



Ғылыми мақала

<https://doi.org/10.32523/3136-3385-2026-155-2-304-317>

Протоколдық SRE-валидация контуры бар актуарлық ML-платформа

К.Г. Мадияров* , **О.Я. Швец** 

Новосібір мемлекеттік экономика және басқару университеті, Новосібір, Ресей

E mail: kuan.mad@mail.ru, o.y.shvec@edu.nsuem.ru

Аңдатпа. Сақтандыру секторында машиналық оқытуға негізделген модельдер сыйлықақыны есептеу, клиенттің кетуін болжау, өтініштерді мәтіндік талдау және сервистік шешімдерді қолдау сияқты қолданбалы міндеттерде кеңінен пайдаланылады. Алайда практикада мұндай модельдер көбіне өзара байланыспаған модульдер ретінде енгізіледі, сондықтан деректер сапасын тексеру, жылыстау тәуекелін бақылау, метрикаларды тіркеу және сервистік күйді бағалау бірыңғай тәртіппен жүргізілмейді. Мақалада аталған мәселені шешуге бағытталған келесі тәсіл қарастырылады — протоколдық SRE-валидация контуры бар актуарлық ML-платформа ұсынылады. Платформа микросервистік архитектураға негізделген және деректерді жинау мен даярлау сервистерін, модельдерді оқыту және бағалау модульдерін, нәтижелерді ұсыну интерфейсін біріктіреді. Протокол шеңберінде әрбір кезеңде құрылымдық тексеру, қателерді жіктеу, дрейфті бақылау, метрикаларды салыстыру және артефакттардың өндірістік ортаға жарамдылығын растау рәсімдері орындалады. Мұндай тәсіл модельді қайта оқыту мен жаңартуды басқарылатын режимде жүргізуге, алдыңғы нұсқамен салыстырмалы тұрақтылықты сақтауға және сервистің үздіксіз жұмысын қамтамасыз етуге ықпалын тигізеді. Сонымен бірге ол модель нәтижелерін тек сапа көрсеткіштерімен емес, эксплуатациялық контекстпен бірге бағалауға жол ашады. Ұсынылған шешім сақтандыру ұйымдарында тәуекелдерді модельдеудің сенімділігін арттыруға және ML-жүйелердің өзгерістерге төзімділігін күшейтуге бағытталған.

Түйін сөздер: актуарлық платформа; ML-конвейер; протоколдық валидация; жылыстауды бақылау; бақыланым; SRE

Кіріспе

Сақтандыру деректері әлдеқашан тарифті есептеудің ғана көзі болудан қалды. Бүгінде бір ақпараттық контурда клиентті ұстап қалу, полис құнын болжау, өтініштерді маршрутизациялау, сервистік тәуекелдерді бағалау және клиентпен өзара әрекеттесуді қолдау сияқты міндеттер қатар шешіледі. Сондықтан модельдің практикалық құндылығы тек дәлдігімен емес, кіріс деректерінің шығу тегі қаншалықты айқын екенімен, оларды пайдалану шектеулері қалай тіркелетінімен және алынған нәтижені нақты сервисте қайта өндіруге бола ма деген мәселемен де айқындалады.

Сақтандыру аналитикасына арналған зерттеулерде тәуекел-классификация, жоғары кардиналды белгілермен жұмыс істеу және үлкен деректерді пайдалану мәселелері егжей-тегжейлі қарастырылады [1-4]. Еңбектердің жеке бір тобы мәтіндік өтініштер мен клиент хабарламаларын көпсыныпты маршрутизациялауға арналған [5-7]. MLOps пен ML-жүйелерді эксплуатациялау жөніндегі әдебиетте деректер нұсқаларын басқару, метрикалар, мониторинг және жеткізу рәсімдері назарға алынады [8-10]. Алайда осы бағыттардың түйісінде елеулі олқылық сақталып отыр: сақтандыру ML-контурлары көбіне не модельдер жиынтығы, не инженерлік пайплайн ретінде сипатталады, ал деректер сапасы, модельдік артефакт және сервистің эксплуатациялық жай-күйі арасындағы байланыс жеткілікті дәрежеде формалданбайды.

Қарастырылған зерттеудің мәселесі мынада: сақтандыру ML-конвейері үшін кету, сыйлықақы, мәтін, travel және loyalty бағыттары бойынша жекелеген модельдерді оқыту жеткіліксіз. Деректерді анықтауды, құрылымдық тексеруді, жылыстау тәуекелдерін диагностикалауды, оқытуды, метрикаларды сақтауды, сервистік инференсті және эксплуатациялық көрсеткіштерді дәйекті түрде тіркейтін бірыңғай протоколдық контур қажет. Мұндай контурдың болмауы не метрикалардың жасанды түрде жоғарылауына, не өмірлік циклдің әртүрлі міндеттері мен кезеңдері бойынша нәтижелердің салыстырылмауына әкеледі.

Мақаланың мақсаты — қайта өндіруге болатын жергілікті сервис негізінде протоколдық бақылауы бар сақтандыру ML-конвейерін ұсыну және тәжірибелік тұрғыдан тексеру. Қойылған мақсатқа сәйкес зерттеу барысында мынадай міндеттер белгіленді: 1) деректер мен протокол құрылымын беру; 2) валидация рәсімін және диагностикалық сигналдарды көрсету; 3) бірнеше сақтандыру контурлары бойынша нәтижелерді салыстыру; 4) протоколдың модельдік метрикаларды интерфейспен, артефакттар тізілімімен және SRE-бақыланымымен қалай байланыстыратынын көрсету.

Мәселенің күрделілігі автосақтандыру, тұрғын үйді сақтандыру, мәтіндік өтініштер, travel-сценарийлер мен loyalty үшін жеке модельдерді оқытудың өзінде емес, оларды бірыңғай контурға келісілген түрде енгізуде жатыр. Егер құрылымдық валидация, жылыстауды бақылау, метрикаларды тіркеу және сервистік телеметрия бөлек орындалса, онда тіпті жақсы Ассигасу немесе R^2 мәндерінің өзі деректер контексті мен орналастыру шарттарынан тыс дұрыс түсіндірілмейді. Осыған байланысты датасетті анықтаудан бастап артефактты сақтауға және эксплуатациялық тексеруге дейінгі бүкіл жолы бірыңғай протоколмен берілетін платформаны сипаттау міндеті туындайды. Мақалада протоколдық SRE-валидация контурлары бар актуарлық ML-платформа қарастырылады.

Жұмыстың мақсаты — бірыңғай протоколдың қайта өндіруге болатын жергілікті сервис аясында деректерді, модельдерді, артефакттарды және сервистік телеметрияны қалай байланыстыратынын көрсету. Осы мақсатта қолданылған деректер құрамы, протокол құрылымы, метрикалар мен диагностикалық ережелер жиыны дәйекті түрде сипатталып, бұдан кейін бірнеше сақтандыру контуры бойынша алынған нәтижелер және олардың сервистік мәні талқыланады.

Әдіснама

Платформа прототипі FastAPI негізіндегі жергілікті сервис түрінде, браузерлік интерфейспен және модельдер мен есептік артефакттарға арналған жеке каталогтармен жүзеге асырылды. Мұндай шешім оқыту мен эксплуатацияны бір процестің өзара байланыстыруға ынғайлы болып табылады: әрбір іске қосудан кейін құрылымдық тексеру нәтижелері, модель метрикалары, артефакттар тізілімі және протоколдың жиынтық көрсеткіштері тіркеледі. Эксперименттік база ретінде churn, home premium, мәтіндік классификация, travel және loyalty міндеттеріне арналған ашық сақтандыру деректер жиынтықтары пайдаланылды. Экспериментке алты ашық жиынтық енгізілді: autoinsurance churn [11], home insurance train және home insurance test [12], bitext insurance [13], travel insurance [14] және loyalty [15]. Жалпы көлемі 3 031 858 жазбаны құрайды.

Кесте 1. Деректер контурлары және құрылымдық валидация нәтижелері

Контур	Жол саны	Баған саны	Бос мән	Дубли кат	ID-қауіп	Күн өрісі	Сапа
auto	1 680 909	22	2 111 311	жоқ	2	3	0,9229
text	39 000	5	жоқ	жоқ	0	анықталмаған	0,9724
home_train	1 000 000	28	жоқ	жоқ	2	анықталмаған	0,9800
home_test	300 000	28	жоқ	жоқ	2	анықталмаған	0,9800
travel	10 000	7	жоқ	205	0	анықталмаған	0,9713
loyalty	1 949	8	335	жоқ	1	анықталмаған	0,9685

Кестелік контурлар үшін сандық және категориялық белгілері аралас деректерге төзімді алгоритмдер қолданылды; олар бос мәндерді алдын ала өңдеумен, категорияларды кодтаумен және идентификаторлық өрістерді бақылаумен толықтырылды. Мәтіндік модульде өтініштер TF-IDF әдісімен векторланады, одан кейін классификация логистикалық регрессия арқылы орындалады; мұндай үйлесім сирек мәтіндік ұсынылымдармен тиімді жұмыс істейді әрі есептеу тұрғысынан интерпретациялауға қолайлы болып қалады [16, 17]. Барлық сценарийлерде оқыту модельді, параметрлердің қысқаша тізілімін және жарияланымдық артефакттарды reports каталогында сақтаумен аяқталады. Прототиптік режимде тұрғын үй бойынша сыйлықақы болжамы 150 000 оқыту

(train) және 50 000 тексеру (test) көлеміндегі бақыланатын іріктемеде оқытылды, бұл артефактты дайындау уақыты қолайлы деңгейде сақталған жағдайда қайта өндірілуін қамтамасыз етті. Барлық модельдер нысаналы айнымалы, файл көлемі және оқыту ұзақтығы көрсетіліп, тізілімге енгізіледі.

1-кесте көрсеткендей, бастапқы деректер сапасы әртүрлі сақтандыру контурларында бірдей емес. Ең сезімтал болып auto-контур шықты, мұнда бос мәндердің едәуір көлемі, күн өрістері және идентификаторлық қауіп белгілері бір мезгілде кездеседі. Ал home, text, travel және loyalty сценарийлерінде деректер құрылымы анағұрлым орнықты көрінеді, дегенмен бұл жағдайларда да протокол жалпы толықтықты ғана емес, кейінгі оқыту мен модельді интерпретациялауға әсер етуі мүмкін белгілер қасиеттерін тіркейді.

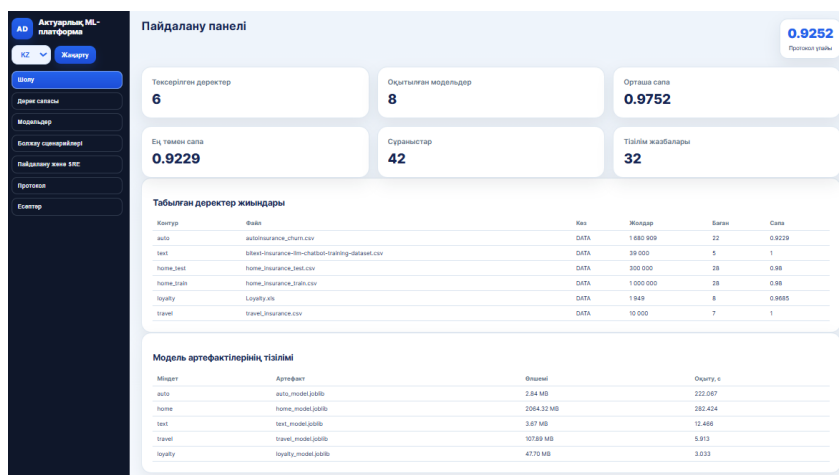
Құрылымдық валидация ең проблемалы контурдың autoinsurance екенін көрсетті: 1 680 909 жол болғанда онда 2 111 311 бос мән, үш күн өрісі және идентификаторлық қауіптің екі белгісі бар. Керісінше, home_train және home_test контурларында бос мәндер жоқ, бірақ екі identifier-risk өрісі (uuid және quote_id) қамтылған, сондықтан оларды белгілер кеңістігінен айқын түрде алып тастау қажет. Loyalty контурында жергілікті бос мәндер табылды, ал travel контурында 205 дубликат анықталды. Демек, сызбалар мен деректерді бірыңғай тексеру оқытуға дейінгі кезеңде сандық score қана емес, интерпретациялауға болатын тәуекел сигналдарын да береді.

Протоколдық контур бірізді байланысқан сегіз кезеңді қамтиды: деректер жиынтықтарын анықтау, құрылымдық тексеру, жылыстауды бақылау, мамандандырылған модельдерді оқыту, метрикаларды сақтау, сервистік инференс, SRE-бақыланымы және жеткізу контуры. Мұндай бөліну өз алдына мақсат емес; оның мәні — платформа ішіндегі деректер мен артефакттардың қозғалыс траекториясын бір сипаттамада тұтас ұстап тұру.

Кәдімгі практикада жүктеу, оқыту және тексеру қадамдары көбіне бөлек тіркеледі. Қарастырылып отырған платформада модель кіріс деректерінің күйі, диагностикалық сигналдар, артефакт көлемі, оқыту уақыты, метрикалар журналдары және эксплуатациялық телеметрия ескерілетін неғұрлым кең объектінің бөлігі ретінде ғана қабылданады. Соның арқасында қорытынды баға тек нысаналы метриканың мәніне емес, сол метриканың қандай контексте алынғанына да тәуелді болады.


Мәтіндік контурда құжаттар алдымен TF-IDF кеңістігіне түрлендіріледі, мұнда белгі мәні терминнің құжаттағы жиілігі мен оның корпустың таралуын түзету арқылы анықталады [16]. Осындай ұсынылым үстінде логистикалық регрессия [17] пайдаланылады; ол сирек белгілер матрицаларымен орнықты жұмыс істейді және есептеу контурын шамадан тыс күрделендірмей сенімді базалық классификатор жасауға мүмкіндік береді. Классификациялық міндеттер үшін Assurasy, macro-F1 және AUC метрикалары қолданылады. Assurasy дұрыс классификацияланған бақылаулардың үлесін көрсетеді [18]. Macro-F1 сыныптар бойынша F1 өлшемінің салмақталмаған орташа мәні ретінде есептеледі, сондықтан ең жиі кездесетін сыныптың басымдығына тәуелсіз түрде модель сапасын бағалауға мүмкіндік береді [19]. AUC объектілерді болжамды бағалары бойынша ранжирлеу сапасын сипаттайды және шешім қабылдаудың бекітілген шегіне тәуелді емес [20]. Регрессиялық контурларда MAE, RMSE және R^2 қолданылады. MAE болжамның орташа абсолют қателігін көрсетеді [21]. RMSE қатенің квадратына және кейін квадрат түбірін

алуға негізделетіндіктен, ірі ауытқуларды күштірек айқындайды [22]. R^2 коэффициенті тұрақты базалық болжаммен салыстырғанда нысаналы айнымалы вариациясының қандай үлесін модель түсіндіретінін көрсетеді; бұл ретте модель базалық бағдардан на шар жұмыс істесе, оның мәні теріс те болуы мүмкін [23]. Бұдан басқа, артефакттар тізілімі модель файлының көлемін және оқыту ұзақтығын сақтайды, ал протокол қосымша интерпретацияны қажет ететін жағдайлар үшін арнайы белгілерді бөліп көрсетеді: күдік тудыратындай жоғары метрикалар, идентификаторлық қауіп белгілерінің болуы, дубликаттар және оқыту мен бақылау деректерінің қиылыстары. Осындай көрсеткіштер жиынтығы модель сапасын оқшау түрде емес, деректер сипаттамаларымен және оны кейін пайдалану шарттарымен өзара байланыста ашып көрсетуге жол ашады.



Сурет 1. Контурлар картасы мен модель артефакттары тізілімін қамтитын сервистің шолу панелі

1-суретте бір кеңістікте деректер контурлары, модельдер тізілімі және негізгі эксплуатациялық көрсеткіштер тоғысқан сервистің шолу панелі берілген.



Сурет 2. Бос мәндер, дубликаттар және идентификаторлық қауіптер бойынша жинақталған көрсеткіштері бар деректер сапасы экраны

Мұндай экран тек навигациялық құрылғысы ғана ретінде қарастырылмайды: ол платформаның жекелеген модельмен оқшау жұмыс істеуге емес, сценарийлер мен артефакттарды салыстыруға бағдарланғанын көрсетеді.

2-суретте берілген деректер сапасы экраны кейінгі нәтижелерді түсіндірудің бастапқы нүктесі қызметін атқарады. Дәл осы жерде бос мәндер, дубликаттар, идентификаторлық белгілердің қауіптері және кейін модельдік метрикаларды талқылауда ескерілетін деректер жиынтықтарының өзге де қасиеттері тіркеледі.

Нәтижелер және талқылау

Алынған нәтижелер сақтандыру контурларының күрделілігі әртүрлі екенін растайды. Home-болжам үшін ықшам 5,27 MB артефакт және 11,638 с оқыту уақыты жағдайында $R^2 = 0,9848$ жоғары детерминация коэффициентіне қол жеткізілді. Loyalty контуры шағын деректер көлемінде практикалық тұрғыдан пайдалы деп бағалауға болатын $R^2 = 0,8564$ нәтижесін көрсетті. Travel контуры айтарлықтай күрделірек болып шықты: оқыту жылдам өткеніне қарамастан, регрессиялық сапа $R^2 = 0,4677$ мәнімен шектелді, ал артефакт көлемі 107,89 MB-қа жетті. Text-модулі үшін Accurasy мен macro-F1 көрсеткіштері шамамен 0,986 деңгейінде тұрақты болды, алайда category ассурасу қосымша түрде күдік тудыратындай жоғары деп белгіленді.

Ең айқын мысал — auto-контур. Оның сандық нәтижелері шекке жуық мінсіз көрінеді, бірақ протокол мұндай мәндерді шартсыз қабылдамайды. Керісінше, ол leakage-aware ескертулерін автоматты түрде қалыптастырып, оларды деректер сипаттамаларымен — individual_id, address_id өрістерінің болуымен, бірнеше күн белгілерімен және бос мәндердің жоғары үлесімен — байланыстырады. Бұл протоколды сәндік қабаттан ғылыми және инженерлік тұрғыдан негізделген өзін-өзі тексеру тетігіне айналдырады.

Кесте 2. Модельдердің негізгі метрикалары және артефакт параметрлері

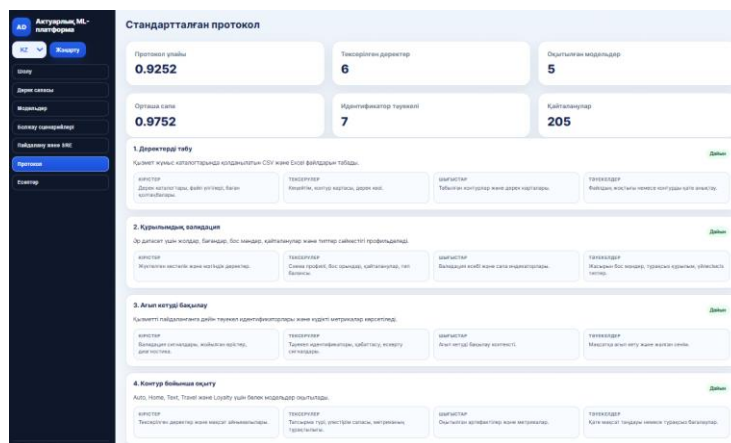
Контур	Метрикалар	Артефакт	Көлемі	Оқыту, с	Белгі
auto	Accuracy=0,9996; F1=0,9990; AUC=0,9988	auto_model.joblib	2,84 MB	213,619	күдік тудырады
home	MAE=41,11; RMSE=51,41; $R^2=0,9848$	home_model.joblib	5,27 MB	11,638	-
text	Acc=0,9859; F1=0,9860; cat-Accuracy =0,9906	text_model.joblib	3,67 MB	12,338	күдік бар cat-Acc
travel	MAE=251,56; RMSE=552,98; $R^2=0,4677$	travel_model.joblib	107,89MB	5,850	-
loyalty	MAE=0,3222; RMSE=0,4157; $R^2=0,8564$	loyalty_model.joblib	47,70 MB	2,949	-

Негізгі сандық нәтижелер мен сақталған модельдердің сипаттамалары 2-кестеде

жинақталған. Сандық метрикаларды ғана салыстыратын кәдімгі тәсілден айырмашылығы, мұнда болжау сапасы, артефакт көлемі, оқыту ұзақтығы және диагностикалық белгілер бірге берілген. Мұндай біріктіру модельді абстрактілі алгоритм ретінде емес, қайта өндірілуі, интерпретациялануы және сервистік контурға енгізілуі тиіс эксплуатациялық объектіге жатқызуға болатыны мүмкін.

2-кестеден көрінгендей, тұрғын үй контуры артефакттың ықшам көлемі мен оқытудың орташа уақыты жағдайында анағұрлым орнықты регрессиялық сапаны қамтамасыз етеді. Loyalty контуры едәуір аз бақылаулар жиынтығында практикалық тұрғыдан пайдалы дәлдік деңгейін көрсетіп, протоколдық схеманың тек ірі деректерге ғана емес, шағын жиынтықтарға да қолданылатынын дәлелдейді. Travel-сценарийінде сапа неғұрлым ұстамды болды, бұл бастапқы белгілер құрылымының қарапайымдылығы және деректер көлемінің аздығымен үйлеседі. Мәтіндік модуль жоғары Accuracy және macro-F1 мәндерін көрсетеді, алайда бұл көрсеткіштер сенімділіктің өздігінен жеткілікті дәлелі ретінде емес, протоколдық белгілермен бірге түсіндіріледі. Ең айқын мысал — автосақтандыру контуры: мұнда сандық метрикалар шекті мәндерге жақын, бірақ протокол бір мезгілде деректердің біртектес еместігін және ықтимал жылыстауға қосымша тексеріс қажет ететін белгілердің бар екенін көрсетеді.

Нәтижелердің қайта тексерілуін қамтамасыз ету үшін осы контурларда пайдаланылған бастапқы деректер ашық көздерден алынды: autoinsurance churn жиынтығы Kaggle платформасынан, home insurance train мен home insurance test жиынтықтары Hugging Face-terі BilalAhxmd/Insurance-data қорынан, bitext insurance жиынтығы bitext/Bitext-insurance-llm-chatbot-training-dataset репозиторийінен, travel insurance жиынтығы supersam7/travel_insurance қорынан, ал loyalty жиынтығы Kaggle-дері Customer Loyalty score dataset бетінен алынды [11-15].




Сурет 3. Қадамдық мәртебелер, кірістер, тексерулер, шығыстар және тәуекелдер көрсетілген стандартталған протокол экраны

Платформа бірыңғай сервистік контур ретінде іске асырылған: онда пайдаланушылық сценарийлер, валидация нәтижелері, модельдік көрсеткіштер мен эксплуатациялық индикаторлар үйлестірілген веб-интерфейс арқылы қолжетімді. Интерфейс функционалдық бөлімдер бойынша ұйымдастырылып, жүйенің жиынтық күйінен деректер сапасына, модель сипаттамаларына, қолданбалы болжау сценарийлеріне,

протоколдық қадамдарға және эксплуатациялық көрсеткіштерге бірізді көшуге үміт арттырады. Жоғарыда қарастырылған бірыңғай құрылым ML-конвейерді тек есептеу нысаны емес, ішкі қызметтік файлдарға жүгінбей-ақ күйін интерпретациялауға болатын бақыланатын объект етеді.

Платформаның пайдаланушылық қабаты бірнеше пәндік сценарийді қолдайды: автосақтандырудағы кету қаупін бағалау, сақтандыру сыйлықақысын болжау, мәтіндік өтініштерді өңдеу, сондай-ақ travel және loyalty контурлары. Әр сценарий үшін интерфейс кіріс параметрлерінің келісілген пішінін ұсынады және нәтижені қолданбалы түрде қайтарады; бұл жүйені тек модельдерді баптау құралы ретінде емес, эксплуатацияға жақын жағдайда сервистің жұмысқа қабілеттілігін көрсететін орта ретінде де қарастырылады. Платформаның маңызды қасиеті — көптілділік: бөлімдер мен сценарийлер бір тілдік режимнің ішінде терминдерді араластырмай, үш тілде қолжетімді – ол орысша мен қазақша тілдерінде және ағылшын тілінде.

3-суретте сервистің сегіз қадамы жай формальды тізім ретінде емес, кірістері, тексерулері, шығыстары және тәуекелдері бар жұмыс реттілігі ретінде көрсетілген протокол экраны берілген. Мұндай ұсыну тәсілі мақала үшін маңызды, өйткені ол есептеу процесін оның интерпретациясымен көрнекі түрде байланыстырып, диагностикалық ескертпелердің қай кезеңде туындайтынын айқын көрсетеді.



Сурет 4. Сервистің эксплуатациялық контуры және SRE-телеметриясы экраны

4-суретте платформаның SRE-телеметриясы бар эксплуатациялық контуры көрсетілген. Мұнда сервистің қолжетімділігі, сұранымдар қарқындылығы және өңдеу кідірістері тіркеледі, сондықтан модель күйі оны пайдаланатын сервистің жай-күйімен бірге қарастырылады. Сақтандыру аналитикасы үшін бұл принципті маңызды: егер сервистік контур ашық емес немесе орнықсыз болса, модель сапасының жоғары болуының өзі практикалық құндылығын жоғалтады. Алынған нәтижелер протоколдық контурдың тек есептеулерді техникалық ұйымдастыру құралы ғана емес, қолданбалы сақтандыру ортасында модельдік нәтижелерді интерпретациялау тәсілі ретінде де пайдалы екенін көрсетеді. 2-кесте мен 3-4-суреттер қорытынды көрсетілген сапалық метрикаларының мәндерінің бастапқы деректер сапасымен, артефакттың көлемі мен түрімен, оқыту ұзақтығымен және сервистік контурдың ағымдағы жай-күйімен бірге ғана мәнді болатынын көрсетеді. Сондықтан нәтижелерді талқылау жекелеген сандар төңірегінде

емес, деректер, модель және эксплуатация шарттары арасындағы байланыс төңірегінде құрылады.

Мұндай ұсыну тәсілі жекелеген модельдерді көрсетуден әр контур бірдей қадамдар тізбегінен өтетін басқарылатын платформаны сипаттауға көшуге негіз болады: деректерді айқындау, құрылымдық тексеру, тәуекелдерді бақылау, оқыту, артефакттарды сақтау, сценарийлік пайдалану және эксплуатациялық қадағалау. Нәтижесінде қорытындылар бір-бірімен байланыспаған метрикалардың қосындысы ретінде емес, модельдік шешімдерді салыстырмалы, бақыланатын және сақтандырудың ақпараттық-талдамалық жүйесі құрамында одан әрі кеңейтуге жарамды ететін қайта өндірілуі мүмкін процестің сипаттамасы ретінде қалыптасады.

Қорытынды

Жұмыстың мақсатына қол жеткізілді: деректерді валидациялауды, модельдерді оқытуды, сервистік инференсті және эксплуатациялық бақыланымды бір қайта өндірілуі мүмкін платформада біріктіретін протоколдық бақылауы бар сақтандыру ML-конвейері құрылып, тәжірибелік тұрғыдан тексерілді. Қарастырылған платформа сақтандыру ML-контур үшін модель метрикаларының қорытынды мәндері ғана емес, оларды алу тәсілі, деректер құрылымы және сервистің эксплуатациялық жай-күйі де маңызды екенін көрсетеді. Протоколдық ұйымдастыру осы элементтердің барлығын бірыңғай сипаттамаға біріктіріп, нәтижелерді неғұрлым интерпретацияланатын етеді. Ұсынылған платформа деректер, модельдер, артефакттар және SRE-көрсеткіштер бір сервис контурының бөліктері ретінде қарастырылатын қайта өндірілуі мүмкін протоколды қалыптастырады. Құрылымдық валидация сақтандыру деректер жиынтықтарының толықтығы, дубликаттардың болуы және идентификаторлық белгілер тәуекелдері бойынша едәуір айырмашылық жасайтынын көрсетті, сондықтан оқыту алдындағы бірыңғай бақылау сызбасы формальды рәсім емес, қолдануға ыңғайлы негізгі талаптардың бірі. Бірнеше контур аясында алынған нәтижелер протоколдық тәсілдің тиімділігін растады: жоғары метрикалар тек диагностикалық белгілермен, артефакттар тізілімімен және модель оқытылған жағдайларды тексерумен бірге ғана мазмұнды интерпретация алады. Платформаның практикалық құндылығы — мониторингке, ішкі есептілікке және сақтандырудың ақпараттық-талдамалық жүйесін одан әрі дамытуға жарамды модельдік, протоколдық және эксплуатациялық артефакттардың бірыңғай жиынтығын қалыптастыруында.

Авторлардың қосқан үлесі.

К.Г. Мадияров зерттеудің негізгі идеясын ұсынды, платформаның тұжырымдамасы мен архитектурасын әзірлеуге, деректер контурларын жинақтауға, валидация және leakage-бақылау логикасын сипаттауға, модельдерді оқыту мен эксперименттерді жүргізуге жетекші үлес қосты. Сондай-ақ нәтижелерді жүйелеу, кестелер мен суреттерді дайындау

және мақаланың бастапқы нұсқасын жазу осы автордың қатысуымен орындалды.

О.Я. Швец зерттеудің ғылыми-әдіснамалық негізін нақтылауға, нәтижелерді интерпретациялауға, мақаланың құрылымы мен дәлелдеу логикасын жетілдіруге, сондай-ақ мәтінді ғылыми редакциялауға елеулі үлес қосты. Автор платформаның инженерлік шешімдерін, SRE-бақыланым мен протоколдық валидацияның мазмұнын талқылауға және мақаланың қорытындыларын тұжырымдауға қатысты.

Әдебиеттер тізімі

1. Eling M., Gemmo I., Guxha D., Schmeiser H. Big data, risk classification, and privacy in insurance markets // The Geneva Risk and Insurance Review. - 2024. - Vol. 49. - P. 75-126. DOI: 10.1057/s10713-024-00098-5.
2. Poufinas T., Gogas P., Papadimitriou T., Zaganidis E. Machine learning in forecasting motor insurance claims // Risks. - 2023. - Vol. 11(9). - Art. 164. DOI: 10.3390/risks11090164.
3. Shi P., Shi K. Non-life insurance risk classification using categorical embedding // North American Actuarial Journal. - 2023. - Vol. 27(3). - P. 579-601. DOI: 10.1080/10920277.2022.2123361.
4. Avanzi B., Taylor G., Wang M., Wong B. Machine learning with high-cardinality categorical features in actuarial applications // ASTIN Bulletin. - 2024. - Vol. 54(2). - P. 213-238. DOI: 10.1017/asb.2024.7.
5. Vinayak V., Chandrasekharan J. Consumer complaints classification using deep learning and word embedding models // Proceedings of the 2023 14th International Conference on Computing Communication and Networking Technologies (ICCCNT), Delhi, India, July 6-8, 2023. - P. 1-5. DOI: 10.1109/ICCCNT56998.2023.10307286.
6. Vairetti C., Aranguiz I., Maldonado S., Karmy J.P., Leal A. Analytics-driven complaint prioritisation via deep learning and multicriteria decision-making // European Journal of Operational Research. - 2024. - Vol. 312(3). - P. 1108-1118. DOI: 10.1016/j.ejor.2023.08.027.
7. Helmy Y., Ashraf M., Abdelhamid L. Assessing the effectiveness of various text classification algorithms in customer complaint classification // International Journal of Computer Applications. - 2024. - Vol. 186(2). - P. 8-16. DOI: 10.5120/ijca2024923346.
8. Kreuzberger D., Kuhl N., Hirschl S. Machine learning operations (MLOps): Overview, definition, and architecture // IEEE Access. - 2023. - Vol. 11. - P. 31866-31879. DOI: 10.1109/ACCESS.2023.3262138.
9. Liu R., Park K., Psallidas F. et al. Optimizing data pipelines for machine learning in feature stores // Proceedings of the VLDB Endowment. - 2023. - Vol. 16(13). - P. 4230-4239. DOI: 10.14778/3625054.3625060.
10. Zarour M., Alzabut H., Al-Sarayreh K.T. MLOps best practices, challenges and maturity models: A systematic literature review // Information and Software Technology. - 2025. - Vol. 183. - Art. 107733. DOI: 10.1016/j.infsof.2025.107733.
11. Kaggle. Auto Insurance churn analysis dataset [Электрондық ресурс]. - URL:

- <https://www.kaggle.com/datasets/merishnasuwal/auto-insurance-churn-analysis-dataset> (қаралған күні: 10.04.2026).
12. Hugging Face. BilalAhxmd/Insurance-data [Электрондық ресурс]. - URL: <https://huggingface.co/datasets/BilalAhxmd/Insurance-data/tree/main> (қаралған күні: 10.04.2026).
 13. Hugging Face. bitext/Bitext-insurance-llm-chatbot-training-dataset [Электрондық ресурс]. - URL: <https://huggingface.co/datasets/bitext/Bitext-insurance-llm-chatbot-training-dataset> (қаралған күні: 10.04.2026).
 14. Hugging Face. supersam7/travel_insurance [Электрондық ресурс]. - URL: https://huggingface.co/datasets/supersam7/travel_insurance/tree/main (қаралған күні: 10.04.2026).
 15. Kaggle. Customer Loyalty score dataset [Электрондық ресурс]. - URL: <https://www.kaggle.com/datasets/nasirhussainshah/multiple-linear-regression-dataset-loyalty-score> (қаралған күні: 10.04.2026).
 16. scikit-learn developers. TfidfVectorizer. scikit-learn 1.8.0 documentation [Электрондық ресурс]. - URL: https://scikit-learn.org/stable/modules/generated/sklearn.feature_extraction.text.TfidfVectorizer.html (қаралған күні: 04.01.2025).
 17. scikit-learn developers. LogisticRegression. scikit-learn 1.8.0 documentation [Электрондық ресурс]. - URL: https://scikit-learn.org/stable/modules/generated/sklearn.linear_model.LogisticRegression.html (қаралған күні: 04.01.2025).
 18. scikit-learn developers. accuracy_score. scikit-learn 1.8.0 documentation [Электрондық ресурс]. - URL: https://scikit-learn.org/stable/modules/generated/sklearn.metrics.accuracy_score.html (қаралған күні: 12.01.2026).
 19. scikit-learn developers. f1_score. scikit-learn 1.8.0 documentation [Электрондық ресурс]. - URL: https://scikit-learn.org/stable/modules/generated/sklearn.metrics.f1_score.html (қаралған күні: 15.01.2026).
 20. scikit-learn developers. roc_auc_score. scikit-learn 1.8.0 documentation [Электрондық ресурс]. - URL: https://scikit-learn.org/stable/modules/generated/sklearn.metrics.roc_auc_score.html (қаралған күні: 21.01.2026).
 21. scikit-learn developers. mean_absolute_error. scikit-learn 1.8.0 documentation [Электрондық ресурс]. - URL: https://scikit-learn.org/stable/modules/generated/sklearn.metrics.mean_absolute_error.html (қаралған күні: 05.02.2026).
 22. scikit-learn developers. mean_squared_error. scikit-learn 1.8.0 documentation [Электрондық ресурс]. - URL: https://scikit-learn.org/stable/modules/generated/sklearn.metrics.mean_squared_error.html

23. scikit-learn developers. r2_score. scikit-learn 1.8.0 documentation [Электрондық ресурс].
- URL: https://scikit-learn.org/stable/modules/generated/sklearn.metrics.r2_score.html
(қаралған күні: 16.02.2026).

K.G. Madiyarov* , O.Ya. Shvets

Novosibirsk State University of Economics and Management, Novosibirsk, Russia

Actuarial ML Platform with a Protocol-Based SRE Validation Layer

Abstract. Insurance companies increasingly rely on machine learning methods to determine payouts and premiums, forecast customer churn, process complaint narratives and support a variety of service functions. In practice, however, such models often evolve as isolated modules, which makes data quality checks, leakage control, metric registration, and service-state assessment inconsistent across the analytical pipeline. This paper proposes an actuarial ML platform with a protocol-based SRE validation layer designed to integrate these procedures into a single operational framework. The platform follows a microservice architecture and combines data collection and preparation services, model training components, an evaluation block, and a results delivery interface. Within the protocol, each stage includes structural data checks, error classification, drift monitoring, metric comparison, and confirmation that model artifacts are suitable for production use. This approach enables controlled retraining and model updates, preserves comparability with previous versions, and supports service continuity. The proposed solution is aimed at improving the reliability of risk modeling in insurance organizations and strengthening the resilience of ML systems to changes in data and operating conditions.

Keywords: actuarial platform; ML pipeline; protocol validation; leakage control; observability; SRE

References

1. Eling M., Gemmo I., Guxha D., Schmeiser H. Big data, risk classification, and privacy in insurance markets // The Geneva Risk and Insurance Review. - 2024. - Vol. 49. - P. 75-126. DOI: 10.1057/s10713-024-00098-5.
2. Poufinas T., Gogas P., Papadimitriou T., Zaganidis E. Machine learning in forecasting motor insurance claims // Risks. - 2023. - Vol. 11(9). - Art. 164. DOI: 10.3390/risks11090164.
3. Shi P., Shi K. Non-life insurance risk classification using categorical embedding // North American Actuarial Journal. - 2023. - Vol. 27(3). - P. 579-601. DOI: 10.1080/10920277.2022.2123361.
4. Avanzi B., Taylor G., Wang M., Wong B. Machine learning with high-cardinality categorical features in actuarial applications // ASTIN Bulletin. - 2024. - Vol. 54(2). - P. 213-238. DOI: 10.1017/asb.2024.7.
5. Vinayak V., Chandrasekharan J. Consumer complaints classification using deep learning and word embedding models // Proceedings of the 2023 14th International Conference on Computing Communication and Networking Technologies (ICCCNT), Delhi, India, July 6-8, 2023. - P. 1-5. DOI: 10.1109/ICCCNT56998.2023.10307286.

6. Vairetti C., Aranguiz I., Maldonado S., Karmy J.P., Leal A. Analytics-driven complaint prioritisation via deep learning and multicriteria decision-making // *European Journal of Operational Research*. - 2024. - Vol. 312(3). - P. 1108-1118. DOI: 10.1016/j.ejor.2023.08.027.
7. Helmy Y., Ashraf M., Abdelhamid L. Assessing the effectiveness of various text classification algorithms in customer complaint classification // *International Journal of Computer Applications*. - 2024. - Vol. 186(2). - P. 8-16. DOI: 10.5120/ijca2024923346.
8. Kreuzberger D., Kuhl N., Hirschl S. Machine learning operations (MLOps): Overview, definition, and architecture // *IEEE Access*. - 2023. - Vol. 11. - P. 31866-31879. DOI: 10.1109/ACCESS.2023.3262138.
9. Liu R., Park K., Psallidas F. et al. Optimizing data pipelines for machine learning in feature stores // *Proceedings of the VLDB Endowment*. - 2023. - Vol. 16(13). - P. 4230-4239. DOI: 10.14778/3625054.3625060.
10. Zarour M., Alzabut H., Al-Sarayreh K.T. MLOps best practices, challenges and maturity models: A systematic literature review // *Information and Software Technology*. - 2025. - Vol. 183. - Art. 107733. DOI: 10.1016/j.infsof.2025.107733.
11. Kaggle. Auto Insurance churn analysis dataset [Electronic resource]. Available at: <https://www.kaggle.com/datasets/merishnasuwal/auto-insurance-churn-analysis-dataset> (accessed 10.04.2026).
12. Hugging Face. BilalAhxmd/Insurance-data [Electronic resource]. Available at: <https://huggingface.co/datasets/BilalAhxmd/Insurance-data/tree/main> (accessed 10.04.2026).
13. Hugging Face. bitext/Bitext-insurance-llm-chatbot-training-dataset [Electronic resource]. Available at: <https://huggingface.co/datasets/bitext/Bitext-insurance-llm-chatbot-training-dataset> (accessed 10.04.2026).
14. Hugging Face. supersam7/travel_insurance [Electronic resource]. Available at: https://huggingface.co/datasets/supersam7/travel_insurance/tree/main (accessed 10.04.2026).
15. Kaggle. Customer Loyalty score dataset [Electronic resource]. Available at: <https://www.kaggle.com/datasets/nasirhussainshah/multiple-linear-regression-dataset-loyalty-score> (accessed 10.04.2026).
16. scikit-learn developers. TfidfVectorizer, scikit-learn 1.8.0 documentation [Electronic resource]. Available at: https://scikit-learn.org/stable/modules/generated/sklearn.feature_extraction.text.TfidfVectorizer.html (accessed 04.01.2025).
17. scikit-learn developers. LogisticRegression, scikit-learn 1.8.0 documentation [Electronic resource]. Available at: https://scikit-learn.org/stable/modules/generated/sklearn.linear_model.LogisticRegression.html
18. scikit-learn developers. accuracy_score, scikit-learn 1.8.0 documentation [Electronic resource]. Available at: https://scikit-learn.org/stable/modules/generated/sklearn.metrics.accuracy_score.html

- learn.org/stable/modules/generated/sklearn.metrics.accuracy_score.html (accessed 12.01.2026).
19. scikit-learn developers. f1_score, scikit-learn 1.8.0 documentation [Electronic resource]. Available at: https://scikit-learn.org/stable/modules/generated/sklearn.metrics.f1_score.html (accessed 15.01.2026).
20. scikit-learn developers. roc_auc_score, scikit-learn 1.8.0 documentation [Electronic resource]. Available at: https://scikit-learn.org/stable/modules/generated/sklearn.metrics.roc_auc_score.html (accessed 21.01.2026).
21. scikit-learn developers. mean_absolute_error, scikit-learn 1.8.0 documentation [Electronic resource]. Available at: https://scikit-learn.org/stable/modules/generated/sklearn.metrics.mean_absolute_error.html (accessed 05.02.2026).
22. scikit-learn developers. mean_squared_error, scikit-learn 1.8.0 documentation [Electronic resource]. Available at: https://scikit-learn.org/stable/modules/generated/sklearn.metrics.mean_squared_error.html (accessed 09.02.2026).
23. scikit-learn developers. r2_score, scikit-learn 1.8.0 documentation [Electronic resource]. Available at: https://scikit-learn.org/stable/modules/generated/sklearn.metrics.r2_score.html (accessed 16.02.2026).

Авторлар туралы мәлімет

Мадияров Куан Галымович — хат-хабар авторы, аспирант, Новосібір мемлекеттік экономика және басқару университеті, қызметтік мекенжайы: 630099, Новосібір қ., Каменская көшесі, 56, Ресей Федерациясы

Швец Ольга Яковлевна — техника ғылымдарының кандидаты, қауымдастырылған профессор, қолданбалы информатика кафедрасы, Новосібір мемлекеттік экономика және басқару университеті, қызметтік мекенжайы: 630099, Новосібір қ., Каменская көшесі, 56, Ресей Федерациясы

Kuan Galymovich Madiyarov — corresponding author, postgraduate student, Department of Applied Informatics, Novosibirsk State University of Economics and Management, 56 Kamenskaya Street, Novosibirsk 630099, Russian Federation.

Olga Yakovlevna Shvets — Candidate of Technical Sciences, Associate Professor, Department of Applied Informatics, Novosibirsk State University of Economics and Management, service address: 56 Kamenskaya Street, Novosibirsk 630099, Russian Federation.



Copyright: © 2026 by the authors. Submitted for possible open access publication under the terms and conditions of the Creative Commons Attribution (CC BY NC) license (<https://creativecommons.org/licenses/by-nc/4.0/>).