SUST SHAKLLANGAN JARAYONLARNI BASHORATLASHDA MOSLASHUVCHAN ANSAMBL METODOLOGIYASI

Pulatov G‘iyos Gofurjonovich

“TIQXMMI” Milliy tadqiqot universiteti
E-mail: giyospulatov1987@gmail.com

K E Y W O R D S

dinamik ansambl seleksiyasi, moslashuvchan bashoratlash, mustahkamlash mexanizmi, kompetentlik bahosi, metamodel

A B S T R A C T

Bashoratlash modellarini bir marta hisoblangan og‘irliklar bilan birlashtirish, garchi statik yondashuvlarga nisbatan yutuqqa ega bo‘lsa-da, vaqt o‘tishi bilan ma’lumot xususiyatlari o‘zgarganda o‘z samaradorligini yo‘qota boshlaydi. Ushbu ishda sust shakllangan jarayonlarni bashoratlash uchun uchta bosqichni - vaznli ovoz berish, robast kombinatsiya va prognostik xatoga asoslangan dinamik seleksiyani - ketma-ket birlashtiruvchi moslashuvchan metamodel taklif qilinadi. Metodning o‘ziga xosligi shundaki, ansambl tarkibidagi eng kompetent algoritm har bir vaqt oynasi uchun barcha kombinatsiyalarni sanab chiqmasdan, kelgusi xatoni oldindan bashoratlovchi yordamchi tarmoq orqali tanlanadi, tanlov sifati esa modellarni mukofotlash va jarimalash mexanizmi orqali vaqt davomida sayqallanadi. Yurak-qon tomir kasalliklari bo‘yicha bemorlar murojaatini bashoratlash misolida o‘tkazilgan tajriba shuni ko‘rsatdiki, taklif etilgan yondashuv statik kombinatsiyaga nisbatan ham qo‘shimcha yutuq beradi, biroq bu yutuqning qay darajada dinamik seleksiya hisobiga, qay darajada esa boshqa omillar hisobiga ekanligini aniqlash uchun qo‘shimcha, ayirmachi tadqiqotlar zarur - bu masala maqolaning muhokama qismida ochiq muammo sifatida ko‘tarib chiqilgan.

1. Kirish

Ma’lumki, regulyarizatsiyaga asoslangan robast kombinatsiya bazaviy modellar bashoratlari o‘rtasida yuqori korrelyatsiya mavjud bo‘lganda ham turg‘un og‘irliklarni topishga imkon beradi [1]. Lekin bu yerda bir savol ochiq qolib ketadi: agar bir vaqt oynasida LSTM eng yaxshi natija bersa-yu, keyingisida GRU undan o‘zib ketsa, doimiy og‘irliklar bilan ishlaydigan kombinatsiya bu farqni umuman ko‘rmaydi - u faqat o‘rtacha holatga moslashadi. Amalda esa aynan shu “o‘rtacha holat”dan chetga chiqishlar ko‘p uchraydi, ayniqsa meteorologik omillarga sezgir tibbiy ko‘rsatkichlarda.

Bu muammo adabiyotda dinamik ansambl seleksiyasi nomi bilan yuritiladi. Britto va hammualliflari [2] hamda Cruz va boshqalar [3] tomonidan o‘tkazilgan keng qamrovli obzorlarda DES usullarining aksariyati klassifikatsiya masalasi uchun ishlab chiqilgani, kompetentlik esa odatda bashoratlanayotgan namunaga yaqin kuzatuvlardagi mahalliy aniqlik orqali baholanishi qayd etiladi. Regressiya - xususan vaqt qatorlarini bashoratlash - konteksti uchun bu mantiq to‘g‘ridan-to‘g‘ri ko‘chirilmaydi, chunki bu yerda “yaqin kuzatuv” tushunchasi masofaviy emas, balki vaqtli xarakterga ega. Saadallah va hammualliflari [4] onlayn model tanlash masalasini o‘rgangan, Silva, Cavalcanti va Ren esa yaqin vaqt oynalariga asoslangan dinamik prediktor tanlash usulini taklif qilgan [5]; Fu va boshqalar mustahkamlashli o‘qitish yordamida model kombinatsiyasini dinamik boshqarishni ko‘rsatgan [6]. Shu bilan birga, bizga ma’lum manbalarda vaznli ovoz berish, robast kombinatsiya va dinamik seleksiyani bitta ketma-ket ishlaydigan tizimga birlashtirib, buning ustiga modellarni mukofotlash-jarimalash orqali “o‘rgatib boradigan” yagona metamodel tibbiy-meteorologik bashoratlash kontekstida sinovdan o‘tkazilmagan.

(cc) BY

Ushbu maqola aynan shu bo‘shliqni to‘ldirishga qaratilgan. Maqsad - sirg‘aluvchi vaqt oynasi asosida ishlaydigan, statistika hajmiga qarab uch xil rejimda (boshlang‘ich, o‘rta va yetuk) ishlaydigan moslashuvchan metamodel yaratish va uning har bir vaqt oynasi uchun “kim eng yaxshi bashorat qiladi” savoliga real vaqt rejimida javob bera olishini tekshirishdir. Alohida ta’kidlash joizki, biz bu yerda “yaxshiroq” degan xulosani haqiqiy xatoni ko‘rgandan keyin emas, balki xatoni oldindan bashoratlovchi yordamchi model orqali chiqarishga harakat qilamiz - aynan shu jihat metodning hisoblash yukini pasaytiradi, chunki har bir qadamda barcha model kombinatsiyalarini to‘liq sanab chiqish shart bo‘lmay qoladi.

2. Usullar.

Ansambl to‘rtta bazaviy algoritmdan iborat. Ularning har biri - MLP, ANFIS, LSTM va GRU arxitekturalari, o‘qitish tartibi hamda meteorologik-geliogeofizik ma’lumotlar asosidagi dastlabki sinov natijalari - mualliflarning oldingi nashrlarida batafsil yoritilgan [7–9]. Mazkur maqolada e’tibor ushbu to‘rttasining bashoratlarini qanday “boshqarish” masalasiga qaratiladi. Har bir bazaviy algoritm o‘qitilgach yoki sozlanganidan keyin, birinchi bashorat qadamida o‘zining prognostik xato bahosini o‘rtacha kvadratik xatoning kvadrat ildizi ko‘rinishida hosil qiladi; keyingi qadamlarda esa bu baho har safar yangilanib boriladi. Qaror qabul qilish bloki ana shu bahoni va bazaviy modellar bashoratini qabul qilib, hisoblagich ko‘rsatkichiga qarab uchta algoritmdan birini - A1, A2 yoki A3 - ishga tushiradi.

Hisoblagich mantig‘i unchalik murakkab emas: statistika endigina to‘planayotganda A1 ishlaydi, chunki bu bosqichda modellar orasidagi bog‘liqlikni ishonchli baholash uchun kuzatuvlar yetarli emas. Ma’lumot hajmi o‘sib, korrelyatsion tuzilma ancha-muncha ko‘zga tashlana boshlagach, boshqaruv A2 ga - regulyarizatsiyaga asoslangan robast kombinatsiyaga - o‘tadi. Va nihoyat, xato bashoratlovchi yordamchi tarmoqlarni o‘qitish uchun yetarli tarix to‘planganda, tizim A3 rejimiga kiradi va endi har bir oyna uchun bitta “eng mos” IA ni tanlashga harakat qiladi.

A3 algoritmining yuragi - har bir bazaviy IA uchun alohida qurilgan, uning kelgusi qadamdagi xatosini bashoratlovchi yordamchi ko‘p qatlamli perseptron. Bunday yordamchi tarmoqlar to‘g‘ridan-to‘g‘ri haqiqiy chiqishni emas, balki asosiy modelning o‘sha oynadagi kutilayotgan xatosini bashoratlaydi:

$$\hat{e}_i(t) = g_i(e_i(t-1), e_i(t-2), \ldots, e_i(t-k)) \quad (1)$$

bu yerda $e_i(t-j)$ - i-modelning oldingi j-qadamdagi haqiqiy xatosi, g_i - Levenberg-Marquardt usuli bilan o‘qitilgan xato bashoratlovchi tarmoq. Bunday yondashuvning afzalligi shundaki, xatoni bashoratlash o‘zi ham nisbatan yengil hisoblash masalasi bo‘lib, u asosiy modellarning to‘liq qayta o‘qitilishini talab qilmaydi - demak, real vaqt rejimida qo‘llash mumkin.

Har bir IA ning integral kompetentlik bahosi uchta komponentdan yig‘iladi: oldingi qadamdagi haqiqiy xato, joriy qadam uchun bashoratlangan xato va vaqt davomida to‘plangan kompetentlik darajasi. Ushbu uchtasini birlashtiruvchi baho quyidagi ko‘rinishda yoziladi:

$$K_i(t) = \alpha \cdot e_i(t-1) + \beta \cdot \hat{e}_i(t) + \gamma \cdot (1 - c_i(t)) \quad (2)$$

bunda $c_i(t)$ - i-modelning joriy kompetentlik darajasi, α, β, γ - vazn koeffitsientlari. Eng kichik $K_i(t)$ qiymatiga ega bo‘lgan model joriy oyna uchun optimal deb e’lon qilinadi. Agar bir nechta model bir xil eng kichik qiymatga ega bo‘lib chiqsa, tanlov kompetentlik darajasi yuqoriroq, u ham teng bo‘lsa - tartib raqami kichikroq modelga beriladi.

Haqiqiy qiymat ma’lum bo‘lgach, har bir IA ning haqiqiy xatosi qayta hisoblanadi va shu asosda kompetentlik darajasi yangilanadi. Agar model shu qadamda ansambl bo‘yicha eng yaxshi natijani bergan bo‘lsa, uning kompetentligi oshiriladi; eng yomon natija bergan model esa jarimaga tortiladi:

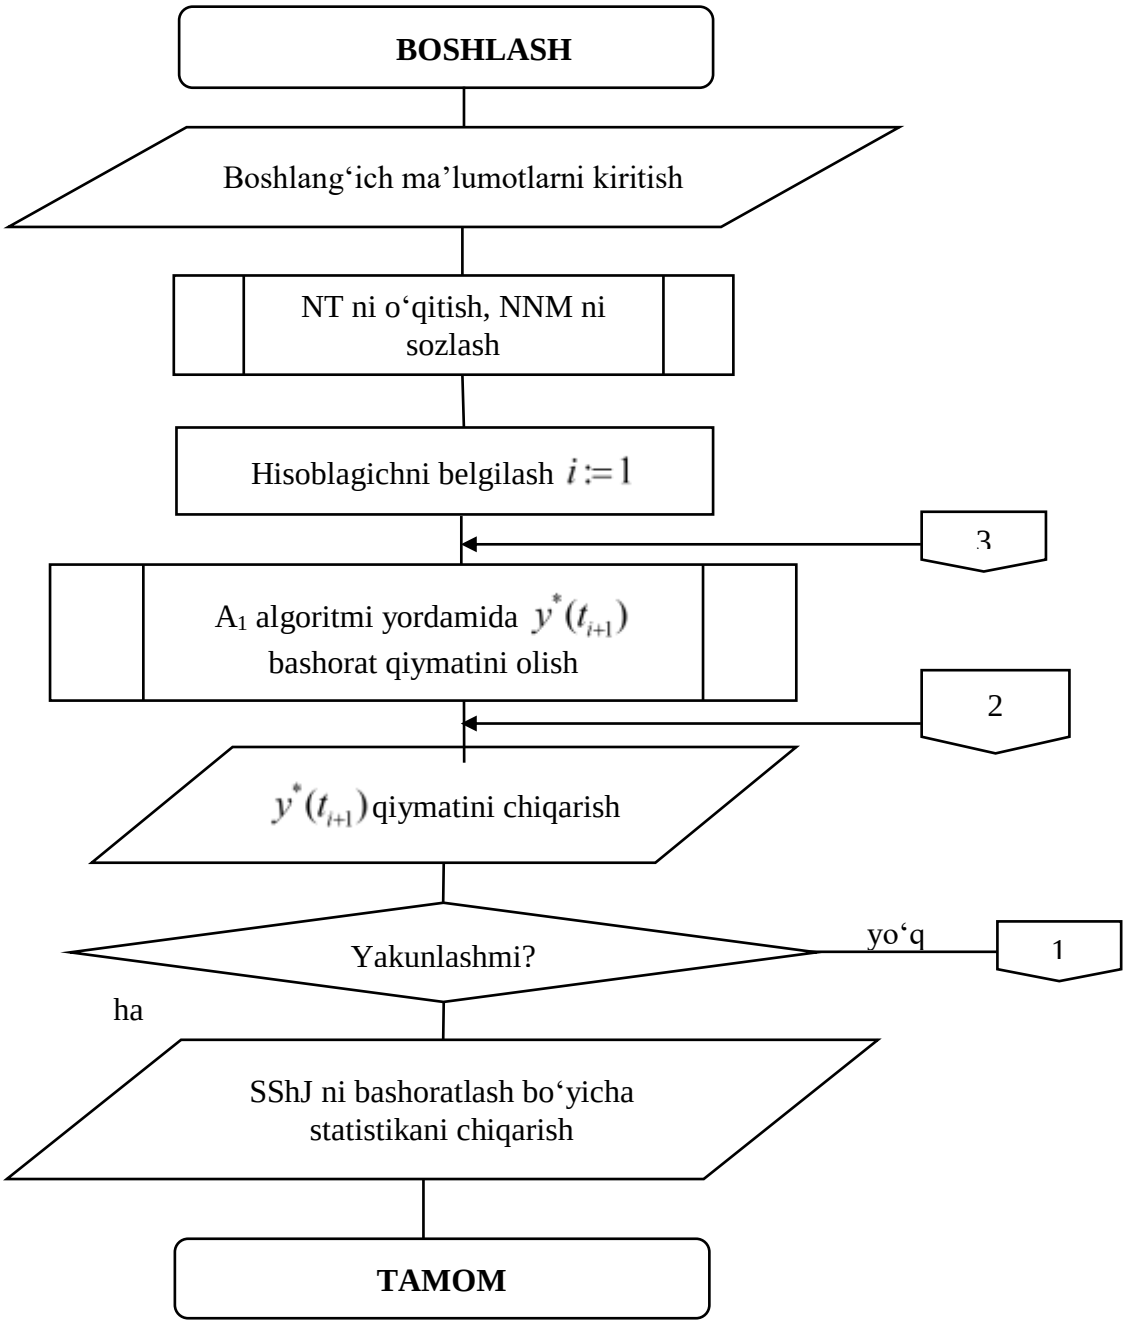
$$c_i(t+1) = c_i(t) + R(n_\beta) \quad \text{- eng yaxshi bo‘lganda} \quad (3)$$

$$c_i(t+1) = c_i(t) - P(n_v) \quad \text{- eng yomon bo‘lganda} \quad (4)$$

(cc) BY

bu yerda n_β va n_v - modelning ketma-ket necha marta eng yaxshi yoki eng yomon bo‘lib chiqqanligini hisoblovchi sanoqchilar, R va P esa amaliy mulohazalardan kelib chiqib tanlangan chiziqli o‘sish funksiyalari. Boshqacha aytganda, model qanchalik uzoq vaqt “omadli” bo‘lsa, uning ovozi shunchalik og‘irlashadi, va aksincha. Shuni ochiq aytish kerakki, R va P funksiyalarining aniq koeffitsientlari ushbu tadqiqotda formal optimallashtirish orqali emas, empirik tanlov yo‘li bilan belgilangan - bu, albatta, metodning takrorlanuvchanligiga nisbatan tanqidga ochiq nuqta.

Sinov yurak-qon tomir kasalliklari bilan bog‘liq bemorlar murojaati chastotasi ustida, mualliflarning oldingi tadqiqotlarida qo‘llanilgan turdagi meteorologik-geliogeofizik ma’lumotlar to‘plamida o‘tkazildi [8, 9]. Tanlama o‘qitish (85%) va sinov (15%) qismlariga bo‘lindi, kirish o‘lchami esa yetti kunlik sirpanib boruvchi oyna orqali 70 ga teng qilib olindi. Tahlil ikki bosqichda yuritildi: avval har bir rejim alohida ko‘zdan kechirildi, so‘ng ularning ketma-ket ishlashi natijasida hosil bo‘lgan to‘liq metamodel yakuniy ko‘rsatkich sifatida qayd etildi.

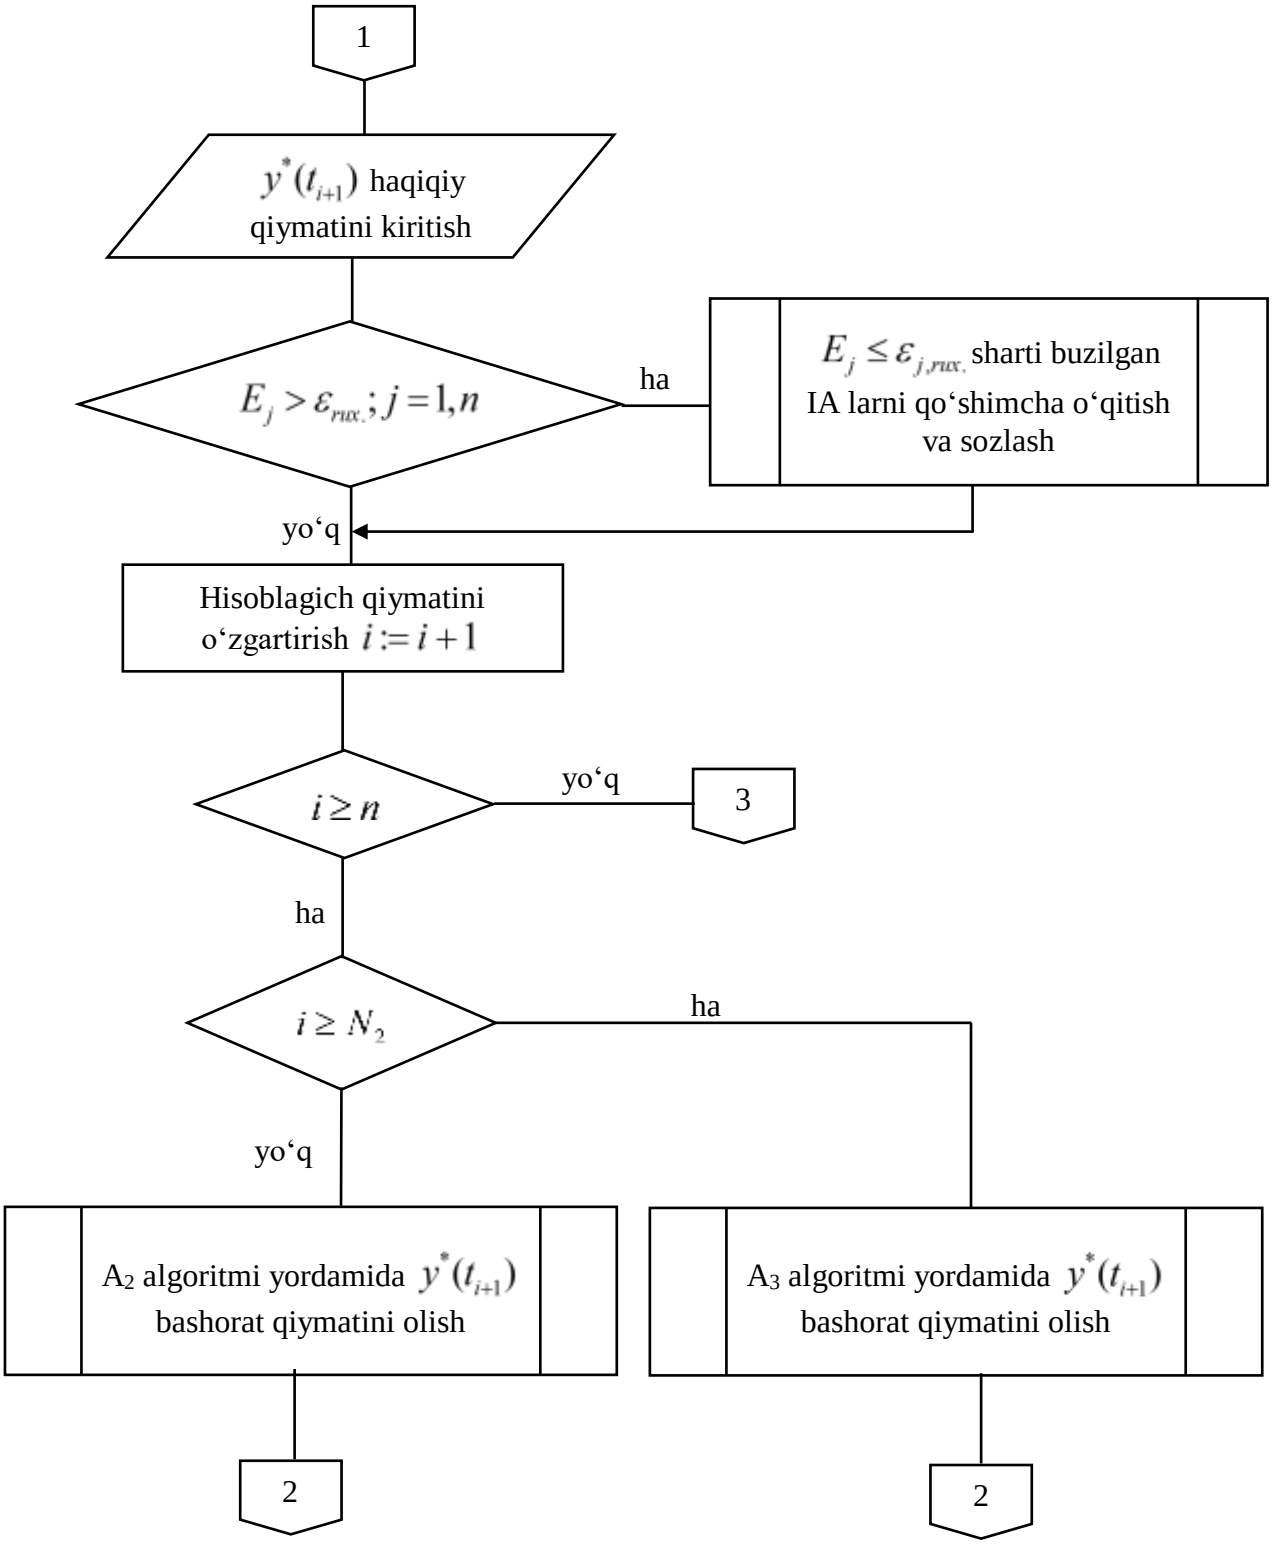


1- rasm. Sust shakillangan jarayonlarni bashoratlash IA ansamblining ishlash algoritmi blok-sxemasi

.

(cc) BY *dtai.uz*

ISSN: 3030-3346



2 - rasm. Sust shakillangan jarayonlarni bashoratlash IA ansamblining ishlash algoritmi blok-sxemasi. NT-neyron tarmoq. NNM-neyro-noravshan model.

3. Natijalar

Sinov davri davomida A3 qaysi modelni qachon tanlagani kuzatilganda, kutilgan naqsh tasdiqlandi: LSTM asosan nisbatan barqaror, trendga ega oraliqlarda yetakchilik qildi, GRU esa meteorologik ko‘rsatkichlar keskin sakragan qisqa oraliqlarda tezroq “moslashib” ustunlikka chiqdi. ANFIS ning silliqlash xususiyati lokal tekis segmentlarda foydali bo‘lib chiqdi, MLP esa vaqti-vaqti bilan, ayniqsa qisqa va nisbatan oddiy oraliqlarda, eng past bashoratlangan xatoni ko‘rsatdi. 1-jadvalda ushbu kuzatuv umumlashtirilgan.

(cc) BY

1-jadval.

IA lar farqli jadvali.

Vaqt oynasi turi	Tez-tez tanlangan IA	Kuzatilgan sabab
O‘rta muddatli stasionar tendensiya	LSTM	Uzoq xotira ustunligi
Tez o‘zgaruvchan meteo-sharoit	GRU	Tezkor moslashuvchanlik
Lokal silliq oraliqlar	ANFIS	Qoidaviy silliqlash effekti
Qisqa barqaror oraliqlar	MLP	Statik akslantirish yetarli

Bu yerda bitta mulohaza qilib o‘tish joiz: jadvaldagi taqsimot statistik ma’noda qat’iy emas - u sifatli (qualitative) kuzatuvlarga asoslangan umumlashtirish bo‘lib, har bir toifa uchun aniq foiz yoki namunalar soni keltirish, afsuski, hozirgi eksperiment protokolida alohida qayd etilmagan. Kelgusi ishlarda buni raqamli jadvalga aylantirish maqsadga muvofiq bo‘lardi.

Yakuniy taqqoslash 2-jadvalda keltirilgan. To‘liq metamodel sinov tanlamasida 0.1985 RMSE ko‘rsatkichini berdi. Shuni alohida ta’kidlash lozimki, bu raqam butun tizimning - ya’ni A1, A2 va A3 birgalikda ishlagan holatdagi - yakuniy natijasi bo‘lib, chunki hisoblash eksperimenti to‘liq metamodel bo‘yicha o‘tkazilgan va A2 alohida, izolyatsiya qilingan holda qayta sinovdan o‘tkazilmagan.

2-jadval.

Algoritimlarni natijalari.

Yondashuv	RMSE
Eng yaxshi yakka model (LSTM)	0.2600
Statik robast kombinatsiya (faqat A2)	~0.20*
To‘liq moslashuvchan metamodel (A1→A2→A3)	0.1985

Aynan shu nuqta ushbu tadqiqotning eng zaif joyi hisoblanadi va buni yashirishning hojati yo‘q: biz A1, A2 va A3 ning har birining yakuniy natijaga qo‘shgan alohida hissasini hozircha ajrata olmaymiz, chunki tajriba ularni ketma-ket, bitta yaxlit oqim sifatida sinagan. Boshqacha aytganda, 0.1985 raqami - butun tizimning natijasi, dinamik seleksiyaning “sof” yutug‘i emas. Buni aniqlashtirish uchun kamida uchta qo‘shimcha sinov kerak: faqat A1, faqat A2 va A1+A2 rejimlarida bir xil ma’lumotda alohida hisoblash.

[ATTENTION: Insert Figure here - Vaqt oynalari bo‘yicha A3 tomonidan tanlangan optimal IA ning taqsimoti]

4. Muhokama

Nazariy jihatdan, dinamik seleksiya statik kombinatsiyaga nisbatan afzal bo‘lishi kerak, chunki u vaqt bo‘yicha o‘zgaruvchan kompetentlikni hisobga oladi - bu fikr adabiyotda ham keng qo‘llab-quvvatlanadi [2, 3, 5]. Bizning kuzatuvlarimiz ham shu yo‘nalishda: turli vaqt oynalarida turli model yetakchilik qilishi, A3 ning bu farqni real vaqtda ushlab olishi - bularning barchasi yondashuvning mantiqiy asosliligini ko‘rsatadi.

Ammo xolisona aytganda, hozirgi ko‘rinishdagi tadqiqot bir nechta jiddiy bo‘shliqqa ega. Eng avvalo, yuqorida aytilgan ablation muammosi - A1, A2, A3 ning alohida hissasi noaniqligi - natijaning ilmiy talqinini qiyinlashtiradi. Bundan tashqari, mustahkamlash mexanizmidagi R va P funksiyalari, shuningdek $K_i(t)$ formulasidagi α, β, γ koeffitsientlari grid-search yoki boshqa sistematik usul bilan emas, tajriba-xato yo‘li bilan tanlangan; bu koeffitsientlarning boshqa ma’lumotlar to‘plamida qanday ishlashi noma’lum. Yana bir masala - taklif etilgan metod hozircha faqat bitta baseline, ya’ni statik robast kombinatsiya bilan solishtirilgan, holbuki adabiyotda mavjud boshqa DES usullari (masalan, [3, 5] da tavsiflangan yondashuvlar) bilan bevosita qiyoslash o‘tkazilmagan - bu qiyoslashsiz “eng yaxshi” degan xulosaga kelish erta.

Shunga qaramay, natijalar amaliy nuqtai nazardan qiziqarli: hisoblagichga asoslangan uch bosqichli rejim tizimni ma’lumot yetishmasa ham ishlashga, ma’lumot yetarli bo‘lganda esa nozikroq mexanizmlarga o‘tishga imkon beradi - bu amaliy joriy etish nuqtai nazaridan foydali xususiyat, chunki real muassasada tarixiy ma’lumot hajmi har doim ham bir xil bo‘lavermaydi.

(cc) BY

5. Xulosa

Ushbu maqolada sust shakllangan jarayonlarni bashoratlash uchun vaznli ovoz berish, robast kombinatsiya va prognostik xatoga tayanuvchi dinamik seleksiyani ketma-ket birlashtiruvchi moslashuvchan metamodel taklif qilindi. Metodning markazida - har bir bazaviy modelning kelgusi xatosini oldindan bashoratlovchi yordamchi tarmoq va shu bashoratga asoslangan mukofotlash-jarimalash mexanizmi yotadi. YQTK bo‘yicha o‘tkazilgan tajriba metodning ishlash qobiliyatini tasdiqladi, biroq A1, A2 va A3 bosqichlarining alohida hissasini aniqlashtiruvchi ablation tadqiqot, mustahkamlash parametrlarini sistematik optimallashtirish hamda mavjud DES usullari bilan to‘g‘ridan-to‘g‘ri qiyoslash - bularning barchasi kelgusi ishning aniq va zarur davomi sifatida qoladi.

Foydalanilgan adabiyotlar

1. Bertsimas D., Boussioux L. Ensemble Modeling for Time Series Forecasting: an Adaptive Robust Optimization Approach // arXiv:2304.04308. – 2023.
2. Britto A.S. Jr., Sabourin R., Oliveira L.E.S. Dynamic selection of classifiers – A comprehensive review // Pattern Recognition. – 2014. – Vol. 47, No. 11. – P. 3665–3680.
3. Cruz R.M.O., Sabourin R., Cavalcanti G.D.C. Dynamic classifier selection: Recent advances and perspectives // Information Fusion. – 2018. – Vol. 41. – P. 195–216.
4. Saadallah A., Jakobs M., Morik K. Online Ensemble Aggregation using Deep Reinforcement Learning for Time Series Forecasting // Proceedings of IEEE DSAA 2021. – 2021. – P. 1–8.
5. Silva E.G., Cavalcanti G.D.C., Ren T.I. A Dynamic Predictor Selection Method Based on Recent Temporal Windows for Time Series Forecasting // IEEE Access. – 2021. – Vol. 9. – P. 108466–108479.
6. Fu Y., Wu D., Boulet B. Reinforcement Learning Based Dynamic Model Combination for Time Series Forecasting // Proceedings of the AAAI Conference on Artificial Intelligence. – 2022. – Vol. 36, No. 6. – P. 6639–6647.
7. Pulatov G. Development of an ANFIS neuro-fuzzy model for forecasting weakly structured processes // Modern American Journal of Engineering, Technology, and Innovation. – 2026. – Vol. 2, No. 3. – P. 18–26.
8. Pulatov G., Pulatova G. Neural network prediction of the frequency of admission of patients with cardiovascular diseases to clinical institutions // Eureka Journal of Artificial Intelligence and Data Innovation (EJAIDI). – 2026. – Vol. 2, No. 3. – P. 46–54.
9. Kabildjanov A., Pulatov G. Neural Network Forecasting of “Quality of the Day” for the Category of People Sensitive to Weather with Cardiovascular Diseases // Journal of Communications Software and Systems. – 2025. – Vol. 21, No. 4. – P. 496–503.
10. Moura T.J.M., Cavalcanti G.D.C., Oliveira L.S. MINE: A framework for dynamic regressor selection // Information Sciences. – 2021. – Vol. 543. – P. 157–179.
11. Cesa-Bianchi N., Lugosi G. Prediction, Learning, and Games. – Cambridge University Press, 2006.
12. Krogh A., Vedelsby J. Neural network ensembles, cross validation, and active learning // Advances in Neural Information Processing Systems. – 1995. – Vol. 7. – P. 231–238.
13. Zhang Z.-L., Liu X.-W., Yan W.-J. DES-AS: Dynamic ensemble selection based on algorithm Shapley // Pattern Recognition. – 2025. – Vol. 158. – Article 111062.

(cc) BY