



Ўзбекистон Республикаси
Марказий банки

**Банк тизими ликвидлигини тўлов тизимлари
маълумотлари асосида прогнозлаштириш:
эконометрик ва машинавий ўқитиш усуллари
орқали**

Муаллиф: Ш. Махмудов

Пул-кредит сиёсати департаменти

Тошкент – 2025

Банк тизими ликвидлигини тўлов тизимлари маълумотлари асосида прогнозлаштириш: эконометрик ва машинавий ўқитиш усуллари орқали

Аннотация

Пул-кредит сиёсатини самарали амалга ошириш учун банк тизимининг ликвидлигини прогноз қилиш жуда муҳим аҳамиятга эга. Ушбу тадқиқот банк тизими ликвидлигининг автоном омилларини прогноз қилишда турли эконометрик ва машинавий ўқитиш (*Machine learning – ML*) моделларининг самарадорлигини ўрганади. Тадқиқот *SARIMA*, экспоненциал текислаш ва *Prophet* каби кенг қўлланиладиган эконометрик моделларни тасодифий ўрмон (*Random Forest*) ва сунъий нейрон тармоқларига (*artificial neural network*) асосланган *ML* моделлари билан таққослайди. Бундан ташқари, прогнозлар аниқлигини яхшилаш учун ансамбль (прогнозларни бирлаштириш) усулларида фойдаланилди. Тажрибалар натижалари шуни кўрсатадики, *SARIMA* энг яхши якка модел бўлди, аммо унинг *Prophet* ва тасодифий ўрмон билан ансамбли прогноз кўрсаткичларини янада яхшилади. Нейрон тармоқ моделлари архитектурасини оптималлаштиришдаги қийинчиликлар туфайли нисбатан пастроқ аниқликдаги прогнозлаш қобилиятини намоён этди. Келгуси тадқиқотларда прогнозларнинг аниқлигини ошириш учун кўп ўзгарувчи ва таркибий моделлар, шунингдек илғор нейрон архитектуралари устида изланишлар олиб бориш кўзда тутилган.

1 Кириш

Нархлар барқарорлигини таъминлаш каби бош мақсадга эга бўлган ҳар қайдай марказий банк учун банк тизими ликвидлигини ва банклараро кредитлар бўйича фоиз ставкаларини бошқариш муҳим аҳамиятга эга, чунки бу марказий банк қарорларини иқтисодиётга ўтказилишининг асосий воситасидир.

Пул-кредит операциялари бўйича ставкаларни аниқлашдаги асосий восита бўлиб Ўзбекистон Республикаси Марказий банкнинг асосий ставкаси ҳисобланади. Пул-кредит операцияларини амалга ошириш орқали Марказий банк овернайт депозитлари бўйича пул бозори фоиз ставкаларини фоиз коридори ичида асосий ставкага яқин даражада шакллантиришдан иборат бўлган ўзининг оператив мақсадига эришишга интилади. Бу эса асосий мақсад – инфляциянинг белгиланган таргети доирасида шаклланишига ёрдам беради.

Музкур тадқиқот иши Ўзбекистон тўлов тизимларининг катта ҳажмдаги маълумотларидан фойдаланган ҳолда банк тизимининг ликвидлигига таъсир этувчи автоном омилларни прогноз қилишда вақт қаторларини таҳлил қилиш учун қўлланиладиган турли хил эконометрик ва машинавий ўқитиш (ML) моделлари устида тажрибалар ўтказишга қаратилган. Бундан мақсад энг самарали моделларни аниқлаш ва улардан банк тизимининг умумий ликвидлигини прогноз қилиш учун фойдаланишдир. Ушбу тадқиқот мақсади ҳам илмий, ҳам сиёсий аҳамиятга эга бўлиб, марказий банкнинг пул-кредит операциялари доирасидаги прогнозларга бўлган муҳим эҳтиёжни қондиришга қаратилган.

Хусусан, муомаладаги нақд пуллар, ҳукумат операциялари ва соф ташқи активлар (марказий банкнинг маҳаллий ишлаб чиқарувчилардан монетар олтинни сотиб олиши, шунингдек, валюта интервенциялари) каби автоном омиллар банк тизимининг умумий ликвидлигини аниқлашда ҳал қилувчи рол ўйнайди. Ушбу омилларни тўғри прогноз қилиш марказий банклар учун очиқ бозор операциялари орқали аниқ ва ўз вақтида монетар интервенцияларни амалга оширишга имконият яратади.

Тадқиқот бевосита САРИМА ва экспоненциал текислаш каби анъанавий вақт қаторлари моделлари ва тасодифий ўрмон ҳамда сунъий нейрон тармоқлар каби замонавий ML усуллари устида амалий тажрибалар ўтказишга қаратилган. Ушбу илғор моделлардан фойдаланиш орқали шу пайтгача аниқлаш қийин бўлган автоном омилларнинг шаклланиши тенденцияларини ўрганиш мақсад қилинган.

Ушбу тадқиқот натижалари ликвидликни прогноз қилиш бўйича мавжуд адабиётларга ҳисса қўшиб, марказий банклар учун пул-кредит сиёсатини амалга оширишни яхшироқ бошқариш ва молиявий барқарорликни таъминлашда амалий воситаларни тақдим этади.

2 Маълумот ва методология

2.1 Маълумот тавсифи


Моделларни баҳолаш ва уларнинг натижаларини текшириш учун фойдаланилган маълумотлар тўплами қуйидаги иккита тизимдан банк транзакциялари тўғрисидаги маълумотларни ўз ичига олади: *Реал-вақт режимидаги ялпи ҳисоб-китоб* тизими сифатида ишлайдиган Банклараро тўлов тизими ва *Тезкор тўлов тизими* (АНОР).

Ўзбекистон Марказий банкининг Банклараро тўлов тизими мамлакат молиявий инфратузилмасининг муҳим таркибий қисми ҳисобланади. Бу банклараро тўловлар бўйича реал вақт режимида ҳисоб-китоб қилиш учун мўлжалланган электрон тўлов тизими бўлиб, банклар ўртасида пул маблағларининг дарҳол ўтказилишини таъминлайди. Бу тизимга барча тижорат банклари уланган бўлиб, у ялпи ҳисоб-китоб тамойили асосида ишлайди, яъни ҳар бир тўлов бўйича кўрсатма гуруҳланган ҳолда эмас, балки алоҳида-алоҳида ҳисоб-китоб қилинади.


Банклараро тўлов тизими банк иш кунлари соат 9:00 дан 17:00 гача ишлайди. Бу вақтда банклар тўлов бўйича кўрсатмаларини Марказий банкнинг клиринг марказига жўнатишлари мумкин. Бу марказ транзакцияларни узлуксиз қайта ишлаш ва ҳисоб-китоб қилиш учун жавобгардир. Ушбу тизим тижорат банкларининг ликвидлик позицияларини сақлаб туришларида ҳал қилувчи рол ўйнайди, чунки улар ўз ҳисобварақларига ўтказилган маблағлардан шу заҳотиёқ фойдаланишлари мумкин.

АНОР тизими Ўзбекистоннинг лаҳзали тўлов тизими сифатида фаолият юритиб, 24/7 режимида тўловларни амалга ошириш имконини беради. 2020 йилнинг феврал ойидан бошлаб Банклараро тўлов тизимида муқобил равишда ишга туширилган АНОР орқали дам олиш ва байрам кунларида ҳам тадбиркорлик субъектлари ўртасидаги транзакцияларни, шунингдек, ҳукумат операцияларини узлуксиз бажариш мумкин.

2024 йилда Банклараро тўлов тизими ва АНОР тизимларининг ҳар бирида Марказий банк (ҳукумат операцияларини ҳам ҳисобга олганда) ва тижорат банклари ўртасида ҳар куни ўртача 200 мингта транзакция амалга оширилди. Ушбу тадқиқот учун биз 2018 йилдан бошлаб ҳар иккала тўлов тизимидан бирлашган кунлик транзакция маълумотларини таҳлил қилишни мақсад қилганмиз (АНОР маълумотлари 2020 йил февралидан бошлаб мавжуд). Ҳар бир транзакция унинг санаси, суммаси ва тўлов мақсади, шунингдек, тўловни юборувчи ва қабул қилувчи банкларнинг идентификаторлари (3 хонали код), миқдорларнинг номлари, банк ҳисобрақамлари (20 хонали код) ва солиқ тўловчининг идентификация рақамлари (9 хонали код) ҳақидаги маълумотларни ўз ичига олади.




Расм 1: Вақт қатори




Расм 2: Тақсимоти

Моделларни қуриш учун ликвидликнинг ҳар бир автоном омили учун кунлик банк операциялари маълумотларидан вақт қаторлари тузилди. Мазкур ҳужжатда *нақд пул операцияларига* мос келадиган вақт қаторлари таҳлилни соддалаштириш мақсадида маълумотларни қайта ишлаш босқичлари ва моделлаштириш натижаларини тақдим этиш учун намуна сифатида кўрсатилган.

1 ва 2-расмлардан кўриш мумкинки, кунлик маълумотлар юқори тебранувчанликни ва бир томонга тўпланган (*skewed*) тақсимот эга. Монетар операциялар ўтказиш мақсадида ликвидликни прогноз қилиш учун ҳафталик ёки 10 кунга жамланган маълумотлар (3-расм) ва прогнозлардан фойдаланиш анча амалий аҳамиятга эга. Бундан ташқари, жамланган маълумотлар тебранувчанликни камайтиради, прогнозларнинг барқарорлигини оширади.



Расм 3: 10 кунга жамланганда



Расм 4: Тақсимоти

Кўпгина эконометрик ва ML моделлар учун вақт қаторлари тренд ва дисперсия бўйича стационарлик хоссасига эга бўлиши керак [1], бироқ биз ўрганаётган вақт қатори юқоридаги чизмалар ва статистик тестлар натижаларига кўра бу талабга зид келади. Масалан, вақт қатори ўртача бўйича стационарлик учун кенгайтирилган Дикки-Фуллер (АДФ) тестига [2] кўра ностационарликни ва Энглнинг авторегрессивлик АР гетероскедастлик тестига [3] кўра статистик жиҳатдан аҳамиятли гетероскедастликни кўрсатди. Бундан ташқари, аксарият ML моделлари учун маълумотлар тақсимоти бир томонга тўпланмасдан, марказлашган ҳолда бўлиши (*centrally distributed*) самаралироқ ҳисобланади. Маълумотларнинг янада мақбул кўринишига эришиш учун биз қуйида турли хил даража трансформациялари ва маълумотларни масштаблаш усулларини таништириб ўтамыз.

2.2 Маълумотларни трансформация қилиш усуллари

Маълумотларни трансформация қилиш уларни ўрганишни осонлаштириш ёки алгоритмик ишлов бериш учун қулайроқ қилиш мақсадида маълумотларнинг қийматларини ўзгартиришни ўз ичига олади. Асосий трансформация усуллари қуйидагилардан иборат:

2.2.1 Даражани ўзгартириш

- **Логарифмик ўзгартириш** нисбатан катта қийматларни кичрайтириш, кичик ва катта қийматлар ўртасидаги нисбий фарқни камайтириш, шу билан дисперсияни барқарорлаштириш ва экстремал ўзгаришлар таъсирини камайтириш орқали бир томонга тўпланган маълумотларни бошқариш учун фойдали ҳисобланади [4].

- **Квадрат илдиздан чиқариш** ҳам кичикроқ қийматларга нисбатан каттароқ қийматларнинг тарқалишини камайтириш орқали маълумотлардаги катта тафовут таъсирини юмшатишга ёрдам беради.
- **Бокс-Кокс трансформацияси** (Box-Cox) нормал тақсимланмаган маълумотларни нормал тақсимотга яқинлаштириш учун қўлланилади [5]. У қуйидагича аниқланади:

$$y = \begin{cases} \frac{x^\lambda - 1}{\lambda}, & \text{агар } \lambda \neq 0 \\ \log(x), & \text{агар } \lambda = 0 \end{cases}$$

Бу ерда λ лог-эҳтимоллик функциясини максималлаштириш орқали топилади. Шунинг таъкидлаш кераки, Бокс-Кокс трансформацияси барча киритилган қийматларнинг мусбат бўлишини талаб қилади.

- **Ео-Жонсон трансформацияси** (Yeo-Johnson) Бокс-Кокс усулининг кенгайтмаси бўлиб, мусбат қийматлар билан бир қаторда нол ёки манфий қийматларни ўз ичига олган ўзгарувчиларда даражани ўзгартиришга имкон беради [6]. Ушбу трансформация, айниқса, манфий қийматларни ўз ичига олиши мумкин бўлган автоном омилнинг умумий ликвидликка соф таъсирини трансформация қилишда фойдалидир.

2.2.2 Масштабни ўзгартириш

Масштабни ўзгартириш маълумот қийматлари оралиғини улар орасидаги нисбатларни бузмасдан ўзгартиради. Кенг фойдаланиладиган масштаблаш усуллари қуйидагилар киради:

- **Мин-Макс масштаблаш:** Қийматларни белгиланган диапазонга ўзгартиради, одатда $[0, 1]$. У қуйидагича аниқланади:

$$x' = \frac{x - x_{\min}}{x_{\max} - x_{\min}}$$

бу ерда $x_{\min}$ ва $x_{\max}$ мос равишда маълумотнинг минимал ва максимал қийматлари.

- **Стандарт масштаблаш:** Маълумотлар стандарт четланишини бирга ва ўртачасини нолга айлантиради:

$$x' = \frac{x - \mu}{\sigma}$$

Бу ерда μ - маълумотнинг ўртачаси ва σ - стандарт четланиши.

- **Барқарор (robust) масштаблаш:** Маълумот медианасидан фойдаланган ҳолда масштаблаш:

$$x' = \frac{x - \text{median}(x)}{\text{IQR}(x)}$$

бу ерда $\text{IQR} = Q_3 - Q_1$ бўлиб, 75инчи (Q_3) ва 25инчи (Q_1) персентиллар орасидаги фарқ.

Ушбу усуллар кўп ўзгарувчили моделлар билан ишлашда ўзгарувчилар масштабларида бир хилликни таъминлаш ва шу билан ML моделларининг ишлаши ва улар асосланган алгоритмларнинг оптимал ечимга яқинлашиш жараёнини яхшилаш учун зарурдир. Ҳатто бир ўзгарувчили моделларда ҳам масштаблаш ўтказилмаса, катта қийматлар ҳаддан ташқари катта вазн қийматларини ўрганган ML моделига олиб келиши мумкин [7]. Бу эса модел прогнозлари барқарорлигига путур етказиб, натижалар аниқлигини кескин пасайтиради.

2.2.3 Тренд-циклга ажратиш

Баъзи моделлар учун маълумотларнинг ўртача бўйича стационарлигини таъминлаш мақсадида тадқиқотда детрендинг (*detrending*) усуллари қўлланилади ва трендларни ҳисоблашнинг иккита ёндашувини таққосланади: Ходрикс-Прессотт (ХП) фильтри [8] ва умумийлаштирилган энг кичик квадратлар усули (*Generalized Least Squares - GLS*) [9].

Усуллар тавсифи

1. **Ходрик-Прескотт (ХП) фильтри:** ХП фильтри y_t вақт қаторини тренд компонентига τ_t ва циклик компонентга c_t ажратади:

$$y_t = \tau_t + c_t$$

Тренд компоненти қуйидаги мақсад функциясини минималлаштириш орқали баҳоланади:

$$\min_{\tau} \sum_{t=1}^T (y_t - \tau_t)^2 + \lambda \sum_{t=2}^{T-1} ((\tau_{t+1} - \tau_t) - (\tau_t - \tau_{t-1}))^2$$

Бу ерда λ маълумотларга мослик яхшилиги ва тренд силлиқлиги ўртасидаги мувозанатни назорат қилувчи параметрдир. Тажрибалардан кейин λ қиймати 129600 ($1600 \cdot 3^4$) га ўрнатилди.

2. **Умумлаштирилган энг кичик квадратлар усули бўйича детрендинг:** GLS детрендинг умумийлаштирилган энг кичик квадратлар усули ёрдамида детерминистик вақт тренди бўйича y_t вақт сериясини регрессиялаш орқали трендни олиб ташлайди. Масалан, чизиқли тренд учун:

$$y_t = \beta_0 + \beta_1 t + \epsilon_t$$

y_t ифодадан модел ёрдамида аниқланган тренд $\beta_0 + \beta_1 t$ айирилганида стационар қолдиқ ϵ_t қолади.

2.3 Самарадорликни ўлчаш

Ушбу тадқиқотда молиявий вақт қаторлари моделларининг прогноз кўрсаткичлари самарадорлигини баҳолашда тез-тез ишлатиладиган [10, 11, 12] учта кўрсаткичдан фойдаланилди:

- **Ўртача абсолют нисбий хатолик (*Mean Absolute Percentage Error – MAPE*)** ҳақиқий ва прогноз қилинган қийматлар ўртасидаги ўртача фоиз фарқини ўлчайди. У қуйидагича аниқланади:

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right|$$

Пастроқ MAPE қиймати (нолга яқин) прогнознинг аниқроқ эканлигини кўрсатади.

- **R^2 кўрсаткичи** ёки детерминация коэффиценти моделдан прогноз қилиш мумкин бўлган дисперсиянинг жами ўзгарувчанликдаги улушини кўрсатади. У қуйидагича аниқланади:

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2}$$

R^2 қиймати 1 га яқинроқ бўлса, бу моделнинг натижаларининг маълумотларга мослигини кўрсатади.

- **Теилнинг У статистикаси** (*Theil's U Statistic*) прогнозлаш моделининг содда моделга нисбатан нисбий аниқлигини ўлчайди. У қуйидагича аниқланади:

$$U = \frac{\sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2}}{\sqrt{\frac{1}{n} \sum_{i=1}^n y_i^2} + \sqrt{\frac{1}{n} \sum_{i=1}^n \hat{y}_i^2}}$$

Унинг қийматлари 0 ва 1 оралиғида бўлади. 0 га яқинроқ қиймат юқори аниқликни билдиради, 1 га яқин қийматлар эса жорий модел содда моделга яқин ишлашни кўрсатади.

Юқоридаги формулаларда y_i – i даврдаги ҳақиқий қиймат, $\hat{y}_i$ – i даврдаги прогноз қилинган қиймат, $\bar{y}$ – ҳақиқий қийматларнинг ўртачаси, n – прогнозлаш даврлари сони. Маълумотлар трейнинг ва тест тўпламларига бўлинганлиги сабабли барча самарадорлик кўрсаткичлари тест тўплам ёрдамида ҳисобланади, яъни кўрсаткичлар **танланмадан ташқари самарадорликни** (*out-of-sample*) акс эттиради.

Амалиётда баъзи ҳолларда самарадолик кўрсаткичлари қарама-қарши қийматларни кўрсатганида потенциал номзод моделлар орасида энг яхши ишлайдиган моделни танлаш қийин бўлиши мумкин. Бу муаммони ҳал қилиш учун биз юқоридаги учта кўрсаткични битта кўрсаткичга жамлаймиз. Вазнли композит балл [13] кўрсаткичларни нормаллаштириш ва уларга тегишли вазнларни белгилаш орқали ҳисобланади. Ушбу ёндашув барча кўрсаткичларни яхлит баҳолаш асосида моделнинг оптимал конфигурациясини тартиблаш ва танлаш имконини беради.

Композит баллни ҳисоблаш ва оптимал моделни аниқлаш қуйидаги босқичларда амалга оширилади:

- **1-қадам:** Ҳар бир кўрсаткични таққосланадиган шкалага (0 дан 1 гача) нормаллаштирилади.
- **2-қадам:** Ҳар бир кўрсаткичга уларнинг амалий аҳамиятидан келиб чиқиб вазнлар белгиланади. Бизнинг ҳолатда

$$w_{MAPE} = \frac{2}{3}, \quad w_{R^2} = \frac{1}{6}, \quad w_{Theil's U} = \frac{1}{6}$$

ўрнатамиз. MAPE кўпроқ вазнга эга, чунки аниқликка асосий аҳамият берилади.

- **3-қадам:** Нормаллаштирилган кўрсаткичларнинг ўртача вазнларидан фойдаланиб, ҳар бир модел учун композит балл ҳисобланади. Композит баллни қуйидагича ҳисоблаш мумкин:

$$Score = w_{MAPE} \cdot MAPE_{norm} + w_{R^2} \cdot (1 - R^2)_{norm} + w_{Theil's U} \cdot Theil's U_{norm}$$

- **4-қадам:** Энг кам композит баллга эга модел танланади.

3 Моделлар натижалари

Ушбу тадқиқотда биз биринчи навбатда ҳеч қандай структуравий элементларни ўз ичига олмайдиган бир ўзгарувчи моделлардан фойдаланган ҳолда бир вақтнинг ўзида бир қадамли прогнозлар билан тажрибалар ўтказишни ва нуқтавий баҳоси атрофида ишонч оралиқларини куришни мақсад қилганмиз. Бундай моделлардан бошлашнинг сабаби шундаки, улар содда ва тушунарли бўлиб, қўшимча мураккабликларни киритмасдан

дастлабки тушунчаларни олиш ва маълумотнинг ўзига хос хусусиятларини тушунишни осонлаштиради.

Ушбу узоқ муддатли тадқиқот ишининг кейинги босқичида биз иқтисодий ва молиявий кўрсаткичларнинг ўзаро таъсирини яхшироқ тушуниш учун бошқа турдаги моделлар, яъни кўпроқ таркибий ва кўп ўзгарувчили моделлар билан тажриба ўтказишни режалаштирмақдамиз.

3.1 САРИМА

САРИМА (*SARIMA – Seasonal Autoregressive Integrated Moving Average*) бир ўзгарувчили модел бўлиб, ўзининг ўтмишдаги қийматларидан (кечикишлар) – авторегрессив қисмдан (*autoregressive*), керак бўлганда стационарликни ўрнатиш учун айирмалардан – интеграллашган (*integrated*) қисмдан, хатоликлар миқдорларидан – сирғалувчи ўртача (*moving average*) қисмдан вақт қаторининг келажакдаги қийматларини прогноз қилишда фойдаланади.

Нақд пул операциялари вақт қаторларини прогноз қилиш учун даражани ўзгартириш трансформациялари ва масштабланиш турли комбинацияларидан фойдаланган ҳолда САРИМА моделларининг турли конфигурациялари синовдан ўтказилди. Энг яхши натижага эришган САРИМА модели ҳеч қандай даража трансформациясиз ва Мин-Макс масштаблаш орқали аниқланди, бунда энг паст MAPE (0,1747), энг юқори R^2 (0,7774) ва энг паст Теилнинг U қийматига (0,0903) эришди. Бу комбинация энг паст композит баллга ҳам олиб келди, бу эса уни прогноз қилиш учун оптимал танловга айлантирди (1-жадвал).

Танланган САРИМА модели (2, 1, 3)(1, 0, 1, 36) тартиби билан тренд компонентисиз аниқланди. Ушбу конфигурация вақт қаторининг мавсумий ва мавсумий бўлмаган динамикасини муваффақиятли қамраб олди ва буни прогнозларнинг аниқлигидан кўриш мумкин. Прогноз чизмаси (5-расм) моделнинг нуқтавий прогноз қийматлари атрофида 95% ишончлилик оралиғини таъминлаб, ҳақиқий маълумотларга жуда яқин прогнозлаш қобилиятини намоён этади.


Трансформация ¹	Масштабланиш	MAPE	R^2	Theils U	Композит балл
none	minmax	0.1747	0.7774	0.0903	0.0000
none	robust	0.1751	0.7775	0.0902	0.0003
none	standard	0.1752	0.7764	0.0905	0.0005
yeo-johnson	standard	0.1893	0.6694	0.1155	0.0211
yeo-johnson	robust	0.1904	0.6596	0.1176	0.0227
yeo-johnson	minmax	0.1881	0.6047	0.1270	0.0242
none	none	0.2089	0.7587	0.0921	0.0309
yeo-johnson	none	0.9343	-5.2088	0.8899	1.0000

Жадвал 1: Прогнозлар натижалари самарадорлиги

3.2 Prophet

Facebook томонидан ишлаб чиқилган Prophet [14] – бу тўлиқ бўлмаган маълумотлар, юқори тебранувчанлик ва сезиларли мавсумийлик каби умумий муаммоларни ҳал қилиш

¹The comparison of power transformations is provided only for no transformation applied (none) and the Yeo-Johnson transformation, as the latter is the most versatile and is chosen for the sake of conciseness.



Расм 5: SARIMA модели прогнози ва ҳақиқий қийматлар

учун мўлжалланган мослашувчан вақт қаторларини прогнозлаш воситаси.

Мазкур тадқиқотда Prophet модели ойлик мавсумийлик, чизикли тренд ва Ўзбекистонга хос байрамларни ўз ичига олган ҳолда тузилди. Натижалар шуни кўрсатадики, Prophet қўлланиладиган маълумотларни дастлабки трансформациялашга қараб турли даражадаги самарадорлик билан прогнозларнинг ўртача аниқлик даражасини намоиш этади.


Prophet учун энг яхши конфигурация Ео-Жонсон трансформацияси ва Мин-Макс масштаблашни ўз ичига олган (2-жадвал). Шуниси эътиборга лойиқки, масштаблашларсиз ва ҳеч қандай трансформация қўлланилмаганда модел бироз ёмонроқ натижаларга олиб келди. Бу Prophet учун масштаблаш натижалар самарадорлигини бир хилда яхшиламаслигини кўрсатади.

Трансформация	Масштаблаш	MAPE	R^2	Theils U	Композит балл
yeo-johnson	minmax	0.1791	0.5459	0.1365	0.0104
none	none	0.1949	0.6378	0.1159	0.0108
none	minmax	0.1947	0.6351	0.1164	0.0109
none	robust	0.2157	0.6336	0.1150	0.0245
none	standard	0.2202	0.6361	0.1143	0.0272
yeo-johnson	robust	0.2492	0.5927	0.1192	0.0499
yeo-johnson	standard	0.2574	0.5805	0.1199	0.0560
yeo-johnson	none	0.9365	-5.2210	0.8913	1.0000

Жадвал 2: Прогнозлар натижалари самарадорлиги

Натижалар маълумотларни олдиндан қайта ишлаш Prophet'нинг ишига сезиларли таъсир қилишини кўрсатади. Ойлик мавсумийлик ва байрам эффектларининг

киритилиши моделнинг вақт қаторидаги асосий тенденцияларни қамраб олиш имконияти яхшилаганини кўрсатади. Прогноз чизмаси 95% ишончлилик оралиғи (6-расм) Prophet'нинг ноаниқликни самарали аниқлаш қобилиятини намоён этади.



Расм 6: Prophet модели прогнозлари ва ишончлилик оралиқлари

Prophet топилган конфигурациялар учун R^2 ва MAPE бўйича SARIMAдан устун бўлмаса-да, унинг мослашувчанлиги уни вақт қаторларини прогноз қилиш учун фойдали воситага айлантиради.

3.3 Экспоненциал текислаш

Экспоненциал текислаш – бу олдинги кузатувлар учун вазнларни экспонент равишда камайтирувчи прогнозлаш усули бўлиб, сўнгги маълумотларга кўпроқ аҳамият беради. Ушбу усул жуда кўп қиррали ва турли хил маълумотлар намуналарини, жумладан мутлақ қийматлар, тренд ва мавсумийликни ўз ичига олади. Ҳолтнинг чизиқли тренд модели [15] ва Ҳолт-Винтерс мавсумий модели [16] каби модел вариантлари мос равишда трендлар ва мавсумий эффектларни қамраб олиш учун базавий ёндашувни кенгайтиради.

Ушбу тадқиқотда мавсумийлик ва чизиқли тренд (Ҳолт-Винтер) модели билан экспоненциал текислаш SARIMA ва Prophet моделларига нисбатан ёмонроқ натижаларга олиб келди (3-жадвал). Стандарт, барқарор ёки Мин-Макс масштаблашлари билан даража трансформацияларисиз моделлар MAPE қийматлари бироз юқорироқ ва 0,3541 атрофида изчил R^2 қийматлари билан деярли бир хил натижаларни берди.


Модел томонидан тақдим этилган ишончлилик оралиқлари прогноз чизмасиди тасвирланганидек, нуқтавий прогнозлар атрофидаги ноаниқликларни акс эттиради (7-расм).

Экспоненциал текислаш прогнозлаш учун тўғридан-тўғри ёндашувни таклиф қилса-да, у SARIMA ва Prophet моделларига нисбатан R^2 ва MAPE кўрсаткичлари

Трансформация	Масштаблаш	MAPE	R^2	Theils U	Композит балл
yeo-johnson	minmax	0.3254	0.3634	0.1445	0.0005
none	standard	0.3524	0.3540	0.1421	0.0307
none	robust	0.3524	0.3541	0.1421	0.0307
none	minmax	0.3524	0.3541	0.1421	0.0307
none	none	0.3609	0.3222	0.1447	0.0419
yeo-johnson	robust	0.3809	0.1765	0.1586	0.0722
yeo-johnson	standard	0.3840	0.1700	0.1590	0.0761
yeo-johnson	none	0.9164	-4.9996	0.8602	1.0000

Жадвал 3: Прогнозлар натижалари самарадорлиги

бўйича ёмонроқ ишлади. Шунга қарамай, бу усулнинг соддалиги ва барқарорлиги уни вақт қаторларини прогноза қилишда фойдали баҳолаш мезонига (*benchmark*) айлантиради.



Расм 7: Экспоненциал текислаш модели прогнозлари ва ишончлилик оралиқлари

3.4 Тасодифий ўрмон

Вақт қаторларини прогнослашда ML моделларини қўллаш маълумотлар динамикасидаги мураккаб қонуниятларини, чизиқли бўлмаган муносабатларни аниқлай олиш ва кўп ўлчовли маълумотларни (бир қанча мустақил ўзгарувчига эга маълумотлар тўпламини) қайта ишлаш қобилияти туфайли катта эътибор қозонган. Мазкур бўлим ушбу тадқиқотда ишлатиладиган асосий ML моделларини ёритади.

Қарор қабул қилиш дарахтлари (*Decision Trees*) чизиқли усуллар билан солиштирганда прогноз қилишнинг мутлақо бошқача усулидир. Дарахтга асосланган

усуллар ўзгарувчилар фазосини соддароқ ҳудудларга рекурсив равишда сегментлашга ҳаракат қилади, бу эса прогноз қилувчи фазонинг қийматлари ҳақида қарор қабул қилиш имконини беради.

Тасодифий ўрмон (*Random Forest*) чизиқли бўлмаган муносабатларни аниқлашда барқарорлиги ва ансамбль ўрганиш ёндашуви туфайли прогнозлаш моделларидан бири сифатида танланган бўлиб, бу ҳаддан ташқари мослашишни (*overfit*) камайтиради. Моделнинг гиперпараметрлари GridSearchCV ва Optuna иштирокидаги икки босқичли жараён ёрдамида оптималлаштирилган.

Тасодифий ўрмон моделининг ишлаш кўрсаткичлари 4-жадвалда кўрсатилганидек, қуйидагиларни қайд этди:

- *Энг яхши даража трансформацияси ва масштаблаш комбинацияси*: Ео-Жонсон трансформацияси ва Мин-Макс масштаблаш комбинацияси MAPE, R^2 ва Теилнинг U статистикаси бўйича энг мувозанатли ишлашни акс эттирувчи энг яхши композит баллга (0,0114) эришди.
- *GridSearchCV ва Optuna*: Бундай ҳолда, энг самарадор модел Optuna эмас, балки GridSearchCV ёрдамида топилди. Бироқ бу умумий натижа эмас ва маълумотлар ҳамда дастлаб берилган параметр фазосига қараб фарқ қилиши мумкин.

Трансформация	Масштаблаш	MAPE	R^2	Theils U	Композит балл
yeo-johnson	robust	0.2235	0.6108	0.1205	0.0129
yeo-johnson	minmax	0.2244	0.6156	0.1199	0.0153
yeo-johnson	standard	0.2264	0.6046	0.1214	0.0821
none	standard	0.2621	0.4988	0.1350	0.9998

Жадвал 4: Прогнозлар натижалари самарадорлиги


Прогноз чизмаси (8-расм) тасодифий ўрмон модели учун ҳақиқий қийматларни, ўртача прогнозларни ва 95% ишончлилик оралиқларини намоиш этади. Ишончлилик оралиқлари якка дарахт прогнозларининг 2,5 ва 97,5 персентиллари сифатида ҳисоблаб чиқилган ва бу прогнозлар атрофидаги ноаниқлик ўлчовини таъминлайди.

9-расмда яхши ишлайдиган моделларни таққослаш келтирилган. Чизма САРИМА, Prophet ва Тасодифий ўрмон моделлари томонидан яратилган прогнозлар билан бирга ҳақиқий қийматларни кўрсатади. Ушбу визуал таққослаш ҳар бир модел маълумотлардаги қонуниятлар ва ўзгарувчанликни қанчалик яхши аниқлаши ҳақида тушунча беради.


3.5 Нейрон тармоқлари

Сўнгги йилларда нейрон тармоқлари матн ва аудио кўринишидаги табиий тил, шунингдек, мусиқа, видео ва вақт қаторлари каби кетма-кет маълумотларга қўлланилганда муваффақиятли прогноз қила олишини намоиш этди.

Ушбу тадқиқотда биз вақт қаторларини прогноз қилиш учун *Gated recurrent unit (GRU)* бирликларидан фойдаланган ҳолда оддий кетма-кетлик (*Sequence-to-Sequence (S2S)*) архитектурасини қуриш учун автокодерлар деб ҳам аталадиган кодловчи-декодер ёндашувидан фойдаланамиз. Пенг ва бошқалар [17] Google Clusters ва Dinda маълумотлар базаларида хост юкланишини прогноз қилиш учун шунга ўхшаш архитектурали моделдан фойдаланган ва унинг ишлашини бошқа иккита юқори самарадорликка эга моделлар, хусусан, Recurrent Neural Networks ва Echo State Networks билан солиштирганда яхшироқ натижаларга эришишган.



Расм 8: Тасодифий ўрмон модели прогнозлари ва ишончлилиқ оралиқлари




Расм 9: Моделлар прогнозларини таққослаш

Шунингдек, тадқиқот давомида ўрганилган *Wavelet-ANN* усули Чан ва Меҳрализаде [18] томонидан киритилган бўлиб, у молиявий фючерс бозорларини прогноз қилиш учун *wavelet denoising*’ни сунъий нейрон тармоқ билан бирлаштирган гибрид усулдир. Асосий ғоя *wavelet* трансформациялар билан вақт қаторини шовқинлардан тозалаш, молиявий техник кўрсаткичларни вақт қаторидан ҳисоблаш ва кейин уларни нейрон тармоқ моделига киритишдир.


Тажрибалар натижаси шуни кўрсатадики, нейрон тармоғига асосланган моделлар

вақт қаторларини прогноزلаш учун назарий ва амалий жиҳатдан истиқболли бўлса-да, *wavelet* трансформациялардан сўнг қўлланиладиган GRU бирликлари бошқа моделларга нисбатан ёмонроқ ишлашни кўрсатди. Хусусан, стандарт масштаблаш ёрдамида даража трансформацияси қўлланилмаганда GRU учун нисбатан яхши натижаларга эришилди, натижада $MAPE=0,357$, $R^2 = -0,2221$ ва Theil's $U = 0,2536$ бўлди (10-расм).

LSTM (WNN) билан *wavelet* трансформация қилинган маълумотлар учун энг яхши конфигурация барқарор масштаблаш, *sym8* тўлқин, 5 даражали шовқиндан тозалаш, *soft* чегара қоидаси, 3 даражали қайта кўриб чиқиш, квадрат илдиз трансформацияси ва техник кўрсаткичларнинг киритилмаганлигини ўз ичига олади. Ушбу конфигурация ёрдамида $MAPE=0,4411$, $R^2 = -0,3868$ ва Theil's $U = 0,2392$ (расм 11) ҳосил қилинди. Ушбу моделларнинг қониқарсиз деб топилишининг асосий сабабларидан бири бу манфий R^2 бўлиб, бу моделларнинг ўртача прогнозлари вақт қаторининг шунчаки ўртача қийматини тахмин қилишдан кўра ёмонроқ эканлигини кўрсатади.



Расм 10: GRU модели прогнозлари



Расм 11: WNN модели прогнозлари

Бундай натижалар нейрон тармоқлари архитектурасини соzлашнинг мураккаблиги билан боғлиқ бўлиши мумкин. Яширин қатламлар сони (чуқурлик – *depth*), тугунлар сони (кенглик – *width*), фаоллаштириш функциялари, ҳисоб-китоб учун партия ўлчамлари (*batch size*), йўқотиш функциялари ва турли хил нейрон тармоқ турларининг комбинацияси (масалан, кўп қатламли, конволюцион, рекуррент, эшикли, узоқ-қисқа муддатли хотира ва уларнинг комбинацияси) каби модел хусусиятлари учун оптимал соzлашни аниқлашда универсал қоидалар ёки олдиндан белгиланган процедура мавжуд эмас [18, 19]. Бунинг ўрнига, ушбу конфигурацияларни яхшироқ калибрлаш одатда тажриба ва синов-хато (*trial-and-error*) экспериментларига таянади [20] ва кўпинча оптимал параметр фазоси ва трейнинг динамикасини тушуниш учун чуқурроқ изланишлар талаб этилади [21], бу эса кўп вақт талаб этади ва амалда самарали оптималлаштириш қийин бўлиши мумкин. Тадқиқотнинг кейинги босқичларида нейрон тармоқларнинг турли архитектуралари билан чуқурроқ тажрибалар ўтказиш режалаштирилган.

3.6 Ансамбль усуллар

ML моделлаштириш амалиётида бир нечта моделлар ансамбли кўпинча энг яхши кўрсаткичли якка моделдан яхшироқ натижа беради [22, 23]. Бунинг сабаби шундаки, якка моделнинг ишлашидаги тебранувчанликни (*variance*) унга силжиш (*bias*) қўшиш орқали камайитириш мумкин. Бунга бир нечта моделлар прогнозларини бирлаштириш

орқали эришилади ва бу жараён одатда *ансамбль ўрганиш (ensemble learning)* деб аталади.

Ансамбллаш учун ишлатиладиган моделлар бир биридан фарқли қобилиятларга эга бўлиши тавсия этилади [7], масалан, чизиқли ва чизиқли бўлмаган моделлар ёки нейрон тармоқлар ва дарахтга асосланган моделлар натижалари бирлаштирилиши мумкин. Бундан ташқари, ML моделларининг кўпчилигида трейнинг жараёни стохастик элементларни ўз ичига олганлиги сабабли турли қайта ҳисоблашлар (*different runs*) бўйича прогнозларни бирлаштириш барқарорликни таъминлашга ёрдам беради.

Ушбу тадқиқотда синовдан ўтказилган ансамбль ўрганиш ёндашуви прогнозларнинг аниқлиги ва барқарорлигини ошириш учун ҳар бирида турли хил методлардан фойдаланадиган бир нечта моделлар бўйича прогнозларни бирлаштириш самарадор эканлигини кўрсатади. Синовдан ўтказилган ансамбл усуллари вазнли аралаштириш (*blending*), оддий аралаштириш (модел прогнозларининг оддий ўртачаси), устунлаш (*stacking*) ва тескари кутилган дисперсия (*inverse expected variance*) усулларини ўз ичига олади. Уларнинг ҳар биридан нисбатан яхши натижалар кўрсатган SARIMA, Prophet ва Тасодифий ўрмон моделларидан олинган натижаларни бирлаштиришда фойдаланилди.

Вазнли аралаштириш. Якка модел прогнозларини бирлаштириш учун вазнлар уларнинг трейнинг жараёнидаги ўртача мутлақ хатолиги (*Mean absolute error – MAE*) асосида аниқланади, бунда пастроқ MAE қийматлари юқори вазнларга тўғри келади. Аралаштирилган прогноз формуласи қуйидагича берилган:

$$\text{Blended Forecast} = w_1 \cdot \text{SARIMA} + w_2 \cdot \text{Prophet} + w_3 \cdot \text{Random Forest}.$$

Устунлаш (стакинг) якка моделлар прогнозларини бирлаштиришнинг оптимал комбинациясини топиш учун мета-модел сифатида бизнинг ҳолатда чизиқли регрессиядан фойдаланади. Устунлаш аралаштириш учун муқобил ёндашувни таклиф қилса-да, натижалар вазнли аралаштириш билан солиштирганда юқори MAPE ва пастроқ R^2 кўрсатиб, ансамбллаш стратегиясини танлаш муҳимлигига эътибор қаратишга ундайди.

Тескари кутилган дисперсия усули прогноз қилинган модел дисперсияларининг нормаллаштирилган тескари қийматлари ёрдамида ансамбл вазнларини белгилайди. Ушбу ёндашувнинг афзаллиги шундаки, унда вазнлар ўзгармас бўлмайди, бунинг ўрнига агар якка модел маълум бир давр учун прогнозида юқори ноаниқликни намойиш қилса – бу юқори дисперсия билан акс эттирилади – ўртачани ҳисоблаш жараёнида у камроқ вазн олади:

$$\text{Ensemble Forecast}_i = \frac{1}{\sigma_{1,i}^2} \cdot \text{SARIMA}_i + \frac{1}{\sigma_{2,i}^2} \cdot \text{Prophet}_i + \frac{1}{\sigma_{3,i}^2} \cdot \text{Random Forest}_i.$$


бу ерда $\frac{1}{\sigma_{k,i}^2}$ прогноз даврининг i -давридаги k -моделнинг нормаллаштирилган тескари дисперсияси.

Ушбу усул ишончлилиги юқори (пастроқ дисперсияли) бўлган моделлар якуний прогнозга кучлироқ таъсир кўрсатишини таъминлайди ва прогноз ноаниқлиги асосида якка модел ҳиссаларини динамик равишда мослаштиради.

Таҳлилдан (5-жадвал) **тескари дисперсия** энг самарали ансамбл усули сифатида намоён бўлиб (12-расм), у MAPE бўйича ҳатто SARIMAdан ҳам ўзиб, бошқа ансамбль моделлари орасида энг паст MAPE кўрсаткичига эришди. Бу прогнозлашнинг аниқлигини ошириш учун SARIMA, Prophet ва Тасодифий ўрмон моделларининг кучли томонларини бирлаштиришнинг юқори имкониятидан далолат беради. Бундан ташқари, танланмадан ташқари прогноз бўйича ўртача абсолют хатоликка асосланган прогноз қилиш аниқлиги

Ансамбль усули	MAPE	R^2	Theils U	Композит балл
Тескари дисперсия	0.1658	0.6624	0.2592	0.1904
Оддий аралаштириш	0.1731	0.6908	0.2524	0.2020
Вазнли аралаштириш	0.1818	0.6753	0.2527	0.2685
Устунлаш	0.2753	0.4912	0.1346	0.8333

Жадвал 5: Прогнозлар натижалари самарадорлиги



Расм 12: Тескари дисперсия ансамбль усули прогнозлари ва ишончлилик оралиқлари


учун Диеболд-Мариано тести [24] шуни кўрсатадики, бу ансамбл усули якка ҳолда энг яхши ишлайдиган САРИМА моделига нисбатан статистик жиҳатдан сезиларли фарқни намоиш этади.

Устунлаш усули, назарий жиҳатдан барқарор бўлса-да, ушбу контекстда нисбатан заифроқ ишлашни кўрсатди ва бу ансамбл қилиш учун оптимал мета-модел танлаш муаммоларини таъкидлади.

Тақдим этилган чизмалардаги визуал таққослаш (13-расм) ушбу топилмаларни қўшимча равишда қўллаб-қувватлайди. Бу эса ансамбль ёндашувларининг прогнозлаш хатоларини камайтириш ва янада ишончли прогнозларга эришишдаги амалий афзалликларини намоиш этади.

4 Хулоса

Ушбу тадқиқот маълумотларни турли хил олдиндан қайта ишлаш усулларида фойдаланган ҳолда банк тизимининг ликвидлигини прогноз қилиш масаласини ҳал қилиш учун вақт қаторларини прогнозлаш учун энг кенг тарқалган эконометрик моделлар ҳамда регрессия ва кетма-кетликни прогноз қилиш масалалари учун ML моделларини



Расм 13: Ансамбль усуллари таққослаш

синовдан ўтказди. Тажрибалар натижалари ликвидликнинг автоном омилларининг фақат битта компоненти, яъни марказий банкдан ташқарида бўлган нақд пуллар компоненти орқали кўрсатилди. Энг яхши кўрсаткичга эга яқка модел САРИМА бўлди. Ундан эса САРИМА, Prophet ва Тасодифий ўрмон моделларини кутилган тескари дисперсия усулидан фойдаланган ҳолдаги ансамбл модели устун келди.

Тадқиқотнинг Python дастурлаш тилидаги тадбиқи кодлари қуйидаги *GitHub* репозитарийсига жойлаштирилган: https://github.com/Shahzod-CBU/BCC_liquidity

Адабиётлар рўйхати

- [1] J. D. Hamilton, *Time series analysis*. Princeton, N.J: Princeton University Press, 1994.
- [2] D. A. Dickey and W. A. Fuller, "Distribution of the Estimators for Autoregressive Time Series With a Unit Root," *Journal of the American Statistical Association*, vol. 74, no. 366, p. 427, Jun. 1979. [Online]. Available: <https://www.jstor.org/stable/2286348>
- [3] R. F. Engle, "Autoregressive Conditional Heteroscedasticity with Estimates of the Variance of United Kingdom Inflation," *Econometrica*, vol. 50, no. 4, pp. 987–1007, 1982. [Online]. Available: <https://www.jstor.org/stable/1912773>
- [4] R. J. Hyndman and G. Athanasopoulos, *Forecasting: principles and practice*, 2nd ed. Melbourne: OTexts, 2018.
- [5] G. E. P. Box and D. R. Cox, "An Analysis of Transformations," *Journal of the Royal Statistical Society Series B: Statistical Methodology*, vol. 26, no. 2, pp. 211–243, Jul. 1964. [Online]. Available: <https://academic.oup.com/jrsssb/article/26/2/211/7028064>
- [6] I. Yeo and R. A. Johnson, "A new family of power transformations to improve normality or symmetry," *Biometrika*, vol. 87, no. 4, pp. 954–959, Dec. 2000. [Online]. Available: <https://doi.org/10.1093/biomet/87.4.954>
- [7] J. Brownlee, *Better deep learning: train faster, reduce overfitting, and make better predictions*. Machine learning mastery, 2018.
- [8] R. J. Hodrick and E. C. Prescott, "Postwar U.S. Business Cycles: An Empirical Investigation," *Journal of Money, Credit and Banking*, vol. 29, no. 1, p. 1, Feb. 1997. [Online]. Available: <https://www.jstor.org/stable/2953682>
- [9] G. Elliott, T. J. Rothenberg, and J. H. Stock, "Efficient Tests for an Autoregressive Unit Root," *Econometrica*, vol. 64, no. 4, p. 813, Jul. 1996. [Online]. Available: <https://www.jstor.org/stable/2171846>
- [10] E. Altay and M. H. Satman, "Stock market forecasting: artificial neural network and linear regression comparison in an emerging market," *Journal of Financial Management & Analysis*, vol. 18, no. 2, p. 18, 2005.
- [11] T. J. Hsieh, H. F. Hsiao, and W. C. Yeh, "Forecasting stock markets using wavelet transforms and recurrent neural networks: An integrated system based on artificial bee colony algorithm," *Applied soft computing*, vol. 11, no. 2, pp. 2510–2525, 2011.
- [12] Z. Guo, H. Wang, Q. Liu, and J. Yang, "A feature fusion based forecasting model for financial time series," *PloS one*, vol. 9, no. 6, p. e101113, 2014.
- [13] M. Kane and S. M. Case, "The reliability and validity of weighted composite scores," *Applied Measurement in Education*, vol. 17, no. 3, pp. 221–240, 2004.
- [14] S. J. Taylor and B. Letham, "Forecasting at scale," Sep. 2017. [Online]. Available: <https://peerj.com/preprints/3190v2>
- [15] C. C. Holt, "Planning production, inventories, and work force." 1960.
- [16] P. R. Winters, "Forecasting sales by exponentially weighted moving averages," *Management science*, vol. 6, no. 3, pp. 324–342, 1960.

- [17] C. Peng, Y. Li, Y. Yu, Y. Zhou, and S. Du, "Multi-step-ahead host load prediction with gru based encoder-decoder in cloud computing," in *2018 10th International Conference on Knowledge and Smart Technology (KST)*, 2018, pp. 186–191.
- [18] J. Chan Phooi M'ng and M. Mehralizadeh, "Forecasting east asian indices futures via a novel hybrid of wavelet-pca denoising and artificial neural network models," *PLOS ONE*, vol. 11, no. 6, pp. 1–29, 06 2016. [Online]. Available: <https://doi.org/10.1371/journal.pone.0156338>
- [19] J. M. Zurada, *Introduction to artificial neural systems*. St. Paul: West, 1992.
- [20] D. Guo, D. Yang, H. Zhang, J. Song, R. Zhang, R. Xu, Q. Zhu, S. Ma, P. Wang, X. Bi *et al.*, "DeepSeek-R1: Incentivizing Reasoning Capability in LLMs via Reinforcement Learning," *arXiv preprint arXiv:2501.12948*, 2025.
- [21] X. Bi, D. Chen, G. Chen, S. Chen, D. Dai, C. Deng, H. Ding, K. Dong, Q. Du, Z. Fu *et al.*, "DeepSeek LLM: Scaling open-source language models with Longtermism," *arXiv preprint arXiv:2401.02954*, 2024.
- [22] F. O'Donncha, Y. Zhang, B. Chen, and S. C. James, "An integrated framework that combines machine learning and numerical models to improve wave-condition forecasts," *Journal of Marine Systems*, vol. 186, pp. 29–36, 2018. [Online]. Available: <https://www.sciencedirect.com/science/article/pii/S0924796317304827>
- [23] Z. Wang, Y. Wang, and R. S. Srinivasan, "A novel ensemble learning approach to support building energy use prediction," *Energy and Buildings*, vol. 159, pp. 109–122, 2018.
- [24] F. X. Diebold and R. S. Mariano, "Comparing predictive accuracy," *Journal of Business & economic statistics*, vol. 20, no. 1, pp. 134–144, 2002.