

УДК: 556.16

**ПИСКОМ ДАРЁСИ ОҚИМИНИ ТУРЛИ ПРОГНОЗЛАШ МОДЕЛЛАРИ АСОСИДА
БАҲОЛАШНИНГ ИЛМИЙ АСОСЛАРИ****Ў.А. БАЛХИЕВ^{1*}, К.Ф. ҒОФУРЖОНОВ¹, Д.М. ТУРҒУНОВ¹**¹ Гидрометеорология илмий-тадқиқот институти, balxiyevo@gmail.com

Аннотация. Ушбу мақолада Писком дарёси ҳавзасидаги метеорологик маълумотлар асосида Machine Learning (ML) моделларидан фойдаланиб сув сарфини прогнозлаш имкониятлари ўрганилди. Мақолада Писком дарёси оқими билан метеорологик омиллар орасидаги боғланишлар Random Forest, XGBoost ва LSTM моделлари асосида кўрилди ҳамда уларнинг аниқлиги турли баҳолаш кўрсаткичлари (MAE, RMSE, R² ва NSE) орқали таққосланди. Таҳлиллар шуни кўрсатдики, Random Forest модели Писком дарёси сув сарфини юқори аниқлик билан прогнозлашда энг самарали натижани берди. Тадқиқот натижалари дарё оқимини миқдорий баҳолаш ва сув ресурсларини бошқаришда ML моделлари самарали восита бўлиши мумкинлигини кўрсатади.

Калит сўзлар: дарё ҳавзаси, дарё оқими, сув сарфи, метеорологик омиллар, дарё оқимини прогнозлаш моделлари, Machine Learning, Random Forest, XGBoost, LSTM, прогнозлаш аниқлиги.

Кириш. Сўнгги йилларда дунё миқёсида сув ресурсларига бўлган талаб йилдан-йилга ортиб бормоқда. БМТ маълумотларига кўра, 2050 йилга бориб дунё аҳолиси 9,7 миллиард кишига етиши кутилмоқда [UN ..., 2022], бу эса сувдан фойдаланиш ҳажмининг кескин ортишига олиб келади. Шу билан бирга, иқлим ўзгариши атмосфера ёғинларининг тақсимооти, буғланиш жараёнлари ва дарё оқимларига сезиларли таъсир кўрсатмоқда. Хусусан, қурғоқчилик ва тошқин хавфларининг кучайиши, сув ресурсларининг ҳудудий ва мавсумий нотекис тақсимланиши инсоният учун катта хавф туғдирмоқда. Бу эса, ўз навбатида, гидрологик прогнозлар соҳасида замонавий гидрологик тадқиқотларни олиб боришни тақозо этади.

Бугунги кунда Марказий Осиё минтақаси, жумладан, Ўзбекистонда гидрологик прогнозлар сув ресурсларини интеграллашган ҳолда бошқариш, гидроэнергетика, қишлоқ хўжалиги, саноат, сув тошқинлари хавфини камайтириш, қурғоқчиликни юмшатиш каби масалалар бўйича қарорлар қабул қилишда биринчи даражали аҳамиятга эга.

Анъанавий гидрологик моделлар (масалан, сув баланси моделлари, физика асосидаги детерминистик ёндашувлар) кўплаб параметр ва мураккаб тенгламаларни талаб қилади. Амалий шароитда бундай моделлар учун зарур бўлган маълумотларни тўплаш қийин, натижалари эса ҳар доим ҳам юқори аниқлик бермайди. Шу сабабли, сўнгги йилларда гидрологияда ML (Machine Learning) ва сунъий интеллект усулларидан фойдаланиш тобора кенгаймоқда.

ML усуллари гидрологик кузатув маълумотлардан ўхшашлик ва боғлиқликларни автоматик аниқлайди ва бу асосда прогноз тузади. Масалан, Random Forest, XGBoost ва LSTM каби моделлар вақт қаторлари билан самарали ишлай олади. ML усуллари нафақат қисқа муддатли прогнозлар, балки иқлим сценарийлари асосида узоқ муддатли прогнозлар учун ҳам қўлланилиши мумкин [Kratzert et al., 2019].

Тадқиқотнинг асосий мақсади – Писком дарёси оқими билан метеорологик омиллар – ҳаво ҳароратлари ва атмосфера ёғинлари орасидаги боғланишларни аниқлаш, ML моделларини қўллаш орқали дарё оқимини прогнозлаш, моделлар аниқлигини турли баҳолаш методлари ёрдамида таққослаш ҳамда сув ресурсларини бошқаришда ушбу ёндашувнинг самарадорлигини ёритишдан иборатдир.

* Масъул муаллиф: balxiyevo@gmail.com, тел.: +998947773007

Бирламчи маълумотлар. Тадқиқот ишида Писком дарёси ҳавзасидаги танланган метеорологик станция ва гидрологик постда кузатилган кундалик сув сарфи, кундалик ўртача ҳаво ҳарорати ва кундалик атмосфера ёғинлари миқдорининг кўп йиллик (1991–2024 йй.) маълумотлари тўпланди ва таҳлил қилинди.

Услубият. Ишни бажаришда Machine Learning алгоритми бўлган Random Forest, XGBoost (Extreme Gradient Boosting), LSTM (Long Short-Term Memory) моделларидан фойдаланилди. Шунингдек, ишда қўлланилган моделларнинг аниқлигини ошириш мақсадида Lag features, Rolling features ва Validatsiya каби усуллардан фойдаланилди.

Lag features (кечкикиш хусусияти). Вақт қаторларида ҳозирги ҳолат кўпинча аввалги қийматларга боғлиқ бўлади. Шу сабабли, дарё оқимини прогноزلашда олдинги кунларнинг қийматлари (**lag features**) қўлланилди. Масалан, $Q(t-1)$, $Q(t-2)$, $Q(t-7)$ каби хусусиятлар ёрдамида модел дарё оқимининг вақт бўйича кечиккан таъсирини ўрганади. Бу ёндашув гидрологик жараёнларда мавжуд бўлган инерция ва кечикишни ҳисобга олиш имконини беради.

Rolling features. Дарё оқимида қисқа муддатли тебранишлар билан бир қаторда умумий тенденциялар ҳам муҳим аҳамиятга эга. Масалан, $Q(t-7)$ – охирги 7 кунлик сув сарфининг ўртача қиймати ёки $X(t-30)$ – охирги 30 кунлик ёғин миқдори. Ушбу кўрсаткичлар дарё оқимини мавсумий хусусиятларини яхшироқ ифодалайди.

Validation. Моделни баҳолаш учун вақт қаторлари асосида *ўргатувчи* ва *назорат* бўлиниши амалга оширилди. Дастлабки давр (1991–2015 йиллар) *ўргатувчи* сифатида, сўнгги давр (2016–2020 йиллар) эса *назорат* сифатида ажратилди. Бундай бўлиниш моделни келажакдаги даврларни прогноزلашга яқинроқ шароитда синовдан ўтказиш имконини беради.

Юқорида келтирилган Random Forest, XGBoost, ва LSTM моделлари сув ресурслари прогноزلаш жараёнида кенг қўлланиши мумкин. Ҳар бир моделнинг ўзига хос афзалликлари ва чекловлари мавжуд бўлиб, маълумотларнинг хусусияти, прогноз мақсади ҳамда мавжуд ресурслардан келиб чиққан ҳолда мос модел танланади. Шу билан бирга, баҳолаш мезонлари сифатида MAE, RMSE, R^2 ва NSE каби кўрсаткичлар қўлланилиши модел натижаларини илмий асосда солиштириш ва таҳлил қилиш имконини беради.

Баҳолаш мезонлари. Ишда олинган натижалар иккита асосий тоифадаги тўртта статистик кўрсаткичдан фойдаланган ҳолда баҳоланди (1-жадвал): **Хатолик катталиги** (RMSE, MAE) ва **Мослик ёки Корреляция** (R^2 , NSE) [Nishonov, Abdurakhmanov, 2025].

1-тоифа Хатолик катталиги:

a) MAE (Mean Absolute Error) – Ўртача абсолют хатолик

$$MAE = \left(\frac{1}{n}\right) * \sum_{i=1}^n |y_i - \hat{y}_i| \quad (1)$$

b) RMSE (Root Mean Squared Error) – ўртача квадратли четлашиш

$$RMSE = \sqrt{\left(\left(\frac{1}{n}\right) * \sum_{i=1}^n (y_i - \hat{y}_i)^2\right)} \quad (2)$$

2-тоифа Мослик ёки Корреляция:

a) R^2 (детерминация коэффиценти)

$$R^2 = \frac{(\sum (y_i - \hat{y}_i)(y_i - \bar{y}))^2}{\sum (y_i - \hat{y}_i)^2 \sum (y_i - \bar{y})^2} \quad (3)$$

b) NSE (Nash–Sutcliffe Efficiency) – Неш-Сатклиф самарадорлиги

$$NSE = 1 - \left(\frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2}\right) \quad (4)$$

Бу ерда y_i – ҳақиқий қиймат, $\hat{y}_i$ – модел прогнози, n – кузатувлар сони.

1-жадвал

Статистик усулларнинг қийматлари

Таблица 1

Значения статистических методов

Table 1


Values of statistical methods

N	Статистик кўрсаткичлар	Ўлчаш кўрсаткичи	Оралик	Энг яхши қиймат
1	MAE	Кузатилган ва прогноз қилинган қийматлар орасидаги ўртача абсолют фарқни кўрсатади	0 дан ∞ гача	0 га яқин бўлиши яхши
2	RMSE	Катта хатоликларга кўпроқ эътибор берадиган умумий аниқлик ўлчови	0 дан ∞ гача	0 га яқин бўлиши яхши
3	R ²	Модел кузатилган қийматлардаги ўзгарувчанликни кўрсатади	0 дан 1 гача	1 га яқин бўлиши яхши
4	NSE	Модел натижалари кузатилган маълумотларга яқинлигини баҳолайди	$-\infty$ дан 1 гача	0 га яқин бўлиши яхши

Асосий натижалар ва уларнинг муҳокамаси. Ишда тадқиқот объекти сифатида танлаб олинган Писком дарёси Чирчиқ дарёсининг йирик ирмоқларидан бири ҳисобланади (1-расм). У қишлоқ хўжалиги, ичимлик суви таъминоти ва гидроэнергетика учун муҳим манба бўлиб хизмат қилади. Шу боис, дарёда шаклланадиган сув ресурсларидан фойдаланишни режалаштириш, сув тақчиллиги ва тошқин хавфларининг олдини олиш, шунингдек, экологик барқарорликни таъминлашда алоҳида аҳамиятга эга. Писком дарёсининг умумий узунлиги 70 км, сув йиғилиш майдони эса 2840 км² га тенг. Писком дарёси Майдонтол ва Ойгаинг дарёларининг қўшилишидан ҳосил бўлади. Бу икки дарёнинг сув йиғилиш майдони биргаликда Писком дарёси сув йиғилиш майдонининг ярмидан кўпроғини (55%) ташкил этади.

Писком чуқур водийда тез оқадиған тоғ дарёсидир. Дарёнинг юқори оқимида водий ён бағирлари жуда тик ва баланд. Дарёнинг қуйи оқимида эса улар анча ётиқ ва паст. Дарёнинг фақат бошланиш қисмидагина яққол шаклланган анча кенг (200-250 м) қайир ҳосил бўлган. Дарёнинг ўрта ва қуйи оқимида эса қайир онда-сонда учрайди. Дарёнинг ўзани ўртача эгри-бугри, водий кенгайган ва қайир ҳосил бўлган жойларда бир нечта тармоқларга ажралиб, ўз қиёфасини тез-тез ўзгартириб турадиган кичкина-кичкина ороллар ҳосил қилган.

Писком дарёсининг асосий ташкил этувчилари бўлган Майдонтол ва Ойгаинг дарёларининг сув йиғиш майдонлари Чирчиқ ҳавзасидаги бошқа дарёлардан баланд (Майдонтол – 3016 м, Ойгаинг – 2998 м). Ушбу дарёларнинг ҳавзаси нам ҳаво массаларига очик ва қулай жойлашганлиги туфайли дарёлар ҳавзасида қор кўп ёғади ва қор чизиғи анча пастдан ўтган. Ҳавзада абадий қор ва музликлар ҳам нисбатан кўпроқ. Чирчиқ ҳавзасида ҳисобга олинган музликларнинг деярли 3/4 қисми (173 км² дан 129 км²) ёки 222 та музликдан 140 таси Писком ҳавзасида, асосан Майдонтол ва Ойгаинг дарёларининг сув йиғиш майдонида жойлашган [Шульц, Машрапов, 1969].




1-расм. Писком дарё ҳавзасининг гипсографик харитаси

Рис. 1. Гипсографическая карта бассейна реки Пскем

Fig. 1. Hypsographic map of the Pskem river basin

Писком дарёсининг ўртача йиллик сув сарфи $56-118 \text{ м}^3/\text{с}$ оралиғида ўзгариб туради. Ўрта ҳисобда Писком дарёсида йиллик оқимнинг 47 фоизи март-июнь даврида, қарийб 38 фоизи июль – сентабр даврида ва қолган 15 фоизи октябрь-февраль даврида оқиб ўтади (2-расм). Бироқ, шуни кўрсатиб ўтиш зарурки, айрим йилларнинг иқлимий хусусиятларига боғлиқ ҳолда оқимнинг йил ичида тақсимланиши юқори кўрсатилгандан анча ўзгача бўлиши ҳам мумкин.




2-расм. Писком дарёси оқимининг йиллараро ўзгариши

Рис. 2. Межгодовые изменения стока реки Пскем

Fig. 2. Interannual changes in Piskom river water discharge

Тадқиқотнинг асосий мақсадидан келиб чиққан ҳолда, Писком дарёси оқимининг 1996–2024 йиллардаги ўзгаришларини баҳолашда Machine Learning алгоритмлари – Random Forest, XGBoost (Extreme Gradient Boosting) ва LSTM (Long Short-Term Memory) моделларнинг асосий ўзгарувчилари сифатида метеорологик кўрсаткичлар (ёғин миқдори – X , ҳаво ҳарорати – T) танланди. Бунда, дарёда кузатилган ўртача ойлик сув сарфлари (Q), ўртача ойлик ҳаво ҳарорати (T) ва ойлик атмосфера ёғинлари ҳақидаги гидрометеорологик маълумотлардан фойдаланилди (3-расм).



3-расм. Писком дарёсида сув сарфи (Q), ҳаво ҳарорати (T) ва ёғин миқдори (X) ўртасидаги мавсумий Пирсон корреляцияси

Рис. 3. Сезонная корреляция Пирсона между расходом воды (Q), температурой воздуха (T) и количеством осадков (X) в реке Пскем

Fig. 3. Seasonal Pearson correlation between discharge (Q), temperature (T) and precipitation (X) in the Pskem river

Пирсон корреляция кўрсаткичлари (r) бўйича мавсумий таҳлил қуйидаги натижаларни берди.

Сув сарфи (Q) ва ёғин миқдори (X) ўртасидаги боғлиқлик ёзги мавсумда (апрель-сентябрь) ижобий ($r = 0,77$), қишда (октябрь–март) эса ўртача ($r = 0,53$). Бу ёғиннинг гидрологик оқимга асосий таъсир этувчи омиллардан бири эканини кўрсатади.

Сув сарфи (Q) ва ҳаво ҳарорати (T) ўртасида ёзги мавсумда ижобий корреляция ($r = 0,74$), қишда эса ўртача ($r = 0,65$) аниқланди. Бу ҳаво ҳароратининг оқим шаклланиш жараёнлари ва мавсумий оқим ўзгаришларига таъсирини акс эттиради.


Ҳаво ҳарорати (T) ва ёғин миқдори (X) ўртасида ёзги мавсумда ўртача ижобий боғлиқлик ($r = 0,67$), қишда эса заиф ($r = 0,40$) кузатилди. Бу метеорологик жараёнларнинг ўзаро таъсирининг мавсумга боғлиқлигини ифодалайди.

Мазкур мавсумий статистик боғланишлар ML моделларида атмосфера ёғинлари ва ҳаво ҳарорати маълумотларидан дарё оқимини прогнозлашда фойдаланиш юқори аниқликдаги натижаларга эришишни таъминлайди. Шу сабабли, ишда ушбу ўзгарувчилар моделларнинг асосий ўзгарувчилари сифатида танланди. Боғланишлардаги фарқларни инобатга олган ҳолда, мавсумий индикаторларни қўшиш орқали прогнозлаш сифатини оширишга эришилди.

Ишнинг кейинги босқичида Machine Learning алгоритми бўлган Random Forest, XGBoost (Extreme Gradient Boosting), LSTM (Long Short-Term Memory) моделлари ёрдамида Писком дарёси оқими 1996-2024-йиллар даври учун баҳоланди [Pedregosa et al., 2021].

Random Forest – ансамбль услубидаги ML алгоритми бўлиб, кўплаб статистик таҳлиллар ёрдамида прогноз беради (4-расм). Модел ҳар бир қатор натижасини бирлаштириб, янада барқарор ва ишончли прогнозга эришади. Ушбу ёндашув ҳаддан ташқари ўрганиш (overfitting) муаммосини камайтиради ва турли хил маълумот турларида

яхши натижа беради. Random Forest афзалликлари у юқори аниқликда ишлайди ва мураккаб боғланишларни аниқлаш имкониятини беради. Random Forest моделининг яна бир устун жиҳати – унинг чидамлилиги. Агар маълумотлар орасида ноаниқликлар, етишмовчиликлар ёки шовкин (noise) бўлса ҳам, у умумий тебранишни тўғри аниқлай олади. Бу хусусият гидрологик маълумотлар билан ишлашда айниқса муҳим. Камчиликлари эса кўп устунлар ишлатилганда ҳисоблаш тезлиги секинлашади ва модел ички механизмини тушунтириш (яъни, қайси омил прогнозга қанчалик таъсир қилганини аниқ ифода этиш) қийин. Шундай бўлса-да, Random Forest кўп ҳолларда гидрологик ва метеорологик прогнозлаш вазифалари учун ишончли, барқарор ва аниқ модел сифатида тавсия этилади [Machine ..., 2025].




4-расм. Писком дарёси оқимини Random Forest модели ёрдамида баҳолаш

Рис. 4. Оценка стока реки Пскем с использованием модели Random Forest

Fig. 4. Assessment of the Piskom river water flow using the Random Forest model

XGBoost (Extreme Gradient Boosting) – градиентли кучайтириш алгоритмининг самарали ва тез ишловчи версияси ҳисобланади (5-расм). Модел кетма-кет қурилган қаторлар ёрдамида ишлайди, яъни ҳар бир янги қатор олдинги қатор хатоларини тузатишга ҳаракат қилади. Шу сабабли юқори аниқлик ва тезликка эришилади. Ушбу моделда прогноз аниқлиги юқори, катта ҳажмдаги маълумотлар билан тез ишлайди, мослашувчан параметрлар мавжуд. Камчилиги – модел параметрлари кўп бўлганилиги сабабли созлаш мураккаб, Шунингдек, катта ҳажмдаги маълумотларда моделни ўқитиш жараёни айрим ҳолларда катта ҳисоблаш ресурсларини талаб қилиши мумкин [XGBoost ..., 2025].

Random Forest ва XGBoost моделлари ансамбл усулига асосланган, шунингдек, ҳар икки усул ҳам натижанинг четлашиш (overfitting) муаммосини камайитишга қаратилган бўлиб, турли типдаги маълумотлар билан ишлашда барқарор натижа беради. Фарқи шундаки, Random Forest статистик таҳлилларни мустақил равишда ўргатиб, натижани *random* ёки ўртача қиймат орқали аниқлайди. У содда ва барқарор, аммо ҳисоблаш тезлиги нисбатан паст. XGBoost эса статистик таҳлиллари кетма-кет ўргатади, яъни ҳар бир қатор олдинги хатоларни тузатишга қаратилган бўлади. Бу усул юқори аниқлик ва тез ишлашни таъминлайди, аммо параметрларни нотўғри танлаш ҳолатида overfitting хавфини оширади [XGBoost ..., 2025].




5-расм. Писком дарёси оқимини XGBoost модели ёрдамида баҳолаш

Рис. 5. Оценка стока реки Пскем использованием модели XGBoost

Fig. 5. Assessment of the Piskom River water flow using the XGBoost model

LSTM (Long Short-Term Memory) – чуқур ўрганишга асосланган такрорланувчи нейрон тармоқ тури бўлиб, вақт қаторларида узоқ муддатли боғланишларни аниқлаш имкониятига эга (6-расм). Модел “хотира хужайралари” орқали маълумотларни сақлаб туриши ва керак бўлганда янгилаб бориши билан бошқа нейрон тармоқлардан фарқ қилади. Афзалликлари вақт қаторларидаги узоқ муддатли тенденцияларни самарали аниқлайди, мураккаб ва чизиқли бўлмаган боғланишларни ҳисобга олади. Камчиликлари ўқитиш жараёни секин, катта ҳажмдаги маълумот ва ҳисоблаш ресурсларини талаб қилади [LSTM ..., 2025].



6-расм. Писком дарёси оқимини LSTM модели ёрдамида баҳолаш

Рис. 6. Оценка стока реки Пскем использованием модели LSTM

Fig. 6. Assessment of the Piskom river water flow using the LSTM model

4, 5 ва 6-расмларда келтирилган графиклардан кўриниб турибдики, моделларнинг дарё оқимини баҳолашдаги ишлаши фарқ қилади. Ушбу натижаларни янада чуқур таҳлил қилиш мақсадида ишда моделлардан олинган натижалар аниқлиги баҳоланди (2-жадвал).

2-жадвал

ML моделларини баҳолаш

Таблица 2


Оценка моделей ML

Table 2

Evaluation of ML models

	RandomForest	XGBoost	LSTM
MAE	1,925	2,496835	3,725286
RMSE	3,509	4,664222	5,653058
R ²	0,996	0,994598	0,992006
NSE	0,983	0,975691	0,989253

Ўтказилган таҳлиллар натижасида Писком дарёси сув сарфини прогноزلашда турли ML моделлари – Random Forest, XGBoost ва LSTM моделлари синовдан ўтказилди. Баҳолаш натижалари шуни кўрсатдики, барча моделлар юқори аниқликка эга бўлишига қарамай, Random Forest модели энг оптимал натижаларни тақдим этди. Аниқроғи, Random Forest модели учун MAE = 1,925, RMSE = 3,509, R² = 0,996 ва NSE = 0,983 қийматлари олинди. Бу кўрсаткичлар XGBoost (MAE = 2,496, RMSE = 4,664, R² = 0,994, NSE = 0,976) ҳамда LSTM (MAE = 3,725, RMSE = 5,653, R² = 0,992, NSE = 0,989) моделлари натижаларига нисбатан бироз яхшироқдир (7-расм).



Қора чизиқ - 1991-2010 йиллардаги ҳақиқий сув сарфи (ўқитиш маълумоти) | Яшил чизиқ - 2011-2020 йиллардаги ҳақиқий сув сарфи | Қизил чизиқ - RandomForest модели прогнозлари | Тўқ сариқ чизиқ - XGBoost модели прогнозлари | Мовий чизиқ - LSTM модели прогнозлари

7-расм. ML моделларининг валидацияси

Рис. 7. Валидация моделей ML


Fig. 7. Validation of ML models

Тадқиқот ишида ўтказилган таҳлиллар асосида Random Forest моделининг қуйидаги устунликлари асосланди.

1. **Ансамбл хусусияти** – Random Forest бир нечта статистик таҳлиллар яратиб, уларнинг ўртача натижасини ҳисоблайди. Натижада, модел четлашиши (overfitting) муаммосини камайтиради ва умумлаштириш қобилиятини оширади.

2. **Мураккаб чизикли бўлмаган боғлиқликларни аниқлаш қобилияти** – дарё оқими, ҳаво ҳарорати ва атмосфера ёғинлари миқдори ўртасидаги чизикли бўлмаган боғланишларни самарали таҳлил қилади (8-расм).


3. **Параметрларни созлашнинг оддийлиги** – XGBoost ва LSTM моделлари билан солиштирганда, Random Forest нисбатан камроқ гиперпараметрларни талаб қилади, бу эса уни амалий жиҳатдан қулайроқ қилади (9-расм).



8-расм. Кузатилган ва прогноз қилинган сув сарфларининг қийматлари ўртасидаги боғланиш графиги

Рис. 8. График связи между наблюдаемыми и прогнозируемыми значениями расхода воды

Fig. 8. Graph of the relationship between observed and predicted discharge values



9-расм. Random Forest модели валидацияси

Рис. 9. Валидация модели Random Forest

Fig. 9. Validation of the Random Forest model

Хулоса қилиб айтганда, олинган натижалар Писком дарёси оқимини ўрганишда **Random Forest** моделининг **ишончли ва барқарор** восита эканини кўрсатади (8-9-расмлар). Шу сабабли, ушбу модел келгусида бошқа тоғ дарёлари ёки сув ҳўжалиги ҳавзаларида ҳам самарали қўлланилиши мумкин.

Муаллифлар хиссаси. **Ў.А. Балхиев:** маълумотларни йиғиш, қайта ишлаш, натижалар таҳлили, мақола матнини ёзиш. **К.Ф. Ғофуржонов:** маълумотларни йиғиш ва қайта ишлаш. **Д.М. Турғунов:** мақола ғояси, методология, объектни танлаш, мақолани

тахрир қилиш, илмий раҳбарлик. Барча муаллифлар қўлёзманинг нашрга тайёрланган матнини ўқиб чиқдилар ва ўз розиликларини билдирдилар.

АДАБИЁТЛАР

- Шульц В.Л., Маиранов Р. Ўрта Осиё гидрографияси. – Тошкент: Ўқитувчи, 1969. – 327 б.
- Nishonov B. E., Abdurakhmanov, M. M. Evaluation of ERA5 reanalysis data with observed data in the Akhangaran River Basin // Hydrometeorology and Environmental Monitoring, 2025. №1. – PP. 28-38.
- Kratzert F., Klotz D., Brenner C., Schulz K., Herrnegger M. Rainfall–runoff modelling using long short-term memory (LSTM) networks // Hydrology and Earth System Sciences, 2023. №2. – PP. 19-48.
- Pedregosa, F., Varoquaux, G., Gramfort, A., Michel V., Thirion B., Grisel O., Duchesnay É. Machine Learning in Python // Journal of Machine Learning Research, 2021. №5. – PP. 23-39.
- Электрон ресурслар:
- UN “World Population Prospects 2022”. URL: <https://www.un.org>
- Machine Learning Tutorial. URL: <https://www.geeksforgeeks.org/machine-learning>
- XGBoost Tutorials. URL: <https://xgboost.readthedocs.io/en/stable/tutorials/model.html>
- LSTM Tutorials. URL: <https://scikit-learn.org/stable/modules/ensemble.html>

НАУЧНЫЕ ОСНОВЫ ОЦЕНКИ СТОКА РЕКИ ПСКЕМ НА ОСНОВЕ РАЗЛИЧНЫХ МОДЕЛЕЙ ПРОГНОЗИРОВАНИЯ

У.А. БАЛХИЕВ¹, К.Ф. ГОФУРЖОНОВ¹, Д.М. ТУРГУНОВ¹

¹ Научно-исследовательский гидрометеорологический институт, balxiyevo@gmail.com

Аннотация. В данной статье исследованы возможности прогнозирования расхода воды в бассейне реки Пскем на основе метеорологических данных с использованием моделей машинного обучения (ML). В статье изучены взаимосвязи между стоком реки Пскем и метеорологическими факторами на основе моделей Random Forest, XGBoost и LSTM, а их точность сравнивалась с использованием различных метрик оценки (MAE, RMSE, R^2 и NSE). Анализ показал, что модель Random Forest обеспечивает наилучшую точность при прогнозировании расхода воды реки Пскем. Результаты исследования свидетельствуют о том, что модели машинного обучения могут быть эффективным инструментом для предварительной оценки стока реки и управления водными ресурсами.

Ключевые слова: речной бассейн, речной сток, расход воды, метеорологические факторы, модели прогноза речного стока, Machine Learning, Random Forest, XGBoost, LSTM, точность прогноза.

SCIENTIFIC BASIS FOR ASSESSING THE PSKEM RIVER FLOW BASED ON VARIOUS FORECASTING MODELS

U.A. BALKHIEV¹, K.F. GOFURJONOV¹, D.M. TURGUNOV¹

¹ Hydrometeorological Research Institute, balxiyevo@gmail.com

Abstract. This article explores the possibilities of forecasting water discharge in the Piskom River basin based on meteorological data using Machine Learning (ML) models. The study establishes relationships between the Piskom River flow and meteorological factors using Random Forest, XGBoost,

and LSTM models, with their accuracy compared through various evaluation metrics (MAE, RMSE, R^2 , and NSE). The analysis demonstrates that the Random Forest model provides the highest accuracy in forecasting the water discharge of the Piskom River. The research results indicate that ML models can serve as an effective tool for preliminary assessment of river flow and water resource management.

Keywords: river basin, river flow, water discharge forecasting, meteorological factors, river flow forecasting models, Machine Learning, Random Forest, XGBoost, LSTM, forecasting accuracy.

REFERENCES

Shuls V.L., Mashrapov R. Orta Osiyo gidrografiya [Hydrography of Central Asia]. – Toshkent: Oqituvchi, 1969. – 327 s. (in Uzbek)

Electronic resources:

UN “World Population Prospects 2022”. URL: <https://www.un.org>

Machine Learning Tutorial. URL: <https://www.geeksforgeeks.org/machine-learning>

XGBoost Tutorials. URL: <https://xgboost.readthedocs.io/en/stable/tutorials/model.html>

LSTM Tutorials. URL: <https://scikit-learn.org/stable/modules/ensemble.html>