SUN’IY INTELLEKT YORDAMIDA MA’LUMOTLAR BAZASINI AVTOMATIK BOSHQARISH USULLARI

Berdiyev G’olib Rashidovich

Axborot texnologiyalari va menejment universiteti,
E-mail: golibberdiev@gmail.com
ORCID: 0000-0003-0075-5414

K E Y W O R D S

sun’iy intellekt, ma’lumotlar bazasi, avtomatik boshqaruv, self-tuning database, workload classification, query optimization, index recommendation, reinforcement learning, DBMS, anomaliya aniqlash

A B S T R A C T

Mazkur maqolada sun’iy intellekt yordamida ma’lumotlar bazasini avtomatik boshqarish usullari tahlil qilinadi va gibrid boshqaruv metodikasi taklif etiladi. Tadqiqotda o‘z-o‘zini sozlaydigan ma’lumotlar bazalari, ish yuklamasini avtomatik tasniflash, so‘rovlarni optimallashtirish, indeks va ko‘rinishlarni tavsiya etish, konfiguratsion parametrlarni sozlash, nosozliklarni erta aniqlash hamda qayta tiklash mexanizmlarining zamonaviy holati o‘rganildi. Adabiyotlar tahlili asosida xalqaro va MDH/O‘zbekiston olimlarining ishlari umumlashtirilib, ma’lumotlar bazasini avtomatik boshqarishning beshta ustuvor yo‘nalishi ajratildi: ish yuklamasiga mos tuning, o‘rganilgan so‘rov optimizatsiyasi, avtomatik indekslash, anomaliyalarni aniqlash va driftga mos adaptiv boshqaruv. Maqolada ish yuklamasi telemetriyasi, xususiyatlar vektori, klassifikator, ko‘p mezonli qaror qabul qiluvchi optimizator, xavfsiz joriy etish va rollback mexanizmlarini o‘z ichiga olgan gibrid metodologiya bayon etiladi. Taklif etilgan yondashuv ma’lumotlar bazasi boshqaruvini inson omiliga kamroq bog‘liq, uzluksiz monitoringga asoslangan va o‘zgaruvchan yuklama sharoitida moslashuvchan holga keltirishga xizmat qiladi. Tadqiqot natijalari ma’lumotlar bazalarini boshqarish, korporativ axborot tizimlari, davlat axborot platformalari va ilmiy-ta’limiy raqamli muhitlarda amaliy qo‘llash uchun metodik asos bo‘lib xizmat qilishi mumkin.

KIRISH

Ma’lumotlar bazalarini samarali boshqarish zamonaviy axborot tizimlarining asosiy muammolaridan biridir. Amaliyotda DBA tomonidan bajariladigan indeks tanlash, konfiguratsion parametrlarni sozlash, so‘rov rejasini tahlil qilish, ish yuklamasini monitoring qilish va nosozliklarni bartaraf etish kabi vazifalar vaqt talab qiladi va ko‘pincha inson tajribasiga kuchli bog‘liq bo‘ladi. So‘nggi yillarda bu jarayonlarni avtomatlashtirish uchun o‘z-o‘zini sozlaydigan va o‘zini boshqaradigan ma’lumotlar bazalari konsepsiyasi faol rivojlanmoqda; adabiyotlarda self-tuning yondashuv SQL va NoSQL muhitlarida sxema dizayni, fizik tuzilma va boshqaruv parametrlarini avtomatik optimallashtirishni qamrab olishi ko‘rsatilgan. OtterTune kabi tizimlar esa oldingi tuning sessiyalaridan to‘plangan bilimlarni qayta ishlatib, yangi DBMS konfiguratsiyalarini avtomatik tavsiya qilishga qodirligini namoyish etgan.

Sun’iy intellekt asosidagi avtomatik boshqaruv yondashuvlari faqat parametr tuning bilan cheklanmaydi. NoisePage self-driving DBMS arxitekturasi DBMSning o‘zini uzoq muddatli avtonom boshqarishga yo‘naltirilgan bo‘lsa, openGauss va DBMind platformalarida o‘rganilgan query rewrite, cost/cardinality estimation, self-monitoring, self-diagnosis, self-configuration va self-optimization modullari yagona avtonom ramkaga birlashtirilgan. NeurDB esa ma’lumotlar va ish yuklamasi driftiga moslasha oladigan AI-powered autonomous database sifatida taklif etilgan bo‘lib, AI

© Berdiyev G’olib Rashidovich

modellarini bevosita DBMS ichiga chuqur integratsiyalash zarurligini ko‘rsatadi.

Shu bilan birga, ma’lumotlar bazasini avtomatik boshqarish masalasi hali to‘liq yechilgan deb bo‘lmaydi. Sababi, o‘zgaruvchan workload, drift, sovuq start, xavfsiz joriy etish va noto‘g‘ri tavsiyalar tufayli unumdorlikni pasaytirish xavfi kabi omillar mavjud. Ayniqsa, korporativ yoki davlat tizimlarida har bir avtomatik qarorning izohlanishi, xavfsizligi va qayta tiklash imkoniyati kafolatlanishi lozim. Shu bois sun’iy intellekt yordamida ma’lumotlar bazasini avtomatik boshqarish usullarini tizimli tahlil qilish va gibrid metodologiya taklif etish dolzarb ilmiy-amaliy vazifa hisoblanadi.

Mazkur tadqiqotning maqsadi sun’iy intellekt yordamida ma’lumotlar bazasini avtomatik boshqarish usullarini IMRAD formatida tizimlashtirish, xalqaro hamda O‘zbekiston/MDH tajribasini tahlil qilish va workload-aware, xavfsiz hamda moslashuvchan gibrid boshqaruv metodikasini taklif etishdan iborat.

Adabiyotlar tahlili va metodologiya

Xalqaro tadqiqotlar shuni ko‘rsatadiki, avtomatik DB boshqaruvining asosiy yo‘nalishlari sxema va fizik dizaynni avtomatik optimallashtirish, parametr tuning, indekslash, so‘rovlarni optimallashtirish, anomaliya diagnostikasi va driftga moslashuvdan iborat. Mozaffari va hammualliflar self-tuning database systems bo‘yicha tizimli sharhida SQL va NoSQL bazalarda avtomatik sxema dizayni va tuning alohida ilmiy yo‘nalishga aylanganini, ayniqsa NoSQL muhitlarda konseptual, mantiqiy va fizik darajalar birgalikda ko‘rib chiqilishini ta’kidlaydi. OtterTune esa ish yuklamasini xarakterlash, muhim knoblarni ajratish va oldingi sessiyalardagi bilimlardan foydalanish orqali DBMS konfiguratsiyasini avtomatik tavsiya qilishga yo‘naltirilgan. LlamaTune ish yuklamalari bo‘yicha avtomatik konfiguratsiya tuningni amaliy miqyosga yaqinlashtirib, konfiguratsiya qidiruvini sezilarli darajada kamroq sinovlar bilan amalga oshira olishini ko‘rsatgan.

So‘rovlarni optimallashtirish yo‘nalishida chuqur o‘rganish va mustahkamlovchi o‘qitish usullari alohida o‘rin tutadi. Balsa tizimi chuqur reinforcement learning yordamida SQL so‘rovlar uchun reja qurishni trial-and-error asosida o‘rganib, PostgreSQL va tijorat tizimidagi optimizatorlarga teng yoki ayrim holatlarda ustun natija bera olishini ko‘rsatgan. DB-BERT esa tabiiy tilni qayta ishlash va BERT modeli asosida ma’lumotlar bazasi qo‘llanmalari hamda tuning bo‘yicha matnli manbalardan foydali tavsiyalarni chiqarib, ularni reinforcement learning bilan birlashtirish orqali PostgreSQL va MySQL uchun tuning sifatini yaxshilashni taklif etgan. Bu yo‘nalish AI4DB sohasida til modellarini DB boshqaruv jarayoniga qo‘shish imkoniyatini ochib bermoqda.

Platforma darajasida qaralganda, openGauss avtonom bazasi o‘rganilgan query rewrite, learned cost/cardinality estimation, join order selection, self-monitoring, self-diagnosis, self-configuration va self-optimization komponentlarini bitta tizimga birlashtiradi. DBMind shu oiladagi self-driving platforma sifatida o‘zini monitoring qilish, nosozlik sababini LSTM orqali aniqlash va reinforcement learning asosida knob tuning hamda index/view selectionni amalga oshirishni ko‘rsatgan. NeurDB esa AI modellarini DBMS ichiga chuqur singdirish, in-database analytics va data/workload driftga tez moslashish muammolarini yechishga qaratilgan yangi bosqich sifatida tavsiflanadi. PilotScope kabi middleware yechimlari esa knob tuning, index recommendation, cardinality estimation va query optimizer vazifalarini turli bazalarga ulashni soddalashtirishga xizmat qilmoqda.

O‘zbekiston va MDH olimlarining ishlari ham mazkur mavzu uchun muhim metodologik asos beradi. Ostanakulov va Dzhabborov intellektual muhit uchun informatsion bazani loyihalashda ontologiyalar, semantik qayta ishlash va mashinali o‘qitish bilan integratsiyani markaziy yondashuv sifatida ko‘rsatgan hamda O‘zbekiston sharoitiga mos konseptual model taklif qilgan. Petunin, Verbov va Lavrinchuk ma’lumotlar bazasi workload monitoring ma’lumotlari asosida so‘rovlarni klasterlash va ish yuklamasi sinflarini ajratish uchun mashinali o‘qitishdan foydalanishni taklif etgan. Konovalov DBMSlarda so‘rov optimallashtirish uchun mashinali o‘qitishning rolini ko‘rib chiqib, query planning jarayonida ML usullarining amaliy ahamiyatini yoritgan . Malykhina va Buyanov esa foydalanuvchiga mavjud ma’lumotlar bazasi tuzilmasini ketma-ket normallashtirish va tushuntirishlar tizimi orqali

(cc) BY © Berdiyev G’olib Rashidovich

samarali shaklga keltirishga yordam beruvchi intellektual loyihalash tizimini tasvirlagan.

Tahlil natijasida quyidagi xulosa olindi: sun'iy intellekt yordamida ma'lumotlar bazasini avtomatik boshqarish usullari beshta asosiy sinfga ajraladi:
1) workload-aware parametr tuning; 2) learned query optimization; 3) avtomatik indeks va view tavsiyasi; 4) anomaliya aniqlash va self-healing; 5) driftga mos adaptiv boshqaruv. Demak, zamonaviy DBMSni avtomatik boshqarish uchun bitta model emas, balki telemetriya, klassifikatsiya, prediksiya, optimallashtirish va xavfsiz joriy etishdan iborat yopiq boshqaruv sikli talab etiladi.

Mazkur tadqiqotda obyekt sifatida o'zgaruvchan ish yuklamasiga ega relyatsion ma'lumotlar bazalari uchun avtomatik boshqaruv jarayonlari tanlandi. Tadqiqotning metodik asosini tizimli tahlil, qiyosiy adabiyotlar tahlili, workload modeling, xususiyatlar vektori asosidagi klassifikatsiya va ko'p mezonli optimallashtirish tashkil etdi. Ishlab chiqilgan metodologiya OtterTune'dagi workload characterization va knob identification tamoyillari, Balsa va DB-BERT'dagi reinforcement learning paradigmalari, DBMind/openGauss'dagi self-monitoring va self-optimization mexanizmlari hamda Ostanakulov–Dzhabborov ishlaridagi semantik-integratsion yondashuvlar bilan uyg'unlashtirildi

Taklif etilgan metodologiyada birinchi bosqichda DBMS telemetriyasi va ish yuklamasi tavsiflari yig'iladi. Har bir vaqt oralig'i uchun holat vektori quyidagicha aniqlanadi:

$$x_t = [qps_t, lat_t, cpu_t, mem_t, io_t,$$

$$lock_t, cache_t, join_t, idx_t]$$

bu yerda qps_t — soniyasiga bajarilgan so'rovlar soni, lat_t — o'rtacha kechikish, cpu_t, mem_t, ,io_t— resurs yuklamalari, $lock_t$ — blokirovka ko'rsatkichlari, $cache_t$ — cache hit darajasi, $join_t$ — join murakkabligi, idx_t esa indekslardan foydalanish holatini bildiradi. Petunin va hammualliflar workload statistikasi asosida sinflashtirish, OtterTune esa ichki runtime metrikalarni faktorial va klasterlash yondashuvlari bilan qisqartirish muhim ekanini ko'rsatadi.

Ikkinchi bosqichda workload klassifikatsiyasi amalga oshiriladi:

$$c_t = f_\phi(x_t)$$

bu yerda f_ϕ — klassifikator modeli, c_t — joriy workload sinfi. Mazkur klassifikator tasniflangan workloadga qarab qaysi boshqaruv strategiyasi qo'llanishini belgilaydi. Masalan, analitik workload holatida indeks/view recommendation kuchaytiriladi, tranzaksion workloadda esa memory, checkpoint va concurrency parametrlarini tuning qilish ustuvor bo'ladi. Workload classification avtonom tuning uchun birinchi va eng muhim qadam ekani alohida ta'kidlangan [10], [15].

Uchinchi bosqichda boshqaruv qarori ko'p mezonli optimallashtirish masalasi sifatida qo'yiladi. Joriy holat uchun bajariladigan harakat:

$$a_t = (\Delta k_t,\ I_t,\ P_t,\ R_t)$$

ko'rinishida ifodalanadi. Bu yerda Δk_t— knoblar to'plamining yangi qiymatlari, I_t— indeks yoki materialized view tavsiyasi, P_t — query plan strategiyasi, R_t— resurs ajratish qarori. Maqsad funksiyasi:

$$J(\ a_t|\ x_t = \alpha\ \hat{L}_t + \beta\hat{U}_t + \gamma\hat{S}_t + \ \delta\hat{T}_t$$

ko'rinishida tanlandi; bunda $\hat{L}_t$ — kutilayotgan kechikish, $\hat{U}_t$ — resurs sarfi, $\hat{S}_t$— saqlash xarajati, $\hat{T}_t$— throughput, α, β, γ, δ esa boshqaruv siyosatining og'irlik koeffitsiyentlaridir. LlamaTune, Balsa va DB-BERT ishlarida aynan qidiruv makonini qisqartirish, xavfsiz sinovlar va reward asosidagi tuning boshqaruv samaradorligini oshirishi ko'rsatilgan.

To'rtinchi bosqichda xavfsiz joriy etish mexanizmi ishlatiladi. Taklif etilgan harakat avval shadow-mode yoki test replika muhitida sinovdan o'tkaziladi. Agar yangi siyosat bo'yicha foyda mezoni

$$r_t = -(J_t - J_{t-1})$$

uchun $r_t > r$ sharti bajarilsa va kechikish, xatolik, replikatsiya kechikishi hamda disk bosimi kabi xavfsizlik cheklovlari buzilmasa, qaror ishlab turgan muhitga joriy etiladi; aks holda rollback ishga tushadi. Bu tamoyil DBMind'dagi self-

(cc) BY © Berdiyev G'olib Rashidovich

monitoring/self-diagnosis va openGauss’dagi validation model g‘oyalari bilan mos keladi.

Beshinchi bosqichda tizim o‘z-o‘zini o‘qituvchi yopiq siklga o‘tadi. Har bir yangi monitoring davri tugagach, tizim joriy qaror natijalarini omborlashtiradi, yangi holat–harakat–natija uchliklari bazasini boyitadi va shunga ko‘ra klassifikator hamda tavsiya beruvchi modellarni qayta yangilaydi. Drift aniqlanganda modelni to‘liq qayta o‘qitish emas, balki adaptiv yangilash mexanizmlaridan foydalanish maqsadga muvofiq. NeurDB aynan data/workload driftga tez moslashuvchi AI-embedded DBMS konsepsiyasini ilgari suradi.

Natijalar

Tadqiqot natijasida sun’iy intellekt yordamida ma’lumotlar bazasini avtomatik boshqarish usullari tizimli ravishda umumlashtirildi va ularning asosiy funksional yo‘nalishlari aniqlandi. Tahlil shuni ko‘rsatdiki, zamonaviy avtonom DBMS yechimlari asosan ish yuklamasiga mos parametr tuning, so‘rovlarni intellektual optimallashtirish, indeks va materialized view tavsiyalari, self-monitoring va self-diagnosis, shuningdek driftga mos adaptiv boshqarish kabi yo‘nalishlarda rivojlanmoqda. Bu esa ma’lumotlar bazasini avtomatik boshqarish faqat bitta modul yoki bitta algoritmga emas, balki o‘zaro bog‘langan intellektual komponentlar tizimiga tayanuvchi yopiq boshqaruv sikli ekanini ko‘rsatadi.

Ayniqsa, workload turini aniqlash avtomatik boshqaruvda markaziy o‘rin tutishi aniqlandi. Chunki analitik, tranzaksion, aralash yoki pik yuklama holatlarida DBMS uchun ustuvor boshqaruv strategiyalari turlicha bo‘ladi. Shu bois joriy workloadni to‘g‘ri sinflashtirish keyingi tuning, indekslash va resurslarni qayta taqsimlash qarorlarining sifatini belgilaydi.

1-jadval.

Sun’iy intellekt asosida ma’lumotlar bazasini avtomatik boshqarishning umumlashtirilgan yo‘nalishlari va workloadga mos strategiyalar

Yo‘nalish / workload holati	Boshqaruv obyekti	Ustuvor AI yoki boshqaruv yondashuvi	Kutiladigan natija
Avtomatik parametr tuning	DBMS konfiguratsiya parametrlari	regressiya, Bayesian optimization, reinforcement learning	Ish yuklamasiga mos optimal konfiguratsiyani tanlash
So‘rovlarni intellektual optimallashtirish	Query plan va execution strategy	deep RL, learned optimizer	So‘rov bajarilish vaqtini kamaytirish
Avtomatik indekslash va view tavsiyasi	Fizik dizayn	tavsiya beruvchi model, RL	Qidiruv va JOIN amallarini tezlashtirish
Self-monitoring va self-diagnosis	Telemetriya va nosozlik sabablari	LSTM, klassifikatsiya, anomaliya aniqlash	Muammolarni erta topish va sababini ajratish
Driftga mos adaptiv boshqaruv	Model va boshqaruv siyosati	continual learning, adaptive retraining	Yangi workload sharoitiga moslashish
Analitik workload	SELECT, JOIN, materialized view	indekslash, query rewrite	Murakkab analitik so‘rovlar tezlashadi
Tranzaksion workload	xotira, checkpoint, concurrency	memory tuning, checkpoint control	Kechikish kamayadi, barqarorlik oshadi
Aralash workload	resurslar va konfiguratsiya	gibrid tuning, adaptiv taqsimlash	Resurslar muvozanatli boshqariladi
Yuqori pik yuklama	xavfsiz ishlash muhiti	safe deployment, throttling, rollback	Tizim izdan chiqishining oldi olinadi
Drift kuzatilgan workload	model va tavsiyalar bazasi	adaptiv yangilash	Tizim yangi sharoitga moslashadi

© Berdiyev G’olib Rashidovich

1-jadvaldan ko‘rinadiki, avtomatik boshqaruvning samaradorligi bevosita workload turini aniqlash va unga mos boshqaruv strategiyasini tanlashga bog‘liq. Agar workload noto‘g‘ri baholansa, tizim noto‘g‘ri tuning, indeks tavsiyasi yoki resurs taqsimoti qarorini berishi mumkin. Demak, workload classification avtomatik DB boshqaruvining boshlang‘ich va eng muhim qaror nuqtasi sifatida namoyon bo‘ladi.

Adabiyotlar va metodologik tahlil shuni ham ko‘rsatdiki, sun’iy intellekt yordamidagi boshqaruv tizimlari an’anaviy qo‘lda boshqaruvga nisbatan tezkorlik, moslashuvchanlik va ko‘p mezonli qaror qabul qilish afzalliklariga ega. Ayrim tadqiqotlarda LlamaTune konfiguratsiya qidiruvini ancha kam sinov bilan bajarishi, DBMind esa monitoring jarayonida juda kichik qo‘shimcha yuk bilan ishlashi ko‘rsatilgan. Bu holat avtomatik boshqaruvning nafaqat nazariy, balki amaliy jihatdan ham samarali ekanini tasdiqlaydi.

2-jadval.

Amaliy tizimlar va taklif etilgan konseptual arxitekturaning umumlashtirilgan natijalari

Tizim / modul	Asosiy vazifa	Qayd etilgan yoki umumlashtirilgan natija	Tahliliy ahamiyati
OtterTune	konfiguratsiya tuning	Inson eksperti darajasidagi, ba’zan undan yaxshi tavsiyalar	AI-tuning amaliy qo‘llashga yaroqli ekanini ko‘rsatadi
DBMind	monitoring, diagnostika, optimallashtirish	Monitoring yuklamasi past, self-monitoring va self-diagnosis integratsiyalashgan	Uzluksiz telemetriya yig‘ish xavfsizligini asoslaydi
LlamaTune	sample-efficient tuning	Kamroq sinov bilan throughputni oshirishga erishadi	Qidiruv makonini aqlli qisqartirish foydasini ko‘rsatadi
openGauss	avtonom DB arxitekturasi	self-monitoring, self-diagnosis va self-optimization birlashtirilgan	Kompleks avtonom DB arxitekturasi zarurligini ko‘rsatadi
Telemetriya yig‘ish moduli	runtime metrikalarni to‘plash	DBMS holati haqida uzluksiz ma’lumot shakllanadi	Keyingi tahlil uchun tayanch baza yaratiladi
Xususiyatlar fazosini shakllantirish	metrikalarni yagona tavsifga keltirish	Workloadni tavsiflovchi xususiyatlar vektori olinadi	Sinflashtirish va tavsiya sifatini oshiradi
Workload klassifikatsiyasi	joriy yuklama turini aniqlash	Mos boshqaruv strategiyasi tanlanadi	Qaror qabul qilish aniqligini oshiradi
Qaror generatori	tuning, indeks, resurs va plan bo‘yicha tavsiyalar	Optimallashtirish qarorlari shakllanadi	Proaktiv boshqaruvni ta’minlaydi
Xavfsiz joriy etish	shadow-mode, replika sinovi, rollback	Tizim barqarorligi saqlanadi	Noto‘g‘ri qarorlar xavfini kamaytiradi
Feedback asosida yangilash	natijalarni omborlashtirish va modelni qayta o‘qitish	Uzoq muddatli moslashuvchanlik ta’minlanadi	Tizim o‘z-o‘zini o‘qituvchi platformaga aylanadi

© Berdiyev G’olib Rashidovich

2-jadval asosida shuni ko‘rish mumkinki, eng katta samaradorlik bitta universal algoritm orqali emas, balki vazifaga mos AI modullarini birlashtiruvchi gibrid arxitektura orqali ta’minlanadi. Ya’ni, monitoring, workload classification, tuning, xavfsiz joriy etish va feedback asosidagi yangilash birgalikda ishlaganda ma’lumotlar bazasini avtomatik boshqarish yanada barqaror, moslashuvchan va amaliy jihatdan foydali bo‘ladi.

Shunday qilib, umumlashtirilgan natijalar sun’iy intellekt yordamida ma’lumotlar bazasini avtomatik boshqarish alohida yordamchi mexanizm emas, balki DBMS boshqaruvining yangi paradigmasi sifatida shakllanayotganini ko‘rsatadi. Ayniqsa, workload-aware qaror qabul qilish, xavfsiz deployment, feedback asosida yangilanish va gibrid AI modullaridan foydalanish yondashuvi korporativ axborot tizimlari, davlat ma’lumotlar bazalari hamda yirik raqamli platformalarda amaliy ahamiyatga ega ekanligi bilan ajralib turadi.

Muhokama. Taklif etilgan yondashuvning birinchi afzalligi — inson omiliga bog‘liqlikni kamaytirishidir. Zamonaviy DBMSlarda yuzlab parametrlar, ko‘plab indeks kombinatsiyalari va murakkab reja qidiruvi mavjud bo‘lgani sababli, ularni qo‘lda optimal holga keltirish tobora qiyinlashmoqda. Sun’iy intellekt bu yerda konfiguratsiyalarni qidirish, workloadni sinflarga ajratish, query rejalari va resurs sarfini bashorat qilish orqali boshqaruvni tizimli ravishda avtomatlashtiradi.

Ikkinchi afzallik — o‘zgaruvchan workloadga moslashuvchanlikdir. Klassik qoida asosidagi tuning statik bo‘lib, yangi workload yoki drift paydo bo‘lganda samarasini yo‘qotishi mumkin. Balsa, LlamaTune va NeurDB ishlari modelni feedback, sinov va adaptiv yangilash asosida takomillashtirish zarurligini ko‘rsatadi. Shu ma’noda, avtomatik boshqaruv samaradorligi faqat bir martalik “eng yaxshi” konfiguratsiyaga emas, balki uzluksiz monitoring va qayta o‘qitish sikliga bog‘liq.

Biroq bunday tizimlarning cheklovlari ham mavjud. Birinchidan, sifatli telemetriya va toza monitoring ma’lumotlari bo‘lmasa, model noto‘g‘ri qaror berishi mumkin. Ikkinchidan, reinforcement learning yoki learned optimizerlar haqiqiy muhitda xavfli sinovlarni keltirib chiqarishi ehtimoli bor; shuning uchun safe execution, shadow deployment va rollback majburiy komponent bo‘lishi kerak. Uchinchidan, lokal kontekstga mos bilim bazasi va semantik metadata bo‘lmasa, AI modeli tavsiyalarining izohlanishi qiyinlashadi; bu nuqtada O‘zbekiston sharoitiga mos intellektual informatsion baza va ontologik qatlamlardan foydalanish foydali bo‘ladi.

Amaliy nuqtai nazardan, O‘zbekiston tashkilotlarida avtomatik DB boshqaruv tizimlarini joriy etish bosqichma-bosqich bo‘lishi maqsadga muvofiq: avval monitoring va diagnostika, keyin workload classification, undan so‘ng tavsiya rejimidagi tuning, oxirida esa cheklangan avtonom deployment. Bunday yo‘l xavfsizlikni saqlagan holda AI4DB texnologiyalarini korporativ va davlat platformalariga tatbiq etish imkonini beradi.

Shuni ochiq aytish kerakki, ushbu maqolada taklif etilgan gibrid metodologiya konseptual va metodik model sifatida ishlab chiqildi. Uning PostgreSQL, MySQL, openGauss yoki boshqa DBMSlarda to‘liq eksperimental validatsiyasi alohida amaliy tadqiqot bosqichini talab qiladi.

Xulosa. Mazkur maqolada sun’iy intellekt yordamida ma’lumotlar bazasini avtomatik boshqarish usullari IMRAD talabi asosida tahlil qilindi. Adabiyotlar sharhi natijasida avtomatik DB boshqaruvining beshta ustuvor sinfi — workload-aware tuning, learned query optimization, automatic index/view recommendation, self-monitoring/self-diagnosis va drift-adaptive autonomous management — ajratildi. Xalqaro hamda O‘zbekiston/MDH tajribasini umumlashtirish asosida workload vektori, klassifikator, ko‘p mezonli optimallashtirish, xavfsiz deployment va feedback asosida o‘zini yangilovchi gibrid metodologiya taklif etildi.

Tadqiqotning ilmiy yangiligi shundaki, ma’lumotlar bazasini avtomatik boshqarish faqat parametrlarni tuning qilish emas, balki struktura, semantika, workload sinflari va runtime telemetriyasini birlashtirgan yopiq boshqaruv sikli sifatida talqin qilindi. Amaliy jihatdan ushbu yondashuv korporativ DBMSlar, davlat axborot

© Berdiyev G’olib Rashidovich

tizimlari, ilmiy-ta’limiy platformalar va katta hajmdagi ma’lumotlar bilan ishlovchi raqamli ekotizimlarda sun’iy intellektga tayangan xavfsiz avtomatik boshqaruv yechimlarini ishlab chiqish uchun metodik asos bo‘lib xizmat qilishi mumkin.

Adabiyotlar ro‘yxati

1. Li, G., Zhou, X., & Cao, L. *Machine Learning for Databases*. *Proceedings of the VLDB Endowment*, 14(12), 2021. 3190–3193.
2. Zhou, X., Jin, L., Sun, J., Zhao, X., Yu, X., Feng, J., Li, S., Wang, T., Li, K., & Liu, L. *DBMind: A Self-Driving Platform in openGauss*. *Proceedings of the VLDB Endowment*, 2021. 14(12), 2743–2746.
3. Kanellis, K., Ding, C., Kroth, B., Müller, A., Curino, C., & Venkataraman, S. *LlamaTune: Sample-Efficient DBMS Configuration Tuning*. *Proceedings of the VLDB Endowment*, 15(11). 2022. 2953–2965.
4. Ostanakulov, K. A. u., & Dzhabborov, K. I. *Designing an Information Base for an Intelligent Environment*. *Science and Education Scientific Journal*. 2025. 6(4), 78–85.
5. Konovalov, G. G. *Primenenie mashinnogo obucheniya dlya optimizatsii zaprosov v sistemakh upravleniya bazami dannykh*. *Mezhdunarodnyy zhurnal gumanitarnykh i estestvennykh nauk*. 2023. 10-2(85), 58–61
6. Berdiev G. et al. CNN-Based Image System for Automated Agricultural Crop Condition Monitoring //Academia Open. – 2026. – T. 11. – №. 1. – C. 10.21070/acopen. 11.2026. 13423-10.21070/acopen. 11.2026. 13423.
7. Golib B. METHODS OF CONSTRUCTING 3D SHAPES OF HYPERCOMPLEX FRACTALS //Harvard Educational and Scientific Review. – 2022. – T. 2. – №. 2.
8. Berdiev G., Ochilova S., Norboboev A. System analysis and virtual simulation integration to improve physics education through a web platform //Engineer. – 2025. – T. 3. – №. 4. – C. 16-19.

© Berdiyev G’olib Rashidovich