinkimas: Kai duomenys yra skaidomi, reikia nustatyti, kuris kriterijus geriausiai padeda juos klasifikuoti arba numatyti.
 - Medžio konstravimas: Duomenys yra skaidomi į šakas pagal pasirinktus kriterijus. Kiekvienai šakai yra priskiriama kategorija arba numatyta reikšmė, atsižvelgiant į tai, kaip gerai kriterijus padeda klasifikuoti duomenis.
 - Medžio apmokymas: Sprendimų medžio modelis yra mokomas pagal turimus duomenis, siekiant sukurti optimalią medžio struktūrą, kuri geriausiai atitinka duomenų ypatybes ir užduotį, kurią bandoma spręsti.
 - Klasifikavimas arba regresija: Kai sprendimų medžio modelis yra apmokytas, jis gali būti naudojamas klasifikuoti arba numatyti naujus duomenis, remiantis medžio struktūra ir priskirtomis kategorijomis arba reikšmėmis.

Lentelė apačioje susisteminta, kaip įvairūs neuroniniai tinklai gali būti taikomi siekiant efektyviau aptarnauti vartotojus ir užtikrinti kokybišką paslaugų teikimą fintech sektoriuje:

Lentelė 3

Matematinų modelių integravimas į pokalbių robotus fintech sektoriuje

Neuroninių tinklų tipas	Matematiniai modeliai, algoritmai ar skaičiavimai	Praktinis naudojimas pokalbių robotuose	Pagrindinės užduotys
Konvoliuciniai neuroniniai tinklai (CNN)	Konvoliucija, ReLU aktyvacijos funkcijos, gradiento nusileidimas	Vaizdo atpažinimas ir analizė siekiant suprasti vartotojų elgesį	Saugumas: Šifravimas, biometrinė autentifikacija
Pasikartojantys neuroniniai tinklai (RNN)	Tiesinė algebra, skaičiavimo metodai, statistika, tikimybių teorija, klasifikavimas, regresija	Teksto supratimas, kalbos vertimas, kontekstinis atsakymų generavimas	Integracija: API, duomenų sinchronizacija

Šaltinis: sudaryta autoriaus remiantis Knight, R. (2023), Maher, S., Kayte, S., Nimbhore, S. (2020), Revathi, V. M. (2023).

Neuroninių tinklų tipas	Matematiniai modeliai, algoritmai ar skaičiavimai	Praktinis naudojimas pokalbių robotuose	Pagrindinės užduotys
Tikimybiniai neuroniniai tinklai (PNN)	Radialinių bazinių funkcijų (RBF) teorija, tikimybių teorija, sąlyginės klasės tikimybės skaičiavimas	Klasifikacija ir prognozavimas remiantis vartotojo įvestimi	Prisitaikymas: Dideli vartotojų srautai, realaus laiko analizė
Sprendimų medžiai	Duomenų skaidymas, kriterijų pasirinkimas, medžio konstravimas, medžio apmokymas, klasifikavimas, regresija	Sprendimų priėmimas, klasifikavimas ir rekomendacijos	Analizė: Duomenų skaidymas, personalizuotos rekomendacijos

Šaltinis: sudaryta autoriaus remiantis Knight, R. (2023), Maher, S., Kayte, S., Nimbhore, S. (2020), Revathi, V. M. (2023).

Apibendrinant, galima daryti išvadą, kad matematiniai modeliai yra esminiai dirbtinio intelekto asistentų veikimo elementai, leidžiantys jiems suprasti, apdoroti ir generuoti atsakymus įvairiose užduotyse, nuo teksto analizės iki sprendimų priėmimo.

1.2. Finansinių paslaugų funkcijų integravimas verslo ir individualių vartotojų poreikių bei UX (angl. user experience) kriterijų atžvilgiu

Finansinių paslaugų svarba šiuolaikinėje ekonomikoje yra nepakeičiama, tai apima įvairias funkcijas, kurios užtikrina ekonomikos stabilumą, plėtrą ir efektyvumą. Finansinės paslaugos yra pagrindas, leidžiantis tiek verslui, tiek individualiems vartotojams valdyti savo finansus, investuoti ir pasiekti finansinius tikslus.

Finansinių paslaugų funkcijų integravimas, siekiant patenkinti tiek verslo, tiek individualių klientų poreikius, yra sudėtingas ir svarbus procesas. Pirmiausia, reikia atsižvelgti į skirtingus šių dviejų vartotojų galimus reikalavimus ir lūkesčius. Verslo klientai dažnai reikalauja aukšto lygio saugumo, efektyvumo ir specializuotų funkcijų, kurios padėtų valdyti jų finansinius srautus bei užtikrintų sklandų operacijų vykdymą. Tuo tarpu individualūs vartotojai ieško paprastumo, patogumo ir prieinamumo, kad kasdienės finansinės operacijos būtų atliekamos greitai ir be didelių pastangų. Integruojant šias funkcijas, svarbu užtikrinti, kad vartotojo patirtis (UX) būtų aukščiausio lygio. Tai apima intuityvų dizainą, aiškią ir patogią sąsają, bei greitą ir efektyvų klientų aptarnavimą. Be to, būtina užtikrinti, kad tiek verslo, tiek individualūs klientai gautų personalizuotas paslaugas, kurios atitiktų jų specifinius poreikius (Successive, 2024). Tinkamai suderinti šiuos elementus leidžia kurti

vertę tiek įmonei, tiek jos klientams, užtikrinant ilgalaikį bendradarbiavimą ir aukštą pasitenkinimą teikiamomis paslaugomis.

Kaip teigia Cemantica (2024) vartotojų pasitikėjimas yra gyvybiškai svarbi klientų patirties teikiant finansines paslaugas dalis. Tai yra pagrindas, ant kurio kuriami ir palaikomi santykiai su klientais. Finansų institucijos turi teikti pirmenybę vartotojų pasitikėjimo kūrimui ir palaikymui, užtikrindamos klientų duomenų saugumą ir privatumą, veikdamos skaidriai ir etiškai bei aiškiai bendraujant su klientais.

Taigi, finansinių paslaugų funkcijų integravimas siekiant patenkinti tiek verslo, tiek individualių klientų poreikius yra sudėtingas procesas, kuris reikalauja atsižvelgti į specifinius šių dviejų grupių reikalavimus, užtikrinti aukščiausio lygio vartotojo patirtį, teikti personalizuotas paslaugas ir kurti vartotojų pasitikėjimą per duomenų saugumą, skaidrumą. Kartu labai svarbu teikiamų paslaugų tipą, tai taip pat lemia paslaugos reikšmingumą ir svarbą skirtingų poreikių klientams.

1.2.1. Pagrindinės finansinių paslaugų rūšys ir jų reikšmė verslui ir individualiems vartotojams

Finansinės paslaugos apima platų spektrą paslaugų ir produktų, kurie yra teikiami tiek verslo, tiek individualiems klientams. Dažnu atveju literatūroje, kaip viena svarbiausių finansų paslaugų yra įvardijamos bankininkystės paslaugos, kurios apima sąskaitų atidarymą ir tvarkymą (einamosios ir taupomosios sąskaitos), paskolas ir kredito paslaugas, o lengvas sąskaitos atidarymas yra svarbiausias veiksnys klientams. 2023 metais atliktas tyrimas parodė, kad kai bankai sugriežtina skolinimo standartus, tai turi neigiamą poveikį įmonių kreditavimui. Konkrečiai, jie nustatė, kad kai skolinimo standartai sugriežtinami vienu standarto nuokrypiu, įmonių kredito augimas sumažėja 0,26 procentinio punkto. Tai reiškia, kad griežtesni bankų reikalavimai dėl paskolų suteikimo (pavyzdžiui, didesni garantijų reikalavimai, griežtesni kreditingumo vertinimo kriterijai) tiesiogiai sumažina įmonėms suteikiamų kreditų kiekį, lėtinami jų augimą ir galimai ribodami įmonių galimybes finansuoti savo veiklą ar plėtrą. (Ricci, Soggia, Trimarchi, 2023).

Kita finansinių paslaugų rūšis yra investicinės paslaugos, kurios apima investavimo patarimus ir konsultacijas, vertybinių popierių prekybą (akcijos, obligacijos, ETF), investicinius fondus ir pensijų planus bei portfelio valdymą. Li (2020) atliktas tyrimas išanalizavo investicinių vertybinių popierių fondų įtaką Kinijos vertybinių popierių rinkos efektyvumui ir padarė išvadą, kad nors kai kurios fondų prekybos elgsena mažina akcijų rinkos efektyvumą, bendra prekyba fondais turi teigiamą vaidmenį gerinant rinkos kainų nustatymo galimybes. Tai reiškia, kad dalyvavimas fondų rinkoje gali prisidėti prie geresnio akcijų kainų nustatymo ir galimai didesnio likvidumo, kas gali būti naudinga investuotojams siekiant tikslingai valdyti savo investicijas. Nemažiau reikšminga finansinė paslauga

yra draudimas, kuri apima įvairias draudimo rūšis, apsaugančias asmenis ir įmones nuo finansinių nuostolių dėl įvairių rizikų. Šios paslaugos gali būti plačiai suskirstytos į tris pagrindines sritis: gyvybės, sveikatos ir turto draudimą. Dabar draudimo įmonės diegia pažangias technologijas, tokias kaip dirbtinis intelektas, duomenų analizė ir automatiniai sprendimai, siekiant optimizuoti procesus, gerinti klientų aptarnavimą ir pasiūlyti personalizuotas draudimo paslaugas. Taip pat bendradarbiavimas su insurtech startuoliais padeda draudikams siekti inovatyvių sprendimų ir prisitaikyti prie šiuolaikinių technologinių tendencijų (Parashar, 2024). Verta paminėti ir mokėjimo paslaugas, kurios yra svarbi finansų sektoriaus dalis, apimanti įvairius būdus, kaip asmenys ir įmonės gali atlikti finansines operacijas. Pastebėta, kad vartotojai vis dažniau naudoja skaitmenines pinigines tiek parduotuvėse, tiek internete, įnešdami naujas technologines inovacijas į pagrindinę rinką. Prognozuojama, kad šiais metais dėl P2P (peer-to-peer), kur operacijos vyksta be tarpininkų, tokių kaip bankai, ir greitai, mobiliųjų mokėjimų vartotojų skaičius padidės 9%, pasiekdamas 147,6 milijardo JAV dolerių vertę (Emarketer, 2024).

Šios finansinės paslaugos yra svarbios tiek privatiems, tiek verslo klientams, tačiau jų reikšmė skiriasi. Žemiau esančioje lentelėje išryškinama šių paslaugų svarba kiekvienai klientų grupei:

Lentelė 4

Finansinių paslaugų svarba privatiems ir verslo klientams

Finansinė paslauga	Svarba privatiems asmenims	Svarba verslui
Bankininkystė	Privatiems klientams svarbu lengvas sąskaitos atidarymas ir paskolos.	Verslui svarbu prieinamos paskolos ir kredito linijos veiklos finansavimui ir plėtrai. Griežtesni skolinimo standartai gali riboti kreditavimo galimybes ir lėtinti įmonių augimą.
Investicinės paslaugos	Padedą privatiems asmenims planuoti ir valdyti investicijas, įskaitant akcijų, obligacijų, investicinių fondų ir pensijų planų pasirinkimą.	Verslui svarbios investavimo konsultacijos, portfelio valdymas ir vertybinių popierių prekyba, siekiant efektyviai valdyti investicijas ir didinti įmonės kapitalo vertę.
Draudimas	Svarbus gyvybės, sveikatos ir turto draudimas, apsaugantis nuo finansinių nuostolių dėl įvairių rizikų.	Įmonėms svarbu apsaugoti nuo įvairių verslo rizikų, įskaitant turto, atsakomybės ir darbuotojų sveikatos draudimą. Pažangios technologijos ir insurtech startuoliai padeda draudikams optimizuoti procesus ir teikti personalizuotas paslaugas.

Šaltinis: sudaryta autoriaus pagal Maze (2023) ir Smith (2022)

Finansinė paslauga	Svarba privatiems asmenims	Svarba verslui
Mokėjimo paslaugos	Svarbios kasdieniams mokėjimams tiek parduotuvėse, tiek internete. P2P mokėjimų augimas leidžia greitai ir patogiai atlikti operacijas be tarpininkų.	Verslui svarbios greitos ir saugios atsiskaitymo priemonės, padedančios efektyviai valdyti pinigų srautus ir užtikrinti sklandžius atsiskaitymus su klientais ir tiekėjais.

Šaltinis: sudaryta autoriaus pagal Maze (2023) ir Smith (2022)

Taigi, finansinės paslaugos apima bankininkystės, investicines, draudimo ir mokėjimo paslaugas, kurios yra svarbios tiek verslo, tiek individualiems klientams. Bankininkystės paslaugos, tokios kaip sąskaitų atidarymas ir kredito teikimas, yra esminės klientams, o griežtesni skolinimo standartai gali neigiamai paveikti įmonių kreditavimą ir augimą. Investicinės paslaugos padeda tiek privatiems asmenims, tiek įmonėms efektyviai valdyti investicijas, o draudimo paslaugos apsaugo nuo įvairių rizikų. Mokėjimo paslaugos, įskaitant skaitmeninius ir P2P mokėjimus, yra svarbios kasdieniams finansiniams sandoriams, užtikrinant greitą ir patogų atsiskaitymą.

1.2.2. Fintech inovacijos ir jų poveikis įvairių verslo sektorių ir individualių vartotojų sąveikos sistemose

Finansinės technologijos, arba fintech, pastaraisiais metais iš esmės pakeitė finansinių paslaugų teikimo būdus, paveikdamos tiek verslo sektorius, tiek individualius vartotojus. Šios inovacijos, įskaitant skaitmenines mokėjimo platformas, mobilius pinigines ir automatizuotus finansinius sprendimus, leidžia efektyviau ir patogiau valdyti finansinius procesus. Fintech technologijos ne tik optimizuoja verslo operacijas, mažina kaštus ir didina saugumą, bet ir keičia kasdieninį vartotojų sąveiką su finansų sistemomis, suteikdamos greitesnes ir lengvesnes paslaugas.

Fintech yra terminas, apibrėžiantis technologijų naudojimą finansinių paslaugų teikimui. Tai apima plėtrą ir diegimą įvairių technologinių sprendimų, kurie siekia pagerinti finansinių paslaugų efektyvumą, saugumą ir prieinamumą. Fintech sektorius sparčiai vystosi ir įtraukia naujas technologijas, kurios transformuoja tradicinę finansų pramonę (Chance, 2023). Remiantis Clifford Chance straipsniu, pagrindinės fintech inovacijos yra šios:

1. **Skaitmeninės mokėjimo platformos** - šios platformos, tokios kaip PayPal, Venmo ir Square, leidžia vartotojams atlikti mokėjimus internetu ir mobiliuosiuose įrenginiuose. Jos suteikia greitus, patogius ir saugius mokėjimų sprendimus, kurie vis labiau keičia tradicinius mokėjimo būdus.

2. **Kripto valiutos ir blokų grandinė (blockchain)** - kripto valiutos, tokios kaip Bitcoin ir Ethereum, bei blokų grandinės technologija suteikia naujus būdus atlikti finansines operacijas, užtikrinant didesnę saugumą ir skaidrumą. Blokų grandinė taip pat naudojama kitose srityse, tokiose kaip išmaniųjų sutarčių sudarymas ir tiekimo grandinės valdymas.
3. **Robo-advisors** - automatizuoti finansiniai patarėjai (robo-advisors) naudoja algoritmus, kad pateiktų investavimo patarimus ir valdyti investicinius portfelius be žmogaus įsikišimo. Tai leidžia sumažinti paslaugų kainą ir suteikti prieinamą investavimo patarimus platesnei auditorijai.
4. **P2P skolinimasis ir finansavimas** - Peer-to-peer (P2P) skolinimo platformos, tokios kaip LendingClub ir Prosper, sujungia skolintojus ir skolininkus tiesiogiai, apeinant tradicinius finansinius tarpininkus. Tai leidžia greičiau ir dažnai pigiau gauti paskolas.
5. **Isurtech** - tai technologijų diegimas draudimo sektoriuje, įskaitant pažangias duomenų analizės priemones, dirbtinį intelektą ir automatizavimą, siekiant optimizuoti draudimo paslaugų teikimą ir padidinti klientų aptarnavimo kokybę. (Chance, 2023)

Fintech inovacijos reikšmingai keičia verslo procesus ir klientų santykį su finansinėmis paslaugomis. Fintech inovacijos padeda verslams efektyviau valdyti finansinius procesus, mažinant kaštus ir didinant operacijų greitį. Fintech inovacijos padeda verslams efektyviau valdyti finansinius procesus, mažinant kaštus ir didinant operacijų greitį. Automatizuotos apskaitos sistemos ir robotizuoti procesų automatizavimo įrankiai (RPA) leidžia verslams sumažinti administracinį darbą, sutaupyti laiko ir sumažinti žmogiškųjų klaidų riziką. Tai ypač naudinga smulkioms įmonėms, kurios dažnai neturi pakankamai išteklių dideliame administraciniame personalui. Be to, fintech sprendimai, tokie kaip realaus laiko mokėjimų platformos, leidžia verslams greičiau gauti mokėjimus iš klientų, taip gerinant pinigų srautų valdymą ir didinant likvidumą. Tai ypač svarbu mažoms ir vidutinėms įmonėms, kurios dažnai susiduria su likvidumo problemomis (Juniper, 2023). Taip pat fintech padeda pagerinti ir sąveiką su klientu. Fintech inovacijos taip pat keičia klientų sąveiką su verslu, suteikiant jiems daugiau patogumo ir skaidrumo. Tokios platformos kaip PayPal, Stripe ir Square suteikia klientams galimybę atlikti mokėjimus greitai ir saugiai, naudojant įvairius mokėjimo būdus. Tai padidina klientų pasitenkinimą ir skatina juos dažniau naudotis paslaugomis. Robo-advisors ir kitos automatizuotos konsultacijų platformos suteikia klientams galimybę gauti individualizuotus finansinius patarimus ir valdyti savo investicijas be tiesioginio žmogaus įsikišimo. Tai leidžia vartotojams lengviau pasiekti finansinius tikslus ir gauti patarimus, kurie anksčiau buvo prieinami tik dideliems investuotojams (Juniper, 2023). Fintech inovacijos iš esmės transformuoja verslo ir klientų sąveikos sistemas, skatindamos efektyvumą, patogumą ir finansinį įtraukimą. Šios technologijos ne tik optimizuoja verslo procesus, bet ir pagerina klientų patirtį, padidindamos jų lojalumą ir pasitenkinimą.

Fintech inovacijos reikšmingai keičia tiek verslo, tiek individualių vartotojų sąveiką su finansinėmis paslaugomis. Šiame skyriuje aptariami pagrindiniai būdai, kaip fintech technologijos transformuoja verslą ir pagerina individualių vartotojų patirtį bei paslaugų prieinamumą. Fintech inovacijos padeda verslams efektyviau valdyti finansinius procesus, mažinant kaštus ir didinant operacijų greitį. Automatizuotos apskaitos sistemos ir robotizuoti procesų automatizavimo įrankiai (RPA) leidžia verslams sumažinti administracinį darbą, sutaupyti laiko ir sumažinti žmogiškųjų klaidų riziką. Tai ypač naudinga smulkioms įmonėms, kurios dažnai neturi pakankamai išteklių dideliam administraciniam personalui. Fintech sprendimai, tokie kaip realaus laiko mokėjimų platformos, leidžia verslams greičiau gauti mokėjimus iš klientų, taip gerinant pinigų srautų valdymą ir didinant likvidumą. Tai ypač svarbu mažoms ir vidutinėms įmonėms, kurios dažnai susiduria su likvidumo problemomis. Tokios platformos kaip PayPal, Stripe ir Square suteikia galimybę atlikti mokėjimus greitai ir saugiai, naudojant įvairius mokėjimo būdus, kas padidina klientų pasitenkinimą ir skatina juos dažniau naudotis paslaugomis (Tang, 2023).

Fintech inovacijos taip pat reikšmingai keičia individualių vartotojų patirtį ir paslaugų prieinamumą. Skaitmeninės mokėjimo platformos, tokios kaip PayPal ir Venmo, leidžia vartotojams atlikti mokėjimus greitai ir patogiai, naudojant mobiliuosius įrenginius. Tai ypač naudinga kasdieniams atsiskaitymams ir pervedimams, suteikiant vartotojams didesnę lankstumą ir kontrolę. Be to, robo-advisors ir kitos automatizuotos konsultacijų platformos suteikia klientams galimybę gauti individualizuotus finansinius patarimus ir valdyti savo investicijas be tiesioginio žmogaus įsikišimo. Tai leidžia vartotojams lengviau pasiekti finansinius tikslus ir gauti patarimus, kurie anksčiau buvo prieinami tik dideliems investuotojams. Fintech inovacijos taip pat didina paslaugų prieinamumą, suteikiant galimybę plačiau naudotis finansinėmis paslaugomis, ypač regionuose, kur tradicinės finansinės paslaugos yra ribotos. Fintech inovacijos iš esmės transformuoja verslo ir individualių vartotojų sąveikos sistemas, skatindamos efektyvumą, patogumą ir finansinį įtraukimą. Šios technologijos ne tik optimizuoja verslo procesus, bet ir pagerina klientų patirtį, padidindamos jų lojalumą ir pasitenkinimą. (Tang, 2023)

Finansinės technologijos iš esmės transformuoja finansinių paslaugų teikimo būdus, skatindamos tiek verslo, tiek individualių vartotojų patirties gerinimą. Šios inovacijos, įskaitant skaitmenines mokėjimo platformas, mobiliąs pinigines ir automatizuotus finansinius sprendimus, leidžia efektyviau ir patogiau valdyti finansinius procesus, didina saugumą ir prieinamumą. Fintech technologijos optimizuoja verslo operacijas, mažina kaštus ir gerina klientų pasitenkinimą, padidindamos lojalumą ir finansinį įtraukimą.

1.2.3. Vartotojų poreikiai ir kaip virtualūs asistentai gali būti naudojami efektyviam asmeniniam aptarnavimui, patirties gerinimui ir našumo didinimui, atsižvelgiant į vartotojų patirtį.

Vartotojų poreikiai nuolat keičiasi ir auga, reikalaujant greito, efektyvaus ir asmeninio aptarnavimo. Šiuolaikinėje skaitmeninėje eroje pokalbių robotai tampa svarbia priemone, padedančia patenkinti šiuos poreikius. Naudojant pažangius dirbtinio intelekto sprendimus, pokalbių robotai gali teikti personalizuotas paslaugas, gerinti vartotojų patirtį ir didinti verslo našumą. Šiame skyriuje aptariama, kaip chatbotai gali būti naudojami efektyviam asmeniniam aptarnavimui, vartotojų patirties gerinimui ir našumo didinimui.

Pagrindiniai vartotojų poreikiai finansinių paslaugų kontekste apima įvairius aspektus, kurie padeda užtikrinti saugumą, patogumą ir efektyvumą. Pagal eMarketer atliktą tyrimą (eMarketer, 2023), šie poreikiai apima:

1. Greitas ir patogus aptarnavimas: vartotojai nori greitai ir patogiai atlikti finansines operacijas, įskaitant mokėjimus, pervedimus ir sąskaitų valdymą. Finansinės institucijos turi užtikrinti greitą prieigą prie paslaugų per įvairias platformas, tokias kaip mobiliosios aplikacijos ir interneto bankininkystė. Pokalbių robotai gali teikti pagalbą bet kuriuo paros metu, užtikrindami, kad klientai galėtų gauti reikiamą informaciją ir pagalbą net ir ne darbo valandomis. Tai ypač svarbu tarptautiniams klientams, kurių laiko juostos skiriasi.
2. Saugumas ir privatumas: saugumas yra vienas iš pagrindinių vartotojų poreikių finansinių paslaugų kontekste. Vartotojams svarbu, kad jų asmeninė ir finansinė informacija yra saugoma ir apsaugota nuo sukčiavimo bei kibernetinių atakų.
3. Personalizuotas aptarnavimas: naudojant dirbtinį intelektą ir duomenų analizę, pokalbių robotai gali teikti personalizuotas rekomendacijas ir patarimus, atsižvelgdami į kliento elgseną, finansinius tikslus ir istorinius duomenis, o tai padeda klientams priimti geresnius finansinius sprendimus.
4. Skaitmeninės inovacijos: vartotojai tikisi modernių ir inovatyvių sprendimų, kurie palengvintų jų finansų valdymą. Tai apima skaitmenines mokėjimo platformas, mobiliuosius pinigų valdymo įrankius ir automatizuotas finansų valdymo sistemas. Pokalbių robotai gali atlikti daugybę užduočių vienu metu, leidžiant darbuotojams, ekspertams susitelkti į sudėtingesnes ir didesnę pridėtinę vertę kuriančias užduotis (eMarketer, 2023).

Pokalbių robotai gali padidinti paslaugų teikimo našumą ir efektyvumą. Virtualūs asistentai, kurie susidoroja su pagrindiniais ar dažnai pasikartojančiais klausimais, gali sumažinti laukimo laiką ir pagerinti paslaugų tiekėjų produktyvumą. Pasak Zendesk, 78% chatbotų, kurie atsako į pagrindinius ar dažnai užduodamus klausimus, gali sumažinti laukimo laiką ir taip leidžiant įmonėms efektyviau valdyti didelius klientų srautą, ypač piko metu, ir užtikrinti, kad sudėtingesnės užklausos būtų

nukreiptos kvalifikuotiems darbuotojams, kurie gali suteikti išsamesnę pagalbą. Be to, virtualūs asistentai gali analizuoti didelius duomenų kiekius realiu laiku, identifikuoti tendencijas ir teikti įžvalgas, kurios padeda gerinti paslaugų kokybę ir veiklos efektyvumą. Ši automatizacija ne tik taupo laiką, bet ir padeda sumažinti klaidų tikimybę, didinant bendrą paslaugų teikimo kokybę. (Zendesk, 2023)

Fintech inovacijos ir pokalbių robotai keičia finansinių paslaugų teikimą, gerindami vartotojų patirtį ir didindami verslo našumą. Naudojant dirbtinį intelektą, virtualūs asistentai užtikrina greitą, efektyvų ir personalizuotą aptarnavimą, mažinant kaštus ir didinant paslaugų kokybę.

1.3. Virtualių asistentų naudojimo galimybės finansų sektoriuje

Finansų sektorius, būdamas viena iš sparčiausiai besivystančių ir nuolat besikeičiančių sričių, vis dažniau į savo veiklą integruoja modernias technologijas, siekdamas pagerinti paslaugų kokybę ir vartotojų patirtį. Tarp šių technologijų išsiskiria virtualūs asistentai, galintys atlikti įvairias užduotis – nuo klientų aptarnavimo iki sudėtingų finansinių konsultacijų teikimo. Virtualių asistentų naudojimas finansų sektoriuje yra itin svarbus, nes jie padeda efektyviau valdyti procesus, mažinti sąnaudas ir didinti klientų pasitenkinimą.

1.3.1. Taisyklėmis pagrįstų ir dirbtinio intelekto pokalbių robotų palyginimas: lankstumas ir adaptacija į vartotojų poreikius

Taisyklėmis pagrįsti virtualūs asistentai yra sukurti remiantis iš anksto nustatytais taisyklėmis ir scenarijais. Jie yra programuojami taip, kad reaguotų į konkrečias vartotojų užklausas, naudodami iš anksto apibrėžtus atsakymus. Šio tipo virtualūs asistentai pasižymi tokiais privalumais, kaip paprastumas, nuspėjamumas, lengvas kontroliavimas. Taisyklėmis pagrįsti chatbotai yra paprastesni kurti ir diegti, nes nereikia sudėtingų algoritmų ar mašininio mokymosi technologijų. Jie naudoja fiksuotą atsakymų rinkinį, kuris yra lengvai suprantamas ir valdomas (Verma et al., 2021). Taip pat, jie suteikia nuspėjamus ir vienodus atsakymus, todėl vartotojai gali lengviau suprasti, ko tikėtis. Tokiu būdu užtikrinama, kad atsakymai būtų nuoseklūs ir atitiks nustatytus standartus, kuriuos išsikelia įmonės, naudojančios juos. Kartu tokių asistentų atsakymus yra lengviau kontroliuoti ir užtikrinti, kad informacija būtų tiksli ir atitiktų įmonės standartus. Tai ypač svarbu finansų sektoriuje, kur bet kokie netikslumai gali turėti reikšmingų pasekmių. Be to, taisyklėmis pagrįsti chatbotai gali būti greitai pritaikomi konkrečioms situacijoms ir dažnai užduodamiems klausimams, nes jų kūrimo procesas nereikalauja sudėtingų algoritmų ar ilgalaikio mokymosi. Šių savybių dėka, įmonės gali užtikrinti klientų aptarnavimo kokybę su minimaliomis pastangomis ir resursais (Suhaili et al., 2021).

Tačiau, nagrinėtoje literatūroje pabrėžiami ir esminiai taisyklėmis pagrįstų virtualių asistentų trūkumai, tokie kaip ribotas lankstumas prisitaikant prie naujų ar neįprastų užklausų, apribotas funkcionalumas sprendžiant sudėtingesnes problemas ir būtinybė nuolat prižiūrėti bei atnaujinti jų atsakymus, siekiant užtikrinti veiksmingumą ir aktualumą. Taisyklėmis pagrįsti chatbotai negali prisitaikyti prie naujų ar neįprastų užklausų, nes jie nėra suprogramuoti mokytis iš sąveikų su vartotojais. Tai reiškia, kad jei vartotojai užduos klausimus, kurie nebuvo numatyti kūrimo etape, chatbotai nesugebės pateikti tinkamo atsakymo. Tai gali sukelti klientų nepasitenkinimą ir mažinti pasitikėjimą įmonės teikiamomis paslaugomis, o tai reiškia, kad kūrėjams reikia nuolat peržiūrėti ir atnaujinti taisykles, kad jos atitiktų naujus vartotojų poreikius ir užklausas (Rath et al., 2023). Taip pat, šie virtualūs asistentai gali atsakyti tik į tas užklausas, kurios buvo iš anksto suprogramuotos, todėl jie negali efektyviai spręsti sudėtingesnių ar nenumatytų klausimų. Tai apriboja jų gebėjimą teikti aukštos kokybės paslaugas sudėtingesnėse situacijose, kuriose reikalinga gilesnė analizė ar konteksto supratimas. Klientams tai gali reikšti prastesnę patirtį, kai jie bando gauti sudėtingesnę informaciją ar spręsti problemas, kurios nėra įprastos. Įmonėms tai gali reikšti prarastas galimybes efektyviai aptarnauti savo klientus ir potencialiai didesnius kaštus, susijusius su papildomu klientų aptarnavimu (Esco, 2023). Svarbu paminėti, kad norint užtikrinti, kad chatbotai būtų veiksmingi ir galėtų atsakyti į naujas užklausas, reikia nuolatinės priežiūros ir atnaujinimų. Tai reiškia, kad kūrėjai turi nuolat stebėti chatbotų veikimą, analizuoti jų atsakymus ir atnaujinti taisykles, kad jos atitiktų kintančius vartotojų poreikius. Tai gali būti sudėtinga ir laiko reikalaujanti užduotis, ypač didelėse organizacijose su dideliu klientų srautu. Klientams tai gali reikšti lėtesnę problemų sprendimo eigą ir mažiau nuoseklų aptarnavimą. Įmonėms tai gali reikšti didesnius kaštus, susijusius su nuolatine priežiūra ir darbuotojų apmokymu. (Meshram, Naik, Megha ir kiti, 2021).

Kalbant apie DI virtualius asistentus, kurie naudoja mašininio mokymosi ir natūralios kalbos apdorojimo (NLP) technologijas, jie gali atsakyti į vartotojų platesnes ir sudėtingesnes užklausas, tad savaime suprantamas jų pranašumas prieš taisyklėmis pagrįstus asistentus. Esminis tokių chatbotų privalumas yra, kad jie gali mokytis iš sąveikų su vartotojais ir nuolat tobulėti, analizuoti vartotojų pateiktus duomenis ir atitinkamai prisitaikyti, suteikdami dinamiškus ir konteksto atžvilgiu tinkamus atsakymus. Tokių DI chatbotų yra labai platus funkcionalumas, jie gali spręsti sudėtingesnius klausimus, prisitaikyti prie naujų situacijų ir taip atlikti įvairias užduotis, pradedant paprastais klientų aptarnavimo klausimais ir baigiant sudėtingais finansiniais konsultavimais (Murali, 2022). Dėl tokių plačių DI klientų aptarnavimo galimybių susiduriama su kita, techninė, jų puse, kuri yra išties sudėtinga ir brangi. AI chatbotai yra sudėtingesni kurti ir diegti, nes reikalauja pažangių algoritmų ir didelių duomenų rinkinių mokymuisi. Tai reiškia, kad jų kūrimas reikalauja daugiau laiko, resursų ir techninių žinių. Lyginant su taisyklėmis grįštais asistentais, tai DI reikalauja didesnių kūrimo ir palaikymo sąnaudų, tai reiškia didesnes pradines investicijas ir nuolatinės išlaidas, susijusias su

chatbotų priežiūra ir atnaujinimu. Nors jie gali mokytis ir tobulėti, pradžioje jų atsakymai gali būti netikslūs arba nepakankamai tikslūs, o tai gali sukelti vartotojų nepasitenkinimą ir sumažinti pasitikėjimą chatbotais (Bhoir, 2022).

Taigi, atlikta literatūros analizė parodo, kad taisyklėmis pagrįsti virtualūs asistentai yra paprasti, nuspėjami ir lengvai kontroliuojami, tačiau jų ribotumas prisitaikant prie naujų situacijų ir sudėtingesnių užklausų gali sumažinti klientų pasitenkinimą. Tuo tarpu dirbtinio intelekto chatbotai, nors ir reikalauja didesnių investicijų ir sudėtingesnio diegimo, gali mokytis ir prisitaikyti laikui bėgant, todėl yra efektyvesni sprendžiant sudėtingas problemas ir teikiant personalizuotas paslaugas.

1.3.2. Virtualių asistentų funkcijos, reikalingos teikti finansines paslaugas

Technologijų pažanga ir skaitmeninė transformacija fintech sektoriuje atvėrė naujas galimybes efektyviai teikti finansines paslaugas naudojant virtualius asistentus. Fintech chatbotai turi specifinių reikalavimų, kurie juos išskiria iš tradicinių finansinių paslaugų chatbotų. Pavyzdžiui, fintech virtualūs asistentai turi būti sukurti naudojant pažangias saugumo technologijas, tokias kaip šifravimas ir biometrinė autentifikacija, kad būtų užtikrintas duomenų saugumas. Be to, jie turi galėti prisitaikyti prie didelių vartotojų srautų bei integruotis su įvairiomis finansinėmis sistemomis, naudodami API ir kitus integracijos sprendimus (Siddik, Li ir Sharif, 2023).

Fintech chatbotai privalo naudoti šifravimo, autentifikacijos ir autorizacijos technologijas, siekiant užtikrinti vartotojų duomenų saugumą ir atitikti specifinius fintech sektoriaus reikalavimus. Fintech sektoriuje yra taikomi specifiniai saugumo standartai, tokie kaip PCI-DSS (Payment Card Industry Data Security Standard), kurie reikalauja griežtų šifravimo metodų ir reguliaraus saugumo patikrinimo. PCI-DSS standartai nustato reikalavimus, kaip turėtų būti apsaugomi mokėjimo kortelių duomenys, įskaitant duomenų šifravimą tiek jų saugojimo metu, tiek perduodant (Csirt, 2023). Taip pat ir autentifikacija, autorizacija yra esminiai saugumo elementai, naudojami siekiant užtikrinti, kad tik įgalioti vartotojai gali prieiti prie jautrių duomenų ir atlikti finansines operacijas (Adams, 2023). Saugumui užtikrinti yra naudojamos šios autentifikacijos ir autorizacijos priemonės:

Autentifikacijos ir autorizacijos priemonės

Priemonė	Aprašymas
Daugelio veiksmų autentifikacija (MFA)	Tai metodas, kai vartotojas turi pateikti kelis įrodymus savo tapatybės patvirtinimui. Pvz., kartu su slaptažodžiu vartotojas gali būti paprašytas pateikti vienkartinį kodą, gautą per SMS arba autentifikavimo programą.
Autorizacijos valdymas	Užtikrina, kad vartotojai gali prieiti tik prie tų sistemos dalių, kurios yra būtinos jų funkcijoms atlikti.

Šaltinis: sudaryta autoriaus pagal Adams, 2023

API (Application Programming Interface) yra esminis komponentas, leidžiantis fintech pokalbių robotams sklandžiai integruotis su esamomis finansinėmis sistemomis. API suteikia standartizuotą metodą, leidžiantį skirtingoms programinėms sistemoms bendrauti ir dalintis duomenimis. Naudodamiesi API, chatbot gali atlikti įvairias funkcijas, tokias kaip mokėjimų apdorojimas, tapatybės patikrinimas, kredito reitingo tikrinimas ir paskolų teikimas. Efektyvi duomenų sinchronizacija tarp chatbotų ir finansinių sistemų yra kritinė fintech sektoriuje, siekiant užtikrinti, kad visos operacijos ir vartotojų informacija būtų nuolat atnaujinama ir tiksliai atspindėtų esamą situaciją. Tai pasiekama naudojant API, kurie leidžia nuolat keistis duomenimis tarp skirtingų sistemų, užtikrinant, kad vartotojai visada turėtų prieigą prie naujausios informacijos (Rajput, 2024). Realus laiko duomenų apdorojimas yra itin svarbus fintech paslaugoms, nes jis leidžia vartotojams gauti greitą ir tikslią informaciją. Tai ypač svarbu tokioms operacijoms kaip mokėjimai, sąskaitų valdymas ir investicijų stebėjimas. Naudojant API, fintech chatbotai gali greitai gauti ir apdoroti duomenis iš įvairių finansinių sistemų, užtikrindami aukštą paslaugų kokybę ir patikimumą. Lentelė apačioje apibendrina specifines konsultacijas ir funkcijas, kurias gali atlikti fintech virtualūs pokalbių robotai:

Specifinės konsultacijos ir funkcijos fintech sektoriuje, kurias gali atlikti pokalbių robotai

Konsultacijos/Funkcijos	Aprašymas
Investicijų patarimai	Fintech pokalbių robotai gali analizuoti rinkos duomenis ir vartotojo portfelį, teikdami rekomendacijas dėl akcijų, obligacijų ar kitų investicinių priemonių pirkimo ar pardavimo.

Šaltinis: sudaryta autoriaus pagal Jain et al., 2023

Konsultacijos/Funkcijos	Aprašymas
Biudžeto planavimas	Pokalbių robotai gali padėti vartotojams sudaryti asmeninį ar šeimos biudžetą, stebint išlaidas ir pajamų srautus, bei teikiant rekomendacijas, kaip optimizuoti išlaidas.
Finansinės prognozės	Naudodami istorinius duomenis, pokalbių robotai gali generuoti prognozes apie vartotojo finansinę būklę ateityje, padedant planuoti ilgalaikius finansinius tikslus.
Automatizuoti mokėjimai	Pokalbių robotai gali atlikti automatizuotus mokėjimus už paslaugas ar prekes, taip sumažinant vartotojo dalyvavimą ir užtikrinant greitą bei efektyvų procesą.
Finansinių operacijų stebėjimas	Naudodami pokalbių robotus, vartotojai gali stebėti savo finansines operacijas realiu laiku, gaudami pranešimus apie bet kokius pokyčius sąskaitoje.
Pajamų ir išlaidų analizė	Pokalbių robotai gali analizuoti vartotojo pajamas ir išlaidas, teikdami įžvalgas apie finansinę padėtį ir rekomendacijas dėl išlaidų optimizavimo.

Šaltinis: sudaryta autoriaus pagal Jain et al., 2023

Nagrinėtoje literatūroje akcentuojama, kad fintech pokalbių robotai atveria naujas galimybes efektyviai teikti finansines paslaugas, integruojant pažangias saugumo technologijas, tokias kaip šifravimas ir biometrinė autentifikacija, siekiant užtikrinti aukštą jautrių duomenų saugumo lygį. Efektyvi duomenų sinchronizacija ir jų apdorojimas realiu laiku užtikrina, kad vartotojai visada turi prieigą prie naujausios ir tiksliausios informacijos, o tai didina paslaugų kokybę ir patikimumą. Fintech pokalbių robotų funkcijos ir teikiamos konsultacijos gali pagerinti vartotojų patirtį, užtikrinti greitą ir efektyvų informacijos suteikimą kartu ir finansinių sprendimų priėmimą.

1.3.3. Finansinės rizikos vertinimo metodų integracija į virtualius asistentus

Finansinė rizika tai neatsiejama finansų valdymo ir sprendimų priėmimo dalis. Tiek fiziniams, tiek juridiniams asmenims yra būtina analizuoti galimas rizikas prieš priimant tam tikrus sprendimus, kurie daro įtaką finansiniam stabilumui. Tad šiose situacija, šiuolaikinių technologijų dėka, virtualūs asistentai tampa veiksmingu įrankiu, padedančiu lengviau suprasti galimas finansines rizikas, o tyrimai rodo, kad šios technologijos reikšmingai gerina finansinės rizikos valdymą.

Viename iš nagrinėtų tyrimų patvirtinta, kad dirbtinio intelekto sprendimai, įskaitant mašininio mokymo modelius, finansinės rizikos vertinimui yra efektyvūs sprendimai. Tiriamasis darbas buvo orientuojamas į tiekimo grandinės finansinės rizikos vertinimą, nagrinėjant pagrindinius rizikos šaltinius ir procesus, susijusius su finansinės rizikos integruotu vertinimu. Tyrimo objektu buvo pasirinktas „M“ bankas, siekiant patikrinti modelių tinkamumą realiame finansiniame scenarijuje, testavimo metu buvo naudojami sprendimų medžiai ir mašininis mokymas, kurie pasižymėjo gebėjimu integruoti kelis rizikos rodiklius, leidžiant geriau suprasti rizikos šaltinius ir jų poveikį tiekimo grandinės finansiniam stabilumui (Liu, Y., 2023).

Straipsnyje „Financial Risk Assessment Model Based on Computer Data Privacy Protection“, autoriaus Jianjie Huang (2024), buvo siekiama užtikrinti kuo didesnę rizikos vertinimo tikslumą ir apsaugoti duomenų privatumą naudojant pažangius algoritmus. Pagrindinis dėmesys buvo skiriamas finansinių sandorių rizikos valdymui, taikant optimizuotus metodus rizikai įvertinti ir privatumui apsaugoti. Tyrime pasiektas ženkliai trumpesnis modelio, kuris paremtas dalelių spiečiaus optimizavimo metodu, treniravimo laikas nei tradicinių modelių, o tai rodo algoritmo didesnę efektyvumą.

Verta paminėti ir didžiųjų duomenų analizę, kuri taip pat daro didelę įtaką virtualių asistentų vystymuisi finansinės rizikos vertinimams. „The Impact of Big Data Analytics on Financial Risk Management“ (2024) nagrinėjama, kaip didžiųjų duomenų analizė transformuoja finansinės rizikos valdymą. Tyrimas parodė, kad didieji duomenys leidžia pagerinti prognozavimo modelius – naudojant įvairius duomenų šaltinius, finansinius rodiklius, vartotojų elgesį, socialinių tinklų duomenis, galima prognozuoti rizikas ir nustatyti išorinius veiksnius, tačiau integracija tarp sistemų ir duomenų privatumo užtikrinimas yra pagrindiniai iššūkiai, siekiant veiksmingai panaudoti didžiuosius duomenis. Taip pat, didieji duomenys leidžia greitai pastebėti rizikingus rinkos pokyčius ir iškart veikti, vertinti besiartinančias rizikas.

Taigi, nagrinėtoje literatūroje išskiriama, kad virtualiuose asistentuose naudojami DI modeliai veikia pagrįstai naudojant banko duomenis, kas rodo jų pritaikomumą realioms finansinėms institucijoms. Tyrimai pabrėžia, kad mašininio mokymosi ir dirbtinio intelekto taikymas ateityje dar labiau pagerins finansinės rizikos vertinimą ir prevenciją, stiprindamas finansinį saugumą bei efektyvumą.

2. DIRBTINIO INTELEKTO SPRENDIMAI - MATEMATINIAI MODELIAI SKOLŲ GRAŽINIMO IR RIZIKOS VERTINIMO ANALIZĖJE

Šiuolaikinėje visuomenėje paskolos ir skolinimasis yra tapę neatsiejamą finansinio gyvenimo dalimi tiek fiziniams, tiek juridiniams asmenims. Paskolos suteikia galimybę įgyvendinti svarbius gyvenimo tikslus – nuo būsto įsigijimo, mokslų finansavimo iki verslo kūrimo ir plėtros. Pasak Yap ir kitų. (2023), pasaulinės vartojimo paskolos ir skolinimas pastarąjį dešimtmetį ženkliai išaugo, ypač besivystančiose šalyse, kur paskolos padeda sukurti geresnes sąlygas verslo plėtrai ir gerovei. Taip yra žinoma, kad beveik 50% visų mažųjų ir vidutinių įmonių pradeda savo veiklą su išorinės finansinės paramos, dažniausiai paskolos, pagalba. Skolinimasis padeda finansuoti verslo plėtros projektus, įsigyti naują įrangą ar plėtoti inovatyvius sprendimus, kurie didina įmonės konkurencingumą. Verslo plėtra, finansuojama per paskolas, yra viena iš pagrindinių ekonomikos augimo varomųjų jėgų, leidžianti įmonėms kurti naujas darbo vietas ir stiprinti ekonomikos stabilumą.

Skolų gražinimo analizė šiame kontekste tampa itin svarbi siekiant užtikrinti tvarų skolinimą. Tai leidžia finansinėms institucijoms įvertinti paskolų riziką ir numatyti, ar klientai bus pajėgūs įvykdyti savo įsipareigojimus. Taip pat šis procesas prisideda prie rizikos mažinimo ir tvaresnio skolinimo, užtikrinant ne tik finansinių institucijų stabilumą, bet ir socialinę-ekonominę gerovę. Tad, tyrimui apie dirbtinio intelekto sprendimus skolų gražinimo kontekste, buvo pasirinkti keli duomenų klasifikavimo modeliai, neuroniniai tinklai ir gilusis mokymasis.

2.1. Duomenų paruošimo metodai

Duomenų paruošimas yra esminis ir būtinas tyrimo pradžios etapas, kuris užtikrina duomenų tinkamumą, kokybę ir modelio efektyvumą. Duomenų standartizacija ir normalizacija yra skirti užtikrinti, kad skirtingų duomenų bruožų reikšmės būtų įvertintos vienodomis skalėmis. Pavyzdžiui, jei vienas bruožas yra atstovaujamas kaip didelio masto skaičiai (pvz., tūkstančiai) ir kitas kaip maži skaičiai (pvz., dešimtainės trupmenos), modelis gali būti linkęs teikti pirmenybę bruožams su didesnėmis reikšmėmis, net jei jie nėra svarbesni. Tai gali lemti iškreiptas modelio prognozes ir klaidingas interpretacijas. Kitas atvejis, kuomet galimas klaidingas duomenų interpretavimas, tai kuomet yra duomenų disbalansas. Tai situacija, kai tam tikros klasės yra daug mažiau atstovaujamos nei kitos klasės. Pavyzdžiui, sveikatos duomenų rinkinyje sergančiųjų klasė gali būti daug mažesnė nei sveikųjų klasė. Nesubalansuoti duomenys gali lemti, kad mašininio mokymosi modelis bus linkęs prognozuoti dažniausią klasę, ignoruodamas rečiau pasitaikančią, tačiau svarbią klasę. Subalansuoti

duomenys ne tik pagerina modeliavimo tikslumą, bet ir padeda užtikrinti teisingesnes ir mažiau šališkas prognozes.

2.1.1. Standartizacija ir normalizacija

„StandardScaler“ yra vienas iš labiausiai naudojamų metodų savybių standartizavimui, kai kiekvieno bruožo reikšmės keičiamos taip, kad jų vidurkis būtų 0, o standartinis nuokrypis – 1. Šis metodas padeda išvengti dominavimo duomenų rinkinį sudarančių bruožų, kurių skalės yra skirtingos. Taip užtikrinama, kad kiekvienas bruožas vienodai prisidėtų prie modelio mokymo. Matematiškai standartizavimas išreiškiamas formule:

$$z = \frac{x - \mu}{\sigma} \quad (1)$$

kur: x – pradinė reikšmė, μ – vidurkis, σ – standartinis nuokrypis

Pasak Haider ir kitų (2024) atliktų tyrimų, „StandardScaler“ yra labai naudingas, kai reikia apdoroti duomenų rinkinius, kuriuose yra reikšmingų dydžio skirtumų tarp bruožų. Taip pat pažymima, kad toks standartizavimas pagerina modelio konvergencijos spartą ir sumažina mokymo laiką.

Normalizavimas skirtas užtikrinti, kad visos savybės būtų išmatuotos vienodais intervalais. Skirtingų skalės dydžių savybės gali sukelti modelio šališkumą. Pabrėžiama, kad normalizavimas ypač svarbus tokiuose metoduose kaip k-artimiausių kaimynų ir neuronų tinklai, kuriuose svarbūs atstumai tarp duomenų taškų. Tyrime (Nithya et al., 2024) aprašoma, kaip normalizacija padėjo gerokai padidinti modelio našumą. Viena iš plačiausiai naudojamų normalizacijos formulių yra MinMax metodas:

$$x' = \frac{x - x_{min}}{x_{max} - x_{min}} \quad (2)$$

2.1.2. Duomenų balansavimo metodai

SMOTE (angl. Synthetic Minority Over-sampling Technique) metodas generuoja naujus sintetinius mažumos klasės pavyzdžius, siekiant sumažinti duomenų disbalansą. Vietoje paprasto egzistuojančių pavyzdžių dubliavimo, SMOTE generuoja naujus taškus, naudojant linijinę interpoliaciją tarp atsitiktinai parinktų mažumos klasės duomenų ir jų artimiausių kaimynų. Šio metodo veikimo procesas yra toks:

1. Pirmiausia pasirenkamas atsitiktinis mažumos klasės pavyzdys x_i .
2. Ieškoma keletas jo artimiausių kaimynų iš tos pačios mažumos klasės.
3. Naujas duomenų taškas x_{new} sukuriamas linijiniu būdu, kuris išskaičiuojamas naudojant šia formulę:

$$x_{new} = x_i + \delta \cdot (x_k - x_i), \quad \delta \in [0,1] \quad (3)$$

kur: x_i – pradinis mažumos klasės pavyzdys, x_k – vienas iš x_i artimiausių kaimynų, δ – atsitiktinis skaičius iš intervalo $[0,1]$

Remiantis moksliniu tyrimu, atliktu Ramadhan ir kitų (2024), buvo įrodyta, kad SMOTE metodas ženkliai pagerina modeliavimo tikslumą nesubalansuotuose duomenyse, tokiuose kaip medicininė diagnozė ar sukčiavimo atpažinimas.

Klasių svorių pritaikymas yra metodas, skirtas pritaikyti modelio jautrumą, skiriant didesnę svorį mažumos klasei. Tai leidžia modeliams efektyviau „mokytis“ mažumos klasės pavyzdžių, suteikiant jiems didesnę svarbą mokymo proceso metu. Klasių svorių pritaikymas veikia taip, kad pirmiausia kiekvienai klasei yra priskiriamas svoris, kuris paprastai apskaičiuojamas kaip atvirkštinė proporcija klasės dažnumui, skaičiavimai vyksta pagal šią formulę:

$$w = \frac{1}{f} \quad (4)$$

kur: w – svoris klasei, f – klasės dažnumas

Tuomet, mokymo proceso metu modelis optimizuojamas taip, kad mažumos klasės pavyzdžiai turėtų didesnę poveikį klaidos funkcijai ir mokymosi kriterijams. Klasių svorių panaudojimas leidžia modeliams atkreipti didesnę dėmesį į mažiau atstovaujamas klases, todėl jie tampa tikslesni.

2.2. Mašininio mokymosi metodai paskolų rizikos analizėje

Mašininis mokymasis yra plačiai naudojamas paskolų rizikos analizei, nes leidžia efektyviai apdoroti didelius duomenų kiekius ir nustatyti kliento riziką pagal įvairius veiksnius. Šie metodai padeda numatyti galimas neapmokėjimo rizikas, analizuodami istorinius duomenis ir pritaikydami modelius, kurie gali būti dinamiškai atnaujinami.

2.2.1. Logistinės regresijos metodas

Mašininio mokymosi metodai, taikomi paskolų rizikos analizei, leidžia klasifikuoti ir prognozuoti skolininkų elgesį, remiantis įvairiais duomenimis ir charakteristikomis. Šio metodo tikslas yra

suskirstyti skolininkus į skirtingas rizikos grupes, pavyzdžiui, didelės ir mažos rizikos grupes, remiantis jų ankstesniu elgesiu ir kitais veiksniais. Klasifikavimo algoritmai, tokie kaip sprendimo medžiai, logistinė regresija ir atsitiktiniai miškai, dažniausiai naudojami, siekiant nustatyti skolininkų grupes, kurios turi didesnę tikimybę neįvykdyti paskolų įsipareigojimų. Šie modeliai optimizuoja tikimybinį sprendimų priėmimą, leidžiant efektyviau valdyti riziką ir leidžia tiksliai identifikuoti aukštos rizikos klientus, minimizuoti finansines rizikas bei efektyviau paskirstyti paskolų portfelį. Mašininio mokymosi metodai leidžia prognozuoti tikimybę, ar konkretus skolininkas grąžins paskolą, remiantis praeities duomenimis ir kitais rodikliais. Prognozavimo algoritmai, tokie kaip regresijos modeliai ar laiko eilučių analizė, gali suteikti tikslią prognozę dėl kliento būsimų veiksmų. Pavyzdžiui, naudojant logistinę regresiją, tikimybės formulė yra tokia:

$$P(Y = 1 | X) = \frac{1}{1 + e^{-(\beta_0 + \beta_1 X_1 + \dots + \beta_n X_n)}} \quad (5)$$


Čia $P(Y = 1 | X)$ reiškia tikimybę, kad įvyks neapmokėjimas, o $\beta_0, \dots, \beta_n$ yra modelio parametrai.

Logistinės regresijos modelis leidžia nustatyti skolininkų tikimybę negrąžinti paskolos. Remiantis šia tikimybe, galima segmentuoti klientus į rizikos grupes, aukštos ar žemos rizikos ir priimti efektyvesnius sprendimus dėl paskolos suteikimo ar valdymo. Remiantis Pinto et al. (2024), logistinė regresija buvo taikoma Brazilijos finansų sektoriaus kredito rizikos vertinimui, siekiant išanalizuoti pagrindinius veiksnius, lemiančius skolų neapmokėjimą. Tyrimo metu buvo naudojami duomenys apie paskolos gavėjus, įskaitant jų pajamų lygį, paskolų istoriją, skolos ir pajamų santykį, amžių, lytį, užimtumo tipą ir kitus socialinius bei ekonominius rodiklius. Logistinės regresijos modelis padėjo identifikuoti veiksnius, kurie stipriausiai koreliuoja su neapmokėjimo rizika. Be to, Pinto ir kolegų tyrimas išryškino, kad logistinė regresija leidžia lengviau interpretuoti modelio koeficientus, kas padeda finansų įstaigoms priimti informuotus sprendimus, remiantis aiškiomis prognozėmis. Tai padeda finansų sektoriui ne tik geriau prognozuoti riziką, bet ir taikyti tinkamesnes paskolų suteikimo sąlygas rizikingesniems klientams.

2.2.2. Atsitiktinių miškų metodas

Atsitiktiniai miškai yra vienas iš populiariausių metodų, skirtų klasifikacijai ir prognozavimui. Jis sudarytas iš daugybės sprendimo medžių, kurių kiekvienas prisideda prie galutinės prognozės. Šis metodas pasižymi tvirta struktūra, atsparumu persimokymui ir aukštu tikslumu. Atsitiktinių miškų modelis naudoja šiuos veikimo principus (paveikslėlis):

1. Atsitiktinai pasirinktos savybės: kiekvienas medis suformuojamas remiantis atsitiktinai pasirinktomis savybėmis iš duomenų.
2. Prognozių agregavimas: galutinė prognozė yra visų sprendimo medžių prognozių vidurkis (regresijos atveju) arba daugumos balsas (klasifikacijos atveju).



Šaltinis: Riebesell (2022), išversta autoriaus.

3 pav. Atsitiktinių miškų metodo veikimo principas

Šis modelis leidžia analizuoti kiekvienos įvesties duomenų savybės poveikį galutinei modelio prognozei. Tai reiškia, kad atsitiktiniai miškai gali nustatyti, kurios savybės labiausiai prisideda prie kredito rizikos vertinimo – ar tai būtų kliento pajamos, paskolos dydis, skolos ir pajamų santykis, paskolų istorija, amžius ar kiti duomenys.

Tyrime, kurį atliko Robisco and Martínez (2022), buvo parodyta, kad atsitiktiniai miškai padėjo identifikuoti pagrindines savybes, kurios turi didžiausią įtaką kredito rizikos vertinimui. Tyrimas panaudojo didelį paskolų duomenų rinkinį, kur buvo analizuojamos įvairios savybės, įskaitant finansinius, demografinius ir kitus veiksnius, galinčius turėti įtakos skolininko gebėjimui grąžinti paskolą. Atsitiktinių miškų modeliai suteikė galimybę suprasti, kurie veiksniai yra kritiniai prognozuojant skolos neapmokėjimo riziką. Buvo nustatyta, kad skolos ir pajamų santykis bei kliento paskolų istorija buvo vieni iš svarbiausių prognozių veiksnių, o demografiniai rodikliai, tokie kaip amžius ir gyvenamoji vieta, taip pat turėjo reikšmingą poveikį, tačiau mažesnę svarbą, palyginti su finansiniais rodikliais.

Atsitiktinių miškų modelių savybių svarbos vertinimo galimybės padeda ne tik geriau suprasti, kurie veiksniai labiausiai prisideda prie kredito rizikos, bet ir leidžia finansų įstaigoms imtis tinkamų veiksmų rizikai valdyti.

2.2.3. XGBoost metodas

XGBoost (Extreme Gradient Boosting) – tai optimizuotas „gradient boosting“ algoritmas, skirtas greitam ir tiksliam prognozavimui. Jis yra ypač populiarus paskolų rizikos vertinime, nes siūlo didelę tikslumą, mažą persimokymo riziką ir lengvą interpretaciją. XGBoost modelis dirba iteratyviai, sukurdami naujus modelius, kurie pataiso ankstesnių modelių klaidas, minimizuodami nuostolių funkciją:

$$\text{Obj}(\Theta) = \sum_i L(y_i, \hat{y}_i) + \sum_k \Omega(f_k) \quad (6)$$

kur: L – nuostolių funkcija (dažniausiai kvadratinė klaida), Ω – reguliavimo terminas, padedantis išvengti persimokymo, f_k – kiekvienas modelio komponentas

Wang et al. (2022) tyrime ištirta XGBoost metodo (Extreme Gradient Boosting) taikymo nauda prognozuojant skolos grąžinimo riziką. Šio tyrimo rezultatai parodė, kad XGBoost algoritmas yra ypač efektyvus, nes leidžia tiksliai prognozuoti klientų galimą neapmokėjimą, naudodamas daugybę istorinių ir aktualių duomenų kintamųjų. Pagrindinis šio metodo efektyvumo šaltinis yra gebėjimas geriau apdoroti sudėtingus duomenų ryšius ir padidinti modelio tikslumą mažinant klaidas. Kiekviena nauja modelio iteracija koreguoja ankstesnių modelių klaidas, o tai lemia gilesnį ir tikslesnį prognozavimą.

XGBoost modelis leidžia optimizuoti sprendimų priėmimą, nustatant svarbius veiksnius, kurie labiausiai prisideda prie prognozių. Tai buvo pabrėžta Wang et al. tyrime, kur XGBoost algoritmas parodė geresnius rezultatus, palyginti su kitais tradiciniais metodais, tokiais kaip logistinė regresija ar paprasti sprendimo medžiai.

2.3. Giliojo mokymosi metodai

Giliojo mokymosi metodai plačiai taikomi paskolų rizikos vertinimui, nes leidžia modeliuoti sudėtingas duomenų struktūras ir sąveikas tarp daugelio kintamųjų. Jie suteikia galimybę efektyviai prognozuoti kliento finansinę riziką, įvertinant daugybę veiksnių, tokių kaip pajamų pokyčius, kredito istoriją ir kitas laiko sekų duomenų struktūras.

2.3.1. Daugiapakopis perceptronas (MLP)

Daugiapakopis perceptronas (MLP) – tai giluminis neuroninis tinklas, kuris susideda iš vieno įvesties sluoksnio, vieno ar daugiau paslėptųjų sluoksnių ir išvesties sluoksnio. Kiekvienas sluoksnis

yra visiškai sujungtas su kitais, o kiekvienas neuroninis mazgas naudoja aktyvacijos funkcijas, tokias kaip „ReLU“ (Rectified Linear Unit), kad modeliuotų duomenų ryšius.

Aktyvacijos funkcijos yra esminis giluminio mokymosi modelių komponentas, kuris leidžia neuroniniams tinklams išmokyti sudėtingus duomenų ryšius. Jos įneša netiesiškumą į modelį, leidžiant neuroniniam tinklui išmokyti netiesinių duomenų sąsajas. ReLU yra aktyvacijos funkcija, apibrėžiama kaip:

$$f(x) = \max(0, x) \quad (7)$$

kur: Jei įvesties reikšmė x yra teigiama, „ReLU“ grąžina tą pačią reikšmę ($f(x) = x$). Jei įvesties reikšmė x yra neigiama, „ReLU“ grąžina nulį ($f(x) = 0$).


Kita plačiai naudojama aktyvacijos funkcija yra sigmoidinė funkcija, ypač pravarti ankstyvosiose neuroninių tinklų vystymosi stadijose. Paskolų rizikos prognozavimo užduotyse sigmoidinė funkcija gali būti naudojama modeliuoti tikimybę, kad klientas negrąžins paskolos, remiantis įvairiais duomenimis (pvz., pajamomis, kredito istorija). Jei išvestis yra artima 1, tai rodo, kad klientas turi didelę neapmokėjimo riziką, o jei artima 0 – rizika yra maža. Sigmoidinė funkcija apibrėžiama taip:

$$f(x) = \frac{1}{1 + e^{-x}} \quad (8)$$

kur: e – Eulerio skaičius (apie 2,718), x – įvesties reikšmė.

MPL tinklo struktūra susideda iš šių pagrindinių dalių, 4 paveikslėlis:

1. Įvesties sluoksnis: priima pagrindinius duomenis (klientų finansinius duomenis, pajamų ir skolos santykį).
2. Paslėptieji sluoksniai: jie išmoksta įvairius duomenų ryšius, modifikuoja svorius per atgalinį sklaidimą, siekdami minimizuoti klaidos funkciją. MLP leidžia aptikti kompleksiskus duomenų ryšius ir pagerinti prognozavimo tikslumą.
3. Išvesties sluoksnis: pateikia galutinę prognozę (tikimybę, kad klientas negrąžins paskolos).



Šaltinis: Bento (2022), išversta autoriaus.

4 pav. MLP veikimo principas

Pagal Nasir and Razak (2022), daugiapakopiai perceptrai (MLP) yra sėkmingai pritaikomi finansų sektoriuje prognozuojant kredito riziką, nes jie pasižymi gebėjimu apdoroti sudėtingus, nestruktūrizuotus ir netiesiškai susijusius duomenis. MLP modeliai sugeba išmokti ir išryškinti paslėptus duomenų ryšius, kuriuos sunkiau pastebėti naudojant tradicinius statistinius modelius ar paprastesnius mašininio mokymosi algoritmus. Šis atliktas tyrimas parodė, kad MLP modeliai sugebėjo analizuoti didelės apimties duomenų rinkinį iš banko klientų ir tiksliai prognozuoti kredito rizikos lygį, remiantis daugybe įvairių finansinių ir demografinių kintamųjų. Šis modelis leido išryškinti tokias savybes kaip skolos ir pajamų santykis, kredito istorija bei užimtumo statusas, kurios ypatingai svarbios prognozuojant klientų finansinį patikimumą.

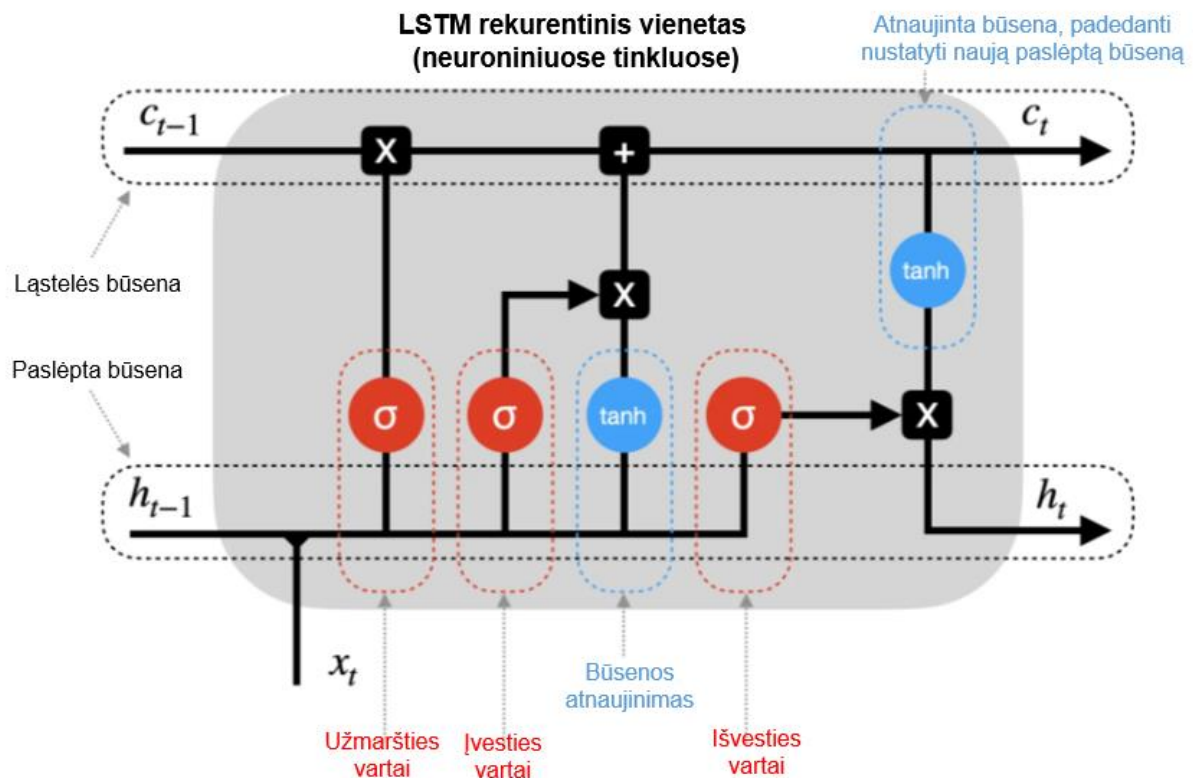
Finansų sektoriaus duomenys dažnai būna itin kompleksiniai, apimantys skirtingus kintamuosius, tokius kaip klientų demografiniai rodikliai, finansiniai įsipareigojimai, kredito istorija ir kiti veiksniai. MLP modeliai, turėdami daug paslėptųjų sluoksnių, leidžia efektyviai apdoroti tokius duomenis, modeliuodami net sudėtingas netiesines sąsajas.

2.3.2. Ilgalaikės atminties modelis (LSTM)

Ilgalaikės atminties modelis (LSTM) yra specializuotas pasikartojančių neuroninių tinklų (RNN) modelis, skirtas laikiniams duomenims analizuoti. Jis efektyviai tvarko ilgalaikę priklausomybę ir leidžia „atsiminti“ svarbią informaciją per ilgą laikotarpį. LSTM tinklai yra naudingi, kai duomenų

rinkiniais turi laiko sekų elementus, pavyzdžiui mokėjimų istoriją. LSTM modelis susideda iš tokių dalių:

1. Ląstelių būseną: leidžia LSTM tinklams „atsiminti“ svarbią informaciją.
2. Vartų mechanizmas: kontroliuoja informacijos srautą:
 - 2.1. Įvesties vartai: nusprendžia, kuri nauja informacija turi būti įtraukta į ląstelių būseną.
 - 2.2. Informacijos užmiršimo vartų: nusprendžia, kokia informacija turi būti pamiršta.
 - 2.3. Išvesties vartai: nusprendžia, kokia informacija turi būti perduota.



Šaltinis: Banoula (2023), išversta autoriaus.

5 pav. LSTM veikimo principas

LSTM tinkluose visi šie vartai dirba kartu, lygiagrečiai, kaip pavaizduota 5 paveikslėlyje, siekdami užtikrinti, kad tinklas galėtų efektyviai mokytis iš ilgalaikių ryšių tarp duomenų. Pavyzdžiui, jei tam tikra informacija buvo naudinga praeityje, įvesties vartai gali leisti jai patekti į ląstelės būseną, o vartų, kuriuose informacija užmirštama, mechanizmas gali nuspręsti, kiek tos informacijos turėtų būti išlaikyta tolimesniems žingsniams. Išvesties vartai užtikrina, kad tik reikšminga informacija perduodama kitam tinklo etapui. Ši struktūra leidžia LSTM tinklams būti labai efektyviais sprendžiant laiko sekų problemas, tokias kaip kalbos atpažinimas, akcijų kainų prognozavimas, klientų mokėjimo elgesio analizė ir daug kitų uždavinių. Pavyzdžiui, finansų srityje LSTM tinklai gali analizuoti klientų paskolų mokėjimo istoriją ir prognozuoti, ar yra didelė rizika, kad klientas vėluos su būsimais mokėjimais, ar klientui paskolos našta bus per didelė.

2.3.3. Modelio mokymosi ir testavimo žingsniai giluminiame mokyme

Mokymo procesas prasideda nuo duomenų padalijimo į mokymo, validavimo ir testavimo rinkinius. Tai užtikrina, kad modeliai gali mokytis iš dalies duomenų ir būti įvertinti su naujais duomenimis, siekiant išvengti persimokymo. Toks duomenų rinkinio padalijimas yra esminis siekiant įvertinti giluminių modelių gebėjimą analizuoti naujus duomenis. Modelio mokymo metu įvesties duomenys praeina per neuroninių tinklų sluoksnius, kuriuose atliekami svertinių sumų skaičiavimai:

$$z = W \cdot X + b \quad (9)$$

kur: W – svoriai, X – įvestis, b – poslinkiai.

Svertinių sumų skaičiavimai vyksta kiekviename neuroniniame sluoksnyje ir apibrėžiami kaip įvesties reikšmių ir jų atitinkamų svorių sandaugų suma, prie kurios pridamas poslinkis (angl. bias). Svertinės sumos padeda transformuoti įvesties duomenis į tinklui suprantamą formatą. Kiekvienam įvesties duomenų taškui priskiriamas skirtingas svoris, atspindintis jo svarbą prognozei. Svoris rodo, kokią poveikį įvesties reikšmė turi modelio rezultatui (prognozei). Didesnis svoris reiškia, kad ta įvesties reikšmė turi didesnę įtaką. Taip modelis gali mokytis sudėtingų ryšių tarp skirtingų duomenų bruožų. Mokymo metu svoriai ir poslinkiai nuolat atnaujinami naudojant optimizavimo algoritmus, siekiant minimizuoti klaidų funkciją. Tai leidžia modeliams palaipsniui mokytis ir optimizuoti prognozes.

Vertinimo metrikos yra būtinos siekiant įvertinti giluminio mokymosi modelio našumą. Jos padeda nustatyti, kaip gerai modelis atpažįsta tinkamus ir netinkamus pavyzdžius, klasifikuoja duomenis ar prognozuoja rezultatus. Tai ypač svarbu tokiose srityse kaip kredito rizikos prognozavimas, kur netinkamos prognozės gali turėti didelį finansinį poveikį. Pateikiamos pagrindinės metrikos, jų reikšmė ir formulės:

1. Tikslumas matuoja teisingai klasifikuotų pavyzdžių dalį, palyginti su bendru pavyzdžių skaičiumi. Tikslumas parodo, kiek modelio prognozės yra teisingos, tačiau jis gali būti klaidinantis, jei duomenys yra labai nesubalansuoti, pavyzdžiui daug daugiau teigiamų nei neigiamų pavyzdžių).

$$\text{Tikslumas} = \frac{TP + TN}{TP + TN + FP + FN} \quad (10)$$

kur: **TP** (True Positive) – teisingai klasifikuoti teigiami pavyzdžiai, **TN** (True Negative) – teisingai klasifikuoti neigiami pavyzdžiai, **FP** (False Positive) – klaidingai klasifikuoti neigiami pavyzdžiai kaip teigiami, **FN** (False Negative) – klaidingai klasifikuoti teigiami pavyzdžiai kaip neigiami

2. Jautrumas (dar vadinamas atsaku) matuoja, kiek procentų tikrųjų teigiamų pavyzdžių modelis teisingai identifikavo. Jautrumas yra svarbus, kai svarbu identifikuoti visus teigiamus pavyzdžius, pvz., kredito rizikos atvejais tai gali būti klientai, kurie greičiausiai negrąžins paskolos.

$$\text{Jautrumas} = \frac{TP}{TP + FN} \quad (11)$$

3. F1 rodiklis yra vidurkis tarp tikslumo ir atsako (jautrumo). Jis yra naudingas, kai turime reikalų su nesubalansuotais duomenimis, ir siekiama išlaikyti pusiausvyrą tarp FP ir FN klaidų. F1 rodiklis suteikia įžvalgą apie modelio gebėjimą teisingai identifikuoti teigiamus pavyzdžius, vengiant per didelio klaidingų teigiamų pavyzdžių skaičiaus.

$$\text{F1 rodiklis} = 2 \cdot \frac{\text{Tikslumas} \cdot \text{Jautrumas}}{\text{Tikslumas} + \text{Jautrumas}} \quad (12)$$

4. ROC kreivė parodo modelio gebėjimą atskirti teigiamus pavyzdžius nuo neigiamų, kintant prognozių ribai. AUC (Area Under Curve) rodo plotą po ROC kreive ir nurodo modelio gebėjimą atskirti klases. AUC reikšmė yra tarp 0 ir 1; kuo didesnė reikšmė, tuo geresnis modelio gebėjimas atskirti klases. AUC=1 rodo tobulą klasifikavimą, o AUC=0.5 rodo atsitiktinę klasifikaciją.

ROC kreivės komponentai:

- TPR (True Positive Rate) arba jautrumas:

$$\text{TPR} = \frac{TP}{TP + FN} \quad (13)$$

- FPR (False Positive Rate):

$$\text{FPR} = \frac{FP}{FP + TN} \quad (14)$$

Mokymo procesas giluminiuose modeliuose prasideda nuo duomenų padalijimo, siekiant užtikrinti generalizaciją ir išvengti persimokymo, o svertinių sumų skaičiavimai leidžia modeliams įvertinti

įvesties reikšmių svarbą prognozėms. Vertinimo metrikos, tokios kaip tikslumas, jautrumas, F1 rodiklis ir ROC-AUC, padeda įvertinti modelio gebėjimą tiksliai atskirti teisingus nuo neteisingų pavyzdžių.

2.4. Dirbtinio intelekto modelių integracija virtualiuose asistentuose

Dirbtinio intelekto modelių integracija virtualiuose asistentuose leidžia sukurti inovatyvius sprendimus, kurie padeda efektyviai, greitai ir aiškiai aptarnauti klientus bei padėti suvaldyti ar bent įsivertinti galimas finansines rizikas.

2.4.1. Kūrimo aplinkos, jų galimybės ir privalumai

Virtualių asistentų kūrimas yra sudėtingas, apimantis dirbtinio intelekto modelius, vartotojo sąsajos kūrimo įrankius ir dideliais duomenų srautais pagrįstas technologijas. Šie asistentai gali analizuoti vartotojų užklausas, atlikti kasdienės užduotis ir teikti pritaikytas rekomendacijas, ypač finansinės rizikos vertinimo scenarijuose.

„Gradio“ yra viena iš pirmaujančių virtualių asistentų kūrimo bibliotekų. Tai supaprastina intuityvių, naršykle pagrįstų sąsajų, kuriose rezultatai rodomi realiuoju laiku, kūrimą. Pagrindinis „Gradio“ pranašumas yra patogumas vartotojui ir galimybė greitai sukurti interaktyvius modelių prototipus, kuriais galima lengvai dalytis su kitais. Virtualių asistentų prototipų kūrimui dažnų atveju kartu naudojamas „Google Colab“, kuris išsiskiria kaip vertinga platforma, nes:

1. Ji siūlo nemokamą prieigą prie GPU ir TPU išteklių, būtinų mokyti ir vykdyti AI modelius.
2. Python kodas gali būti vykdomas tiesiogiai debesyje, todėl nereikia sudėtingų vietinių konfigūracijų ar aparatinės įrangos.
3. „Colab“ palengvina sklandžų projekto dalijimąsi, bendradarbiavimą ir greitą eksperimentavimą ar atnaujinimus, kas ypatingai naudinga kuriant prototipus.

Be „Gradio“ ir „Colab“, virtualiems asistentams kurti taip pat galima naudoti kitas sistemas ir įrankius. „Streamlit“ yra perspektyvi „Gradio“ alternatyva, leidžianti sukurti interaktyvias sąsajas su minimaliu kodavimu. Jis gerai integruojamas su Python modeliais ir palaiko duomenų vizualizavimą realiuoju laiku, todėl idealiai tinka dinaminėms programoms. Kūrimui dažnai naudojamos bibliotekos, kaip „Flask“ ir „FastAPI“. „Flask“ yra plačiai vertinamas dėl savo paprastumo ir lankstumo, o „FastAPI“ siūlo patobulintas funkcijas, tokias kaip asinchroninis užklausų apdorojimas ir integruota API dokumentacija, todėl virtualaus asistento tinkinimas realiuoju laiku tampa efektyvesnis.

Kuriant pažangesnius pokalbių robotus, Rasa yra galinga atvirojo kodo platforma. Tai leidžia kūrėjams valdyti pokalbių srautus, aptikti vartotojų ketinimus ir automatizuoti sprendimų priėmimo

procesus. Arba „Dialogflow“, debesies pagrindu sukurtas sprendimas, leidžia greitai sukurti NLP valdomus pokalbių robotus su minimaliomis pastangomis. Norint mokyti ir diegti sudėtingus AI modelius, debesų platformos, tokios kaip AWS SageMaker ir Azure ML Studio, siūlo visapusišką infrastruktūrą. Šios platformos palaiko modelio kūrimo darbo eigas, įskaitant mokymą, testavimą ir diegimą, užtikrindamos mastelį ir tvirtumą. Galiausiai, tokie įrankiai kaip „Jupyter Notebook“ ir „VS Code“ yra plačiai naudojami kaip kūrimo aplinka. Jupyter Notebook leidžia interaktyviai ir žingsnis po žingsnio vykdyti sklandžiai Python kodą. Kita vertus, VS Code siūlo daug funkcijų turinčią kodavimo aplinką su sklandžiu įvairių bibliotekų ir įrankių integravimu, patenkinančiu sudėtingesnius plėtros poreikius.

2.4.2. API svarba virtualių asistentų kūrime

API (Application Programming Interface) vaidmuo itin svarbus kuriant virtualius asistentus, nes tai leidžia skirtingoms sistemoms ir programoms bendrauti tarpusavyje. API veikia kaip tarpininkas tarp vartotojo užklausų, serverio ar duomenų bazės bei dirbtinio intelekto modelių, užtikrindamas efektyvų duomenų perdavimą ir atsakymų generavimą. API užtikrina greitą ir sklandų informacijos srautą tarp vartotojo sąsajos ir mašininio mokymosi modelių. Pavyzdžiui, vartotojo pateikti parametrai, kaip pavyzdžiui FICO balas, palūkanų norma, gali būti perduodami prognozių modeliui per API. Virtualūs asistentai dažnai naudoja kelių dirbtinio intelekto modelių funkcijas, o naudojant API galima integruoti skirtingus modelius į vieną sistemą ir gauti prognozes realiuoju laiku. API suteikia galimybę naudoti modelius debesų platformose, todėl sistema gali aptarnauti daug vartotojų vienu metu, neprarandant našumo, taip pat tai leidžia lengvai atnaujinti, keisti ar pridėti naujas funkcijas nekeičiant visos sistemos struktūros. API suteikia prieigą prie papildomų funkcionalumų, tokių kaip natūralios kalbos apdorojimas, teksto generavimas ar duomenų analizė, naudojantis trečiųjų šalių platformomis.

OpenAI API yra vienas iš įrankių, naudojamų kuriant virtualius asistentus, ypač diegiant natūralios kalbos apdorojimo (NLP) funkcionalumą. Tai suteikia prieigą prie šiuolaikinių kalbos modelių, tokių kaip GPT-3.5-turbo ir GPT-4, kurie gali interpretuoti ir generuoti natūraliai skambančias reakcijas, artimas žmogaus kalbai. Pagrindinis OpenAI API pranašumas yra jos universalumas ir galimybė palaikyti sudėtingus dialogus, kartu naudoti „pokalbių istoriją“, kuri leidžia modeliui išlaikyti kontekstą ir nuosekliai tęsti dialogą. Ši funkcija ypač svarbi, kai reikia teikti asmenines finansines rekomendacijas ar prognozes. OpenAI API taip pat išsiskiria lengvu integravimu – ją galima lengvai pritaikyti įvairioms kūrimo aplinkoms, tokioms kaip Python, Flask, FastAPI, taip pat sąsajų kūrimo įrankiams, tokiems kaip Gradio ar Streamlit. Integravus OpenAI API į virtualų asistentą, galima sukurti funkcionalią sistemą, galinčią atlikti keletą svarbių užduočių. Pirmą, virtualus asistentas,


remdamasis įvestais duomenimis, gali atlikti klientų užklausų analizę, pavyzdžiui, atsakyti į klausimus apie paskolos neįvykdymo tikimybę. Antra, API gali paaiškinti finansines prognozes, suteikdama prieigą prie modelyje naudojamos analizės ir pateikdama suprantamus argumentus. Trečia, naudodamas vartotojo pateiktus duomenis, asistentas gali generuoti personalizuotas rekomendacijas, pavyzdžiui, optimizuoti mokėjimo planus ar pasiūlymus, padedančius sumažinti finansinę riziką. Taip pat, svarbu paminėti, kad OpenAI savo puslapyje dalinasi detaliu gidu, kaip naudoti API raktus, kad kiekvienas norintis išbandyti nesusidurtu su sunkumais.

Apibendrinant, dirbtinio intelekto modelių integracija į virtualius asistentus leidžia efektyviai ir nuosekliai teikti galimų finansinių rizikų rekomendacijas, o naudojant pažangius kūrimo įrankius, tokius kaip Gradio ar Streamlit, galima greitai sukurti interaktyvius prototipus, palengvinančius bendradarbiavimą ir testavimą. API, ypač OpenAI API, yra pagrindinis komponentas, užtikrinantis sklandų duomenų perdavimą, modelių integraciją bei galimybę generuoti vartotojui lengvai suprantamus atsakymus, kas ypač svarbu teikiant finansines prognozes ir galimus sprendimus.

3. MAŠININIO MOKYMOSI IR VIRTUALAUS ASISTENTO INTEGRUOTO MODELIO EKSPERIMENTINIS TYRIMAS PASKOLŲ GRAŽINIMO IR FINANSINIŲ RIZIKŲ VERTINIMUI

Paskolos ir kreditai šiuolaikiniam žmogui yra labai svarbi finansinio gyvenimo dalis – nuo kasdienių išlaidų valdymo iki didesnių investicijų ar pirkinių. Daugelis žmonių naudojami paskolomis, norėdami realizuoti savo tikslus, todėl paskolų suteikimo procesų ir jų rizikos analizę yra svarbi ne tik paslaugas teikiančioms įmonėms, bet ir patiems klientams. Dirbtinio intelekto (DI) sprendimai tampa reikšmingu įrankiu kredito rizikos vertinimui, siekiant užtikrinti teisingą ir atsakingą skolinimą. Šiuo tyrimu siekiama nagrinėti, kaip skirtingi metodai gali prisidėti prie paskolų rizikos vertinimo ir skolų valdymo procesų, atsižvelgiant į realius klientų duomenis.

Tyrimas orientuotas į eksperimentavimą su dirbtinio intelekto sprendimais, siekiant suprasti jų galimybes ir ribas sprendžiant paskolų grąžinimo rizikos klausimus. Tyrimo metu siekiama ištirti ir atlikti lyginamąją analizę dirbtinio intelekto modelių, galinčių segmentuoti klientus, nustatyti rizikos profilius bei aptikti anomalijas. Tiriami DI sprendimai galėtų būti taikomi paskolų valdymo procesuose ir būti integruoti į išmaniuosius pokalbių robotus, užtikrinant personalizuotą rekomendacijų teikimą ir automatizuotą rizikos vertinimą.



Šaltinis: sudaryta autoriaus

6 pav. Eksperimentinio tyrimo eiga

Tyrimo eiga susideda iš pagrindinių keletos dalių (6 pav.), kuriose pirmosios keturios dalys užtikrina pasiruošimą reikiams komponentams, tokiems kaip kokybiškų duomenų analizė, rizikos veiksnių nustatymas ir DI modelių kūrimas. Šių etapų metu apdorojami duomenys, optimizuojami mašininio ir giliojo mokymosi modeliai, siekiant užtikrinti jų tikslumą bei pritaikomumą realiose situacijose. Sukurti sprendimai orientuoti į automatizuotą finansinės rizikos vertinimą, kuris ne tik sumažina žmoniškųjų klaidų tikimybę, bet ir padidina klientų pasitenkinimą, suteikiant greitus bei personalizuotus atsakymus. Penktoje dalyje visi surinkti komponentai yra sujungiami į vieningą sistemą, kuri integruojama į virtualų asistentą. Ši sistema, pasitelkdamą DI modelius, geba realiuoju laiku analizuoti kliento finansinės istorijos duomenis, identifikuoti potencialias rizikas ir pateikti suasmenintas rekomendacijas. Toks integruotas sprendimas sprendžia vieną iš pagrindinių DI technologijų trūkumų – informacijos patikimumą ir personalizavimą – taip padedant įmonėms efektyviau valdyti paskolų grąžinimo procesus. Darbo tikslas ne tik patikrina DI modelių galimybes realiuose scenarijuose, bet ir pasiūlyti įrankį, kuris galėtų būti naudingas tiek finansinėms institucijoms, tiek klientams.

3.1. Duomenų analizė ir pasiskirstymas


Tyrimui buvo naudojami duomenys iš Kaggle duomenų bazių sistemos (Danielorszag, 2022). Duomenys apima išsamią informaciją apie kreditorių grąžinimo elgseną (134 092 įrašų, 14 kintamųjų), įskaitant sėkmingus ir nesėkmingus paskolų grąžinimus, kartu su pagrindinėmis paskolos sąlygų ir klientų profilių charakteristikomis (7 pav.). Šis duomenų rinkinys yra ypač vertingas dėl turtingos požymių rinkinio, apimančio įvairius paskolų politikos aspektus, įskaitant skirtingų rūšių skolininkus, pritaikytas nuolaidų programas ir specialias paskolos sąlygas. Eksperimentiniame tyrime buvo tiriami kreditorių duomenys naudojant „Python“ programavimo kalbą. Kartu buvo importuojamos įvairios bibliotekos, o vėliau pritaikomi algoritmai pagal pasirinktus matematinius modelius ir vizualizuojami gauti rezultatai.

	A	B	C	D	E	F	G	H	I	J	K	L	M	N
1	credit.policy	purpose	int.rate	installment	log.annual.in.dti	fico		days.with.cr.	revol.bal	revol.util	inq.last.6mt	delinq.2yrs	pub.rec	not.fully.paid
2	1	debt_consoli	0.1189	829.1	11.35040654	19.48		737	5639.958333	28854	52.1	0.0	0.0	0
3	1	credit_card	0.1071	228.22	11.08214255	14.29		707	2760.0	33623	76.7	0.0	0.0	0
4	1	debt_consoli	0.1357	366.86	10.37349118	11.63		682	4710.0	3511	25.6	1.0	0.0	0
5	1	debt_consoli	0.1008	162.34	11.35040654	8.1		712	2699.958333	33667	73.2	1.0	0.0	0
6	1	credit_card	0.1426	102.92	11.29973224	14.97		667	4066.0	4740	39.5	0.0	1.0	0
7	1	credit_card	0.0788	125.13	11.90496755	16.98		727	6120.041667	50807	51.0	0.0	0.0	0
8	1	debt_consoli	0.1496	194.02	10.71441777	4.0		667	3180.041667	3839	76.8	0.0	0.0	1
9	1	all_other	0.1114	131.22	11.00209984	11.08		722	5116.0	24220	68.6	0.0	0.0	1
10	1	home_impro	0.1134	87.19	11.40756495	17.25		682	3989.0	69909	51.1	1.0	0.0	0

Šaltinis: Kaggle duomenų bazė loan_data.csv

7 pav. Segmentas iš duomenų bazės, naudojamos tyrime

Norint susipažinti su tyrime naudojama Kaggle duomenų baze, visų pirma buvo siekiama suprasti pagrindinius duomenų pasiskirstymo ypatumus, įvertinti klientų profilius ir nustatyti galimus rizikos veiksnius. Paskolų neišmokėjimo dažnio vizualizacija apačioje rodo kokia dalis paskolų buvo neapmokėta, remiantis įvairiais rodikliais kaip paskolos dydžiu, palūkanų norma ar FICO balais. Ši informacija padeda nustatyti, kokios sąlygos yra labiausiai susijusios su neapmokėjimo rizika ir kurios klientų grupės gali kelti didžiausią riziką. Matome, kad tyrime naudojamoje duomenų bazėje 16% paskolų buvo nepilnai gražintos, o 84% paskolų buvo sėkmingai gražintos.




Šaltinis: sudaryta autoriaus pagal Kaggle duomenų bazę.

8 pav. Duomenų bazė: išmokėtos ir neišmokėtos paskolos

Debt-to-Income (DTI) rodiklis nurodo, kiek asmens pajamų yra skirta skolos mokėjimams. Šio rodiklio paskirstymas padeda nustatyti skolininkų grupes, kurios turi aukštesnę finansinę naštą, o tai yra svarbus rizikos faktorius. Aukštas DTI rodo didesnę tikimybę, kad klientas gali susidurti su sunkumais gražinant paskolą. DTI (Debt-to-Income) vidutinė reikšmė šioje duomenų bazėje yra apie 12.61, o standartinis nuokrypis – 6.88, kas rodo, kad skolininkų pajamos ir skolos yra gana įvairios, tad tyrimo atlikimui duomenų bazė yra tinkama. Minimalus DTI yra 0, o maksimalus – beveik 30. Tai leidžia daryti prielaidą, kad yra klientų, kurie praktiškai neturi skolų, ir tokių, kurie turi reikšmingą skolos naštą. Aukštas DTI gali reikšti didesnę riziką, nes didelė pajamų dalis skiriama skoloms.

Paskolos palūkanų analizėje pagal paskirtį nagrinėjama, kaip skiriasi paskolų palūkanų normos, priklausomai nuo paskolos paskirties. Pagal paskolų paskirtį palūkanų normos skiriasi, didžiausia palūkanų norma pastebima paskolose smulkiam verslui (vidutiniškai 13.81%), o mažiausia –

pagrindiniams pirkiniams (vidutiniškai 11.42%). Tai rodo, kad skolinimas smulkiam verslui yra rizikingesnis nei vartojimo paskolos, kurioms taikomos aukštesnės palūkanų normos.




Šaltinis: sudaryta autoriaus pagal Kaggle duomenų bazę.

9 pav. Nemokėjimo tikimybė pagal paskolos paskirtį

FICO balai yra kredito reitingų rodiklis, rodantis kliento kreditingumą. Šio rodiklio paskirstymas ir sąsajos su paskolos grąžinimu leidžia įvertinti, kaip klientai su skirtingais kredito balais susidoroja su paskolų grąžinimu. Tai padeda nustatyti, kokios rizikos yra susijusios su skolinimu skirtingoms klientų kategorijoms. Vidutinis FICO balas yra apie 711, su minimaliu balu 612 ir maksimaliu 827. Tai rodo, kad dauguma skolininkų yra vidutinės ar aukštesnės kredito kategorijos ir tai rodo geresnę kreditingumo istoriją ir mažesnę paskolos negrąžinimo riziką.

„Days with Credit Line“ rodiklis nurodo, kiek laiko klientas jau turi aktyvią kredito istoriją. Analizuojant šio rodiklio paskirstymą, galima įvertinti, kaip kliento kredito istorijos ilgis veikia jo paskolos grąžinimo galimybes. Ilgesnis kredito istorijos laikotarpis dažnai reiškia mažesnę riziką, nes klientas turi daugiau patirties valdyti kreditą. Kredito istorijos dienų vidurkis yra apie 4212 dienų (maždaug 11.5 metų). Tai rodo, kad dauguma klientų turi ilgą kredito istoriją, kas gali reikšti geresnę kredito patikimumą. Tačiau yra ir klientų su trumpomis kredito istorijomis (minimaliai 179 dienos), kurie gali būti rizikingesni. Paveikslėlyje 10 (mėlyna spalva) vaizduoja pilnai grąžintą skolą, o 1 (oranžinė spalva), kad paskola nebuvo grąžinta.



Šaltinis: sudaryta autoriaus pagal Kaggle duomenų bazę.

10 pav. Kredito grąžinimo tendencijos

Tyrimui pasirinktos duomenų bazės didžioji dalis paskolų (84%) buvo sėkmingai grąžintos, o 16% liko neapmokėtos. padeda geriau suprasti bendrą paskolų portfelio riziką ir identifikuoti veiksnius, labiausiai susijusius su neapmokėjimo tikimybe. Vizualizacijos suteikė aiškesnį vaizdą apie rizikos pasiskirstymą tarp klientų, o kartu tai naudingas įrankis finansų institucijoms priimti sprendimus dėl skolinimo strategijų.

Ši duomenų bazė iš Kaggle sudaryta iš įvairių finansinių rodiklių, tokių kaip paskolos dydis, palūkanų norma, FICO balas, kredito istorijos trukmė ir DTI, leidžiančių vertinti klientų riziką ir paskolos grąžinimo galimybes. Šie duomenys bus naudingi eksperimentiniams tyrimams, kuriant matematinius modelius ir dirbtinio intelekto sprendimus skolinimo rizikai prognozuoti ir ją optimizuoti.

3.2. Duomenų klasifikavimas ir klasterizacija

Tęsiant tyrimą buvo atliekamas klientų klasifikavimas remiantis rizikos profiliavimu. Šioje dalyje naudojant klasifikavimą ir klasterizavimo metodus sugrupuojami klientai pagal rizikos veiksnius, tokius kaip DTI ir FICO, kad būtų atpažintos netipinės elgsenos bei identifikuoti klientai, kurių rizikingumas yra aukštesnis.


Panaudojus du klasterizacijos metodus – Gaussian Mixture Model (GMM) ir K-means – gauti rezultatai buvo labai panašūs. Abu metodai suformavo tris klasterius, siekdami grupuoti klientus

pagal jų rizikos lygį, atsižvelgiant į FICO balo ir DTI skirtumus. Klasteris 1 apima mažos rizikos klientus su aukštu kredito balu ir žemu įsipareigojimų lygiu, tuo tarpu Klasteris 0 žymi aukštesnės rizikos klientus su žemu kredito balu ir dideliu DTI. Klasteris 2 yra tarpinė grupė, turinti vidutinę riziką, aukštesnį FICO balą nei Klasteris 0, bet panašų DTI. Paveikslėlis apačioje tik patvirtina, kad gaunami rezultatai yra beveik identiški naudojant skirtingus klasterizacijos metodus.



Šaltinis: sudaryta autoriaus pagal Kaggle duomenų bazę.

11 pav. GMM klasterizacijos pasiskirstymas




Šaltinis: sudaryta autoriaus pagal Kaggle duomenų bazę.

12 pav. K-means klasterizacijos pasiskirstymas

Toliau pritaikyta tiesinė regresija, siekiant suprasti ryšį tarp kliento mėnesinės įmokos dydžio ir jo metinių pajamų. Tai padeda įvertinti, ar aukštesnės pajamos reiškia mažesnę finansinę naštą (mažesnes įmokas). Gautas tiesinės regresijos koeficientas yra 150.92, tai reiškia, kad su kiekvienu metinių pajamų padidėjimu (logaritminiu masteliu) mėnesinė įmoka padidėja vidutiniškai apie 151 dolerį. Tai rodo teigiamą ryšį tarp pajamų ir paskolos dydžio – aukštesnes pajamas turintys klientai dažnai ima didesnes paskolas su didesnėmis mėnesinėmis įmokomis.


Taip pat buvo lyginamos dvi analizės metodikos – anomalijų aptikimą naudojant Z-score ir neapmokėjimo tikimybės analizę pagal paskolos tikslą – galime palyginti jų tikslus ir naudingumą sprendžiant rizikos valdymo problemas. Anomalijų aptikimas naudojant Z-score metodiką buvo naudojama tam, kad identifikuotų netipinius klientų elgesio modelius pagal FICO balus ir DTI. Z-score rodo, kurie klientai žymiai skiriasi nuo vidurkio. Tačiau pagal gautus duomenis ši analizė neatskleidė reikšmingų anomalijų, nes nebuvo klientų, kurių Z-score viršytų 3 (11 pav.). Tai reiškia, kad dauguma klientų yra pakankamai vienodi pagal rizikos kriterijus, todėl šis metodas, konkrečiai šioje situacijoje, nedavė naudingos informacijos apie netipinius klientus.



Šaltinis: sudaryta autoriaus pagal Kaggle duomenų bazę.

13 pav. Anomalijų aptikimas naudojant Z-score

Analizuojant neapmokėjimo tikimybę pagal paskolos tikslą, tokius kaip smulkus verslas, skolų konsolidacija, namų renovacija, remontas ir kt., rezultatai parodė, kad didžiausia neapmokėjimo tikimybė yra paskoloms, skirtoms smulkiam verslui (27.8%), o mažiausia – pagrindiniams pirkiniams ir kreditinių kortelių skoloms padegti (apie 11%). Tai leidžia suprasti, kurios paskolų rūšys kelia didesnę riziką ir, atitinkamai, reikalauja papildomo dėmesio valdant paskolų portfelį. Lyginant šiuos du metodus, neapmokėjimo tikimybės analizę pagal paskolos tikslą yra naudingesnė, nes ji pateikė konkrečias išvagas apie rizikos lygius pagal paskolos paskirtį. Tuo tarpu Z-score metodas buvo naudingas kaip papildoma priemonė preliminariai įvertinti galimus duomenų nuokrypius, tačiau nesuteikė didesnės pridėtinės vertės analizei.



Šaltinis: sudaryta autoriaus pagal Kaggle duomenų bazę.

14 pav. Paskolos palūkanų norma pagal paskirtį

Klientų klasifikavimas pagal riziką ir klasterizacija parodė, kad skirtingi metodai pateikė labai panašius rezultatus, o tiesinės regresijos analizė patvirtino teigiamą ryšį tarp pajamų ir paskolos dydžio. Neapmokėjimo tikimybės analizė pagal paskolos tikslą buvo naudingesnė identifikuojant aukštos rizikos paskolas, o tuo tarpu Z-score anomalijų aptikimas nesuteikė reikšmingos informacijos.

3.3. Rizikos veiksnių sąryšio ir koreliacijos analizė


Šioje duomenų analizės dalyje tikslas buvo išsiaiškinti, kaip rizikos veiksniai tarpusavyje susiję, kurie iš jų daro didžiausią poveikį paskolos grąžinimo tikimybei ir kaip atskiri kintamieji gali įvertinti riziką. Toliau aptariama kaip metodai buvo pritaikyti šiai Kaggle duomenų bazei:

- 1) Logistinė regresija paskolos neišmokėjimo prognozavimui: logistinė regresija buvo pritaikyta siekiant numatyti, ar klientai grąžins paskolas. Pagrindiniai modelio kintamieji buvo FICO balas, palūkanų norma, DTI rodiklis ir mėnesinė įmoka. Analizės metu gauti šie rezultatai:
 - a) FICO balas turi neigiamą koeficientą (-0.0083), kas reiškia, kad aukštesnis FICO balas sumažina paskolos negrąžinimo tikimybę.

- b) Palūkanų norma turi stipriai teigiamą koeficientą (7.7936), kas rodo, kad didesnė palūkanų norma yra susijusi su didesne neapmokėjimo rizika.
- c) DTI koeficientas (-0.0014) nėra reikšmingas ($p\text{-value} > 0.05$), o tai reiškia, kad šiuo atveju DTI nėra statistiškai reikšmingas veiksnys neapmokėjimo prognozavimui.
- d) Įmoka turi teigiamą koeficientą (0.0005), kas rodo, kad didesnės įmokos šiek tiek padidina neapmokėjimo tikimybę.

Logistinė regresija leidžia daryti išvadas, kad FICO balas ir palūkanų norma yra pagrindiniai veiksniai, darantys įtaką paskolos grąžinimo tikimybei, aukštesnės palūkanų normos padidina riziką, o aukštesnis FICO balas ją mažina.

- 2) Palūkanų normų poveikis paskolos neišmokėjimui: paveikslėlyje matome, kad neapmokėjimo tikimybė didėja su didesnėmis palūkanų normomis. Paveikslėlyje, palūkanų normos buvo padalintos į šiuos intervalus: 0 - 0.1: „Very Low“ (Labai žema), 0.1 - 0.15: „Low“ (Žema), 0.15 - 0.2: „Moderate“ (Vidutinė), 0.2 - 0.25: „High“ (Aukšta), 0.25 - 0.3: „Very High“ (Labai aukšta). Kategorijoje "High" neišmokėjimo tikimybė yra aukšta, kas rodo, kad klientai, kuriems taikomos didelės palūkanų normos, yra labiau linkę susidurti su grąžinimo problemomis ir netęsti įsipareigojimų. Tai leidžia daryti išvadą, kad aukštos palūkanų normos yra reikšmingas rizikos veiksnys, ir finansų institucijoms reikėtų tai atsižvelgti suteikiant paskolas.




Šaltinis: sudaryta autoriaus pagal Kaggle duomenų bazę.

15 pav. Nemokėjimas pagal palūkanų normos kategoriją

- 3) Koreliacinė matrica su šilumos žemėlapiu: žemėlapis parodo tokius ryšius, kaip palūkanų norma (int.rate) ir FICO balas turi stiprią neigiamą koreliaciją (-0.71), reiškiančią, kad klientai su aukštesniu FICO balu gauna mažesnes palūkanas. Neišmokėjimo tikimybė (not.fully.paid) turi teigiamą koreliaciją su palūkanų norma (0.16), kas reiškia, kad didesnės palūkanos yra susijusios su didesne neapmokėjimo rizika. FICO balo koreliacija su neapmokėjimo tikimybe yra neigiama

(-0.15), patvirtinant, kad aukštesnis FICO balas sumažina neapmokėjimo riziką. Šis žemėlapis dar kartą įrodo, kad FICO balas ir palūkanų norma yra pagrindiniai veiksniai, darantys įtaką paskolos grąžinimo rizikai, aukštesnis FICO balas ir mažesnės palūkanos padeda sumažinti neišmokėjimo riziką, o didesnės palūkanos ir mažesnis FICO balas – ją tik didina.



Šaltinis: sudaryta autoriaus pagal Kaggle duomenų bazę.

16 pav. Paskolos duomenų ypatybių koreliacinė matrica

Tad, logistinė regresija parodė, kad aukštesnis FICO balas mažina neapmokėjimo tikimybę, o aukštesnė palūkanų norma ją didina. Barplot diagrama, atvaizduojanti neapmokėjimo tikimybę pagal palūkanų normų kategorijas, išryškino kad didžiausia neapmokėjimo rizika yra tarp klientų, kuriems taikomos aukštos ar labai aukštos palūkanos. Šilumos žemėlapis, naudojamas vizualizuoti koreliacijoms, patvirtino neigiamą ryšį tarp FICO balo ir palūkanų normos bei teigiamą ryšį tarp palūkanų normos ir neapmokėjimo rizikos.

3.4. Dirbtinio intelekto sprendimas: mašininio mokymosi modeliai

Tyrimo metu buvo eksperimentuota su mašininio mokymosi modeliais. Svarbu buvo nustatyti, kurie mašininio mokymosi sprendimai tinkamiausi siekiant identifikuoti ir vertinti paskolų riziką bei kokią vertę jie galėtų suteikti ateityje diegiant chatbot'us finansų sektoriuje. Mašininio mokymosi

modeliai pasižymi keletą svarbių savybių, kurias tyrime buvo siekiama išbandyti naudojant paskolų grąžinimo duomenų bazę. Daugeliui mašininio mokymosi modelių, tokiems kaip logistinė regresija ir atsitiktinių miškų modeliai, kurie padeda lengvai suprasti, kurie kintamieji labiausiai prisideda prie rizikos prognozės. Šis aspektas yra itin svarbus, kai dirbtinio intelekto sprendimai yra naudojami virtualaus asistento aplinkoje, nes reikia suteikti galimybę klientams ar įmonės darbuotojams suprasti, kodėl buvo priimti konkretūs sprendimai.

Eksperimentuojant buvo atlikti du bandymai, kurių metu siekiama optimizuoti modelių klasifikavimo galimybes bei įvertinti klientų paskolų grąžinimo riziką. Šiuose dviejuose eksperimentuose buvo atliekamas klientų paskolų grąžinimo rizikos vertinimas naudojant įvairius klasifikacijos modelius, įskaitant logistinę regresiją, atsitiktinius miškus (random forest), XGBoost, naive Bayes, neuroninius tinklus ir ansamblio metodus. Abu eksperimentai buvo atliekami su tam tikrais skirtumais ir panašumais, kurie buvo orientuoti į modelių tikslumo ir bendrųjų rezultatų optimizavimą. Toliau darbe aprašomi abu eksperimentai detalai, jų skirtumai, panašumai ir bendras eksperimento procesas.

3.4.1. Duomenų apdorojimo ir modelių treniravimo etapai

Šioje darbo dalyje aptariami visi pagrindiniai žingsniai atlikti mašininio mokymo modeliuose, kurie abiejuose bandymuose buvo tokie pat, tai yra nuo duomenų paruošimo, modelių hiperparametrų optimizavimo, mokymo, vertinimo, iki savybių analizės.

Kaip ir buvo minėta anksčiau naudodami Kaggle duomenų bazę eksperimentas pradėtas nuo duomenų užkrovimo ir naudojami išskirtinai šie duomenys: fico, int.rate, dti, installment, log.annual.inc. Tikslingas kintamasis buvo not.fully.paid, kuris nurodo, ar paskola buvo pilnai grąžinta. Toliau atliktas žingsnis, kuriame duomenys yra transformuojami į tinkamą formą, kad būtų užtikrintas modelių mokymosi efektyvumas, naudojant standartizuotą metriką „StandardScaler“. Abu eksperimentai suskirstė duomenis į mokymo ir testavimo rinkinius, naudojant `train_test_split` funkciją su tais pačiais parametrais (`test_size=0.2`, `random_state=42`), siekiant užtikrinti palyginamus rezultatus ir sumažinti atsitiktinių pokyčių įtaką. Eksperimentuose buvo naudojama `GridSearchCV` atsitiktinių miškų hiperparametrų paieškai. Abu eksperimentai siekė optimizuoti tuos pačius parametrus: `n_estimators`, `max_depth` ir `min_samples_split`. Abu bandymai naudojo tuos pačius klasifikavimo modelius, įskaitant logistic regression, random forest, XGBoost ir naive Bayes. Modeliai buvo treniruojami ant mokymo rinkinio ir vertinami naudojant testavimo rinkinį. Vertinimo metrikos buvo accuracy, precision, recall, F1 score, ROC-AUC ir confusion matrix, o rezultatai buvo išsaugomi siekiant palyginimo.

Abu eksperimentai naudojo Keras biblioteką neuroninio tinklo sukūrimui, su Adam optimizavimo funkcija ir sigmoid aktyvacijos funkcija išėjimo sluoksnyje. Abu neuroniniai tinklai buvo treniruojami naudojant mokymo ir testavimo rinkinius, o mokymosi procesas buvo stebimas ir vizualizuojamas. Abiems eksperimentams buvo naudojamas VotingClassifier ansamblio modelis, kuris naudojo soft voting strategiją. Ansamblį sudarė logistinė regresija, atsitiktinių miškų ir XGBoost modeliai, o kartu buvo atlikta savybių svarbos analizė, naudojant atsitiktinių miškų modelį, siekiant nustatyti, kurios savybės labiausiai prisideda prie modelio klasifikavimo rezultatų.

3.4.2. Mašininio mokymosi modelių optimizacijos ir tobulinimo procesai

Kaip ir buvo minėta anksčiau, buvo atlikti du eksperimentai skiriasi tam tikrai sprendimai, kurie lėmė skirtingus modelių rezultatus. Pradedant nuo klasių disbalanso korekcijų, Pirmasis eksperimentas nenaudojo jokio metodo klasių disbalansui spręsti, kas galėjo lemti mažumos klasės diskriminavimą. Taip buvo siekiama įvertinti, kaip gerai modeliai sugebėtų atskirti nedaug pavyzdžių turinčią klasę be jokių korekcijos metodų. Tai leido geriau suprasti pradinį modelių šališkumą daugumos klasei ir įvertinti jų pradinį efektyvumą. Antrasis eksperimentas naudojo SMOTE (Synthetic Minority Over-sampling Technique) metodą, kad padidintų mažumos klasės pavyzdžių skaičių ir subalansuotų duomenų rinkinį. Tai buvo siekiama sumažinti modelių šališkumą daugumos klasei ir padidinti jų gebėjimą klasifikuoti mažumos klasę. SMOTE padėjo užtikrinti, kad modeliai turėtų daugiau informacijos apie mažumos klasės pavyzdžius, todėl jų tikslumas ir jautrumas padidėjo, o tai ypač svarbu siekiant gerai identifikuoti retus įvykius, pavyzdžiui, neapmokėtas paskolas.

Kalbant apie neuroninių tinklų architektūrą, pirmasis eksperimentas sukūrė neuroninį tinklą su daugiau sluoksnių:

1. Pirmasis paslėptas sluoksnis: 64 neuronai.
2. Antrasis paslėptas sluoksnis: 32 neuronai.
3. Trečiasis paslėptas sluoksnis: 16 neuronų.

Buvo naudojami Dropout sluoksniai po pirmo ir antro sluoksnio siekiant sumažinti permokymo riziką. Daugiau sluoksnių ir neuronų leido tinklui išmokti sudėtingesnius ryšius tarp savybių, todėl modelis galėjo pasiekti didesnę tikslumą, tačiau ilgesnis treniravimo procesas ir daugiau parametrų reiškė didesnę permokymo riziką, todėl Dropout sluoksniai buvo būtini. Modelis buvo treniruojamas 100 epochų, siekiant ilgesnio mokymosi proceso. Tai leido tinklui geriau optimizuoti svorius ir išmokti duomenų struktūrą, tačiau ilgesnis mokymosi procesas taip pat galėjo didinti permokymo riziką, todėl būtina stebėti mokymosi kreives. Antrasis eksperimentas sukūrė paprastesnį neuroninį tinklą:

1. Pirmasis paslėptas sluoksnis: 16 neuronų.
2. Antrasis paslėptas sluoksnis: 8 neuronai.

Naudojamas tik vienas Dropout sluoksnis po pirmo sluoksnio. Ši architektūra buvo paprastesnė, todėl modelis treniravosi greičiau ir turėjo mažesnę permokymo riziką. Paprastesnis tinklas gali būti naudingas, jei duomenų rinkinys nėra labai didelis arba jei norima išvengti sudėtingumo be žymaus našumo praradimo. Modelis buvo treniruojamas 50 epochų, kas leido sutrumpinti mokymosi laiką. Tai buvo naudinga greitesniam modeliavimo procesui ir leidžia geriau stebėti, ar modelis gali išmokti pagrindinius ryšius net su mažesniu treniravimosi laiku.

Dar vienas skirtumas tarp dviejų šių modelių buvo toks, kad pirmasis eksperimentas naudojo ansamblio modelį su standartiniais modeliais be papildomų hiperparametrų, išskyrus tuos, kurie buvo rasti naudojant GridSearchCV. Ši strategija leido įvertinti, kiek ansamblis gali pagerinti rezultatus, naudojant paprastą ir greitai parengtą modelių kombinaciją. Tai suteikė pagrindinę informaciją apie tai, kaip kombinuoti skirtingus modelius ir kaip jie gali papildyti vienas kitą. O antrasis eksperimentas įtraukė ansamblį, kuriame buvo naudojamas atsitiktinių miškų modelis su parametrais, rasti naudojant GridSearchCV, siekiant maksimaliai padidinti jo tikslumą. Šis ansamblio modelis buvo labiau pritaikytas ir optimizuotas pagal geriausius hiperparametrus, todėl padidėjo modelio prognozavimo tikslumas. Toks požiūris leidžia efektyviau išnaudoti modelių kombinacijas, užtikrinant, kad kiekvienas į ansamblį įtrauktas modelis dirbtų savo optimaliomis sąlygomis.

3.4.3. Eksperimentų rezultatai ir palyginimas

Rezultatai rodo aiškius skirtumus tarp pirmojo ir antrojo eksperimentų. Pirmasis eksperimentas pasiekė gana aukštą tikslumą (accuracy), bet daugeliui modelių precision, recall ir F1 score buvo 0. Tai rodo, kad pirmojo bandymo modeliai nesugebėjo tinkamai atskirti mažumos klasės. Tai greičiausiai buvo dėl klasių disbalanso, kuris nebuvo koreguotas pirmojo eksperimento metu. Ši problema privertė modelius nesugebėti tiksliai klasifikuoti mažumos klasės pavyzdžių, todėl precision ir recall reikšmės yra nulinės. Tuo tarpu antrajame eksperimente buvo naudojamas SMOTE metodas klasių disbalanso korekcijai, kuris padėjo subalansuoti duomenis ir padidinti mažumos klasės pavyzdžių skaičių. Tai leido modeliams geriau klasifikuoti abejas klases, todėl antrajame bandyme visi modeliai pasiekė aukštesnes precision, recall, F1 score ir ROC-AUC reikšmes. Išsamius modelių rezultatus galime matyti lentelėse apačioje.

Mašininio mokymo metodų, 1 bandymo, rezultatai

Modelis	Accuracy	Precision	Recall	F1 Score	ROC-AUC
Logistic Regression	0.8408	0.0	0.0	0.0	0.5000
Random Forest	0.8408	0.0	0.0	0.0	0.5000
XGBoost	0.8387	0.3571	0.0164	0.0313	0.5054
Naive Bayes	0.8351	0.2963	0.0262	0.0482	0.5072
Neural Network	0.8408	-	-	-	-
Ensemble	0.8398	-	-	-	-

Šaltinis: sudaryta autoriaus pagal Kaggle duomenų bazę.

Mašininio mokymo metodų, 2 bandymo, rezultatai

Modelis	Accuracy	Precision	Recall	F1 Score	ROC-AUC
Logistic Regression	0.5827	0.5754	0.6209	0.5973	0.5828
Random Forest	0.7393	0.7051	0.8198	0.7581	0.7395
XGBoost	0.7837	0.7863	0.7774	0.7818	0.7837
Naive Bayes	0.6007	0.5796	0.7244	0.6439	0.6011
Neural Network	0.6035	-	-	-	-
Ensemble	0.8511	-	-	-	-

Šaltinis: sudaryta autoriaus pagal Kaggle duomenų bazę.

Antrasis eksperimentas, kuriame buvo naudojamas SMOTE metodas klasių disbalanso korekcijai, gerokai pagerino modelių veikimą, ypač tikslumo, recall ir F1 score rodiklius. Pirmasis eksperimentas parodė, kad klasių disbalansas gali lemti mažumos klasės ignoravimą, kas buvo akivaizdu pagal precision ir recall reikšmes, kurios buvo lygios 0 daugeliui modelių. Antrasis eksperimentas gerokai padidino modelių gebėjimą klasifikuoti abejas klases, kas padarė modelius geresnius ir patikimesnius. Todėl galima teigti, kad antrasis eksperimentas, su klasių disbalanso korekcija, pasirodė geriau, nes leido modeliams pasiekti didesnę veiksmingumą.

Klaidų matricos analizė (lentelės apačioje) pateikia svarbią informaciją apie modelių tikslumą ir jų gebėjimą atskirti skirtingas klases. Pirmojo eksperimento klaidų matricos analizė parodo, kad dėl klasių disbalanso pirmojo eksperimento metu modeliai nesugebėjo atpažinti mažumos klasės pavyzdžių (TP buvo labai mažas arba lygus nuliui). Tai reiškia, kad modeliai buvo šališki daugumos klasei, o tai lėmė labai žemus recall ir precision rodiklius. Antrojo eksperimento metu naudotas SMOTE padėjo modeliams geriau aptikti mažumos klasės pavyzdžius ir sumažinti klaidų kiekį. Random Forest ir XGBoost modeliai ypač išsiskyrė geresniu teigiamų pavyzdžių aptikimu bei

sumažintu klaidingų teigiamų prognozių skaičiumi. XGBoost modelis pasirodė kaip geriausias pasirinkimas, nes jis sugebėjo gerai subalansuoti tikslumą ir klaidų kiekį.

Lentelė 9

1 bandymo klaidų matrica

Modelis	True Negatives	False Positives	False Negatives	True Positives
Logistic Regression	1611	0	305	0
Random Forest	1611	0	305	0
XGBoost	1602	9	300	5
Naive Bayes	1592	19	297	8

Šaltinis: sudaryta autoriaus pagal Kaggle duomenų bazę.

Lentelė 10

2 bandymo klaidų matrica

Modelis	True Negatives	False Positives	False Negatives	True Positives
Logistic Regression	879	735	608	996
Random Forest	1064	550	289	1315
XGBoost	1275	339	357	1247

Šaltinis: sudaryta autoriaus pagal Kaggle duomenų bazę.

Antrajame eksperimente, naudojant SMOTE metodą klasių disbalanso korekcijai, modeliai sugebėjo geriau aptikti mažumos klasės pavyzdžius ir ženkliai pagerino precision, recall ir F1 score rodiklius. Pirmojo eksperimento rezultatai parodė, kad klasių disbalanso ignoravimas lėmė labai prastus modelių rezultatus, nes jie buvo šališkai daugumos klasei ir nesugebėjo tinkamai klasifikuoti mažumos klasės pavyzdžių.

3.4.4. Mašininio mokymo modelių pritaikymas virtualiuose asistentuose

Šie du bandymai gali būti labai vertingi virtualaus asistento kūrimui, ypač sprendžiant klientų klasifikavimo ir rizikos vertinimo uždavinius finansų sektoriuje. Pirmasis bandymas parodė, kad neatsižvelgus į klasių disbalansą, modeliai tampa šališki ir mažumos klasė – pavyzdžiui, rizikingi klientai – gali būti ignoruojama. Tokia situacija yra nepriimtina chatbot'ui, kuris skirtas asmeniniam finansų valdymui, kadangi rizikingų klientų ignoravimas gali sukelti didesnes finansines problemas tiek klientams, tiek įmonėms. Naudojant antrojo bandymo požiūrį su SMOTE klasių disbalanso korekcija, chatbot gali efektyviau klasifikuoti klientus, net jei jie priklauso mažumos klasei, tokioms kaip klientai su prasta mokymo istorija ar didesne rizika. Toks chatbot galėtų pateikti

personalizuotas rekomendacijas dėl paskolos ar mokėjimų atidėjimo, padedant klientams išvengti problemų su skolos padengimu. Be to, tikslus mažumos klasės atpažinimas gali padėti įmonėms identifikuoti aukštos rizikos klientus ankstyvose stadijose ir imtis veiksmų, sumažinančių nuostolius.

Modeliai, kurie buvo naudoti bandymuose, tokie kaip XGBoost ir Random Forest, galėtų būti įdiegiami į chatbot sistemą, kad teiktų prognozes apie kliento mokumą remiantis jų finansiniais duomenimis. Tai galėtų padėti įmonėms pasiūlyti tinkamas paslaugas kiekvienam klientui, įskaitant paskolos ar kredito limitų pritaikymą pagal kliento rizikos profilį. Tuo tarpu klientams toks chatbot galėtų pasiūlyti geriausius sprendimus, padedančius tvarkyti finansinius įsipareigojimus ir išvengti neapmokėjimo situacijų. Be to, neuroninių tinklų naudojimas, nors ir paprastesnės architektūros antrajame bandyme, galėtų leisti chatbot'ui atlikti kompleksiškesnę analizę, vertinti kliento elgesio pokyčius, o gal net ir prognozuoti, kada klientui gali kilti sunkumų su mokėjimais. Tai padėtų įmonėms išlaikyti stipresnį ryšį su klientais, užtikrinti geresnę klientų aptarnavimo kokybę ir galimai sumažinti klientų nusiskundimų kiekį.

Taigi, abu bandymai pademonstravo, kaip svarbu koreguoti duomenų disbalansą, kad vėliau, tai panaudojus virtualiuose asistentuose, jis būtų naudingas tiek klientams, siūlant tinkamus sprendimus ir mažinant riziką, tiek įmonėms, gerinant klientų klasifikavimą ir mažinant finansinius nuostolius.

3.5. Dirbtinio intelekto sprendimas: giliojo mokymosi modeliai


Šioje tyrimo dalyje buvo eksperimentuojama naudojant giluminio mokymosi modelį, siekiant optimizuoti paskolų negražinimo rizikos vertinimą ir patobulinti modelių gebėjimą klasifikuoti skolininkų elgesį. Šis tyrimas gali būti naudingas įmonėms, kurios dirba su finansinėmis paslaugomis, geriau suprasti savo klientų rizikos profilius ir priimti tikslesnius sprendimus dėl paskolų išdavimo. Taip pat šie giluminio mokymosi modeliai gali būti pritaikomi kuriant išmanius virtualius asistentus, kurie padėtų įmonės darbuotojams ar klientams priimti sprendimus, paremtus detalio duomenų analize. Tai padeda padidinti efektyvumą, sumažinti nuostolių riziką ir pagerinti klientų patirtį.

3.5.1. Duomenų apdorojimo ir modelio paruošimo žingsniai

Visų pirma, buvo atliktas išsamus duomenų paruošimas, į kurį įėjo pradinio duomenų apdorojimo, standartizacijos, klasių disbalanso sprendimo ir mokymo/testavimo rinkinių padalijimo žingsniai. Šie žingsniai buvo būtini, kad modeliai galėtų mokytis efektyviai ir teisingai. Pirmiausia buvo užkrauti duomenys apie paskolas, ir buvo išrinktos pagrindinės savybės, tokios kaip „fico“, „int.rate“, „dti“, „installment“ ir „log.annual.inc“. Tikslinis kintamasis „not.fully.paid“ parodo, ar paskola buvo pilnai gražinta, kas buvo pagrindinis analizės rodiklis. Šis pradinis žingsnis buvo svarbus tam, kad duomenys būtų tinkamai struktūruoti tolimesniam apdorojimui.


Toliau buvo atlikta duomenų standartizacija naudojant „StandardScaler“. Tai reikalinga tam, kad suvienodinti įvairių savybių skalę, nes skirtingų savybių reikšmės gali turėti skirtingus diapazonus. Standartizuojant buvo siekiama, kad visų savybių vidurkis taptų 0, o standartinis nuokrypis – 1. Tai padėjo modeliams greičiau konverguoti ir pasiekti geresnius rezultatus. Kitas žingsnis buvo duomenų padalinimas į mokymo ir testavimo rinkinius. Duomenys buvo padalinti naudojant „train_test_split“ funkciją, kurioje 80 % duomenų buvo naudojama mokymui, o likę 20 % – testavimui. Naudotas „random_state=42“ leidžia užtikrinti, kad rezultatai būtų atkuriami, kas yra svarbu patikimumui ir rezultatų atkartojamumui. Mokymo duomenys buvo skirti modelių treniravimui, o testavimo duomenys buvo skirti modelio veikimo vertinimui.

Siekiant spręsti klasių disbalanso problemą, buvo panaudotas SMOTE (angl. Synthetic Minority Over-sampling Technique) metodas. Šis metodas generuoja papildomus mažumos klasės pavyzdžius, kad būtų galima subalansuoti klases ir išvengti šališkumo daugumos klasei. SMOTE metodas padėjo pagerinti mažumos klasės, kuri yra negrąžintos paskolos atvejai, atpažinimo tikslumą (paveikslėlis). Taip pat buvo apskaičiuoti klasių svoriai, kad būtų galima subalansuoti mokymosi procesą ir priskirti didesnę reikšmę mažumos klasei. Klasių svorio pritaikymas užtikrina, kad mokymosi proceso metu modelis bus nešališkas, taip padidinant mažumos klasės pavyzdžių atpažinimo tikslumą.



Šaltinis: sudaryta autoriaus pagal Kaggle duomenų bazę.

17 pav. Pradinis klasių pasiskirstymas



Šaltinis: sudaryta autoriaus pagal Kaggle duomenų bazę.

18 pav. Klasių pasiskirstymas po SMOTE

Siekiant išvengti modelio permokymo, buvo įdiegta ankstyvo sustabdymo sąlyga. „EarlyStopping“ funkcija stabdo modelio mokymą, kai nuostoliai (val_loss) nustoja mažėti po tam tikro skaičiaus epochų. Tai padėjo užtikrinti, kad modelis nebūtų „perdėm išmokęs“ mokymo rinkinio duomenų, o tai sumažintų jo gebėjimą prognozuoti nepažįstamus duomenis. Galiausiai, buvo įdiegta „Focal Loss“ funkcija, kuri suteikė didesnę svarbą sunkiau klasifikuojamiems pavyzdžiams, ypač mažumos klasei. Tai padeda kovoti su klasių disbalanso problema ir užtikrina, kad modelis atsižvelgtų į sunkiau atpažįstamus mažumos klasės pavyzdžius, tokius kaip aukštos rizikos skolininkai.

3.5.2. Giliojo mokymosi modelių kūrimas ir algoritmų naudojimas

Šioje tyrimo dalyje buvo kuriami giluminio mokymosi modeliai – daugiapakopis perceptronas (MLP) ir ilgalaikės atminties (LSTM) modelis, siekiant optimizuoti paskolų grąžinimo rizikos vertinimą. Pagrindinis tikslas buvo išanalizuoti, kaip efektyviai šie modeliai gali įvertinti paskolų gavėjų grąžinimo tikimybę, palyginti su tradiciniais metodais. Taip pat siekta patikrinti, ar giluminio mokymosi algoritmai gali geriau spręsti klasių disbalanso problemą. Daugiapakopis perceptronas (MLP) buvo vienas iš giluminio mokymosi modelių, naudotų šio tyrimo metu. Jis sudarytas iš kelių paslėptų sluoksnių: pirmasis sluoksnis turi 256 neuronus, antrasis – 128, o trečiasis – 64 neuronai. Modelyje taip pat buvo naudojami BatchNormalization ir Dropout sluoksniai, siekiant pagerinti mokymosi kokybę ir sumažinti permokymo riziką. BatchNormalization sluoksniai užtikrina, kad duomenys bus tinkamai standartizuoti tarp kiekvieno sluoksnio, kas padeda stabiliai treniruoti modelį

ir greičiau konverguoti. Dropout sluoksniai atsitiktinai atmeta tam tikrą dalį neuronų mokymosi metu, taip mažinant modelio šališkumą ir užtikrinant geresnį bendrą modelio gebėjimą prognozuoti.

MLP modelis buvo naudingas, kadangi jis leido apdoroti ir modeliuoti sudėtingus ryšius tarp duomenų savybių, įskaitant tokius veiksnius kaip FICO balas, palūkanų norma, pajamos ir kitus finansinius rodiklius. Šio modelio gebėjimas prognozuoti, ar paskolos gavėjas grąžins paskolą, buvo svarbus žingsnis kuriant sprendimus, kurie galėtų padėti finansinėms įstaigoms sumažinti riziką.

LSTM Modelis buvo kitas giluminio mokymosi modelis, naudotas šiame tyrime. LSTM modeliai yra tinkami analizuoti sekos duomenis, nes jie sugeba "prisiminti" informaciją tam tikrą laiko tarpą ir fiksuoti ryšius tarp sekos elementų. Pirmajame LSTM sluoksnyje buvo naudojami 128 vienetai su aktyvacijos funkcija relu ir return_sequences=True, o antrame sluoksnyje – 64 vienetai. Modelis taip pat turėjo Dropout sluoksnius, siekiant sumažinti permokymo riziką ir užtikrinti bendresnį modelio mokymąsi. LSTM modelis buvo naudingas analizuojant, kaip tam tikri veiksniai ir jų pokyčiai laikui bėgant gali paveikti paskolos grąžinimo tikimybę. LSTM modelio gebėjimas apdoroti laiko eilučių duomenis padėjo sužinoti, ar sekos savybės gali turėti įtakos paskolų grąžinimo prognozavimui. Tai buvo svarbus aspektas, siekiant pagerinti prognozių kokybę ir sumažinti finansines rizikas tiek įmonėms, tiek klientams.

Naudodami abu modelius – MLP ir LSTM – galėjome išanalizuoti duomenis iš skirtingų perspektyvų: MLP apdorojo duomenis kaip fiksuotą savybių rinkinį, tuo tarpu LSTM gilinosi į sekos ryšius tarp savybių. Toks požiūris padeda gauti daugiau informacijos apie paskolos gavėjų elgseną, taip pat identifikuoti rizikingus klientus, kas yra svarbu tiek kredito įstaigoms, siekiančioms mažinti riziką, tiek klientams, norintiems gauti naudingesnių patarimų, kaip sėkmingai grąžinti paskolą.

3.5.3. Modelių rezultatai ir lyginamoji analizė

Šių giliojo mokymosi modelių rezultatai leidžia aptarti, kaip skirtingi algoritmai sugeba prognozuoti paskolos negrąžinimo riziką. Modelių tikslumas (accuracy) ir kiti vertinimo rodikliai, tokie kaip precision, recall, F1 score ir ROC-AUC, rodo jų gebėjimą identifikuoti tiek mažumos, tiek daugumos klases. Aptarsime daugiapakopio perceptrono (MLP) ir ilgalaikės atminties (LSTM) modelių rezultatus. MLP modelis pasiekė tik 70,46 % tikslumą, tačiau svarbu mažas precision ir recall reikšmės mažumos klasei (klientams, kurie negrąžins paskolos). Precision yra tik 0,2253, kas reiškia, kad modelis dažnai daro klaidų, prognozuodamas, kad klientas negrąžins paskolos, kai iš tikrųjų jis ją grąžina. Recall yra 0,3508, kas rodo, kad tik 35,08 % klientų, kurie negrąžins paskolos, buvo tinkamai identifikuoti. Šio modelio F1 score (0,2744) taip pat yra žemas, o tai parodo, kad tarp precision ir recall nėra balanso, ir modelis negali efektyviai atpažinti mažumos klasės. ROC-AUC (0,5612) rodiklis rodo, kad modelis tik šiek tiek geriau nei atsitiktinumas atskiria tarp klasių.

LSTM modelis sugebėjo pasiekti 84,08 % tikslumą, tačiau dėl klasių disbalanso jis nesugeba atpažinti mažumos klasės – klientų, kurie negrąžins paskolos. Precision, Recall ir F1 score yra 0, kas rodo, kad LSTM modelis nesugeba teisingai identifikuoti nei vieno kliento, kuris negrąžins paskolos. ROC-AUC rodiklis yra 0,5, kas yra tolygus atsitiktinumui ir rodo, kad modelis nesugeba atskirti mažumos ir daugumos klasių. Klaidų Matrica patvirtina, kad modelis klasifikuoja visus pavyzdžius kaip daugumos klasę (t. y., visus priskiria kaip "grąžins paskolą"). Tai ypač problema, nes mažumos klasė yra svarbi finansinių paslaugų kontekste – būtent šie klientai kelia didžiausią riziką. LSTM modelio prasta mažumos klasės atpažinimo kokybė gali būti nulemta dėl klasių disbalanso problemos, nepaisant to, kad buvo naudojama SMOTE metodika balansavimui. Akivaizdu, kad modelis nebuvo tinkamai optimizuotas ar treniruotas, kad galėtų gerai atpažinti mažumos klasę. Tokie rezultatai rodo būtinybę toliau tobulinti modelį, galbūt keisti tinklo struktūrą, hiperparametrus ar toliau koreguoti klasės disbalanso problemą.

Abi giluminio mokymosi architektūros parodė didelių sunkumų identifikuojant mažumos klasę – klientus, kurie negrąžins paskolos. MLP modelis pasiekė geresnį balanso tarp precision ir recall rezultatą, tačiau vis dar yra žemos vertės, o LSTM visiškai nesugebėjo atpažinti mažumos klasės. Nors LSTM modelis teoriškai turėtų geriau veikti, jei duomenys turėtų laiko sekų savybių, šiame tyrime jis nebuvo efektyvus. Taip pat, šie rezultatai privertė pergaltvoti ar naudojami giluminio mokymosi metodai iš tiesų yra tinkami šiam duomenų rinkiniui, ar reikėtų grįžti prie paprastesnių modelių ar bandyti pažangesnius giluminio mokymosi modelius, tokius kaip GRU ar Transformer, kurie galbūt geriau susidorotų su šia problema.

Lentelė 11

MLP ir LSTM modelių rezultatai

MLP Modelio Rezultatai		LSTM Modelio Rezultatai	
Rodiklis	Reikšmė	Rodiklis	Reikšmė
Tikslumas (Accuracy)	0.7046	Tikslumas (Accuracy)	0.8408
Tikslumas (Precision)	0.2253	Tikslumas (Precision)	0.0000
Sugrąžinimas (Recall)	0.3508	Sugrąžinimas (Recall)	0.0000
F1 Reikšmė (F1 Score)	0.2744	F1 Reikšmė (F1 Score)	0.0000
ROC-AUC	0.5612	ROC-AUC	0.5000

Šaltinis: sudaryta autoriaus pagal Kaggle duomenų bazę.

3.5.4. Mašininio mokymo ir giliojo mokymo modelių palyginimas

Tyrimo metu buvo atliktas mašininio mokymosi ir giliojo mokymo modelių palyginimas, siekiant optimizuoti paskolų grąžinimo rizikos vertinimą. Abu modeliai buvo vertinami pagal gebėjimą atpažinti rizikingus klientus ir pateikti naudingas rekomendacijas finansiniame sektoriuje.

Eksperimento metu žiūrėta, kaip modeliai sprendžia klasių disbalanso problemą ir kiek efektyviai klasifikuoja tiek daugumos, tiek mažumos klases.

Mašininio mokymosi modeliai, tokie kaip logistinė regresija, atsitiktiniai miškai ir XGBoost, pasižymėjo paprastesne architektūra ir aiškesnėmis savybėmis, leidžiančiomis suprasti, kurie kintamieji labiausiai prisideda prie rizikos vertinimo. Tai ypač svarbu virtualaus asistento aplinkoje, kur reikia užtikrinti sprendimų aiškumą klientams ir darbuotojams. Pirmojo eksperimento metu, kai nebuvo naudojamas klasių disbalanso koregavimas, šie modeliai nesugebėjo tinkamai atpažinti mažumos klases. Antrasis eksperimentas, naudojant SMOTE metodą, parodė žnymiai geresnius rezultatus – modeliai sugebėjo tiksliau klasifikuoti rizikingus klientus, ypač naudojant XGBoost.

Giliojo mokymosi modeliai, kaip daugiapakopis perceptronas (MLP) ir ilgalaikės atminties (LSTM) modelis, buvo panaudoti siekiant spręsti paskolų negrąžinimo rizikos klausimus naudojant giluminio mokymosi algoritmus. MLP modelis sugebėjo įvertinti kompleksiškus ryšius tarp skirtingų savybių, o LSTM leido analizuoti laiko seką ir nustatyti tendencijas. Tačiau, abu modeliai susidūrė su sunkumais atpažįstant mažumos klasę. MLP pasiekė geresnį balanso tarp tikslumo ir atsėjimo rezultatą nei LSTM, tačiau abu modeliai rodo, kad jų architektūros gali reikalauti tobulinimo, siekiant efektyvesnio klasių disbalanso problemos sprendimo.

Apibendrinant, mašininio mokymosi modeliai pasižymėjo paprastesniu pritaikymu ir aiškinamumu, kas yra svarbu virtualių asistentų aplinkoje, o giluminio mokymosi modeliai potencialiai gali suteikti daugiau įgaliojimo numatant sudėtingesnius ryšius. Tačiau, norint užtikrinti optimalų giliojo mokymosi modelių veikimą, reikalinga geresnė klasių disbalanso korekcija ir modelio parametrų optimizavimas.

3.6. Dirbtinio intelekto modelių integracija į virtualų asistentą: realizacija

Giliojo mokymosi modelių pritaikymas virtualiuose asistentuose yra svarbus ir daug potencialo turintis metodas, kuris gali reikšmingai pagerinti virtualių asistentų gebėjimą suprasti vartotojų poreikius ir teikti asmenines finansines rekomendacijas. Atlikto tyrimo kontekste MLP gali modeliuoti sudėtingas priklausomybes tarp įvairių duomenų savybių. Naudojant MLP, virtualūs asistentai gali įvertinti individualių klientų riziką remiantis skirtingais duomenimis, tokiais kaip kliento kredito balas, palūkanų norma, skolinimosi istorija ir kt. Šio modelio gebėjimas mokytis sudėtingus ryšius padeda virtualiems asistentams atlikti tikslesnius vertinimus ir teikti rekomendacijas, tokias kaip paskolos mokėjimo tvarkaraščių pakeitimai arba individualios rizikos valdymo patarimai. MLP modelio naudojimas virtualiuose asistentuose leidžia ne tik atlikti prognozes, bet ir apdoroti didelius duomenų kiekius bei identifikuoti specifines kliento finansinės situacijos ypatybes.

LSTM modelis eksperimente buvo panaudotas norint įvertinti laiko seka susijusius duomenis ir jų įtaką paskolos grąžinimo tikimybei. Virtualiuose asistentuose šio tipo modeliai gali būti labai naudingi, ypač jei reikia apdoroti dinamiškus duomenis, kurie nuolat kinta laikui bėgant. LSTM gali „prisiminti“ svarbią informaciją apie vartotojo elgseną per tam tikrą laikotarpį, todėl gali būti naudojamas numatyti, kaip keičiasi vartotojo finansinė padėtis. Tai leidžia virtualiems asistentams reaguoti į ilgalaikius pokyčius kliento elgsenoje, pavyzdžiui, identifikuoti padidėjusią riziką laiku negrąžinti paskolos, taip pat pateikti rekomendacijas, kada būtų palanku keisti paskolos sąlygas arba sudaryti naujus mokėjimo planus.


Abu giluminio mokymosi modeliai leidžia virtualiam asistentui asmeniškai reaguoti į kiekvieno kliento situaciją, teikiant pasiūlymus, kurie atitinka individualią finansinę padėtį ir riziką. Tai pagerina vartotojo patirtį, nes rekomendacijos tampa labiau pritaikytos ir tinkamos. MLP ir LSTM modeliai leidžia virtualiems asistentams efektyviai vertinti paskolų negrąžinimo riziką, identifikuoti galimai rizikingus klientus ir numatyti jų elgseną. Tyrimo metu buvo gauti rezultatai, kurie parodė, kad giluminio mokymosi modeliai gali būti naudingi prognozuojant paskolos grąžinimo riziką, tačiau taip pat buvo identifikuotos sritys, kurias reikia tobulinti, siekiant didesnio tikslumo.

3.6.1. Virtualaus asistento integracija Gradio aplinkoje naudojant Open AI

Šio eksperimento metu buvo siekiama sukurti interaktyvų, tekstu paremtą virtualų asistentą, leidžiantį sąveikauti su anksčiau apmokytais mašininio mokymo modeliais bei analizuojamu paskolų duomenų rinkiniu. Buvo siekiama, kad vartotojas galėtų gauti informaciją apie galimas finansines rizikas, bet ir atlikti įvairias užklausas apie neapmokėjimo tikimybės prognozavimą pagal konkrečius savo pateiktus duomenis, arba užduoti klausimus apie paskolų galimybes. Ši eksperimento dalis buvo atliekama naudojant „Google Colab“ ir tokius įrankius kaip Open AI bei Gradio. Šie įrankiai leido greitai parengti prototipą:

1. Buvo panaudotas anksčiau eksperimente parengtas modelių rinkinys – ansamblio modelis, kartu su tapačia duomenų baze, iš kurios virtualus asistentas mokosi. Chatboto funkcija, gavusi parametrus, gali atlikti standartizuojančius skaičiavimus (naudodama scaler) ir prognozuoti neapmokėjimo tikimybę (`ensemble_model.predict_proba`) remdamasi tuo pačiu mašininio mokymu, kuris buvo aptartas metodologijos skyriuje.
2. Kuriant prototipą buvo pasitelkta Open AI teikiamais kalbos modelių resursais. Tam, kad juos būtų galima naudoti, buvo reikalingas API raktas. Tyrimo metu šis raktas buvo gautas iš

OpenAI platformos, užsiregistravus bei patvirtinus savo paskyrą. Šis unikalus raktas užtikrina prieigą prie modeliui reikalingų ne tik kalbos, bet ir skaičiavimo resursų.



Šaltinis: sudaryta autoriaus iš Open AI puslapio.

19 pav. Open AI API raktas

3. Virtualus asistentas sukurtas naudojant, vieną iš daugelio, Open AI gpt-3.5-turbo modelį, jam pateikiant vartotojo užklausų istoriją (conversation_history). Kode taip pat nurodoma asistento rolė, kontekstas ir galimybės: asistentas informuojamas apie turimas duomenų ypatybes, modelių gebėjimus, bei nurodomi vartotojo galimi užklausų tipai ir tai leidžia modeliui generuoti atsakymus, remiantis nustatytu vaidmeniu.

Model usage		
Allowed models Only these models can be used in this project. Remove Edit		
✓ gpt-3.5-turbo		
Rate limits Rate limited models in this project. Rate limits are inherited from the organization unless overridden. Remove Edit		
MODEL	TOKENS / MIN (TPM)	REQUEST AND OTHER LIMITS
gpt-3.5-turbo	40,000 / 200,000 TPM	3 / 500 RPM

Šaltinis: sudaryta autoriaus iš Open AI puslapio

20 pav. Open AI nustatymai panaudoti virtualiame asistente

- Panaudojus gradio.Interface, buvo sukurta internetinė vartotojo sąsaja, atidaroma naršyklėje. Paleidus kodą „Google Colab“ aplinkoje, sugeneruojama lokali ar vieša nuoroda, kurioje galima naudotis virtualiu asistentu.

Finansinių rizikų asistentas

Sveiki! Esu čia, kad padėčiau Jums suprasti galimas finansines rizikas. Drąsiai klauskite – stengsiuosi viską paaiškinti kuo paprasčiau.

user_input

Clear Submit

output

Flag

Use via API · Built with Gradio


Šaltinis: sudaryta autoriaus

21 pav. Finansinių rizikų asistentas

Sukurtas virtualus asistentas ne tik gali pateikti rekomendacijas, bet kartu vartotojui leidžia bendrauti natūralia, šnekamąja kalba, kas leidžia ne techniniam vartotojui gauti naudą: duomenų analizę paremtą mašininio mokymu. Dar vienas šio virtualaus asistento yra, kad jis realizuotas „Google Colab“ aplinkoje, kuri leidžia paprastai dalintis projektu su kitais, jį keisti, atnaujinti ir eksperimentuoti. Tačiau dabartinis asistentas neturi integruoto realaus laiko duomenų paieškos funkcionalumo: jis neperkrauna duomenų, negeneruoja naujų skaičiavimų be atitinkamo kodo atnaujinimo. Ateityje būtų galima sukurti papildomus filtrus, patikrinti vartotojo ketinimus (intent detection) ir taip padaryti sąveiką dar tikslesnę.

3.6.2. Virtualaus asistento veikimo demonstracija

Virtualaus asistento veikimo procesas (20 pav.) susideda iš tokių dalių kaip vartotojo užklausoje apdorojimas, komunikacija su duomenų baze bei ansamblio modeliu ir Open AI API naudojimas galutinio atsakymo generavimui.

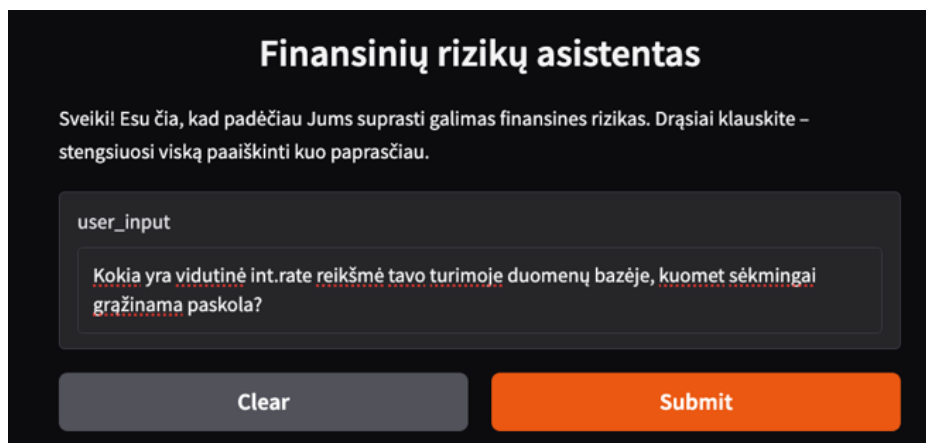


Šaltinis: sudaryta autoriaus.

22 pav. Virtualaus asistento veikimo schema

Virtualaus asistento veikimo žingsniai:

1. Vartotojas per virtualaus asistento sąsają pateikia tekstinę užklausą (23 pav.). Asistentas yra supažindintas kokio konteksto užklausas gali gauti (24 pav.)



Šaltinis: sudaryta autoriaus.

23 pav. Vartotojas per virtualaus asistento sąsają pateikia tekstinę užklausą

```
conversation_history = [
    {"role": "system", "content": (
        "Tu esi Finansų Rizikos Vertinimo Chatbotas. "
        "Turi prieigą prie apmokytų ML modelių ir paskolų duomenų (loan_data)"
        "Gali atlikti paskolos gražinimo tikimybės prognozę pagal nurodytus parametrus, "
        "Gali pateikti statistinę informaciją iš duomenų bazės. "
        "Vartotojas gali pateikti parametrus (fico, int.rate, dti, installment, log.annual.inc), pagal kuriuos gali paskaičiuoti neapmokėjimo tikimybę."
        "Jei paklausia apie duomenų savybes (pvz. vidutinis int.rate), pateik statistiką tiesiogiai iš loan_data. "
    )}
]
```

Šaltinis: sudaryta autoriaus.

24 pav. Ištrauka iš kodo, kurioje virtualus asistentas supažindinamas su kokiomis užklausomis dirbs

2. Taip pat, 24 paveikslėlyje užfiksuota kodo dalis, gautą užklausą patikrina pokalbių istorijoje (conversation_history), kad būtų matoma, ar apie tą pačią temą jau buvo pateikta informacija. Tai leidžia virtualiam asistentui atsiminti ankstesnius pokalbius ir užtikrinti nuoseklumą bei tinkamą kontekstą.
3. Užklausa perduodama į logikos ir apdorojimo bloką, kuriame atliekama jos interpretacija, tikrinama ar užklausa susijusi su paskolos neapmokėjimo prognozavimu, iš užklaustos išrenkami reikalingi parametrai, jei juos pateikia vartotojas, tokie kaip „fico“, „int.rate“, „dti“, „installment“, „log.annual.inc“, tikrinama ar užklausoje klausiama apie duomenų bazę (pvz., „Kokia yra vidutinė int.rate tavo turimoje duomenų bazėje, kuomet buvo sėkmingai gražinta paskola?“), atliekami skaičiavimai tiesiogiai naudojant Kaggle loan_data duomenų bazę.

```

if "Prognozuok neapmokėjimo tikimybę:" in user_input:
    pattern = r'fico=(\d+),\s*int.rate=(\d\.\d+),\s*dti=(\d\.\d+),\s*installment=(\d\.\d+),\s*log.annual.inc=(\d\.\d+)'
    match = re.search(pattern, user_input)
    if match:
        fico_val = float(match.group(1))
        int_rate_val = float(match.group(2))
        dti_val = float(match.group(3))
        installment_val = float(match.group(4))
        log_annual_inc_val = float(match.group(5))

```

Šaltinis: sudaryta autoriaus.

25 pav. Ištrauka iš kodo, kuri išrenka iš užklauso, skaičiavimams reikalingus duomenis

- Užklausa apdorojama, naudojant duomenų bazines, kaip „loan_data“ (duomenų bazė, kurią sudaro paskolos informacija) ir „conversation_history“ (duomenų bazė, kurioje saugoma pokalbių istorija). Šiose duomenų bazėse saugoma visa reikalinga informacija: Loan_data, kuri naudojama paskolos rodikliams ir analizei ir Conversation_history, kurioje saugoma informacija apie anksčiau atliktus pokalbius, kuri padeda nustatyti kontekstą.
- Jeigu užklausa susijusi su paskolos neapmokėjimo prognozavimu, duomenys yra standartizuojami naudojant „Scaler“. Standartizuoti duomenys perduodami į ansamblio modelį, kuris atliks prognozę naudodamas funkciją ensemble_model.predict_proba.
- Po prognozės sugeneruojamos reikšmės, kurios siunčiamos į OpenAI API naudojant „gpt-3.5-turbo“ modelį. Atsakyme naudojama tiek ankstesnė pokalbio istorija, tiek nauji duomenys, gauti iš duomenų analizės ar prognozių rezultatų.
- Sugeneruotas atsakymas grąžinamas į virtualaus asistento sąsają, kur vartotojas gali peržiūrėti atsakymą. Tuo pačiu metu, tiek atsakymas, tiek vartotojo užklausa pridedami į pokalbių istoriją, kad būtų užtikrintas konteksto išlaikymas į vėlesnes užklausas.

Finansinių rizikų asistentas

Sveiki! Esu čia, kad padėčiau Jums suprasti galimas finansines rizikas. Drąsiai klauskite – stengsiuosi viską paaiškinti kuo paprasčiau.

user_input

Kokia yra vidutinė int.rate reikšmė tavo turimoje duomenų bazėje, kuomet sėkmingai grąžinama paskola?

Clear

Submit

output

Vidutinė int.rate reikšmė sėkmingai grąžintose paskolose yra 11.089%.

Flag

Šaltinis: sudaryta autoriaus

26 pav. Virtualaus asistento atsakymas į vartotojo užklausa

Finansinių rizikų asistentas

Sveiki! Esu čia, kad padėčiau Jums suprasti galimas finansines rizikas. Drąsiai klauskite – stengsiuosi viską paaiškinti kuo paprasčiau.

user_input

Koks turėtų būti mano, kaip jurinio asmens, fico balas, kad būtų sėkmingai gražinama paskola?

Clear

Submit

output

Sėkmingai gražinamų paskolų analizė parodė, kad klientai su FICO balu, didesniu nei 700, turėjo didesnę tikimybę sėkmingai gražinti paskolas. Taigi, jūsų, kaip juridinio asmens, FICO balas turėtų būti didesnis nei 700, norint sėkmingai gražinti paskolą. Tačiau įsitikinkite, kad FICO balas yra tik vienas iš veiksnių, įtakančių paskolos sėkmingą gražinimą.

Šaltinis: sudaryta autoriaus.

27 pav. Sukurto virtualaus asistento veikimo pavyzdys

Apibendrinant, sukurtas virtualus asistentas, prototipas, skirtas finansinių paslaugų sektoriui, kuris geba analizuoti klientų pateiktus duomenis, pateikia personalizuotas prognozes bei atsakymus ir gali būti pritaikomas įvairioms finansinėms paslaugoms. Šis prototipas sugeba apdoroti ir pateikti atsakymus tekstiniu formatu (27 pav.), tačiau siekiant didesnio išpildymo, būtų tikslinga jį tobulinti, kad būtų galimybė priimti įvairaus formato užklaudas, pavyzdžiui, dokumentus, lenteles ar net vaizdus, ir pateikti atsakymus ne tik tekstiniu, bet ir grafiniu ar vaizdiniu formatu. Toks funkcionalumas leistų vartotojui pateikti informaciją patogesniu būdu ir gauti vizualiai patrauklesnius, išsamesnius bei lengviau suprantamus atsakymus.

Virtualus asistentas yra lankstus ir lengvai pritaikomas įvairioms sritims, todėl jo funkcionalumas gali būti išplėstas pagal įmonės ar klientų poreikius. Taip pat būtų galimybė tokią virtualų asistentą nuolat tobulinti ir jame naudojamus modelius, pritaikant juos prie kintančios finansinės aplinkos ir rinkos sąlygų. Tai leistų ne tik išlaikyti atsakymų tikslumą, bet ir stiprinti vartotojų pasitikėjimą, teikiant personalizuotas bei aktualias išvalgas. Šio prototipo pritaikymas galėtų apimti tokias sritis kaip paskolų rizikos vertinimas, draudimo konsultacijos ar investavimo strategijų pateikimas. Nepaisant jau dabar pasiektų rezultatų, šis prototipas dar turi didelį tobulėjimo potencialą. Vizualinis dizainas galėtų būti patobulintas, kad naudotojui būtų malonu jį naudoti, o papildomos galimybės, kaip, pavyzdžiui, grafinių vizualizacijų generavimas, dar labiau padidintų jo naudingumą. Nuolat eksperimentuojant su naujais metodais ir technologijomis, šis virtualus asistentas galėtų tapti patikimu įrankiu finansinių paslaugų sektoriuje.

Sukurtas virtualaus asistento prototipas, leido patikrinti dirbtinio intelekto modelių integracijos galimybes finansinių paslaugų sektoriuje. Eksperimente buvo išbandyta, kaip vienas iš eksperimentuotų DI modelių gali apdoroti klientų duomenis, prognozuoti paskolos neapmokėjimo riziką ir teikti personalizuotus atsakymus per interaktyvią sąsają „Gradio“. Asistentas sujungia mašininio mokymosi galimybes su natūralios kalbos apdorojimu, užtikrindamas sklandžią vartotojo sąveiką ir duomenų analizę. Nors prototipas veikia, tolesnis tobulinimas galėtų apimti įvairaus formato duomenų apdorojimą, vizualizacijų generavimą ir platesnį funkcionalumą finansų sektoriuje.

IŠVADOS IR PASIŪLYMAI

1. Atlikus literatūros analizę, pastebėta, kad virtualūs asistentai skirstomi į du pagrindinius tipus: taisyklėmis grįsti ir dirbtinio intelekto asistentai. Taisyklėmis grįsti virtualūs asistentai naudoja iš anksto apibrėžtas atsakymo taisykles, o dirbtinio intelekto asistentai pasitelkia mašininio mokymosi algoritmus, leidžiančius analizuoti duomenis, mokytis ir adaptuotis pagal vartotojo poreikius, tad jų techninė struktūra visiškai skirtinga.
2. Nagrinėtoje literatūroje išnagrinėtas neuroninių tinklų ryšys su matematika, pabrėžiama, kad tai yra dirbtinio intelekto pagrindas. Matematiniai modeliai leidžia suprasti, apdoroti ir generuoti atsakymus įvairiose užduotyse, nuo teksto analizės iki sprendimų priėmimo. Finansinės rizikos vertinimui matematika suteikia galimybę tiksliai analizuoti klientų kredito balus, skolos ir pajamų santykius bei jautrius duomenis, prognozuojant neapmokėjimo riziką ir teikiant personalizuotas paskolos valdymo rekomendacijas.
3. Atlikus dirbtinio intelekto modelių, naudojamų finansų sektoriuje ir skolų grąžinimo rizikos vertinimams, analizę, nustatyta, kad giluminio mokymosi metodai, tokie kaip MLP ir LSTM, yra ypač veiksmingi prognozuojant paskolų negrąžinimo riziką. MLP modeliai leidžia modeliuoti sudėtingas priklausomybes tarp įvairių duomenų savybių, tokių kaip kredito balas, pajamos ar palūkanų norma, o LSTM modeliai yra tinkami analizuoti laikui jautrius duomenis, atsižvelgiant į ilgalaikes vartotojų elgsenos tendencijas.
4. Atliktas eksperimentinis tyrimas, naudojant Kaggle.com finansinių paskolų grąžinimo duomenų bazę (134092 įrašų, 14 kintamųjų). Eksperimentiniame tyrime buvo tiriama kreditorių duomenys naudojant „Python“ programavimo kalbą ir bibliotekas. Atliktas klasterizavimas, klasifikavimas, koreliacinė analizė, rizikos vertinimas. Duomenims apdoroti taikyti mašininio ir giluminio mokymosi algoritmai, atlikta jų lyginamoji analizė – pastabėta, kad siekiant tikslesnių rezultatų yra būtina skirti dėmesio duomenų klasių disbalanso koregavimui.
5. Sukurtas virtualaus asistento prototipas finansinės rizikos vertinimams integruojant vieną iš eksperimentuotų DI modelių, pasitelkiant Gradio, kuris leidžia sukurti interaktyvias sąsajas mašininio mokymo modeliams ir Open AI API, kurio dėka asistentas bendrauja sklandžiai lietuvių kalba. Sukurtas prototipas geba sąveikauti su vartotoju tekstiniu formatu, analizuoti duomenis bei atlikti prognozes, tačiau asistento veikimas dar gali būti tobulinamas įdiegiant realaus laiko duomenų apdorojimą bei naudojant pažangesnius vartotojų užklausų interpretavimo mechanizmus.

LITERATŪRA

1. Adamopoulou, E., ir Moussiades, L. (2020). Chatbots: History, technology, and applications. *Machine Learning With Applications*.
<https://doi.org/10.1016/j.mlwa.2020.100006>
2. Adams, S. (2023). Implementing biometric authentication and encryption in iOS fintech apps for 100x secure architecture. *Hire Remote Developers | Build Teams in 24 Hours - Gaper.io*. <https://gaper.io/biometric-authentication-encryption/>
3. Ashfaq, M. W. (2022). Analysis of different trends in Chatbot Designing and development: a review. *ECS Transactions*, <https://doi.org/10.1149/10701.7215ecst>
4. Bhoir, S. V., Patil, S. R., & Mogul, I. Y. (2022). Person-based automation with artificial intelligence Chatbots: A driving force of Industry 4.0. In *Elsevier eBooks* (pp. 215–244). <https://doi.org/10.1016/b978-0-323-88468-6.00003-6>
5. Cemantica. (2024). Enhancing Customer Experience in Financial Services. *Cemantica*. <https://www.cemantica.com/customer-experience-blog/enhancing-customer-experience-financial-services>
6. Csirt, S., Csirt, S. (2023). CyberSecurity in FinTech: How to develop a secure FinTech App - Security investigation. *Security Investigation - Be the first to investigate*. <https://www.socinvestigation.com/cybersecurity-in-fintech-how-to-develop-a-secure-fintech-app/>
7. Desirable features of a chatbot-building platform. (2020). *IEEE Conference Publication | IEEE Xplore*. <https://ieeexplore.ieee.org/abstract/document/9230397>
8. Emarketer. (2023). Financial Services Industry 2023: Overview, Trends & analysis. *EMARKETER*. <https://www.emarketer.com/insights/financial-services-industry/>
9. Emarketer. (2024). Digital Payment Services in 2023: Methods, Trends, & Tech. *EMARKETER*. <https://www.emarketer.com/insights/digital-payment-services/>
10. Esco, C. (2023). A review Comparative analysis on various chatbots design. *SlideShare*. <https://www.slideshare.net/slideshow/a-review-comparative-analysis-on-various-chatbots-design/259621075>
11. Fintech in 2023: Five trends to watch. (n.d.). *Clifford Chance*. https://www.cliffordchance.com/insights/thought_leadership/trends/2023/2023-fintech-trends.html
12. Fokina, M. (2024). The Future of Chatbots: 80+ chatbot statistics for 2024. *Tidio*. <https://www.tidio.com/blog/chatbot-statistics/>
13. Gillis, A. S., Brush, K., Scardina, J. (2024). Chatbot. *Customer Experience*. <https://www.techtarget.com/searchcustomerexperience/definition/chatbot>
14. Han, Y., Chen, J., Dou, M., Wang, J., ir Feng, K. (2023). The impact of artificial intelligence on the financial services industry. *Academic Journal of Management and Social Sciences*, 2(3), 83–85. <https://doi.org/10.54097/ajmss.v2i3.8741>

15. Jenneboer, L., Herrando, C., Constantinides, E. (2022). The Impact of chatbots on Customer Loyalty: A Systematic literature review. *Journal of Theoretical and Applied Electronic Commerce Research*, 17(1), 212–229. <https://doi.org/10.3390/jtaer17010011>
16. Jain, R., Prajapati, D., Dangi, A. (2023). Transforming the Financial sector: A review of recent advancements in FinTech. SSRN. https://papers.ssrn.com/sol3/papers.cfm?abstract_id=4380348
17. Karyotaki, M., Drigas, A., & Skianis, C. (2022). Chatbots as Cognitive, Educational, Advisory & Coaching Systems. *Technium Social Sciences Journal*, 30, 109–126. <https://doi.org/10.47577/tssj.v30i1.6277>
18. Knight, R. (2023). Intersections: Mathematics and the artificial intelligence chatbot. Cambridge Mathematics. <https://www.cambridgemaths.org/blogs/intersections-mathematics-and-the-artificial-intelligence-chatbot/>
19. Li, C. (2022). Research on the influence of Securities Investment Fund on the efficiency of Chinese securities market and policy suggestions. *Advances in Economics, Business and Management Research*. <https://doi.org/10.2991/aebmr.k.220306.006>
20. Maher, S., Kayte, S., Nimbhore, S. (2020). Chatbots & its techniques using AI: a review.
21. Maze, C. W. (2023). What is Financial Services & Its Importance. Medium. <https://medium.com/@chadwmaze/what-is-financial-services-its-importance-80a9a016a244>
22. Meshram, S., Naik, N., Megha, V. R., & More, T. (2021). Conversational AI: Chatbots. In *Proceedings of the 2021 International Conference on Advances in Computing, Communication, and Control* (pp. 1-5). IEEE. <https://ieeexplore.ieee.org/abstract/document/9498508/>
23. Murali, S. M. (2022). Analysis of Chat bots based Artificial Intelligence (AI) Marketing. ResearchGate. https://www.researchgate.net/publication/363249181_Analysis_of_Chat_bots_based_Artificial_Intelligence_AI_Marketing
24. Parashar, A. (2024). Top trends in insurance industry for 2023. SP Tech Inc. <https://sptechusa.com/blog/top-trends-in-insurance-industry/>
25. Rajput, N., Rajput, N. (2024). How Digital Transformation is Changing Fintech and API? Ficode. <https://www.ficode.co.uk/blog/how-digital-transformation-is-changing-fintech-and-api>
26. Rath, S., Pattanayak, A., Tripathy, S., Priyadarshini, S. B. B., Tripathy, A., Tanvi, S. (2023). Prediction of a Novel Rule-Based Chatbot Approach (RCA) using Natural Language Processing Techniques
27. (RCA) using Natural Language Processing Techniques. *International Journal of Intelligent Systems and Applications in Engineering*. <https://www.ijisae.org/index.php/IJISAE/article/view/3172>

28. Revathi, V. M. (2023). Mathematics in Artificial Intelligence Chatbots. Bannari Amman Institute of Technology. <https://www.bitsathy.ac.in/mathematics-in-artificial-intelligence-chatbots/>
29. Ricci, L., Soggia, G., Trimarchi, L. (2023). The impact of bank lending standards on credit to firms. *Journal of Banking & Finance*, 152, 106880. <https://doi.org/10.1016/j.jbankfin.2023.106880>
30. Saleem, A. (2024). Python creation for Rule-Based Chatbot Mastery. Data Science Dojo. <https://datasciencedojo.com/blog/rule-based-chatbot-in-python/>
31. Sarker, I. H. (2022). AI-Based modeling: techniques, applications and research issues towards automation, intelligent and smart systems. *SN Computer Science*, 3(2). <https://doi.org/10.1007/s42979-022-01043-x>
32. Siddik, A. B., Li, Y., Sharif, A. (2023). The Role of Artificial Intelligence and Chatgpt in Fintech: Prospects, Challenges, and Research Agendas. SSRN. https://papers.ssrn.com/sol3/papers.cfm?abstract_id=4439965
33. Smith, G. (2024). Financial services trends we'll be watching in 2023. Business Transformation Consultants | Prophet. <https://prophet.com/2022/12/financial-services-trends-well-be-watching-in-2023/>
34. Suhaili, S. M., Salim, N., Jambli, M. N. (2021). Service chatbots: A systematic review. *Expert Systems With Applications*, 184, 115461. <https://doi.org/10.1016/j.eswa.2021.115461>
35. Successive. (2024). FinTech App Development Guide in 2024 | Cost, tips and trends. Successive Digital. <https://successive.tech/blog/fintech-app-development-guide/>
36. Tang, S. (2023). Tech trends that will define fintech in 2023. Forbes. <https://www.forbes.com/sites/forbestechcouncil/2023/02/16/tech-trends-that-will-define-fintech-in-2023/>
37. Thorat, S. A., Jadhav, V. (2020). A review on implementation issues of rule-based chatbot systems. *Social Science Research Network*. <https://doi.org/10.2139/ssrn.3567047>
38. Verma, A., Chandra, P., Joshi, A. (2021). AI Chatbots, it's Feasibility and Reliability in Modern World. ResearchGate. <https://doi.org/10.13140/RG.2.2.17642.64961>
39. Wollny, S., Schneider, J., Di Mitri, D., Weidlich, J., Rittberger, M., & Drachsler, H. (2021). Are we there yet? - A Systematic Literature review on chatbots in education. *Frontiers in Artificial Intelligence*, 4. <https://doi.org/10.3389/frai.2021.654924>
40. Zendesk for service. (n.d.). <https://www.zendesk.co.uk/service/messaging/chatbot/chatbot-trend/>
41. Yap, S., Lee, H. S., & Liew, P. X. (2023). The role of financial inclusion in achieving finance-related sustainable development goals (SDGs): a cross-country analysis. *Economic Research-Ekonomska Istraživanja*, 36(3). <https://doi.org/10.1080/1331677x.2023.2212028>

42. Haider, Z. A., Khan, F. M., Zafar, A., Nabila, & Khan, I. U. (2024). Optimizing machine learning classifiers for credit card fraud detection on highly imbalanced datasets using PCA and SMOTE techniques. *vfast.org*. <https://doi.org/10.21015/vtcs.v12i2.1921>
43. Nithya, R., Kokilavani, T., & Beena, T. L. A. (2024). Balancing cerebrovascular disease data with integrated ensemble learning and SVM-SMOTE. *Network Modeling Analysis in Health Informatics and Bioinformatics*, 13(1). <https://doi.org/10.1007/s13721-024-00447-4>
44. Pinto, A. C., D, A. X. Y., Carvalho, E., Tessmann, M. S., & Lima, A. V. (2024). Are machine learning models more effective than logistic regressions in predicting bank credit risk An assessment of the Brazilian financial markets. *International Journal of Monetary Economics and Finance*, 17(1), 29–48. <https://doi.org/10.1504/ijmef.2024.137545>
45. Robisco, A. A., & Martínez, J. M. C. (2022). Measuring the model risk-adjusted performance of machine learning algorithms in credit default prediction. *Financial Innovation*, 8(1). <https://doi.org/10.1186/s40854-022-00366-1>
46. Wang, J., Rong, W., Zhang, Z., & Mei, D. (2022). Credit Debt Default Risk Assessment Based on the XGBoost Algorithm: An Empirical Study from China. *Wireless Communications and Mobile Computing*, 2022, 1–14. <https://doi.org/10.1155/2022/8005493>
47. Nasir, A. N. K., & Razak, A. a. A. (2022). Opposition-based spiral dynamic algorithm with an application to optimize type-2 fuzzy control for an inverted pendulum system. *Expert Systems With Applications*, 195, 116661. <https://doi.org/10.1016/j.eswa.2022.116661>
48. Riebesell, J. (2022, April 10). *Random Forest*. <https://tikz.net/random-forest/>
49. Bento, C. (2022, January 5). Multilayer Perceptron Explained with a Real-Life Example and Python Code: Sentiment Analysis. *Medium*. <https://towardsdatascience.com/multilayer-perceptron-explained-with-a-real-life-example-and-python-code-sentiment-analysis-cb408ee93141>
50. Banoula, M. (2023, April 27). *Introduction to Long Short-Term Memory(LSTM)*. *Simplilearn.com*. <https://www.simplilearn.com/tutorials/artificial-intelligence-tutorial/lstm>
51. Danielorszag. (2022, July 22). Loan Classification. Retrieved from Kaggle website: https://www.kaggle.com/code/danielorszag/loan-classification?select=loan_data.csv
52. Liu, Y. (2023). *Artificial Intelligence and Machine Learning based Financial Risk Network Assessment Model*. 2023 IEEE 12th International Conference on Communication Systems and Network Technologies (CSNT), 158-163. <https://doi.org/10.1109/CSNT57126.2023.10134653>
53. Huang, J. (2024). Financial Risk Assessment Model Based on Computer Data Privacy Protection. 2024 2nd International Conference on Mechatronics, IoT and Industrial Informatics (ICMIII), 280-284. <https://doi.org/10.1109/ICMIII62623.2024.00058>
54. Olaiya, O., Cynthia, A., Usoro, S., Obani, O., Nwafor, K., & Ajayi, O. (2024). The impact of big data analytics on financial risk management. *International Journal of Science and Research Archive*. <https://doi.org/10.30574/ijrsra.2024.12.2.1313>

PRIEDAI

1 PRIEDAS. Atlikto eksperimento Python kodas:

```
import numpy as np
import pandas as pd
import matplotlib.pyplot as plt
import seaborn as sns
from sklearn.mixture import GaussianMixture
from sklearn.cluster import KMeans
from sklearn.linear_model import LinearRegression, LogisticRegression
from scipy.stats import zscore
import statsmodels.api as sm
from sklearn.model_selection import train_test_split, GridSearchCV
from sklearn.ensemble import RandomForestClassifier, VotingClassifier
from xgboost import XGBClassifier
from sklearn.naive_bayes import GaussianNB
from sklearn.preprocessing import StandardScaler
from imblearn.over_sampling import SMOTE
from sklearn.metrics import (accuracy_score, precision_score, recall_score,
                             f1_score, roc_auc_score, confusion_matrix, classification_report)
from keras.models import Sequential
from keras.layers import Dense, Dropout
from keras.optimizers import Adam
from sklearn.svm import SVC
from sklearn.neighbors import KNeighborsClassifier
from sklearn.tree import DecisionTreeClassifier
from sklearn.ensemble import GradientBoostingClassifier
from sklearn.linear_model import RidgeClassifier

# 1. Duomenų užkrovimas ir paruošimas

loan_data = pd.read_csv('/content/loan_data.csv')

loan_data['fico_category'] = pd.cut(loan_data['fico'],
                                   bins=[300, 580, 670, 740, 800, 850],
                                   labels=['Prastas', 'Vidutinis', 'Geras', 'Labai geras',
                                           'Puikus'])

# 2. EDA (Exploratory Data Analysis)

# 2.1 DTI pasiskirstymas
plt.figure(figsize=(10, 6))
sns.histplot(loan_data['dti'], bins=30, kde=True)
plt.title('DTI pasiskirstymas')
plt.xlabel('Skolos ir pajamų santykis (DTI)')
plt.ylabel('Dažnis')
plt.show()

# 2.2 Paskolos palūkanų analizė pagal paskirtį
plt.figure(figsize=(10, 6))
sns.boxplot(x='purpose', y='int.rate', data=loan_data)
plt.title('Paskolos palūkanų norma pagal paskirtį')
plt.xlabel('Paskolos paskirtis')
plt.ylabel('Palūkanų norma (%)')
plt.xticks(rotation=45)
plt.show()

# 2.3 FICO balų kategorijos ir paskolos grąžinimas
plt.figure(figsize=(10, 6))
sns.countplot(x='fico_category', hue='not.fully.paid', data=loan_data)
plt.title('FICO balų kategorijos pagal paskolos grąžinimą')
plt.xlabel('FICO balų kategorija')
plt.ylabel('Kiekis')
plt.legend(title='Nevisiškai grąžinta (1=Taip, 0=Ne)')
plt.show()

# 2.4 Kredito linijos dienų analizė pagal grąžinimo statusą
plt.figure(figsize=(10, 6))
sns.histplot(data=loan_data, x='days.with.cr.line', hue='not.fully.paid', multiple='stack', bins=30)
plt.title('Kredito linijos trukmė pagal paskolos grąžinimą')
plt.xlabel('Kredito linijos dienos')
plt.ylabel('Dažnis')
plt.show()

# Koreliacinė matrica
```

```

numeric_loan_data = loan_data.select_dtypes(include=[np.number])
correlation_matrix = numeric_loan_data.corr()
plt.figure(figsize=(12, 8))
sns.heatmap(correlation_matrix, annot=True, cmap='coolwarm')
plt.title('Koreliacinė matrica')
plt.show()

# 3. Klasterizacija (GMM ir K-means)

gmm = GaussianMixture(n_components=3, random_state=42)
loan_data['gmm_cluster'] = gmm.fit_predict(loan_data[['fico', 'dti']])

plt.figure(figsize=(10, 6))
sns.scatterplot(x='fico', y='dti', hue='gmm_cluster', palette='viridis', data=loan_data)
plt.title('GMM klasterizacija pagal FICO ir DTI')
plt.xlabel('FICO balas')
plt.ylabel('DTI')
plt.show()

kmeans = KMeans(n_clusters=3, random_state=42)
loan_data['kmeans_cluster'] = kmeans.fit_predict(loan_data[['fico', 'dti']])

plt.figure(figsize=(10, 6))
sns.scatterplot(x='fico', y='dti', hue='kmeans_cluster', palette='plasma', data=loan_data)
plt.title('K-means klasterizacija pagal FICO ir DTI')
plt.xlabel('FICO balas')
plt.ylabel('DTI')
plt.show()

# 4. Regresija (Linijinė ir Logistinė)

# Tiesinė regresija: įmokos vs metinės pajamos
X_lin = loan_data[['log.annual.inc']]
y_lin = loan_data['installment']
model_lin = LinearRegression()
model_lin.fit(X_lin, y_lin)
predicted_installments = model_lin.predict(X_lin)

plt.figure(figsize=(10, 6))
plt.scatter(loan_data['log.annual.inc'], loan_data['installment'], label='Tikros įmokos')
plt.plot(loan_data['log.annual.inc'], predicted_installments, color='red', label='Prognuozuota linija')
plt.title('Įmokos pagal metines pajamas')
plt.xlabel('Metinių pajamų logaritmas')
plt.ylabel('Įmoka')
plt.legend()
plt.show()

# Logistinė regresija: paskolos neapmokėjimo prognozavimas
X_log = loan_data[['fico', 'int.rate', 'dti', 'installment']]
y_log = loan_data['not.fully.paid']
X_log = sm.add_constant(X_log)
logistic_model = sm.Logit(y_log, X_log).fit()
print(logistic_model.summary())

# 5. Anomalių aptikimas su Z-Score

loan_data['installment_zscore'] = zscore(loan_data['installment'])
anomalies = loan_data[np.abs(loan_data['installment_zscore']) > 3]

plt.figure(figsize=(10, 6))
sns.histplot(loan_data['installment_zscore'], bins=30, kde=True)
plt.title('Z-score paskirstymas įmokoms')
plt.xlabel('Z-score')
plt.ylabel('Dažnis')
plt.show()

# 6. Papildoma analizė (Neapmokėjimo tikimybės skirtingomis sąlygomis)

# Paskolų neapmokėjimo dažnis
plt.figure(figsize=(10, 6))
sns.countplot(x='not.fully.paid', data=loan_data)
plt.title('Paskolų neapmokėjimo dažnis')
plt.xlabel('Nevisiškai gražinta (1=Taip, 0=Ne)')
plt.ylabel('Dažnis')
plt.show()

# Neapmokėjimo tikimybė pagal paskirties tipą
loan_purpose_non_payment = loan_data.groupby('purpose')['not.fully.paid'].mean() * 100
plt.figure(figsize=(10, 6))

```

```

loan_purpose_non_payment.plot(kind='bar', color='skyblue')
plt.title('Neapmokėjimo tikimybė pagal paskirtį')
plt.xlabel('Paskolos paskirtis')
plt.ylabel('Neapmokėjimo tikimybė (%)')
plt.xticks(rotation=45)
plt.show()

# Neapmokėjimo tikimybė pagal palūkanų normų kategorijas
loan_data['int.rate.category'] = pd.cut(loan_data['int.rate'],
                                       bins=[0, 0.1, 0.15, 0.2, 0.25, 0.3],
                                       labels=['Labai maža', 'Maža', 'Vidutinė', 'Didelė', 'Labai
didelė'])
plt.figure(figsize=(10, 6))
sns.barpplot(x='int.rate.category', y='not.fully.paid', data=loan_data)
plt.title('Neapmokėjimo tikimybė pagal palūkanų kategoriją')
plt.xlabel('Palūkanų norma')
plt.ylabel('Neapmokėjimo tikimybė')
plt.show()

# Pajamos ir neapmokėjimo tikimybė
plt.figure(figsize=(10, 6))
sns.scatterplot(x='log.annual.inc', y='not.fully.paid', data=loan_data)
plt.title('Pajamos ir neapmokėjimo tikimybė')
plt.xlabel('Metinių pajamų logaritmas')
plt.ylabel('Neapmokėjimo tikimybė')
plt.show()

# FICO skaičiaus pasiskirstymas
plt.figure(figsize=(10, 6))
sns.histplot(data=loan_data, x='fico', hue='not.fully.paid', multiple='stack', kde=True)
plt.title('FICO balų pasiskirstymas pagal gražinimo statusą')
plt.xlabel('FICO balas')
plt.ylabel('Dažnis')
plt.show()

# 7. Klasifikavimo modelių kūrimas ir lyginimas (su SMOTE, Standartizacija)

X_class = loan_data[['fico', 'int.rate', 'dti', 'installment', 'log.annual.inc']]
y_class = loan_data['not.fully.paid']

# Klasių disbalanso korekcija (SMOTE)
smote = SMOTE(random_state=42)
X_resampled, y_resampled = smote.fit_resample(X_class, y_class)
scaler = StandardScaler()
X_scaled = scaler.fit_transform(X_resampled)

# Duomenų padalinimas
X_train, X_test, y_train, y_test = train_test_split(X_scaled, y_resampled, test_size=0.2,
random_state=42)

# Random Forest parametrai (GridSearch)
param_grid_rf = {
    'n_estimators': [100, 200],
    'max_depth': [3, 5],
    'min_samples_split': [2, 5]
}
grid_search_rf = GridSearchCV(RandomForestClassifier(random_state=42), param_grid_rf, cv=3,
scoring='accuracy')
grid_search_rf.fit(X_train, y_train)
print(f'Best Params for Random Forest: {grid_search_rf.best_params_}')

# Modelių sąrašas
models = {
    "Logistic Regression": LogisticRegression(C=1, solver='liblinear', max_iter=200),
    "Random Forest": RandomForestClassifier(**grid_search_rf.best_params_, random_state=42),
    "XGBoost": XGBClassifier(use_label_encoder=False, eval_metric='logloss', learning_rate=0.1,
max_depth=5, random_state=42),
    "Naive Bayes": GaussianNB()
}

# Funkcija metrikų spausdinimui
def evaluate_model(model, X_test, y_test):
    y_pred = model.predict(X_test)
    accuracy = accuracy_score(y_test, y_pred)
    precision = precision_score(y_test, y_pred)
    recall = recall_score(y_test, y_pred)
    f1 = f1_score(y_test, y_pred)
    roc_auc = roc_auc_score(y_test, y_pred)
    return accuracy, precision, recall, f1, roc_auc, confusion_matrix(y_test, y_pred)

```

```

results = {}
for model_name, model in models.items():
    model.fit(X_train, y_train)
    accuracy, precision, recall, f1, roc_auc, confusion = evaluate_model(model, X_test, y_test)
    results[model_name] = {
        "Accuracy": accuracy,
        "Precision": precision,
        "Recall": recall,
        "F1 Score": f1,
        "ROC-AUC": roc_auc,
        "Confusion Matrix": confusion
    }
    print(model_name, results[model_name])

# Neuroninio tinklo kūrimas
nn_model = Sequential()
nn_model.add(Dense(16, input_dim=X_train.shape[1], activation='relu'))
nn_model.add(Dropout(0.3))
nn_model.add(Dense(8, activation='relu'))
nn_model.add(Dense(1, activation='sigmoid'))
nn_model.compile(optimizer=Adam(learning_rate=0.001), loss='binary_crossentropy',
metrics=['accuracy'])
history = nn_model.fit(X_train, y_train, epochs=10, batch_size=32, validation_data=(X_test, y_test))

# Ansamblio modelis
ensemble_model = VotingClassifier(
    estimators=[
        ('logreg', LogisticRegression(C=1, solver='liblinear', max_iter=200)),
        ('rf', RandomForestClassifier(n_estimators=grid_search_rf.best_params_['n_estimators'],
                                     max_depth=grid_search_rf.best_params_['max_depth'],
min_samples_split=grid_search_rf.best_params_['min_samples_split'],
                                     random_state=42)),
        ('xgb', XGBClassifier(use_label_encoder=False, eval_metric='logloss', random_state=42))
    ],
    voting='soft'
)
ensemble_model.fit(X_train, y_train)
y_pred_ensemble = ensemble_model.predict(X_test)
accuracy_ensemble = accuracy_score(y_test, y_pred_ensemble)
print(f'Ensemble Accuracy: {accuracy_ensemble:.4f}')

# Savybių svarba (naudojame RandomForest)
rf_model = RandomForestClassifier(**grid_search_rf.best_params_, random_state=42).fit(X_train,
y_train)
feature_importances = rf_model.feature_importances_
for feature, importance in zip(X_class.columns, feature_importances):
    print(f'{feature}: {importance:.4f}')

# 8. Kiti modeliai (SVM, KNN, Decision Tree ir t.t.)

models_others = {
    "SVM": SVC(probability=True, random_state=42),
    "KNN": KNeighborsClassifier(),
    "Decision Tree": DecisionTreeClassifier(random_state=42),
    "Gradient Boosting": GradientBoostingClassifier(random_state=42),
    "Ridge Classifier": RidgeClassifier()
}

for model_name, model in models_others.items():
    model.fit(X_train, y_train)
    accuracy, precision, recall, f1, roc_auc, confusion = evaluate_model(model, X_test, y_test)
    print(model_name, {
        "Accuracy": accuracy,
        "Precision": precision,
        "Recall": recall,
        "F1 Score": f1,
        "ROC-AUC": roc_auc,
        "Confusion Matrix": confusion
    })

# 9. Duomenų paruošimo, treniravimo istorijos vizualizacija

def plot_training_history(history, title="Modelio mokymosi procesas"):
    plt.figure(figsize=(10, 6))
    plt.plot(history.history['loss'], label='Mokymosi nuostolis')

```

```

plt.plot(history.history['val_loss'], label='Validacijos nuostolis')
plt.title(title)
plt.xlabel('Epochs')
plt.ylabel('Nuostolis (Loss)')
plt.legend()
plt.show()

plot_training_history(history)

def plot_metrics(metrics, model_name="Modelio"):
    plt.figure(figsize=(10, 6))
    plt.bar(metrics.keys(), metrics.values(), color='c')
    plt.xlabel('Metrikos')
    plt.ylabel('Reikšmės')
    plt.title(f'{model_name} metrių vizualizacija')
    plt.show()

```

2 PRIEDAS. Virtualaus asistento prototipo Python kodas.

```

import openai
import gradio as gr
import re
import numpy as np
import pandas as pd

openai.api_key = "X"

conversation_history = [
    {"role": "system", "content": (
        "Tu esi Finansų Rizikos Vertinimo Chatbotas. "
        "Turi prieigą prie apmokytų ML modelių ir paskolų duomenų (loan_data)"
        "Gali atlikti paskolos grąžinimo tikimybės prognozę pagal nurodytus parametrus"
        "Gali pateikti statistinę informaciją iš duomenų bazės (loan_data.csv)"
        "Vartotojas gali pateikti parametrus (fico, int.rate, dti, installment, log.annual.inc),
pagal kuriuos gali paskaičiuoti neapmokėjimo tikimybę."
        "Jei paklausia apie duomenų savybes (pvz. vidutinis int.rate), pateik statistiką tiesiogiai
iš loan_data.csv. "
    )}
]

def chatbot(user_input):
    additional_context = ""

    if "Prognozuok neapmokėjimo tikimybę:" in user_input:
        pattern =
r'fico=(\d+),\s*int.rate=(\d\.\d+),\s*dti=(\d\.\d+),\s*installment=(\d\.\d+),\s*log.annual.inc=(\d\.\d+)'
        match = re.search(pattern, user_input)
        if match:
            fico_val = float(match.group(1))
            int_rate_val = float(match.group(2))
            dti_val = float(match.group(3))
            installment_val = float(match.group(4))
            log_annual_inc_val = float(match.group(5))

            # Standartizuoja šiuos duomenis pagal anksčiau naudotą scaler (užtikrinkite, kad
scaler ir ensemble_model yra apibrėžti):
            X_new = [[fico_val, int_rate_val, dti_val, installment_val, log_annual_inc_val]]
            X_new_scaled = scaler.transform(X_new)

            # Prognozuojame su ansamblio modeliu
            y_pred_proba = ensemble_model.predict_proba(X_new_scaled)[0, 1] # tikimybė, kad
nebus grąžinta (1)
            y_pred = ensemble_model.predict(X_new_scaled)[0]

            additional_context = (
                f"Modelio prognozė:\n"
                f"- Neapmokėjimo tikimybė: {y_pred_proba:.2%}\n"
                f"- Prognozuota klasė (0=grąžinta,1=negražinta): {y_pred}\n\n"
            )
        else:
            additional_context = (
                "Nepavyko išskirti duotų parametrų. Įsitikinkite, kad formatas teisingas (pvz.: "
                "Prognozuok neapmokėjimo tikimybę: fico=700, int.rate=0.12, dti=10, installment=200,
log.annual.inc=10)\n\n"
            )

    # Papildome istoriją su vartotojo žinute ir papildomu kontekstu

```

```

conversation_input = additional_context + user_input
conversation_history.append({"role": "user", "content": conversation_input})

# Siunčiame visą istoriją modeliui
response = openai.ChatCompletion.create(
    model="gpt-3.5-turbo",
    messages=conversation_history
)

# Gautą atsakymą išsaugome istorijoje
assistant_message = response.choices[0].message.content
conversation_history.append({"role": "assistant", "content": assistant_message})
return assistant_message

iface = gr.Interface(
    fn=chatbot,
    inputs="text",
    outputs="text",
    title="Finansinių rizikų asistentas",
    description=(
        "Sveiki! Esu čia, kad padėčiau Jums suprasti galimas finansines rizikas. "
        "Drašiai klauskite - stengsiuosi viską paaiškinti kuo paprasčiau."
    )
)

iface.launch()

```