DOI: 10.65322/j.srd.06202026.45

OQIMLI VAQT QATORLARINI REAL VAQT REJIMIDA VIZUALIZATSIYA QILISHDA ADAPTIVEM4 KOMPOZIT MUHIMLIK ALGORITMINI QIYOSIY EKSPERIMENTAL BAHOLASH

Nuraliyev F.M., *t.f.d., professor,*
Hotamov F.N., *doktorant,*
Muxamedjonova Z.B., *magistr,*
Televizion va media texnologiyalar kafedrasi,
Muhammad al-Xorazmiy nomidagi Toshkent axborot texnologiyalari universiteti

Annotatsiya. *Ekran grafik o‘qi bo‘ylab bor-yo‘g‘i bir necha yuz nuqtani ajrata oladi, shu sababli yuqori chastotali ma’lumotlar oqimi chizishdan oldin agregatsiya qilinishi lozim. Klassik M4 usuli har bir piksel ustunidan to‘rtta nuqtani (birinchi, oxirgi, minimum va maksimum) saqlaydi, biroq ustun ekstremumi bo‘lmagan muhim nuqtalar – anomaliyalar, keskin burilishlar va sath siljishlari – yo‘qoladi. Maqolada M4 rasterizatsiya negizini saqlagan holda pozitsion tanlovni og‘irlikli kompozit muhimlik bahosi bilan almashtiruvchi AdaptiveM4 algoritmi formal tavsiflanadi va qiyosiy eksperimental baholanadi. Baho uchta masshtabdan mustaqil geometrik kattalikni – standart og‘ish (Z-baho), mahalliy qiyalik va uchburchak yuzasi orqali egrilikni – birlashtiradi. Ko‘p yo‘lli nomzodlik qoidasi anomaliya va trend burilishlarini ustuvor qiladi, chiqish hajmi esa qat’iy cheklanadi. O‘n bazaviy usul teng nuqta byudjetida, to‘rt sintetik pattern va binolarning konstruktiv holatini monitoring qilish (SHM) bo‘yicha real belgilangan ma’lumotlar to‘plamida geometrik, perseptual va anomaliyani saqlash metrikalari bilan solishtirildi. Real ma’lumotlarda AdaptiveM4 eng yuqori F1 = 0.318 natijani berdi (eng kuchli bazaviy usulda 0.283), 100 000 nuqta taxminan 20 ms da qayta ishlanadi – bu aniq geometrik soddalashtiruvchilardan bir tartibga tezroq. Og‘irliklarni tanlashdagi optimistik siljish va yaxlit egri aniqligining pasayishi ochiq bayon qilinadi.*

Аннотация. *Экран различает лишь несколько сотен точек вдоль оси графика, поэтому высокочастотный поток данных должен агрегироваться перед отрисовкой. Классический метод M4 сохраняет четыре точки на пиксельный столбец (первую, последнюю, минимум и максимум), однако значимые точки, не являющиеся экстремумами столбца, – выбросы, резкие изгибы и сдвиги уровня – теряются. В статье формально описан и экспериментально исследован алгоритм AdaptiveM4, который сохраняет растровую основу M4 и заменяет позиционный отбор взвешенной композитной оценкой значимости, объединяющей стандартизованное отклонение, локальный наклон и кривизну через площадь треугольника. Многопутевое правило номинирования приоритизирует выбросы и развороты тренда при строгом ограничении размера выхода. Десять базовых методов сравнены при равном бюджете на четырёх синтетических паттернах и реальном размеченном наборе данных мониторинга технического состояния зданий (SHM). На реальных данных AdaptiveM4 показал наибольший F1 = 0,318 (0,283 у лучшего базового метода) и обрабатывает 100 000 точек примерно за 20 мс – на порядок быстрее точных геометрических методов упрощения. Ограничения, включая оптимистическое смещение при подборе весов, изложены открыто.*

Abstract. *A screen resolves only a few hundred points along a plot axis, so a high-rate data stream must be aggregated before rendering. The classical M4 method keeps four marks per pixel column (first, last, minimum and maximum), but discards salient points that are not column extrema, so outliers, sharp bends and level shifts are lost. The paper formally describes and experimentally evaluates AdaptiveM4, which retains the M4 rasterization backbone and replaces positional selection with a weighted composite importance score fusing standardized deviation, local slope and triangle-area curvature. A multi-path nomination rule prioritizes outliers and*

DOI: 10.65322/j.srd.06202026.45

trend reversals while the output size is bounded exactly. Ten baselines are compared under equal budgets on four synthetic patterns and a real labeled building structural health monitoring (SHM) dataset. On the real data AdaptiveM4 attains the highest anomaly-retention F1 of 0.318 against 0.283 for the strongest baseline and processes 100,000 points in about 20 ms, an order of magnitude faster than accurate geometric simplifiers. Limitations, including optimistic bias of the weight selection, are reported openly.

Kalit so‘zlar: *vaqt qatorlarini vizualizatsiya qilish, egri chiziqni soddalashtirish, M4, LTTB, kompozit muhimlik, anomaliyani saqlash, Fréchet masofasi, SSIM.*

Ключевые слова: *визуализация временных рядов, упрощение кривой, M4, LTTB, композитная значимость, сохранение аномалий, расстояние Фреше, SSIM.*

Keywords: *time-series visualization, curve simplification, M4, LTTB, composite importance, anomaly retention, Fréchet distance, SSIM.*

Kirish. Monitoring panellari (dashboard) odatda namuna olish chastotasi ekran o‘lchamidan ko‘p marta yuqori bo‘lgan ma’lumotlar oqimlarini aks ettiradi. Grafik paneli eng ko‘pi bilan bir necha ming piksel kenglikka ega, tezkor sensor esa bu kenglikni bir necha soniyada to‘ldiradi. Natijada ko‘plab namunalar bitta piksel ustuniga to‘g‘ri keladi va ustundagi dastlabki bir nechta nuqtadan keyingi barcha nuqtalar behuda uzatiladi va chiziladi. Bunga standart yechim – vizualizatsiya uchun agregatsiya: n ta kirish namunasi $m \ll n$ ta chiqish nuqtasigacha qisqartiriladi va to‘liq qatorning ko‘rinishi saqlanadi.

Mazkur masala ushbu ishda perseptual va vaqt cheklovlari ostidagi egri chiziqni soddalashtirish (curve simplification) masalasi sifatida qaraladi: chizilgan chiziq vaqt–qiymat tekisligidagi siniq chiziq (polyline) bo‘lib, maqsad – soddalashtirilgan siniq chiziqni asl chiziqqa yaqin saqlash va bir vaqtning o‘zida oqim kelish tezligiga ulgurish. Bu yondashuv 05.01.01 – «Muhandislik geometriyasi va kompyuter grafikasi» ixtisosligining vizualizatsiya usul va algoritmlarini ishlab chiqish yo‘nalishiga bevosita mos keladi.

Mavzuning dolzarbligi shundaki, mavjud usullarning har biri masalaning faqat bitta jihatini optimallashtiradi. Masalan, M4 ustun ekstremumlarini, LTTB uchburchak yuzasini, Douglas–Peucker esa xorda og‘ishini mezon qilib oladi. Ularning hech biri statistik noyoblik, qiyalik o‘zgarishi va egrilikni yagona byudjetli bahoda birlashtirmaydi. Oqibatda keskin sakrash (spike), sath siljishi (level shift) yoki dreyf boshlanishi muayyan usul o‘lchaydigan yagona mezondan o‘tmay qolsa, ekrandan yo‘qoladi. Holbuki monitoring, moliya va konstruksiyalar holatini kuzatish tizimlarida aynan shu hodisalar eng muhim axborotni tashiydi.

AdaptiveM4 algoritmining g‘oyasi, xususiyatlar tarkibi va asosiy natijalari avvalgi ishda [1] e’lon qilingan; ushbu maqolada algoritmning formal tavsifi va qiyosiy baholash protokoli batafsil keltiriladi. Ushbu maqolaning maqsadi – algoritmni qat’iy formal ko‘rinishga keltirish (nomzodlik qoidasi, chiqish byudjeti kafolati, adaptiv bucket tenglamasi, murakkablik bahosi) hamda uni to‘qqizta bazaviy usul bilan teng sharoitda, real belgilangan ma’lumotlar va statistik ahamiyatlilik testlari asosida qiyosiy baholash. Maqsadga erishish uchun quyidagi vazifalar qo‘yildi: (1) uchta geometrik kattalikni birlashtiruvchi masshtabdan mustaqil kompozit bahoni aniqlash; (2) chiqish hajmini qat’iy cheklovchi ko‘p yo‘lli nomzodlik qoidasini ishlab chiqish; (3) kechikishga moslashuvchi bucket qoidasini aniq yangilanish tenglamasi bilan berish; (4) to‘qqizta bazaviy usul, to‘rt sintetik pattern va bitta real ma’lumotlar to‘plami asosida takrorlanuvchan baholash o‘tkazish.

Mavzuga oid adabiyotlar sharhi. Vizualizatsiya uchun vaqt qatorlarini qisqartirish usullarini chiqish semantikasiga ko‘ra bir necha guruhga ajratish mumkin. **Rasterizatsiyaga asoslangan usullar.** U. Jugel va hammualliflarining M4 algoritmi [2] har bir piksel ustunining minimum, maksimum, birinchi va oxirgi qiymatini saqlab, to‘liq chiziqning ikki rangli rasterizatsiyasini aniq takrorlaydi. Keyinchalik M4 relyatsion operatorlar to‘plamiga (VDDA) [3]

DOI: 10.65322/j.srd.06202026.45

umumlashtirildi va Apache IoTDB log-tuzilmali xotirasida hisoblandi [4]. Progressiv so‘rovlar uchun tartiblangan ko‘p darajali min-max tasviri (OM3) [5], interaktivlikni tezlashtirish uchun esa xatolik chegarasi kafolatlangan min-max kesh [6] taklif etilgan.

Perseptual (yuzaga asoslangan) usullar. S. Steinarsson ishlab chiqqan LTTB [7] har bir bucket ichida eng katta mahalliy uchburchak hosil qiluvchi nuqtani tanlaydi; M. Visvalingam va J.D. Whyatt usuli (VW) [8] eng kichik samarali uchburchak yuzali nuqtalarni ketma-ket o‘chiradi. LTTB min-max oldindan tanlash bilan tezlashtirilgan [9], Plotly-Resampler [10] orqali interaktiv grafiklarga moslashtirilgan va qavariq qobiqlarda iterativ ILTS usuli [11] bilan takomillashtirilgan; chiziqli grafiklar uchun nuqta tanlash metrikalar asosida [12] da baholangan.

Geometrik og‘ish va approksimatsiya usullari. Douglas–Peucker (DP) algoritmi [13] asl siniq chiziqdan geometrik og‘ishni minimallashtiradi. Onlayn bo‘lakli-chiziqli approksimatsiya (PLA) [14], o‘xshash segmentlarni birlashtiruvchi Sim-Piece [15] va Mix-Piece [16], avtokorrelyatsiyani saqlovchi CAMEO [17] xatolik bilan chegaralangan soddalashtirishga misoldir. **Silliqlash va simvolik usullar.** PAA [18] teng kenglikdagi oraliqlarni o‘rtachalaydi, SAX [19, 20] bu o‘rtachalarni diskret alifboga kvantlaydi, ASAP [21] esa ko‘rsatishdan oldin qatorni silliqlab, shovqinni bostiradi.

Perseptiv tadqiqotlar pozitsiyani yuza va egrilikdan yuqori baholaydi [22], grafik idrok neyron tarmoqlar bilan ham modellashtirilgan [23]. Anomaliyalar uchun matritsa profili diskord bahosini beradi [24]; vaqt qatorlari tasvirlari [25] da sharhlangan, anomaliya detektorlari [26] da solishtirilgan, keng tarqalgan benchmarklarning kamchiliklari esa [27] da tanqid qilingan.

Mahalliy tadqiqotlarda big data vizualizatsiyasi ko‘proq axborot tizimlari va dasturiy ta’minot kontekstida o‘rganilgan bo‘lib, real vaqt cheklovini hisobga olgan holda egri chiziqni geometrik soddalashtirish masalasi muhandislik geometriyasi va kompyuter grafikasi nuqtai nazaridan yetarlicha tadqiq etilmagan.

Sharh shuni ko‘rsatadiki, barcha oilalarda umumiy bo‘shliq mavjud: har bir usul yagona geometrik kattalikni optimallashtiradi va domen qoidalari uchun maxsus mexanizm taklif etmaydi. AdaptiveM4 aynan shu bo‘shliqni to‘ldirishga mo‘ljallangan. Bundan tashqari, solishtiriladigan usullar bir turdagi emas: **tanlash** (selection) usullari kirish namunalarining qism to‘plamini o‘zgartirmasdan qaytaradi (M4, LTTB, MinMax, DP, VW, PLA); **silliqlash** (ASAP) va **simvolik tasvir** (SAX) esa yangi qiymat yoki vaqt belgilarini sintez qiladi. Faqat tanlash usullarida asl vaqt belgilari aniq saqlanadi, shu sababli vaqt belgisi bo‘yicha saqlash metrikasi faqat ular uchun ma’noga ega. AdaptiveM4 – M4 rasterizatsiya negiziga ega tanlash usuli.

Tadqiqot metodologiyasi. AdaptiveM4 algoritmi. Namunalar paketi D bilan belgilanadi, har bir namuna vaqt belgisi va qiymatdan iborat (t_i, x_i) juftlik bo‘lib, vaqt belgilari qat’iy o‘suvchi. Chiqish byudjeti $m \ll n$ berilganda, ko‘pi bilan m ta nuqtadan iborat shunday S qism to‘plam quriladiki, u D ga masofa bo‘yicha yaqin bo‘lsin va muhim nuqtalarni ustuvor saqlasin. (1)–(3) tenglamalar bir tekis namuna olish oralig‘ini ($t_{i+1} - t_i = \Delta t$) nazarda tutadi; baholangan ikkala ma’lumotlar manbai 1 Gs (bir soniyada bir namuna) to‘rida joylashgan.

Har bir ichki namuna uchun o‘rtacha qiymat μ va standart og‘ish σ asosida uchta masshtabdan mustaqil geometrik kattalik hisoblanadi: standart baho (Z-baho), markaziy qiyalik va mahalliy egrilik:

$$Z_i = |x_i - \mu| / \sigma \quad (1)$$

$$\text{slope}_i = (x_{i+1} - x_{i-1}) / 2 \quad (2)$$

$$A_i = |x_{i-1} - 2x_i + x_{i+1}| / 2 \quad (3)$$

Bir tekis to‘rda uchburchak yuzasi A_i ikkinchi chekli ayirmaning moduliga proporsional bo‘ladi (lekin ikkinchi hosilaning o‘zi emas). Notekis namuna olishda qiyalik haqiqiy vaqt oralig‘i bo‘yicha $\text{slope}^*_i = (x_{i+1} - x_{i-1}) / (t_{i+1} - t_{i-1})$, yuza esa uchta (t, x) nuqta determinantining yarmi sifatida olinadi; doimiy qadamda bu ifodalar (2)–(3) ga aylanadi.

DOI: 10.65322/j.srd.06202026.45

Statistikalar oynali va paket bo‘yicha kauzal hisoblanadi: μ va σ oxirgi $W = 100$ ta kuzatilgan qiymatdan iborat siljuvchi oynadan olinadi, oyna joriy paket agregatsiya qilingandan keyingina yangilanadi. Sovuq ishga tushirishda paketning o‘z statistikalari ishlatiladi, $\sigma = 0$ bo‘lsa, u 1 ga almashtiriladi. Paket ichida algoritm keyingi namunaga (x_{i+1}) qaraydi, ya’ni usul paket darajasida kauzal, paket ichida esa kauzal emas – bu chizishdan oldin to‘liq shakllangan oynani vizual agregatsiya qilish modeliga mos keladi.

Har bir kattalik joriy paketdagi maksimumiga bo‘linib, $S_{stat,i}$, $S_{slope,i}$, $S_{area,i}$ normallangan baholar olinadi. Qat’iy byudjetda faqat paket ichidagi nuqtalar tartibi muhim bo‘lgani uchun maksimum bo‘yicha normallash yetarli. Kompozit muhimlik bahosi og‘irliklar yig‘indisi birga teng bo‘lgan chiziqli kombinatsiya sifatida aniqlanadi:

$$\mathrm{Score}_i = w_{stat} \cdot S_{stat,i} + w_{slope} \cdot S_{slope,i} + w_{area} \cdot S_{area,i} \qquad (4)$$

Chetki nuqtalar maksimal bahoga mahkamlanadi. Tanlangan og‘irliklar: $w_{stat} = 0.40$, $w_{slope} = 0.10$, $w_{area} = 0.50$ – ular to‘r bo‘yicha qidiruv natijasida aniqlandi. Demak, egrilik va statistik og‘ish asosiy rol o‘ynaydi, qiyalik esa eng kam ahamiyatli.

Ko‘p yo‘lli nomzodlik qoidasi. Nuqta bir nechta mustaqil «yo‘l» orqali nomzod qilinadi:

$$\mathrm{nominate}_i = [\mathrm{Score}_i \geq \theta] \vee [Z_i > \tau] \vee [\Delta\mathrm{slope}_i > \delta] \vee [S_{sem,i} = 1] \qquad (5)$$

bu yerda θ – kompozit chegara, τ – Z-baho chegarasi, δ – qiyalik o‘zgarishi chegarasi, $S_{sem,i}$ – ixtiyoriy semantik bayroq. Burilish hadi bir tomonlama ayirmalar $s^-_i = x_i - x_{i-1}$ va $s^+_i = x_{i+1} - x_i$ orqali $\Delta\mathrm{slope}_i = |s^-_i - s^+_i|$ kabi aniqlanadi; nuqta $s^-_i \cdot s^+_i < 0$ va $\Delta\mathrm{slope}_i > \delta$ bo‘lganda nomzod bo‘ladi. Standart qiymatlar: $\theta = 0.60$, $\tau = 2.5$, $\delta = 1.25\sigma$. Qolgan byudjet M4 rasterizatsiyasi bilan to‘ldiriladi.

Nomzod nuqtalar so‘zsiz saqlanmaydi, balki ustuvorlik oladi: har bir nomzodning ustuvorligi uning kompozit bahosiga birni qo‘shish bilan aniqlanadi, shu sababli har qanday nomzod nomzod bo‘lmagan nuqtadan yuqori turadi. Avval ikki chetki nuqta, so‘ngra nomzodlar ustuvorlik kamayishi tartibida byudjet tugaguncha qabul qilinadi. Shunday qilib, barcha nomzodlarni saqlash faqat $|\{i : \mathrm{nominate}_i\} \cup \{1, n\}| \leq m$ bo‘lgandagina kafolatlanadi. Bu ongli kelishuv: chiqish hajmi shartnomasi aniq bajariladi va teng byudjetli solishtirish adolatli bo‘ladi.

Adaptiv bucket qoidasi. Bucket multiplikatori $\rho \in [2, 8]$ ($\rho_0 = 1$) kechikish nisbati $\lambda = L_{obs} / L_{target}$ ($L_{target} = 200$ ms) asosida o‘lik zonali multiplikativ boshqaruvchi bilan yangilanadi (soniyasiga ko‘pi bilan bir marta):

$$\rho \leftarrow \min(4;\ 1.2\rho), \ \text{agar } \lambda > 1.2; \qquad (6)$$
$$\rho \leftarrow \max(1;\ 0.9\rho), \ \text{agar } \lambda < 0.5 \text{ va } \rho > 1,$$

aks holda ρ o‘zgarmaydi. Bucketlar soni ρ orqali quyidagicha aniqlanadi:

$$B = \max(1;\ \min(\lfloor (m_{eff}/4)/\rho \rfloor;\ \lfloor n/4 \rfloor)), \quad m_{eff} = \max(1;\ m - |N|) \qquad (7)$$

bu yerda $|N|$ – nomzod nuqtalar soni. Kechikish yuqori bo‘lsa agregatsiya qo‘pollashadi, zaxira paydo bo‘lsa – aniqlashadi; bu kompyuter grafikasidagi tafsilot darajasi (Level of Detail, LOD) tamoyiliga mos keladi. Domen jihatidan kritik nuqtalar (masalan, xavfsizlik chegarasidan oshgan deformatsiya) ixtiyoriy semantik qoida bilan belgilanadi; standart holatda qoida yo‘q va algoritm sof geometrik-perseptual soddalashtiruvchi bo‘ladi.

Algoritm qadamlari va har bir qadam murakkabligi 1-jadvalda keltirilgan (k – byudjet cheklovidan oldingi nomzodlar soni).

DOI: 10.65322/j.srd.06202026.45

1-jadval

AdaptiveM4 algoritmining paketli agregatsiya qadamlari

№	Qadam	Murakkablik
1	Agar n ≤ m bo'lsa, D ni o'zgarishsiz qaytarish	O(n)
2	Oynadan μ, σ ni olish; Z_i, $slope_i$, A_i va ularning paket maksimumlarini hisoblash	O(n)
3	Normallash; $Score_i$ ni (4) bo'yicha hisoblash; chetki nuqtalarni 1 ga mahkamlash	O(n)
4	Nomzod nuqtalarni (5) bo'yicha belgilash	O(n)
5	m_eff va B ni (7) bo'yicha aniqlash	O(1)
6	Har bir bucketdan birinchi, oxirgi, min, max va eng yuqori bahoga ega nuqtani chiqarish	O(n)
7	Nomzodlarni qo'shish; vaqt belgisi bo'yicha takrorlarni olib tashlash	O(k)
8	Nomzodlar m dan ko'p bo'lsa, ustuvorlik bo'yicha saralab m tagacha qisqartirish	O(k log k)
9	Paketni siljuvchi oynaga qo'shish	O(n)

Natijada paketning umumiy hisoblash murakkabligi

$$O(n + k \cdot \log k) \quad (8)$$

ga teng. Bucket o‘tishi ko‘pi bilan $\lfloor m_{\text{eff}}/4 \rfloor$ bucketdan 5 tadan, ya’ni ko‘pi bilan $5m/4$ nomzod beradi. Normal rejimda nomzodlar to‘plami $O(m)$ bo‘lib, umumiy baho $O(n + m \log m)$ ga, m – ekran kengligi doimiy bo‘lganda esa $O(n)$ ga keltiriladi. Deyarli har bir nuqta burilish bo‘lgan noqulay holatda baho $O(n \log n)$ gacha yomonlashadi, biroq baholangan ma’lumotlarda bunday holat kuzatilmadi.

Ma’lumotlar to‘plamlari. Real belgilangan ma’lumot sifatida binolarning konstruktiv holatini monitoring qilish (structural health monitoring, SHM) to‘plami ishlatildi: 1000 ta bir soniyali namuna, to‘rt kanal – uch o‘qli tezlanish, deformatsiya (strain), harorat va ikkilik holat belgisi; 296 ta namuna anomaliya sifatida belgilangan. Asosiy qator – deformatsiya kanali, belgi esa haqiqiy qiymat (ground truth) vazifasini bajaradi. Har bir belgi alohida vaqt nuqtasini ifodalaydi. Bundan tashqari, seed = 42 va n = 5000 bo‘lgan to‘rtta sintetik pattern generatsiya qilindi: Spike (20 ta tasodifiy sakrash), Level Shift (7 ta sath chegarasi), Gradual Drift (o‘rta uchdan birda 40 birlikli rampa, 34 ta belgi) va Oscillation (o‘rta uchdan birda tebranish portlashi, 51 ta belgilangan ekstremum).

Baholash metrikalari. Uch metrika oilasi qo‘llanildi. *Geometrik* metrikalar ikkala egri asl egri chegaralari bo‘yicha [0, 1] × [0, 1] fazoga o‘tkazilgandan keyin hisoblandi: diskret Fréchet masofasi (Eiter–Mannila dinamik dasturlash usuli [28], uzluksiz ta’rifi [29]), segmentlarni hisobga oluvchi simmetrik Hausdorff masofasi [30] va trapetsiya qoidasi bilan hisoblangan normallangan yuza-farqi. *Perseptual* metrikalar 256 × 128 o‘lchamli ikkilik rastrlarda hisoblandi: SSIM (L = 1, 8 × 8 oynalar) [31] va farq qiluvchi piksellar ulushi (piksel xatoligi). SSIM tabiiy tasvirlar uchun ishlab chiqilgani sababli, u bu yerda inson idroki modelining o‘rnini emas, chizilgan shakl mosligining takrorlanuvchan proksi-o‘lchovi sifatida ishlatiladi. *Xususiyatlarni saqlash* aniq vaqt belgisi bo‘yicha moslik asosidagi precision, recall va F1 bilan o‘lchandi. m = 100 va 296 ta belgida recall nazariy jihatdan 100/296 ≈ 0.34 dan oshmaydi.

Baholash protokoli. AdaptiveM4 va to‘qqizta bazaviy usul solishtirildi: tanlash usullari – AdaptiveM4, M4, LTTB, MinMax, DP, VW, PLA, Random; silliqlash va simvolik usullar – ASAP, SAX. Har bir usul bir xil m byudjetini oladi: m = 100 da M4 25 ta bucket hosil qilib, har biridan 4 nuqta, MinMax esa 50 bucketdan 2 nuqta chiqaradi; LTTB, VW, DP, PLA va Random to‘g‘ridan-to‘g‘ri m nuqta tanlaydi. PLA bazaviy usuli chiqish hajmi oldindan aniq bo‘lmagan onlayn usul [14] o‘rniga byudjet bilan cheklangan yuqoridan-pastga variant sifatida amalga oshirildi va u DP ga yaqin ishlaydi. Kechikish 8 ta qizdirish (JIT) yurishidan keyin 25 ta

DOI: 10.65322/j.srd.06202026.45

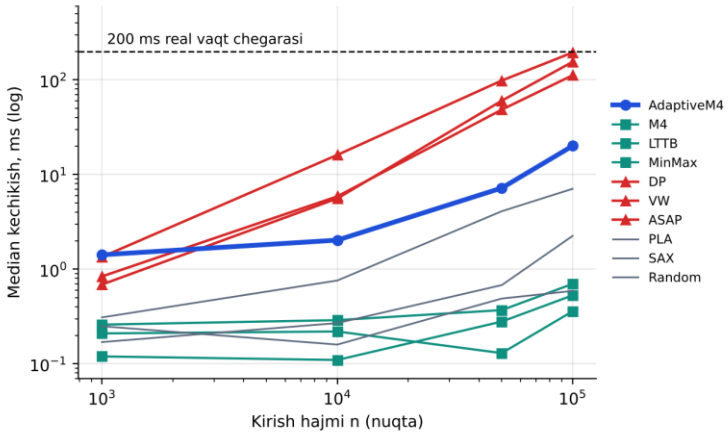
o‘lchovning mediani sifatida olindi. Algoritm Java (JDK 21.0.3, HotSpot) muhitida bir oqimli tarzda amalga oshirildi; sinov platformasi – Intel Core Ultra 9 185H, 32 GB operativ xotira, Windows 11.

Tahlil va natijalar. Samaradorlik. 2-jadvalda teng 100 nuqtali byudjetda har bir usulning median kechikishi, 1-rasmda esa kechikishning kirish hajmiga bog‘liqligi keltirilgan.

2-jadval

Teng 100 nuqtali byudjetda median kechikish, ms

Usul	n = 1 000	n = 10 000	n = 50 000	n = 100 000
AdaptiveM4	1.42	2.03	7.21	20.08
M4	0.21	0.22	0.13	0.36
LTTB	0.26	0.29	0.37	0.70
MinMax	0.12	0.11	0.28	0.53
DP	1.35	16.12	98.44	194.58
VW	0.69	5.59	60.28	155.01
ASAP	0.84	5.88	48.50	111.89
PLA	0.31	0.76	4.10	7.07
SAX	0.25	0.16	0.49	0.59
Random	0.17	0.27	0.68	2.25



1-rasm. Median hisoblash kechikishining kirish hajmiga bog‘liqligi (ikkala o‘q logarifmik). AdaptiveM4 – ko‘k qalin chiziq, aniq geometrik soddalashtiruvchilar – qizil, tezkor agregatorlar – yashil

AdaptiveM4 o‘lchangan oraliqda chiziqli masshtablanadi: $n = 10^4$ dan 10^5 gacha kirish 10 marta oshganda, median kechikish 2.03 ms dan 20.08 ms gacha, ya’ni 9.9 marta oshadi va bir nuqtaga to‘g‘ri keladigan xarajat taxminan 0.20 mks atrofida barqaror qoladi. 100 000 nuqta taxminan 20 ms da qayta ishlanadi – bu 200 ms chegarasidan o‘n baravar kam. 200 ms chegara real vaqtning universal ta’rifi emas, balki panel yangilanishi foydalanuvchi tomonidan bir zumda deb qabul qilinadigan interval sifatida olingan. AdaptiveM4 ning doimiy koeffitsiyenti M4, LTTB va MinMax nikidan yuqori – bu har bir nuqta uchun xususiyatlarni hisoblash narxi. Asosiy natija aniq geometrik soddalashtiruvchilar bilan farqda: $n = 10^5$ da AdaptiveM4 DP dan taxminan 10, VW dan 8, ASAP dan 6 baravar tez. Ushbu usullar 194.58, 155.01 va 111.89 ms bilan chegaraga yaqinlashadi va o‘sishi chiziqlidan yuqori, AdaptiveM4 esa bir tartibli zaxirani saqlaydi.

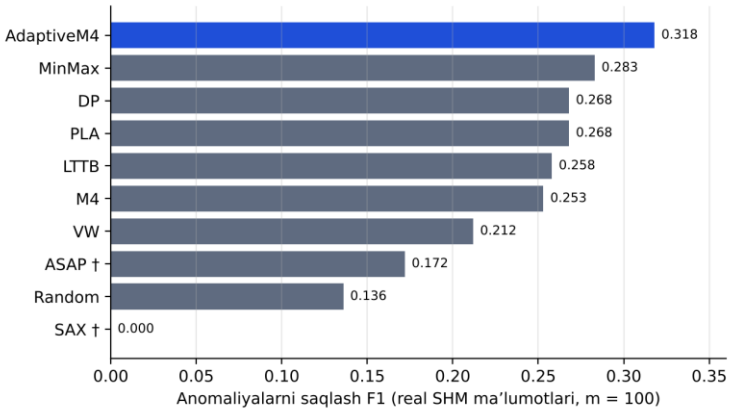
Anomaliyalarni saqlash. 3-jadvalda real SHM ma’lumotlarida saqlash metrikalari, 2-rasmda esa usullar bo‘yicha F1 qiymatlari keltirilgan.

DOI: 10.65322/j.srd.06202026.45

3-jadval

SHM ma’lumotlarida anomaliyalarni saqlash (296 ta belgi, m = 100). † – yangi vaqt belgisi yoki qiymat sintez qiluvchi usullar, aniq vaqt belgisi bo‘yicha bevosita solishtirib bo‘lmaydi

Usul	Sinf	Precision	Recall	F1
AdaptiveM4	tanlash	0.630	0.213	0.318
MinMax	tanlash	0.560	0.189	0.283
DP	tanlash	0.530	0.179	0.268
PLA	tanlash	0.530	0.179	0.268
LTTB	tanlash	0.510	0.172	0.258
M4	tanlash	0.505	0.169	0.253
VW	tanlash	0.420	0.142	0.212
Random	tanlash	0.270	0.091	0.136
ASAP †	silliqlash	0.340	0.115	0.172
SAX †	simvolik	0.000	0.000	0.000



2-rasm. Real SHM ma’lumotlarida teng byudjetda anomaliyalarni saqlash F1 bahosi

AdaptiveM4 eng yuqori F1 va recall qiymatini yuqori precision bilan birga oladi. Biroq eng kuchli bazaviy usul – MinMax ga nisbatan amaliy ustunlik kichik: F1 bo‘yicha 0.318 ga qarshi 0.283, ya’ni 0.035 farq. SAX ning nol natijasi uning vaqt belgilarini segment o‘rtasiga ko‘chirishi oqibati bo‘lib, shaklni yomon saqlash belgisi emas. Shu sababli silliqlash va simvolik usullarni adolatli baholash uchun tolerantlikka asoslangan metrika kiritildi: belgilangan anomaliya, agar chiqishda uning vaqt belgisidan $\pm w$ namuna ichida biror cho‘qqi bo‘lsa, saqlangan hisoblanadi (4-jadval).

4-jadval

SHM ma’lumotlarida tolerantlikka asoslangan F1 (w = 0 – aniq moslik).

Usul	w = 0	w = 1	w = 2	w = 5
AdaptiveM4	0.318	0.488	0.595	0.789
MinMax	0.283	0.497	0.645	0.906
DP / PLA	0.268	0.438	0.576	0.748
LTTB	0.258	0.488	0.659	0.946
M4	0.253	0.398	0.570	0.813
VW	0.212	0.435	0.610	0.867
Random	0.136	0.353	0.530	0.756
ASAP †	0.172	0.383	0.584	0.985
SAX †	0.000	0.285	0.531	0.990

DOI: 10.65322/j.srd.06202026.45

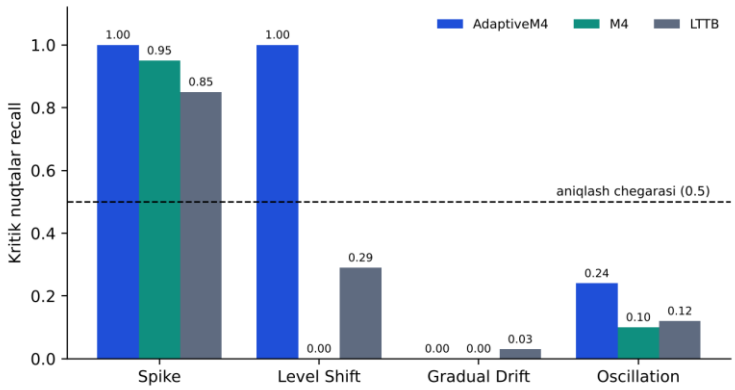
Metrika o‘z vazifasini bajaradi: SAX $w = 1$ da 0.285 ga, $w = 5$ da 0.990 ga ko‘tariladi, ya’ni uning 3-jadvaldagi nol natijasi o‘rta nuqtani tiklash artefaktidir. Shu bilan birga jadval taklif etilgan usulni ham aniqlashtiradi: AdaptiveM4 faqat $w = 0$ da yetakchi, $w = 1$ da LTTB bilan teng va MinMax dan ortda, w oshgani sari farq kengayadi. Bundan kelib chiqadiki, AdaptiveM4 aynan anomal namunaning o‘zini qaytarishga optimallashtirilgan – bu tanlangan nuqtalar tekshirilganda, so‘rov qilinganda yoki xom oqimga indeks sifatida ishlatilganda muhim. Agar talab kuchsizroq bo‘lsa, ya’ni chiziq faqat anomaliya yaqinida egilsa kifoya bo‘lsa, cho‘qqilarni tekisroq taqsimlovchi usul byudjetdan samaraliroq foydalanadi.

Patternlarni qamrab olish. 5-jadvalda har bir sintetik pattern bo‘yicha kritik nuqtalar recall qiymati keltirilgan (recall ≥ 0.5 bo‘lsa, pattern aniqlangan hisoblanadi), 3-rasmda esa uchta tanlash usuli solishtirilgan.

5-jadval

Patternlar bo‘yicha kritik nuqtalarni saqlash (recall)

Usul	Spike	Level Shift	Drift	Oscillation	Aniqlandi
AdaptiveM4	1.00	1.00	0.00	0.24	2
DP	1.00	0.86	0.00	0.33	2
PLA	1.00	0.86	0.00	0.33	2
VW	0.00	1.00	0.03	0.14	1
M4	0.95	0.00	0.00	0.10	1
MinMax	0.95	0.00	0.00	0.20	1
LTTB	0.85	0.29	0.03	0.12	1
Random	0.05	0.00	0.00	0.00	0
ASAP †	0.00	0.00	0.03	0.02	0
SAX †	0.00	0.00	0.00	0.00	0



3-rasm. AdaptiveM4, M4 va LTTB usullarida patternlar bo‘yicha kritik nuqtalarni saqlash

AdaptiveM4 to‘rt patterndan ikkitasini – Spike va Level Shift ni aniqlaydi. Hech bir usul bundan ko‘p patternni qamramaydi, DP va PLA ham aynan shunday natija beradi, shu sababli to‘g‘ri xulosa – mutlaq yetakchilik emas, balki eng yaxshi natijani bo‘lishish. Eng yaqqol yutuq – Level Shift: barcha chegara nuqtalari burilish yo‘li orqali AdaptiveM4 tomonidan saqlanadi, M4 esa ularning birortasini ham saqlamaydi. Gradual Drift va Oscillation patternlarini qat’iy byudjet sababli hech bir usul tiklay olmadi.

Aniqlik kelishuvi. 6-jadvalda real ma’lumotlar bo‘yicha geometrik va perseptual sifat metrikalari keltirilgan; bu metrikalar chizilgan egrilarni solishtirgani uchun barcha o‘n usul, jumladan ASAP va SAX ham bevosita taqqoslanadi.

DOI: 10.65322/j.srd.06202026.45

6-jadval

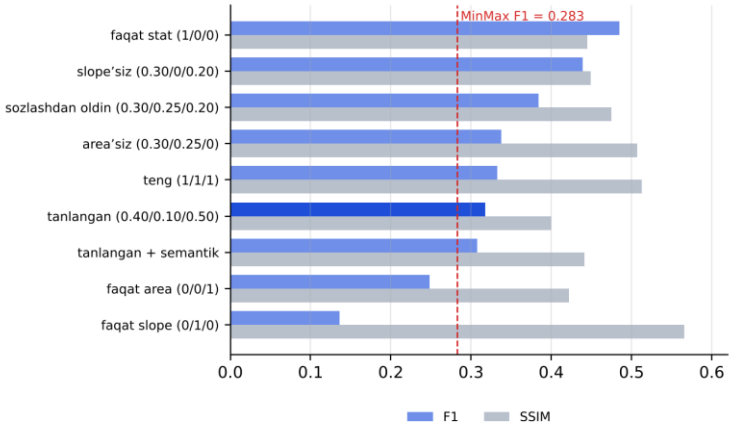
SHM ma’lumotlarida sifat metrikalari (Fréchet, Hausdorff, yuza va piksel xatoligi – kichigi yaxshi; SSIM – kattasi yaxshi)

Usul	Fréchet	Hausdorff	Yuza farqi	SSIM	Piksel xatoligi
AdaptiveM4	0.471	0.060	0.235	0.400	0.184
M4	0.373	0.035	0.190	0.404	0.192
LTTB	0.373	0.074	0.164	0.447	0.184
MinMax	0.555	0.016	0.180	0.406	0.195
DP	0.416	0.069	0.139	0.560	0.152
VW	0.383	0.201	0.132	0.492	0.167
PLA	0.416	0.069	0.139	0.560	0.152
ASAP	0.389	0.292	0.134	0.509	0.156
SAX	0.464	0.464	0.108	0.573	0.136
Random	0.393	0.313	0.134	0.538	0.144

AdaptiveM4 ning yaxlit egri aniqligi past: SSIM va yuza farqi bo‘yicha oxirgi, Fréchet masofasi bo‘yicha esa oxiridan ikkinchi o‘rinda (faqat MinMax undan yomonroq). Hausdorff masofasi bo‘yicha esa u 0.060 bilan uchinchi o‘rinda. Bu dizaynga mos: byudjet anomaliyalar va yuqori egrilikka sarflanadi, natijada eng katta yagona og‘ish kichik bo‘ladi, o‘rtacha aniqlik esa pasayadi. Ya’ni algoritm bir tekis aniqlik o‘rniga xususiyatlar aniqligini afzal ko‘radi; bir tekis aniqlik maqsad bo‘lganda oddiy M4 yoki LTTB afzalroq.

Og‘irliklarni tanlash va ablyatsiya. Og‘irliklar simpleksi 0.1 qadam bilan barcha musbat uchliklar bo‘yicha (36 ta kombinatsiya) ko‘rib chiqildi. Maqsad funksiyasi – to‘rt ma’lumotlar to‘plami (Spike, Level Shift, Oscillation va real SHM) bo‘yicha o‘rtachalangan F1 + ¼·SSIM − ¼·AreaDiff. Eng yaxshi natijani 0.40/0.10/0.50 konfiguratsiyasi berdi: o‘rtacha F1 = 0.235, real F1 = 0.318, o‘rtacha SSIM = 0.617, yuza farqi 0.128, maqsad funksiyasi qiymati 0.358; keyingi konfiguratsiyalar (0.40/0.40/0.20 va 0.30/0.20/0.50) 0.355 qiymatni berdi.

Koeffitsiyentlar (1 va ¼) tanloviga bog‘liqlikni tekshirish uchun to‘r skalyarizatsiyasiz ham tahlil qilindi: 36 ta konfiguratsiyadan 17 tasi Pareto-optimal bo‘lib, tanlangan 0.40/0.10/0.50 konfiguratsiyasi ular orasida va Pareto frontidagi eng yuqori o‘rtacha F1 ga ega. Qiyalik ustun bo‘lgan og‘irliklarga siljish SSIM ni 0.617 dan 0.676 gacha oshiradi, yuza farqini 0.128 dan 0.103 gacha kamaytiradi, ammo real F1 0.318 dan 0.207 gacha tushadi. 4-rasmda real ma’lumotlarda xususiyatlar ablyatsiyasi ko‘rsatilgan.



4-rasm. SHM ma’lumotlarida kompozit baho xususiyatlarining ablyatsiyasi (F1 va SSIM; qavslarda w_stat/w_slope/w_area)

Natijalar og‘irliklarga sezgir: F1 faqat statistik had uchun 0.485 dan faqat qiyalik uchun 0.136 gacha o‘zgaradi; uchta ablyatsiya varianti (faqat qiyalik – 0.136, statistikasiz – 0.172, faqat

DOI: 10.65322/j.srd.06202026.45

yuza – 0.248) bazaviy usullar darajasida yoki undan past. Demak, AdaptiveM4 ning har qanday konfiguratsiyasi bazaviy usullardan ustun degan xulosa noto‘g‘ri. Ablyatsiya tasdiqlaydigan xulosa torroq: statistik og‘ish hadi saqlash uchun eng muhim komponent, yuza hadi esa chizilgan shakl aniqligiga asosiy hissa qo‘shadi.

Adaptiv javob. Adaptiv bucket qoidasi sun’iy kechikish izi bilan sinaldi: kuzatilgan kechikish 200 ms maqsadga qarshi 400 ms ga ko‘tarilib, uch qadam ushlab turildi, so‘ngra 30 ms ga tushirildi. Multiplikator (6) tenglamaga muvofiq 1.000 → 1.200 → 1.440 → 1.728 bo‘ylab o‘sdi, zaxira qaytgach esa 1.555 va 1.400 gacha pasaydi. Boshqaruvchi oldini oluvchi emas, balki tuzatuvchi: u oldingi paket o‘lchoviga reaksiya qiladi, shu sababli sakrash vaqtida kechikish maqsaddan ikki baravar oshadi. Chiqish hajmi shartnomasi har qadamda bajarildi – doimo aniq 100 nuqta.

Statistik ahamiyatlilik. Sintetik baholash 10 ta seed va 4 ta pattern bo‘yicha takrorlandi (40 blok). Fridman omnibus testi usullar orasidagi farqning yuqori ahamiyatliligini ko‘rsatdi (χ^2 = 193.1, $p \approx 9 \cdot 10^{-37}$). Juft taqqoslashlar Wilcoxon ishorali-rang testi bilan bajarildi, p-qiymatlar Holm–Bonferroni usulida tuzatildi, effekt kattaligi sifatida rang-biserial *r* va 10 000 resempl bootstrap 95% ishonch oralig‘i berildi (7-jadval).

7-jadval

40 ta sintetik blokda juft Wilcoxon testlari (AdaptiveM4 – bazaviy usul; musbat farq AdaptiveM4 foydasiga)

Bazaviy usul	O’rtacha farq [95% IO]	r	p (Holm)
M4	+0.056 [+0.043; +0.070]	+0.979	$8.3 \cdot 10^{-6}$
LTTB	+0.049 [+0.037; +0.061]	+0.950	$1.1 \cdot 10^{-5}$
MinMax	+0.038 [+0.023; +0.053]	+0.795	$3.4 \cdot 10^{-4}$
VW	+0.087 [+0.044; +0.133]	+0.589	$4.9 \cdot 10^{-3}$
ASAP	+0.135 [+0.097; +0.174]	+0.866	$1.1 \cdot 10^{-5}$
SAX	+0.145 [+0.108; +0.183]	+1.000	$1.1 \cdot 10^{-5}$
Random	+0.140 [+0.104; +0.178]	+1.000	$1.1 \cdot 10^{-5}$
DP	−0.015 [−0.023; −0.007]	−0.729	$2.2 \cdot 10^{-3}$
PLA	−0.014 [−0.022; −0.007]	−0.667	$4.9 \cdot 10^{-3}$

Tuzatishdan keyin AdaptiveM4 sintetik bloklarda M4, LTTB va MinMax dan katta effekt bilan ahamiyatli ustun. DP va PLA esa AdaptiveM4 dan o‘rtacha F1 bo‘yicha 0.015 va 0.014 ga ahamiyatli ustun – farq mutlaq qiymatda kichik, lekin barqaror. VW bilan solishtirishda median farq nolga teng, shu sababli u g‘alaba sifatida hisoblanmaydi. Real ma’lumotlarda 296 ta belgi bo‘yicha McNemar aniq testi tuzatishdan keyin eng yaqin bazaviy usullar (M4, LTTB, MinMax, DP, PLA) bilan ahamiyatli farqni ko‘rsatmadi, ASAP, SAX va Random ga nisbatan esa farq ahamiyatli. Real ma’lumotlarda AdaptiveM4 m = 50, 100, 200, 400 byudjetlarining barchasida F1 bo‘yicha birinchi o‘rinni egallaydi (m = 50 da MinMax, DP va PLA bilan teng).

Og‘irlik tanlovining validligi. Og‘irliklar real ma’lumotlarni ham o‘z ichiga olgan maqsad funksiyasi bilan tanlangani uchun natijada optimistik siljish bor. Real ma’lumotlar tanlovdan to‘liq chiqarib tashlanganda sintetik maqsad 0.10/0.50/0.40 og‘irliklarni tanlaydi va u real ma’lumotlarda F1 = 0.232 ni beradi – bu eng kuchli bazaviy usuldan (0.283) past. Demak, tanlov bilan bog‘liq optimizm taxminan +0.086 F1 ni tashkil etadi va bu MinMax ustidagi 0.035 marjadan katta. Shu bilan birga 36 ta konfiguratsiyadan 16 tasi real ma’lumotlarda eng kuchli bazaviy usuldan baribir ustun, ya’ni ustunlik faqat tanlov artefakti emas, ammo u og‘irliklarga bog‘liq va bitta e’lon qilingan raqamdan kichikroq. Masalani yakuniy hal qilish uchun mustaqil test to‘plami zarur.

Xulosa va takliflar. Maqolada oqimli vaqt qatorlarini real vaqt rejimida vizualizatsiya qilish uchun statistik og‘ish, mahalliy qiyalik va uchburchak yuzasi orqali egrilikni yagona bahoda

DOI: 10.65322/j.srd.06202026.45

birlashtiruvchi AdaptiveM4 geometrik-perseptual tanlash algoritmi formal tavsiflandi va to‘qqizta bazaviy usul bilan qiyosiy baholandi. Asosiy natijalar:

– ko‘p yo‘lli nomzodlik qoidasi va qat’iy chiqish byudjeti bilan algoritm paketni O($n + k$ log k) murakkablikda qayta ishlaydi; 100 000 nuqta taxminan 20 ms da agregatsiya qilinadi, bu DP, VW va ASAP dan 6–10 baravar tez va 200 ms chegarasidan bir tartib past;

– real SHM ma’lumotlarida anomaliyalarni saqlash bo‘yicha eng yuqori F1 = 0.318 (eng kuchli bazaviy usulda 0.283) olindi; biroq og‘irliklar real ma’lumotlarni ham o‘z ichiga olgan maqsad funksiyasi bo‘yicha tanlangan, real ma’lumotlar tanlovdan chiqarilganda F1 = 0.232 ga tushadi va barcha byudjetlarda birinchi o‘rin saqlandi;

– Level Shift patternidagi barcha chegara nuqtalari saqlandi (M4 da – birortasi ham emas), patternlarni qamrab olish bo‘yicha natija eng yaxshi usullar bilan teng;

– tezkor agregatorlar (M4, LTTB, MinMax) ga nisbatan ustunlik sintetik bloklarda Holm tuzatishidan keyin ham statistik ahamiyatli.

Aniqlangan cheklovlar ochiq bayon qilindi: yaxlit egri aniqligi pasayadi; og‘irliklar tanlovi ma’lumotlarga sezgir va real ma’lumotlar tanlovdan chiqarilganda F1 0.232 gacha tushadi; Gradual Drift va Oscillation patternlari qat’iy byudjetda tiklanmaydi. Ularni bartaraf etish bo‘yicha quyidagi takliflar ilgari suriladi: (1) dreyf va tebranishlar uchun progressiv (ko‘p o‘tishli) variant ishlab chiqish; (2) og‘irliklarni onlayn moslashtirish; (3) mustaqil test to‘plamida tanlangan og‘irliklar bilan qo‘shimcha real va notekis namunali ma’lumotlarda validatsiya qilish.

Olingan natijalar AdaptiveM4 ni egri chiziqni geometrik soddalashtirish asosida vizualizatsiya usul va algoritmlarini ishlab chiqishga qo‘shilgan hissa sifatida baholash imkonini beradi: M4 piksel-ustun negizi saqlangan holda interaktiv tezlikda raqobatbardosh anomaliya saqlash ta’minlanadi.

Foydalanilgan adabiyotlar

1. Geometric perceptual importance algorithm for real-time visualization of streaming time series // Eurasian Journal of Mathematical and Computer Applications. – 2026. – Vol. 14, № 3. – P. 64–84. – DOI: 10.32523/2306-6172-2026-14-3-64-84.

2. Jugel U., Jerzak Z., Hackenbroich G., Markl V. M4: A Visualization-Oriented Time Series Data Aggregation // Proceedings of the VLDB Endowment. – 2014. – Vol. 7, No. 10. – P. 797–808. – DOI: 10.14778/2732951.2732953.

3. Jugel U., Jerzak Z., Hackenbroich G., Markl V. VDDA: Automatic Visualization-Driven Data Aggregation in Relational Databases // The VLDB Journal. – 2016. – Vol. 25, No. 1. – P. 53–77. – DOI: 10.1007/s00778-015-0396-z.

4. Rui L., Huang X., Song S., Kang Y., Wang C., Wang J. Time Series Representation for Visualization in Apache IoTDB // Proc. ACM on Management of Data. – 2024. – Vol. 2, No. 1. – Art. 35. – DOI: 10.1145/3639290.

5. Wang Y. et al. OM3: An Ordered Multi-Level Min-Max Representation for Interactive Progressive Visualization of Time Series // Proc. ACM on Management of Data. – 2023. – Vol. 1, No. 2. – Art. 145. – DOI: 10.1145/3589290.

6. Maroulis S., Stamatopoulos V., Papastefanatos G., Terrovitis M. Visualization-Aware Time Series Min-Max Caching with Error Bound Guarantees // Proceedings of the VLDB Endowment. – 2024. – Vol. 17, No. 8. – P. 2091–2103. – DOI: 10.14778/3659437.3659460.

7. Steinarsson S. Downsampling Time Series for Visual Representation: Master’s thesis. – Reykjavik: University of Iceland, 2013.

8. Visvalingam M., Whyatt J.D. Line Generalisation by Repeated Elimination of Points // The Cartographic Journal. – 1993. – Vol. 30, No. 1. – P. 46–51. – DOI: 10.1179/000870493786962263.

DOI: 10.65322/j.srd.06202026.45

9. Van Der Donckt J., Van Der Donckt J., Rademaker M., Van Hoecke S. MinMaxLTTB: Leveraging MinMax-Preselection to Scale LTTB // Proc. IEEE Visualization and Visual Analytics (VIS). – 2023. – P. 21–25. – DOI: 10.1109/VIS54172.2023.00013.

10. Van Der Donckt J., Van Der Donckt J., Deprost E., Van Hoecke S. Plotly-Resampler: Effective Visual Analytics for Large Time Series // Proc. IEEE Visualization and Visual Analytics (VIS). – 2022. – DOI: 10.1109/VIS54862.2022.00013.

11. Rui L., Huang X., Song S., Wang C., Wang J., Cao Z. Largest Triangle Sampling for Visualizing Time Series in Database // Proc. ACM on Management of Data. – 2025. – Vol. 3, No. 1. – Art. 49. – DOI: 10.1145/3709699.

12. Van Der Donckt J., Van Der Donckt J., Rademaker M., Van Hoecke S. Data Point Selection for Line Chart Visualization: Methodological Assessment and Evidence-Based Guidelines // arXiv:2304.00900. – 2023.

13. Douglas D.H., Peucker T.K. Algorithms for the Reduction of the Number of Points Required to Represent a Digitized Line or its Caricature // Cartographica. – 1973. – Vol. 10, No. 2. – P. 112–122. – DOI: 10.3138/FM57-6770-U75U-7727.

14. Elmeleegy H., Elmagarmid A.K., Cecchet E., Aref W.G., Zwaenepoel W. Online Piece-wise Linear Approximation of Numerical Streams with Precision Guarantees // Proceedings of the VLDB Endowment. – 2009. – Vol. 2, No. 1. – P. 145–156. – DOI: 10.14778/1687627.1687645.

15. Kitsios X., Liakos P., Papakonstantinopoulou K., Kotidis Y. Sim-Piece: Highly Accurate Piecewise Linear Approximation through Similar Segment Merging // Proceedings of the VLDB Endowment. – 2023. – Vol. 16, No. 8. – P. 1910–1922. – DOI: 10.14778/3594512.3594521.

16. Kitsios X., Liakos P., Papakonstantinopoulou K., Kotidis Y. Flexible Grouping of Linear Segments for Highly Accurate Lossy Compression of Time Series Data // The VLDB Journal. – 2024. – Vol. 33, No. 5. – P. 1569–1589. – DOI: 10.1007/s00778-024-00862-z.

17. Muniz-Cuza C.E., Boehm M., Pedersen T.B. CAMEO: Autocorrelation-Preserving Line Simplification for Lossy Time Series Compression // Proc. 29th Int. Conf. on Extending Database Technology (EDBT). – 2026. – P. 15–28. – DOI: 10.48786/edbt.2026.02.

18. Keogh E., Chakrabarti K., Pazzani M., Mehrotra S. Dimensionality Reduction for Fast Similarity Search in Large Time Series Databases // Knowledge and Information Systems. – 2001. – Vol. 3, No. 3. – P. 263–286. – DOI: 10.1007/PL00011669.

19. Lin J., Keogh E., Lonardi S., Chiu B. A Symbolic Representation of Time Series, with Implications for Streaming Algorithms // Proc. 8th ACM SIGMOD Workshop on Research Issues in Data Mining and Knowledge Discovery. – 2003. – P. 2–11. – DOI: 10.1145/882082.882086.

20. Lin J., Keogh E., Wei L., Lonardi S. Experiencing SAX: A Novel Symbolic Representation of Time Series // Data Mining and Knowledge Discovery. – 2007. – Vol. 15, No. 2. – P. 107–144. – DOI: 10.1007/s10618-007-0064-z.

21. Rong K., Bailis P. ASAP: Prioritizing Attention via Time Series Smoothing // Proceedings of the VLDB Endowment. – 2017. – Vol. 10, No. 11. – P. 1358–1369. – DOI: 10.14778/3137628.3137645.

22. Cleveland W.S., McGill R. Graphical Perception: Theory, Experimentation, and Application to the Development of Graphical Methods // Journal of the American Statistical Association. – 1984. – Vol. 79, No. 387. – P. 531–554. – DOI: 10.1080/01621459.1984.10478080.

23. Haehn D., Tompkin J., Pfister H. Evaluating ‘Graphical Perception’ with CNNs // IEEE Transactions on Visualization and Computer Graphics. – 2019. – Vol. 25, No. 1. – P. 641–650. – DOI: 10.1109/TVCG.2018.2865138.

24. Yeh C.-C.M. et al. Matrix Profile I: All Pairs Similarity Joins for Time Series: A Unifying View that Includes Motifs, Discords and Shapelets // Proc. IEEE 16th Int. Conf. on Data Mining (ICDM). – 2016. – P. 1317–1322. – DOI: 10.1109/ICDM.2016.0179.

DOI: 10.65322/j.srd.06202026.45

25. Esling P., Agon C. Time-Series Data Mining // ACM Computing Surveys. – 2012. – Vol. 45, No. 1. – Art. 12. – P. 1–34. – DOI: 10.1145/2379776.2379788.

26. Schmidl S., Wenig P., Papenbrock T. Anomaly Detection in Time Series: A Comprehensive Evaluation // Proceedings of the VLDB Endowment. – 2022. – Vol. 15, No. 9. – P. 1779–1797. – DOI: 10.14778/3538598.3538602.

27. Wu R., Keogh E.J. Current Time Series Anomaly Detection Benchmarks are Flawed and are Creating the Illusion of Progress // IEEE Transactions on Knowledge and Data Engineering. – 2023. – Vol. 35, No. 3. – P. 2421–2429. – DOI: 10.1109/TKDE.2021.3112126.

28. Eiter T., Mannila H. Computing Discrete Fréchet Distance: Technical Report CD-TR 94/64. – Vienna: Christian Doppler Laboratory for Expert Systems, TU Vienna, 1994.

29. Alt H., Godau M. Computing the Fréchet Distance between Two Polygonal Curves // International Journal of Computational Geometry & Applications. – 1995. – Vol. 5, No. 1–2. – P. 75–91. – DOI: 10.1142/S0218195995000064.

30. Huttenlocher D.P., Klanderman G.A., Rucklidge W.J. Comparing Images Using the Hausdorff Distance // IEEE Transactions on Pattern Analysis and Machine Intelligence. – 1993. – Vol. 15, No. 9. – P. 850–863. – DOI: 10.1109/34.232073.

31. Wang Z., Bovik A.C., Sheikh H.R., Simoncelli E.P. Image Quality Assessment: From Error Visibility to Structural Similarity // IEEE Transactions on Image Processing. – 2004. – Vol. 13, No. 4. – P. 600–612. – DOI: 10.1109/TIP.2003.819861.