



ҚАЗАҚСТАН ҰЛТТЫҚ БАНКІ

# ИНФЛЯЦИЯНЫ СЕЛЕКТИВТІ-АРАЛАС БОЛЖАУ ЖҮЙЕСІ (SSCIF)

Ақша-кредит саясаты департаменті  
№2024-13 экономикалық зерттеу  
Жұмыс мақаласы

З. Адилханова  
И. Ержан

Қазақстан Республикасы Ұлттық Банкінің (бұдан әрі – ҚРҰБ) экономикалық зерттеулері мен талдамалық жазбалары ҚРҰБ зерттеулер нәтижесін, сондай-ақ ҚРҰБ қызметкерлерінің басқа ғылыми-зерттеу жұмыстарын таратуға арналған. Экономикалық зерттеулер пікірталастарды ынталандыру үшін қолданылады.

ҚРҰБ қызметкерлерінің жұмыс мақаласы жарияланған күнгі жағдай бойынша аяқталмаған зерттеулерді көрсетеді және талқылауға, түсініктемелер мен ескертулер алуға арналған. Мақалада берілген пікірлер мен уәждер автордың пікірін білдіреді және ҚРҰБ немесе оның басшылығының көзқарастарын білдіретін ретінде қабылданбауы тиіс.

Инфляцияны селективті-аралас болжау жүйесі (SSCIF)

2024 жылғы желтоқсан

**NBRK – WP – 2024 – 13**

# Инфляцияны селективті-аралас болжау жүйесі (SSCIF)

Зарина Адилханова<sup>1</sup>  
Ислам Ержан<sup>2</sup>

## Аннотация

Тұрақсыз макроэкономикалық орта жағдайында инфляцияны болжау дәлдігін арттыру орталық банктер үшін, әсіресе инфляциялық таргеттеу режимін ұстанатындар үшін басым міндет болып табылады. Дәстүрлі эконометрикалық модельдер құбылмалылықты, сыртқы күтпеген өзгерістерді және желілік емес өзара байланыстарды ескергенде шектеулерге тап болады. Бұл зерттеу қолданыстағы инфляцияны селективті-аралас болжау жүйесіне машинамен оқыту әдістерін интеграциялау арқылы инфляцияны болжауды жақсартуға бағытталған. Ridge Regression, Lasso Regression және Elastic Net сияқты алгоритмдерді қосу макроэкономикалық деректердегі күрделі паттерндерді анықтауға және болжамдардың дәлдігін арттыруға мүмкіндік береді.

Дәстүрлі эконометрикалық модельдер (OLS, LTAR, BVAR, RW) мен машиналық оқыту алгоритмдерін пайдалану арқылы алынған болжамдардың салыстырмалы талдауы гибридік тәсіл болжау қателіктерін едәуір төмендетеді және қысқа мерзімді кезеңде болжамдардың сенімділігін арттырады. Алынған нәтижелер орталық банктердің шешім қабылдау сапасын қолдай отырып, макроэкономикалық болжау құралдарын жетілдіруге және неғұрлым тиімді ақша-кредит саясатын дамытуға үлес қосуы мүмкін.

**Негізгі сөздер:** инфляция, болжамдау, тұтыну бағасының индексі, модель, машинамен оқыту, эконометрикалық модельдер, болжамдардың дәлдігі.

**JEL classification:** E31, E37, C52, C61.

---

<sup>1</sup> Адилханова Зарина – Қазақстан Республикасы Ұлттық Банкінің Ақша-кредит саясаты департаментінің Макроэкономикалық зерттеулер және болжау басқармасының бас маман-талдаушысы.

E-mail: [zarina.adilkhanova@nationalbank.kz](mailto:zarina.adilkhanova@nationalbank.kz)

<sup>2</sup> Ержан Ислам – Қазақстан Республикасы Ұлттық Банкінің Ақша-кредит саясаты департаментінің Макроэкономикалық зерттеулер және болжау басқармасы бастығының орынбасары

E-mail: [islam.yerzhan@nationalbank.kz](mailto:islam.yerzhan@nationalbank.kz)

## Мазмұны

|              |   |           |
|--------------|---|-----------|
| <b>1</b>     | <b>Кіріспе</b> .....  | <b>5</b>  |
| <b>2</b>     | <b>Әдебиетке шолу</b> .....   | <b>6</b>  |
| <b>3</b>     | <b>Деректерді сипаттау және әдіснама</b> .....                          | <b>9</b>  |
| <b>3.1</b>   | <b>Инфляция мен деректерді селективті болжау жүйесінің сипаты</b> ... 9 |           |
| <b>3.2</b>   | <b>Қолданыстағы эконометрикалық модельдерді жаңарту</b> .....           | <b>10</b> |
| <b>3.3</b>   | <b>Машинамен оқыту модельдерін пайдалану</b> .....                      | <b>11</b> |
| <b>3.3.1</b> | <b>Ridge Regression</b> .....   | <b>11</b> |
| <b>3.3.2</b> | <b>Lasso Regression</b> .....   | <b>12</b> |
| <b>3.3.3</b> | <b>Elastic Net</b> .....  | <b>13</b> |
| <b>4</b>     | <b>Нәтижелер</b> .....  | <b>14</b> |
| <b>4.1</b>   | <b>Эконометрикалық модельдерді жақсарту</b> .....                       | <b>14</b> |
| <b>4.2</b>   | <b>Машиналық оқыту модельдерін қолдану</b> .....                        | <b>18</b> |
| <b>5</b>     | <b>Тұжырым</b> .....  | <b>22</b> |
| <b>6</b>     | <b>Пайдаланылған әдебиет тізімі</b> .....                               | <b>24</b> |
| <b>7</b>     | <b>Қосымша</b> .....  | <b>25</b> |

## 1 Кіріспе

Жаһандық экономикалық тұрақсыздық пен өсіп келе жатқан белгісіздік жағдайында инфляцияны дәл болжау қабілеті макроэкономикалық орнықтылықты қамтамасыз етудің негізгі элементіне айналады. Инфляцияның сенімді болжамдары ақша-кредит саясатын тиімді басқару үшін ғана емес, экономикалық динамиканың болжамдылығын арттыру үшін де қажет. Бұл әсіресе Қазақстан сияқты дамушы елдер үшін өзекті, онда инфляцияның нақты болжамдары халықтың сатып алу қабілетіне, инвестициялық белсенділікке және бюджет шешімдерге теріс әсерін жеңілдетуде маңызды рөл атқарады. Осылайша, инфляциялық процестерді талдаудың экономикалық шешімдер қабылдайтын, орнықты өсуге ықпал ететін тұрақты және болжамды экономикалық ортаны қолдауға ұмтылатын экономистер мен тұлғалар үшін шешуші мәні бар.

Авторегрессиялық модельдер (Autoregressive model, AR), векторлық авторегрессиялық модельдер (Vector autoregressive model, VAR) және қателерді түзету модельдері (Error correction model, ECM) (Stock and Watson, 2003) сияқты инфляцияны болжаудың дәстүрлі әдістері тұрақты макроэкономикалық жағдайларда жоғары тиімділікті көрсетті. Алайда, экономикалық құбылмалылық күшеюі және белгісіздік артуы нәтижесінде бұл тәсілдер шектеулерге тап болады. Олар желілік емес өзара байланыстарды нашар ескереді және экономикалық жағдайдың тез өзгеруіне жедел бейімделмейді, бұл тұрақсыз жағдайларда болжамдардың дәлдігін төмендетеді.

Осы сын-қатерлерге жауап ретінде қазіргі заманғы зерттеулер машинамен оқыту (Machine learning, ML) модельдерінің интеграциясын қарастырады. Бұл әдістер күрделі экономикалық процестерді модельдеу артықшылықтарын көрсетеді және макроэкономикалық деректердегі жасырын үлгілерді анықтау арқылы болжамдардың дәлдігін жақсартады. Мысалы, эмпирикалық зерттеулер машиналық оқыту алгоритмдері дәстүрлі эконометрикалық модельдермен салыстырғанда, әсіресе жоғары құбылмалылық кезінде болжам қателіктерін едәуір қысқартуы мүмкін екенін көрсетеді (Medeiros et al., 2021).

Машинамен оқыту әдістері деректердегі жасырын өзара байланыстарды талдау мүмкіндіктерін кеңейте отырып, дәстүрлі эконометрикалық модельдерге маңызды толықтыру болды. Mullainathan және Spiess (2017) атап өткендей, ML-алгоритмдері өзгермелі экономикалық жағдайларға бейімделуді арттыра отырып, деректердің желілік емес тәуелділігі мен өзгермелілігін икемді ескеруге мүмкіндік береді. Kohlscheen (2021) және Medeiros et al. (2021) зерттеулері ML ауыспалыларды көптеп тиімді өңдеуге және дәстүрлі тәсілдер үшін қолжетімсіз өзара байланыстарды анықтауға қабілетті екенін растайды, бұл инфляцияға әсер ететін факторларды неғұрлым толық талдауға ықпал етеді.

Осы зерттеу машиналық оқыту әдістерін ҚРҰБ инфляцияны қысқа мерзімді болжау үшін пайдаланатын қолданыстағы селективті-аралас инфляциялық болжам жүйесіне (System of Selective Combined Inflation Forecast, SSCIF) интеграциялау жолымен инфляциялық болжамдардың дәлдігін арттыруға бағытталған. Бұрын SSCIF классикалық эконометрикалық модельдер негізінде қысқа мерзімді болжамдарда дәлдікті табысты көрсетті. Алайда қазіргі заманғы экономикалық жағдайлар көбірек икемділік пен бейімділікті талап етеді, бұл Ridge, Lasso және Elastic Net сияқты машиналық оқыту әдістерін пайдалануды негіздейді. Бұл алгоритмдер дәстүрлі тәсілдердің көмегімен табу қиын күрделі өзара байланыстар мен жасырын үлгілерді тиімді анықтайды (Mullainathan and Spiess, 2017; Zou and Hastie, 2005).

Бұл зерттеудің негізгі мақсаты – дәстүрлі эконометрикалық тәсілдермен машиналық оқыту әдістерін интеграциялау арқылы инфляция болжамдарының дәлдігін арттыру. SSCIF моделінің шеңберінде мұндай біріктіру өзгермелі экономикалық жағдайларға бейімделуді жақсартуға және қысқа мерзімді болжамдардың сапасын арттыруға мүмкіндік береді.

Зерттеу бірнеше бөлімнен тұрады. Екінші бөлімде әдебиетке шолу берілген, ал үшінші бөлімде зерттеудің әдіснамалық аспектілері ашылады. Нәтижелерге арналған төртінші бөлім екі негізгі құрамдас бөлікті қамтиды: бірінші бөлім өзекті экономикалық жағдайды көрсету үшін дәстүрлі үлгілердің коэффициенттері мен теңдеулерін жаңартуды қарастырады, ал екіншісі – экономикалық белгісіздік жағдайларына бейімделген машиналық оқытудың төрт алгоритмінің интеграциясын қарастырады. Қорытынды бөлімде тұжырымдар бар. Зерттеу нәтижелері Қазақстандағы инфляция болжамдарының дәлдігін жақсартып отырып, макроэкономикалық модельдеу үшін машинамен оқыту әдістерінің жоғары әлеуетін көрсетеді.

## 2 Әдебиетке шолу

Әлемдік экономикалық белгісіздік пен құрылымдық өзгерістердің жеделдеуі аясында болжау тек талдамалық міндетке ғана емес, экономикалық саясаттың маңызды құралына да айналады. Болжамдардың жоғары дәлдігі макроэкономикалық тұрақтылықты және басқару шешімдерінің тиімділігін қолдауда маңызды рөл атқарады.

Инфляцияны болжау экономиканың барлық қатысушылары үшін маңызды, себебі ол белгісіздік жағдайында инвестицияларды, шығысты және жинақтарды жоспарлауға мүмкіндік береді. Бұл өз шешімдерін болашақ бағаларды күту негізінде түзететін үй шаруашылықтары мен кәсіпорындар үшін әсіресе өзекті. Инфляциялық таргеттеу саясатын жүргізетін орталық банктер үшін инфляцияның нақты болжамдары пайыздық мөлшерлемелер және ақша-кредит саясатының басқа да шаралары туралы шешімдер қабылдау үшін негіз болып табылады. Олар инфляциялық күтулерді тұрақтандыруға және экономикалық саясатқа деген сенімді арттыруға көмектеседі, бұл

макроэкономикалық орнықтылық пен тұрақты өсуді қамтамасыз ету үшін аса маңызды.

Классикалық эконометриялық модельдер инфляцияны болжауда маңызды орын алады (Stock and Watson, 2003). Бұл әдістер ұзақ мерзімді және қысқа мерзімді үрдістерді сандық бағалау алуының арқасында салыстырмалы түрде тұрақты экономикалық ортада жоғары тиімділікті көрсетті. Дегенмен, қазіргі экономикалық жағдайлар – деректер көлемінің өсуі, жоғары құбылмалылық және жаһандық белгісіздік модельдердің икемділігі мен бейімделуіне жаңа талаптар қойып отыр. Дәстүрлі тәсілдер сыртқы күтпеген өзгерістерге және инфляциялық күтулердің өзгеруіне уақтылы жауап бере алуындағы шектеулерге көбірек ұшырайды, бұл болжамдардың дәлдігін арттыру үшін жаңа шешімдер табуы талап етеді.

Осы сын-қатерлерге жауап ретінде машиналық оқыту әдістері экономикалық зерттеулерде маңызды рөл атқара бастады. Икемділігінің арқасында машиналық оқыту әдістері макроэкономикалық болжау үшін жаңа мүмкіндіктер ашты. Mullainathan және Spiess (2017) мұндай тәсілдер әдеттегі эконометриялық әдістердің мүмкіндіктерін едәуір кеңейте отырып, күрделі сызықтық емес өзара байланысты анықтай алатындығын атап өтті. Классикалық модельдерден айырмашылығы, ML алгоритмдері күрделі және тез өзгертін деректерге бейімделіп, болжамдардың дәлдігін жақсартады. Kohlscheen (2021) және Medeiros et al. (2021) қазіргі алгоритмдер көптеген айнымалылармен жұмыс істей алатынын және инфляцияның детерминанттарын тереңірек түсінуге мүмкіндік беретін әдеттегі тәсілдер үшін жасырын болып қалатын тәуелділікті анықтай алатынын атап көрсетеді.

Әдістерді салыстырмалы талдау машиналық оқыту әдістерінің классикалық эконометриялық тәсілдерге қарағанда бірнеше негізгі артықшылығы бар екенін көрсетеді. Біріншіден, ML модельдері көптеген айнымалылары бар үлкен деректер массивін өңдей алады және көп өлшемділік проблемасын тиімді шеше алады, бұл әсіресе факторлардың кең ауқымына байланысты инфляцияны зерттеуде маңызды (Kohlscheen, 2021). Екіншіден, олар параметрлерді бағалауға ғана емес, болжамдардың дәлдігін оңтайландыруға бағытталған, бұл оларды макроэкономикалық өзгерістерге уақтылы жауап беру үшін қажет қысқа мерзімді болжамдар үшін мейлінше тиімді етеді (Mullainathan and Spiess, 2017). Үшіншіден, ML модельдерінің жаңа деректер түскен кезде автоматты түрде жаңартыла алуы оларға экономикалық ортаның өзгеруіне жедел жауап беруге және нақты уақыттағы өзекті болжамдарды қамтамасыз етуге мүмкіндік береді.

Соңғы жылдары машиналық оқыту әдістерін әдеттегі эконометриялық модельдермен интеграциялау инфляцияны болжауда кеңінен қолданыла бастады. Мұндай гибридті тәсілдер эконометриялық модельдерге тән тарихи экономикалық үрдістердің интерпретациясы мен есебін машиналық оқыту алгоритмдерінің сызықтық емес өзара байланысты анықтау алуымен және тез өзгертін жағдайларға бейімделе алуымен біріктіруге мүмкіндік береді. Мысалы, Medeiros et al. (2021) Байес векторлық авторегрессиялық

модельдердің (BVAR) Ridge және Elastic Net регрессиясы сияқты машиналық оқыту әдістерімен үйлесуі, әсіресе жоғары құбылмалылық кезеңдерінде болжау қателерін айтарлықтай төмендететінін көрсетті.

Гибридті модельдердің артықшылығы – классикалық әдістермен анықтау қиын жасырын тәуелділіктер есебінен мейлінше дәл болжауды қамтамасыз ете алуы. Kohlscheen (2021) адаптивті LASSO сияқты алгоритмдерді эконометриялық модельдерге қосу олардың өзгеретін макроэкономикалық жағдайларға бейімделуін арттырады және болжамдардың дәлдігін жақсартады деп атап өтті.

Бұдан кейінгі зерттеулер машиналық оқыту әдістері мен факторлық модельдерді қолдану әсіресе үлкен деректермен жұмыс жасағанда инфляция болжамдарының дәлдігін едәуір арттыратынын растайды. Medeiros and Vasconcelos (2016) adaLASSO әдісін қолданатын сызықтық модельдер айнымалыларды адаптивті таңдау арқылы болжамдардың дәлдігін арттыратынын көрсетеді. Garcia et al. (2017) shrinkage техникасы және толық жиындардағы регрессия сияқты әртүрлі әдістерді біріктіру, әсіресе Бразилия мысалында көрсетілгендей, деректері көп экономикаларда тиімді болуы мүмкін екенін көрсетеді. Maehashi and Shintani (2020) де машиналық оқыту әдістері мен факторлық модельдер олардың әмбебаптығын көрсететін орта және ұзақ мерзімді болжамдарда жақсы болжай алуын көрсететінін атап өтті.

Сонымен бірге оның артықшылықтарына қарамастан, машиналық оқыту әдістерін қолдану белгілі бір әдіснамалық қиындықтармен байланысты болады. Ең негізгісі – әсіресе макроэкономикалық болжауға тән жоғары өлшемді деректермен жұмыс істеу кезінде қайта оқыту проблемасы. Бұл тәуекелді азайту үшін деректерді тиімді құрылымдау мен түсіндіруде маңызды рөл атқаратын Ridge, Lasso және Elastic Net сияқты пенализация жасалған регрессиялар қолданылады (Bai and Ng, 2008; Kim and Swanson, 2018; Smeekes and Wijler, 2018). Бұл әдістер негізгі айнымалыларды іріктеуді жеңілдетіп, модельдердің орнықтылығын арттырады, бұл әсіресе жоғары белгісіздік пен құбылмалылық жағдайында маңызды.

Осылайша, машиналық оқыту әдістері мен әдеттегі эконометриялық тәсілдерді біріктіретін гибридті модельдер макроэкономикалық болжау құралдарының арсеналында маңызды орын алып отыр. Олар мейлінше сенімді болжамдар жасауға ықпал етіп, орталық банктерге шешім қабылдауда тиімді қолдау көрсетеді.

Заманауи зерттеулер машиналық оқыту мен эконометриялық әдістердің үйлесімі икемді және бейімделгіш модельдерді қамтамасыз ету арқылы инфляция болжамдарының дәлдігін айтарлықтай жақсарта алатынын атап көрсетеді. Алайда, күрделі ML модельдерінің интерпретациялануы және олардың экономикадағы құрылымдық өзгерістер жағдайында қолданылуы сияқты шешілмеген мәселелер қалады. Бұдан кейінгі зерттеулер стационарлық емес деректермен жұмыс істеу үшін машиналық оқыту әдістерін оңтайландыруға және болжамдардың кенеттен экономикалық күтпеген өзгерістерге төзімділігін арттыруға бағытталуы керек.

### 3 Деректерді сипаттау және әдіснама

#### 3.1 Инфляция мен деректерді селективті болжау жүйесінің сипаты

Инфляцияны селективтік-аралас болжау жүйесі Forecasting and Policy Analysis System (FPAS) жүйесі шеңберінде инфляцияны қысқа мерзімді болжау үшін ҚРҰБ әзірлеген және қолданатын болжамдарды іріктемелі құрамдастыру тәсілін практикалық іске асыруды білдіреді. SSCIF дезагрегацияланған деректерді пайдалана отырып, тұтыну бағалары индексінің (ТБИ) серпінін модельдеуге мүмкіндік береді, бұл болжамдардың дәлдігін арттыруға ықпал етеді. Жүйеде ТБИ құрамына кіретін тауарлар мен қызметтердің негізгі топтарын қамтитын 66 қосалқы индекс (Қосымшаның 1-кестесі) пайдаланылады.

Қосалқы индекстердің динамикасын ішінара түсіндіретін экзогендік факторлар теңгенің шетел валюталарына қатысты айырбас бағамдарын, Ресейдегі инфляцияны, Қазақстандағы өнеркәсіптік бағаларды, ақша массасының көлемін, халықтың нақты табысын, сондай-ақ мұнай мен бидайдың әлемдік бағаларын қамтиды. Бұл егжей-тегжейлі тәсіл инфляцияның макроэкономикалық жағдайлардың өзгеруіне тәуелділігін неғұрлым дәл бағалауға мүмкіндік береді.

SSCIF-тегі барлық айнымалылар маусымдық көрсеткіштер қамтылған айлық көрсеткіштер түрінде ұсынылады және уақытша қатарлардың тұрақтылығын қамтамасыз ету үшін олар логарифмдердің әртүрлілігіне түрлендіріледі. Болжау үшін деректер 2011 жылғы қаңтардан бастап пайдаланылады. SSCIF шартсыз және шартты болып бөлінетін үлгілердің төрт түрін біріктіреді: шартсыз модельдерге желілік үрдіспен авторегрессия (LTAR) және кездейсоқ шарлау (RW), ал шартты модельдерге - көпфакторлы регрессия (OLS) және Байес векторлық авторегрессиясы (BVAR) жатады. Болжамдардың дәлдігі орташа шаршы қате көрсеткішінің (RMSE) көмегімен бағаланады, бұл модельді олардың болжамдық дәлдігіне байланысты өлшеуге мүмкіндік береді.

SSCIF моделі әр түрлі уақыт аралығында әрбір модельдің дәлдігін бағалауға және жекелеген уақыт кезеңдері үшін комбинациялық салмақты есептеуге мүмкіндік беретін селективті тәсілді қолданады. Тулеуов (2017) «рекурсивті комбинациялық таразылар» деп атайтын бұл салмақтар жақын аралықтағы болжамдардың дәлдігін арттырады және өзгермелі жағдайларға икемді бейімделуді қамтамасыз етеді. Содан кейін алынған болжам негізінде әрбір қосалқы индекс оның Қазақстанның тұтыну қоржынына қосқан үлесіне сәйкес сараланады. Сараланған қорытынды болжам ТБИ жалпы болжамын білдіреді, ол берілген уақыт кезеңіне инфляцияның болжамды динамикасын көрсетеді.

Осылайша, SSCIF инфляцияны болжауға арналған икемді құрал болып табылады, ол модельдерді біріктіруге және әртүрлі уақыт аралықтарын есепке алуға негізделген, бұл тұтыну бағасының индексінің сенімді болжамдарын қалыптастыруға мүмкіндік береді.

Модельдің жаңартылған нұсқасында, алдыңғы нұсқадағы сияқты, тұтыну бағаларының индексі инфляцияның негізгі көрсеткіші болып қала береді. Машинамен оқыту әдістерін пайдалану шеңберінде пайдаланылатын айнымалылардың тізімі кеңейтілді. Әдеттегі модельдерге қарағанда, машиналық оқыту модельдері өнеркәсіптік бағалардың біріктірілген көрсеткішін емес, оның жекелеген салалар мен тауарлар бойынша біріктірілмеген құрамдас бөліктерін пайдаланады, бұл түсіндіретін ауыспалылардың санын кеңейтеді және экономиканың әрбір секторының инфляцияға әсерін неғұрлым дәл ескеруге мүмкіндік береді. Сондай-ақ модельде бидайдың ғана емес, сондай-ақ болжамдардың дәлдігін арттыруға мүмкіндік беретін FAO азық-түлік бағаларының индексіне кіретін басқа да маңызды тауарлардың әлемдік бағалары пайдаланылатын болады.

Қосылған айнымалылар, бұрынғылар сияқты, маңыздылығы 5% деңгейінде уақытша қатарлардың тұрақтылығын қамтамасыз ету үшін логарифмдер айырмашылығында өзгерген айлық, маусымдық көрсеткіштері қамтылмаған деректерді білдіреді.

### **3.2 Қолданыстағы эконометрикалық модельдерді жаңарту**

Осы зерттеу шеңберінде SSCIF жүйесіне эконометрикалық үлгілерді пайдалана отырып болжау дәлдігін арттыруға бағытталған елеулі жақсартулар енгізілді. SSCIF-те пайдаланылатын эконометрикалық модельдер туралы толық ақпарат Тулеуовтың зерттеуінде (2017) ұсынылған. Модельге енгізілген өзгерістер:

1) Экзогенді айнымалылардың теңдеулері мен болжамдарын жақсарту.

Экзогенді айнымалыларға арналған теңдеулер қайта қаралды, бұл олардың болжамдарының дәлдігін арттыруға мүмкіндік берді. Бұл жақсару Қазақстандағы инфляцияға әсер ететін сыртқы факторларды неғұрлым барабар модельдеуді қамтамасыз етеді.

2) Маусымдық факторлар болжамдарының дәлдігін арттыру

Модель енді экзогенді айнымалылармен байланысты маусымдық факторларды болжауға арналған неғұрлым нақты теңдеулерді қамтиды. Бұл өзгерістер инфляцияның қалыптасуында, әсіресе күшті маусымдық өзгерістерге ұшыраған секторларда шешуші рөл атқаратын маусымдық ауытқуларды болжауды жақсартуға мүмкіндік берді.

3) Ресейдегі инфляция мен әлемдік мұнай бағасының экзогендік болжамдары

Ресейдегі инфляцияны және мұнайдың әлемдік бағасын болжау қазір спутниктік модельдердің болжамдарына негізделген модельде экзогендік түрде берілген. Бұл тәсіл барынша сенімді және өзекті деректерді пайдалана отырып, сыртқы экономикалық жағдайларды ескеруге мүмкіндік береді.

4) BVAR теңдеулерін кеңейту және оңтайландыру:

Байес векторлық авторегрессиялық моделінде (BVAR) теңдеулер саны сараптамалық бағалау және ТБИ құрамына кіретін тауарлар мен қызметтер

топтары арасындағы анықталған корреляциялық байланыстар негізінде 15-тен 18-ге дейін ұлғайтылды. Сонымен қатар, модельдегі кідірістер саны эконометрикалық сынақтарды қолдану арқылы жаңартылды, мысалы, ақпаратты таңдау өлшемшарттары (AIC) және қалдықтардың автокорреляциялық сынақтары, бұл ағымдағы кірістерді толық есепке алуға мүмкіндік берді.

### 3.3 Машинамен оқыту модельдерін пайдалану

Бұл әдіснамалық бөлімде Қазақстандағы инфляцияны қысқа мерзімді болжау үшін пайдаланылатын машинамен оқу модельдері ұсынылған. Ridge, Lasso және Elastic Net әдістерін қолдану макроэкономикалық деректерге тән мультиколлинеарлық және қайта оқыту сияқты мәселелерді азайту арқылы болжамдарды жақсарту қабілетіне негізделген. Бұл тәсілдер бір уақытта көптеген экономикалық айнымалыларды ескеруге және модельді өзгермелі экономикалық жағдайларға бейімдей отырып, болжамдардың тұрақтылығын қамтамасыз етуге мүмкіндік береді.

#### 3.3.1 Ridge Regression

Ridge Regression (еспелі регрессия) – бірнеше желілік регрессия есептеріндегі мультиколлинеарлық мәселені шешу үшін кеңінен қолданылатын регуляризация әдісі. Дәстүрлі регрессия әдістері түсіндіруші айнымалылардың тәуелсіздігін болжайды, бірақ іс жүзінде бұл айнымалылар өзара жиі байланысты болып шығады. Бұл бағалаудың дәлдігінің төмендеуіне әкеледі және модельдің тұрақтылығын жояды. Ridge Regression регрессия коэффициенттерінің шамасы үшін айыппұл қосып, осылайша модельді тұрақтандыру арқылы көп коллинеарлық әсерді регуляризация арқылы азайтуға мүмкіндік береді.

Ridge Regression стандартты бірнеше сызықтық регрессия моделіне негізделген:

$$Y = X\beta + \epsilon$$

мұнда  $Y$  – тәуелді айнымалы (бұл жағдайда инфляция),  $X$  – түсіндірме айнымалылар матрицасы (мысалы, тауарлардың әлемдік бағасы, валюта бағамы, ақша массасы),  $\beta$  – бағаланатын модель коэффициенттері,  $\epsilon$  – кездейсоқ қате.

Стандартты желілік регрессияда мақсат коэффициенттерді табу үшін ауытқу квадраттарының (RSS) қосындысын азайту болып табылады:

$$RSS = \sum_{i=1}^n (Y_i - X_i\beta)^2$$

Ridge регрессиясы бұл функцияға олардың мөлшерін бақылау және қайта оқытпас үшін коэффициенттердің шамасына айыппұл қосады. Ridge азайтатын функция былай болады:

$$RSS + \lambda \sum_{j=1}^p \beta_j^2$$

мұнда  $RSS$  – ауытқу квадраттарының қосындысы,  $\lambda$  – үлкен коэффициент мәндері үшін «айыппұл» дәрежесін бақылайтын реттеу коэффициенті.

Ridge параметрі деп аталатын бұл қосымша параметр мультиколлинеарлықтың әсерін азайтуға мүмкіндік береді, бұл модельді бағалауды тұрақты және дәл етеді.

Кіші  $\lambda$  мәндерінде еспелі регрессия әдеттегі желілік регрессияға жуық болады, мұнда коэффициенттерді бағалау ең кіші квадраттар әдісімен жүзеге асырылады. Алайда,  $\lambda$  жоғарылаған сайын коэффициенттер азаяды, бұл олардың мәндерін мультиколлинеарлық жағдайда тұрақтандыруға және модельдегі вариацияларды азайтуға мүмкіндік береді. Бұл Ridge Regression-тің басты ерекшелігі: ол модельге тым көп түрленуіне әкелуі мүмкін айнымалылардың әсерін азайтады, бұл болжамдардың дәлдігін жақсартуға, әсіресе көптеген корреляциялық айнымалыларды қолданған кезде жақсартуға мүмкіндік береді.

Еспелі регрессияны Hotel and Kenar (1970) ұсынған және содан бері мультиколлинеарлықпен жұмыс істеудің негізгі әдістерінің біріне айналды. Ridge  $\lambda$  параметрі модельдің дәлдігі мен қарапайымдылығын теңестіруге мүмкіндік беретін үлкен коэффициент мәндерін қаншалықты әсер ететінін анықтайды. Оңтайлы  $\lambda$  мәнін таңдау үшін кросс-валидация әдісі жиі қолданылады. Болжам дәлдігі ең жоғары болатын мәнді табу үшін модель әр түрлі кіші деректер үлгілерінде тексеріледі.

Инфляцияны болжау контекстінде Ridge Regression әсіресе әлемдік мұнай бағалары, валюта бағамдары, ақша массасы, халықтың кірісі және басқа да көрсеткіштер сияқты макроэкономикалық айнымалылардың кең ауқымын талдауда пайдалы. Ұқсас өзара тәуелді айнымалылар болған кезде пайда болатын мультиколлинеарлық Проблема дәстүрлі модельдердегі болжамдардың дәлдігін айтарлықтай төмендетуі мүмкін. Ridge Regression қысқа және орта мерзімді перспективада нақты болжамдар жасай отырып, модельді тұрақтандыруға мүмкіндік береді.

Осылайша, Ridge Regression инфляцияны болжау модельдерін құрудың тиімді құралы болып табылады, ол мультиколлинеарлық пен қайта оқытудың әсерін азайтуға қабілетті. Бұл әдіс әсіресе жоғары күрделілікпен және айнымалылар арасындағы қатынастармен сипатталатын макроэкономикалық деректермен жұмыс істеу кезінде өзекті болып табылады.

### 3.3.2 Lasso Regression

Tibshirani (1996) ұсынған Lasso Regression (Least Absolute Shrinkage and Selection Operator) айнымалы шамаларды реттеу мен таңдау үйлесім табатын сызықтық регрессия әдісін білдіреді. Қалыптасып қалған әдістерге қарағанда

Lasso Regression модель коэффициенттерін бағалауға ғана емес, сонымен қатар маңызы жоқ айнымалы шамаларды автоматты түрде алып тастауға мүмкіндік береді, сондықтан ол эконометрикалық модельдерді құруда, атап айтқанда инфляцияны болжауда қымбат құралға айналады.

Lasso әдісінің негізгі қағидаты – коэффициенттердің абсолютті мәндері үшін айыппұл қосылатын L1-норманы қолдану арқылы өзгерту. Бұл барынша азайтудың стандартты функциясының былай өзгеруіне алып келеді:

$$RSS + \lambda \sum_{j=1}^p |\beta_j|$$

мұнда RSS - ауытқу квадраттарының қосындысы,  $\lambda$  – өзгерту коэффициенті.

Айыппұл коэффициенттердің квадратына қолданылатын Ridge Regression әдісіне қарағанда, Lasso олардың абсолютті мәндеріне айыппұл салады, бұл кейбір коэффициенттердің мәндерін нөлге дейін төмендетуге мүмкіндік береді. Осылайша, Lasso жеке айнымалы шамалардың әсерін азайтып қана қоймайды, сонымен қатар тек маңызды факторларды қалдырып, болжамға өте аз үлес қосатын айнымалы шамаларды алып тастайды.

$\lambda$  мәнін теңшеу – Lasso әдісіндегі маңызды кезең, өйткені тек сол ғана модельде қалған айнымалы шамалардың санын анықтайды. Егер  $\lambda=0$  болса, модель қалыпты сызықтық регрессияға дейін азаяды.  $\lambda$  артқан кезде, айнымалы шамалардың көбісі модельден алып тасталады.  $\lambda$  оңтайлы мәні модельдің дәлдігі мен күрделілігі арасындағы тепе-теңдікке қол жеткізу үшін кросс-валидацияны қолдану арқылы таңдап алынады.

Lasso инфляцияны болжаудың қуатты құралы болып табылады, өйткені ол инфляциялық процестерге әсер ететін негізгі факторларды анықтауға көмектеседі. Lasso әдісінің артықшылығы – ол маңызды емес айнымалы шамалардың маңызды түрлерін қалдырып, маңызды емес түрлерін автоматты түрде алып тастайды. Lasso көптеген айнымалы шамалар өзара байланысқа түсетін өте көлемді деректермен жұмыс істеу кезінде тиімді болып келеді. Барлық коэффициенттер төмендейтін Ridge Regression әдісіне қарағанда, Lasso айнымалыларды толығымен жоя алады, бұл модельді түсіндіруді жеңілдетіп, қайта оқу тәуекелін азайтады.

### 3.3.3 Elastic Net

Elastic Net әдісі регрессиялық талдауда түсіндірме айнымалылардың, олардың арасында өзара тығыз байланысатын айнымалылардың көп болуына байланысты есептерді шешу үшін қолданылады. Zou and Hastie (2005) әзірлеген Elastic Net Lasso және Ridge реттеу әдісінің элементтерін біріктіреді, бұл бір уақытта мультиколлинеарлықты еңсеруге және аса маңызды айнымалыларды таңдауға мүмкіндік береді.

Математикалық тұрғыдан алғанда, Elastic Net екі айыппұл функциясы қосылған сызықтық регрессияның кеңеюін білдіреді. Бұл әдістің негізгі мақсаты – мынадай функцияны азайту:

$$RSS + \lambda_1 \sum_{j=1}^p |\beta_j| + \lambda_2 \sum_{j=1}^p \beta_j^2$$

Бұл формулада  $\lambda_1$  L1-өзгертуге жауап береді (Lasso әдісіндегі сияқты), ол маңызы жоқ коэффициенттерді жояды, ал  $\lambda_2$  L2-өзгертуге жауап береді (Ridge әдісіндегі сияқты), ол барлық коэффициенттердің шамасын азайтады және корреляцияланған айнымалылар болған кезде модельді тұрақтандырады.

Деректерде көптеген өзара байланысты айнымалылар болған жағдайда, L1 және L2-тұрақтандыру үйлесімі арқылы Elastic Net әдісі өте пайдалы болады. L1-тұрақтандыру болжамға барынша аз әсер ететін айнымалыларды жоя отырып, айнымалыларды таңдауға ықпал етеді, ал L2-тұрақтандыру модельдің мультиколлинеарлыққа төзімділігін қамтамасыз ете отырып, коэффициенттерді бағалаудың дисперсиясын азайтады. Осылайша, Elastic Net Ridge мен Lasso әдістерінің артықшылықтарын тиімді үйлестіріп, күрделі және кешенді деректер болған кезде сенімді нәтижелерді қамтамасыз етеді. Elastic Net негізгі кезеңдерінің бірі –  $\lambda_1$  және  $\lambda_2$ , параметрлері үшін оңтайлы мәндерді таңдау, бұл әдетте кросс-валидация арқылы жасалады. Бұл процесс айнымалыларды таңдау мен коэффициенттерді тұрақтандыру арасындағы тепе-теңдікті табуға көмектеседі, бұл болжамның дәлдігін жақсартады.

## 4 Нәтижелер

### 4.1 Эконометрикалық модельдерді жақсарту

SSCIF эконометрикалық моделіне енгізілген өзгерістер болжамды тиімділігін айтарлықтай арттырып, болжау қателіктерін азайта отырып, негізгі көрсеткіштерді бағалау дәлдігін жақсартты. Бұл экономикалық айнымалылар арасындағы өзара байланысты тиімді есепке алуға мүмкіндік берді, ал ол алынған нәтижелердің сенімділігін арттырады

1-кестеде SSCIF моделінің бастапқы және жаңартылған нұсқалары үшін Қазақстандағы инфляцияның жалған-іріктеуден тыс болжамдарының дәлдігін сандық бағалау ұсынылған<sup>3</sup>. Болжамдардың дәлдігі орташа квадраттық қате көрсеткішін (RMSE) пайдалану арқылы өлшенді, мұнда төменгі мәндер модельдің болжау сапасының артқанын көрсетеді. Кестедегі деректерге сәйкес, модельдің жаңартылған нұсқасы инфляцияның болжам қателіктерінің

---

<sup>3</sup> Бұл зерттеуде ұсынылған болжамдар эконометрикалық модельдердің ішкі алгоритмдеріне негізделген таза модельдік бағалар болып табылады. Олар сыртқы алғышарттар, сараптамалық пікірлер, геосаяси жағдай, реттелетін бағалардың өзгерістері және басқа да әкімшілік шаралар сияқты қосымша факторларды қамтымайды. Сондықтан бұл нәтижелер экономикалық жағдай мен баға динамикасына әсер ететін сыртқы факторлар мен сараптамалық бағаларды ескеретін нақты болжамдардан ерекшеленуі мүмкін.

едәуір азайғанын көрсетеді. Алайда, 2016 жылдың наурыз-қараша айлары аралығында алдыңғы модель азық-түлікке жатпайтын және қызмет инфляциясын болжауда төменірек RMSE қателігін көрсетті. Бұл оның бастапқыда осы уақыт кезеңінің ерекшеліктерін ескере отырып әзірленгенімен байланысты. Керісінше, жаңартылған модельдің деректері бұл кезең үшін болжамдарда жоғарырақ қателіктерді көрсетеді, себебі ол кеңейтілген уақыттық деректер жиынтығына бейімделген және кейінгі жылдарда алынған жаңа деректерді қамтиды.

**1-кесте. Алдыңғы және жаңартылған модель үшін нақты іріктеудің әртүрлі сынақ учаскелерінде Қазақстандағы инфляцияның жалған-іріктеуден тыс болжамдарының (ТБИ % а/а) дәлдігін сандық бағалау**

| Кезең                                    |                           | Азық-түлік инфляциясы | Азық-түлікке жатпайтын инфляция | Сервистік инфляция | Жалпы инфляция |
|--|---------------------------|-----------------------|---------------------------------|--------------------|----------------|
| <b>2016 ж. наурыз - 2016 ж. қараша</b>   | Алдыңғы модель (RMSE)     | 0.519                 | 0.210                           | 0.281              | <b>0.198</b>   |
|  | Жаңартылған модель (RMSE) | 0.494                 | 0.249                           | 0.285              | 0.206          |
| <b>2018 ж. қаңтар – 2018 ж. қыркүйек</b> | Алдыңғы модель (RMSE)     | 0.331                 | 0.627                           | 0.277              | 0.242          |
|  | Жаңартылған модель (RMSE) | 0.312                 | 0.543                           | 0.247              | <b>0.197</b>   |
| <b>2020 ж. шілде - 2021 ж. наурыз</b>    | Алдыңғы модель (RMSE)     | 0.124                 | 0.323                           | 0.293              | 0.076          |
|  | Жаңартылған модель (RMSE) | 0.134                 | 0.263                           | 0.290              | <b>0.064</b>   |
| <b>2023 ж. мамыр – 2024 ж. қаңтар</b>    | Алдыңғы модель (RMSE)     | 0.484                 | 0.347                           | 0.184              | 0.203          |
|  | Жаңартылған модель (RMSE) | 0.464                 | 0.293                           | 0.184              | <b>0.172</b>   |

Дереккөзі: ҚР СЖПА ҰСБ, автордың есептеулері

Дәлдіктің түс шкаласы

дәл емес

дәлірек

2018 жылдың қаңтар-қыркүйек айлары аралығында жаңартылған модель инфляцияның барлық санаттары бойынша орташа квадраттық қателіктің (RMSE) айтарлықтай төмендегенін көрсетті. Ең үлкен жақсарту жалпы инфляция бойынша байқалды, онда қателік 18,6%-ға азайды. Бұл нәтижелер жаңартылған модельдің алдыңғы нұсқасында көрсетілмеген жаңа экономикалық үрдістерді ескеру қабілетін көрсетеді.

2020 жылдың шілде айынан 2021 жылдың наурыз айына дейінгі кезеңде жаңартылған модель де айтарлықтай жақсартуларды көрсетті, әсіресе жалпы инфляция үшін, онда болжам қателігі 15,8%-ға төмендеді. Бұл жаңартулар

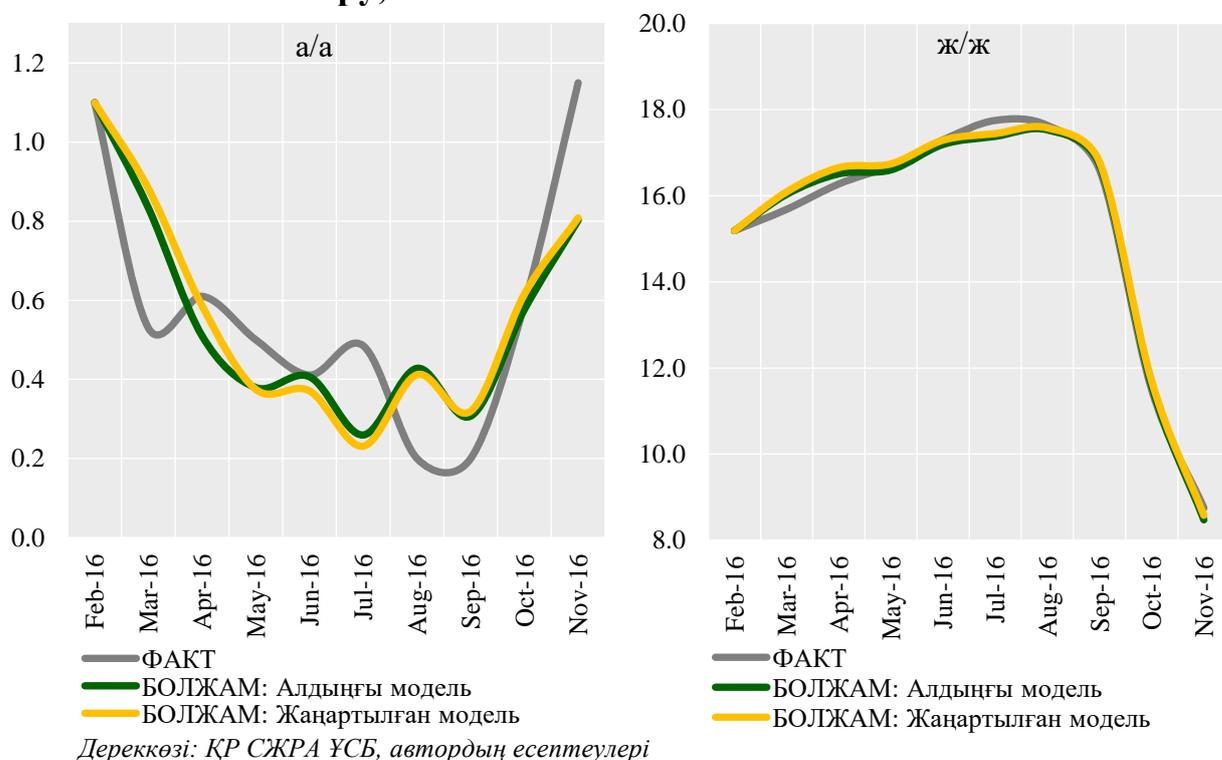
экономикалық айнымалылар арасындағы ұзақ мерзімді өзара байланыстарды ескеруге мүмкіндік бергенін көрсетеді.

2023 жылдың мамыр айынан 2024 жылдың қаңтар айына дейінгі соңғы кезеңде жаңартылған модель жалпы инфляция бойынша RMSE-ні 15,3%-ға төмендетті. Бұл модельдің баға динамикасы мен валюта факторларындағы өзгерістерді қоса алғанда, жаңа макроэкономикалық жағдайларға тиімді бейімделгенін көрсетеді.

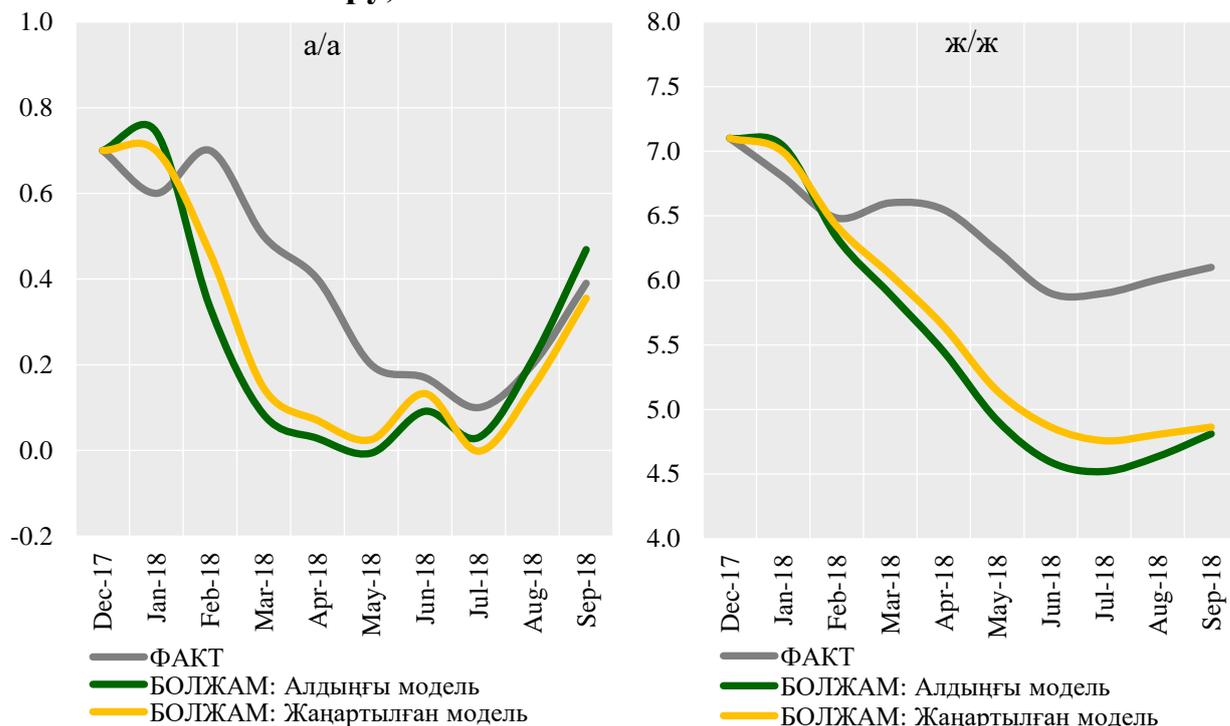
Осылайша, алдыңғы модель 2016 жылдың наурыз-қараша айлары сияқты ерте кезеңдерде жақсырақ дәлдікті көрсетеді, бұл оның бастапқыда осы уақыт аралығына бағытталғандығымен байланысты. Дегенмен, кейінгі кезеңдерде жаңартылған модель айтарлықтай басымдыққа ие, өйткені ол деректердің үлкен көлемін ескереді және жаңа экономикалық жағдайларға бейімделген.

1 және 4-суреттерде SSCIF моделінің екі нұсқасын қолдана отырып жасалған инфляцияның іс жүзіндегі деректері мен нақты жалған-іріктеуден тыс болжамдарын салыстыруды бейнелейтін графиктер келтірілген. Жаңартылған модель инфляцияның айлық және жылдық өзгерістерінде нақты деректердің дәл сәйкестігін көрсетті. Бұл жақсартулар модельдегі жаңартулар экономикадағы өзгерістерді тиімдірек есепке алуға және ТБИ-дың барлық компоненттерін болжауды жақсартуға мүмкіндік бергенін растайды.

**1-сурет. 2016 жылғы наурыздан қарашаға дейін SSCIF бойынша Қазақстандағы инфляцияны фактімен және нақты-іріктеуден тыс болжаммен салыстыру, %**

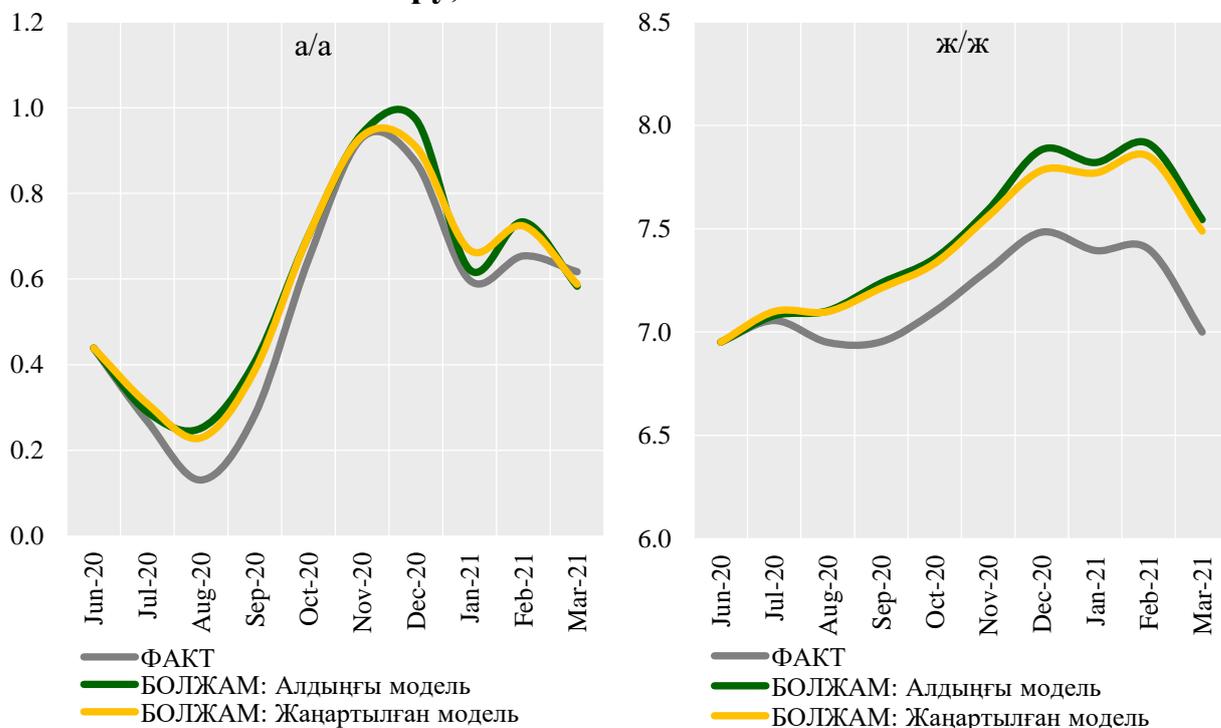


**2-сурет. 2018 жылғы қаңтардан қыркүйекке дейін SSCIF бойынша Қазақстандағы инфляцияны фактімен және нақты-іріктеуден тыс болжаммен салыстыру, %**



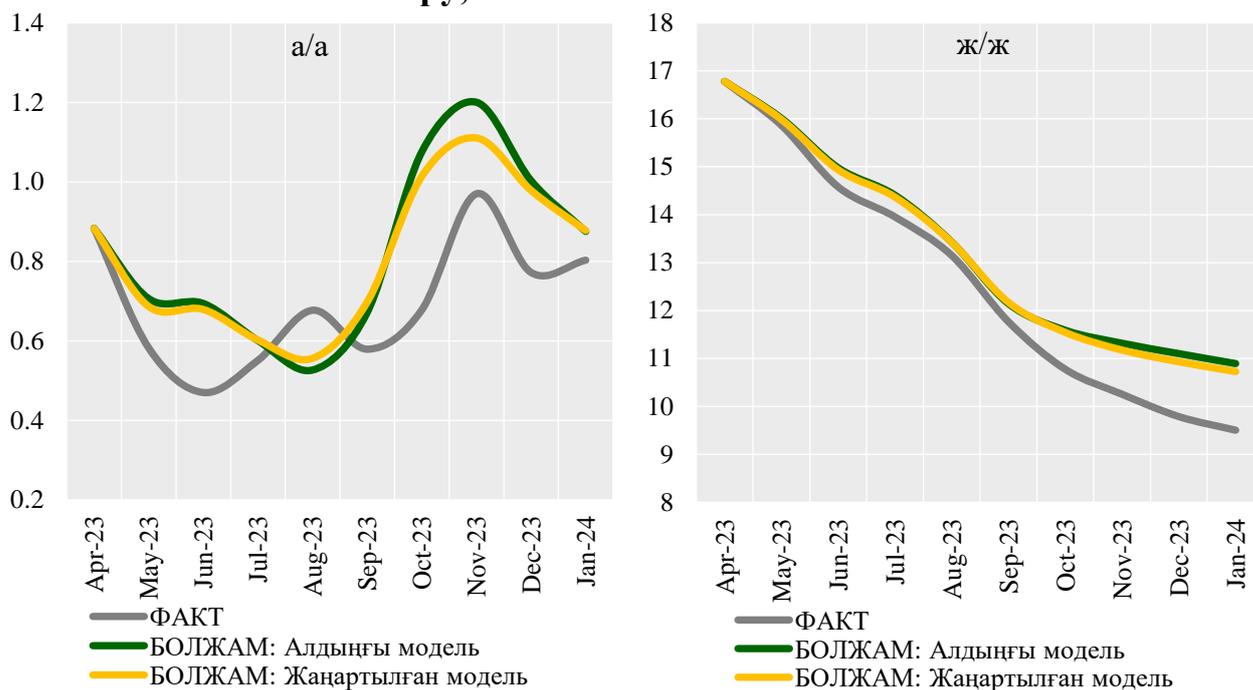
Дереккөзі: ҚР СЖРА ҰСБ, автордың есептеулері

**3-сурет. 2020 жылғы шілдеден 2021 жылғы наурызға дейін SSCIF бойынша Қазақстандағы инфляцияны фактімен және нақты-іріктеуден тыс болжаммен салыстыру, %**



Дереккөзі: ҚР СЖРА ҰСБ, автордың есептеулері

**4-сурет. 2023 жылғы мамырдан 2024 жылғы қаңтарға дейін SSCIF бойынша Қазақстандағы инфляцияны фактімен және нақты-іріктеуден тыс болжаммен салыстыру, %**



Дереккөзі: ҚР СЖРА ҰСБ, автордың есептеулері

Осылайша, түпнұсқа SSCIF-тің жаңартылған нұсқасы инфляцияны болжаудың дәлдігінің жоғары деңгейін қамтамасыз етеді, бұл оны инфляцияны болжаудың сенімді құралы етеді.

## 4.2 Машиналық оқыту модельдерін қолдану

Жалған-іріктеуден тыс инфляция болжамдарының дәлдігін сандық бағалау нәтижелері 2-кестеде келтірілген, ол әртүрлі уақыт аралықтарындағы дәстүрлі және машиналық оқыту (ML) модельдерінің тиімділігіндегі айырмашылықтарды көрсетеді.

2016 жылдың наурыз-қараша айлары аралығында ML моделі азық-түлікке жатпайтын және жалпы инфляцияны болжауда айтарлықтай төмен тиімділікті көрсетті. Бұл модельдің кейінгі уақыт кезеңдеріне бейімделуімен және кеңейтілген деректер жиынтығын пайдаланумен түсіндіріледі.

2018 жылғы қаңтар-қыркүйек аралығындағы жаңартылған модель азық-түлік және сервистік инфляцияны болжауда жоғары дәлдікті көрсетті, бұл орташа квадраттық қатемен расталады (RMSE). Алайда, ML әдістерін қолданатын кеңейтілген модель экономикалық ортадағы өзгерістерге жоғары бейімделуді көрсете отырып, азық-түлікке жатпайтын және жалпы инфляцияны болжауда жаңартылған модельден асып түсті. Осы кезеңде жалпы инфляция бойынша RMSE 12,2%-ға төмендеді.

2020 жылдың шілде айынан 2021 жылдың наурыз айына дейінгі кезеңде ML моделі азық-түлікке жатпайтын және жалпы инфляцияны болжауда айтарлықтай жақсаруларды көрсетті, RMSE сәйкесінше 32,3% және 6,3%-ға

төмендеді, жаңартылған модельмен салыстырғанда. Дегенмен, азық-түлік және қызмет инфляциясы бойынша жаңартылған модель болжамның тұрақтылығын сақтап, жақсы нәтижелер көрсетті.

**2-кесте. Жаңартылған және кеңейтілген модель үшін іс жүзіндегі іріктеудің әртүрлі сынақ учаскелерінде Қазақстандағы инфляцияның жалған-іріктеуден тыс болжамдарының (ТБИ % а/а) дәлдігін сандық бағалау**

| Кезең                                    |                                  | Азық-түлік инфляциясы | Азық-түлікке жатпайтын инфляция | Сервистік инфляция | Жалпы инфляция |
|--|----------------------------------|-----------------------|---------------------------------|--------------------|----------------|
| <b>2016 ж. наурыз - 2016 ж. қараша</b>   | Жаңартылған модель (RMSE)        | 0.494                 | 0.249                           | 0.285              | <b>0.206</b>   |
|  | ML бар кеңейтілген модель (RMSE) | 0.771                 | 0.662                           | 0.336              | 0.473          |
| <b>2018 ж. қаңтар – 2018 ж. қыркүйек</b> | Жаңартылған модель (RMSE)        | 0.312                 | 0.543                           | 0.247              | 0.197          |
|  | ML бар кеңейтілген модель (RMSE) | 0.340                 | 0.351                           | 0.265              | <b>0.173</b>   |
| <b>2020 ж. шілде - 2021 ж. наурыз</b>    | Жаңартылған модель (RMSE)        | 0.134                 | 0.263                           | 0.290              | 0.064          |
|  | ML бар кеңейтілген модель (RMSE) | 0.221                 | 0.178                           | 0.258              | <b>0.060</b>   |
| <b>2023 ж. мамыр – 2024 ж. қаңтар</b>    | Жаңартылған модель (RMSE)        | 0.464                 | 0.293                           | 0.184              | 0.172          |
|  | ML бар кеңейтілген модель (RMSE) | 0.276                 | 0.167                           | 0.234              | <b>0.131</b>   |

Дереккөзі: ҚР СЖРА ҰСБ, автордың есептеулері

Дәлдіктің түс шкаласы

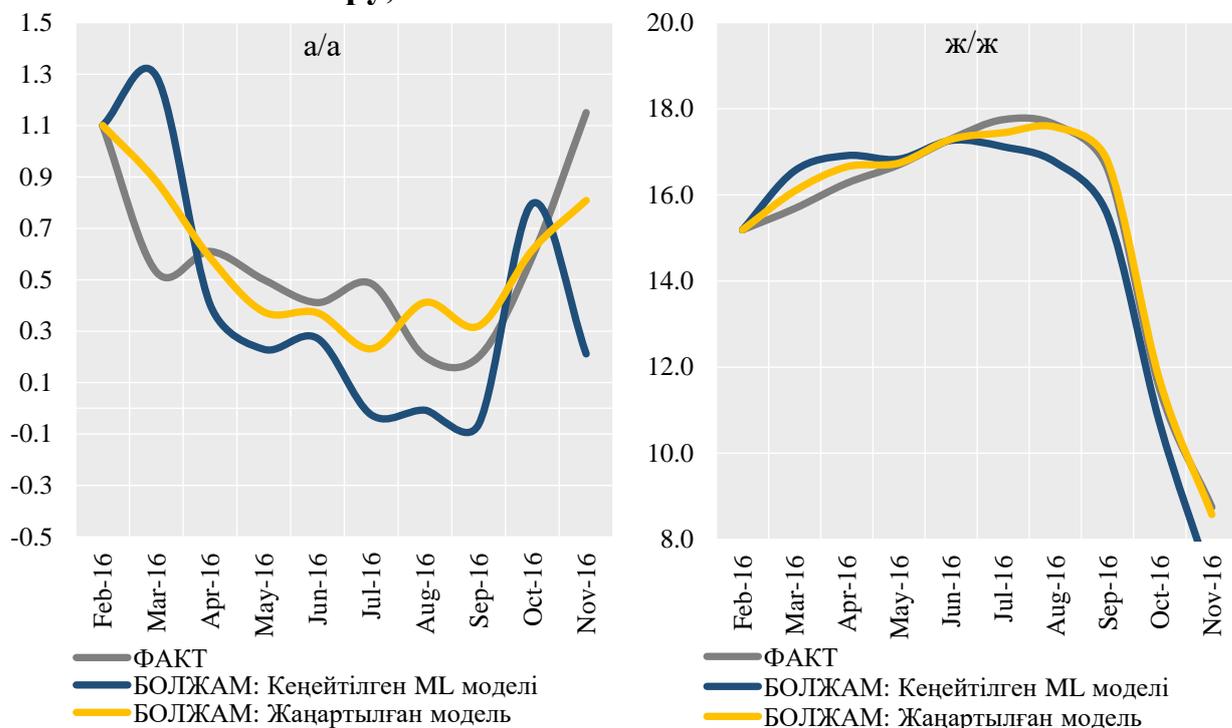


2023 жылғы мамырдан 2024 жылғы қаңтарға дейінгі кезеңді қамтитын кейінгі уақыт аралығында ML моделі инфляцияның барлық дерлік санаттарын болжауда айқын артықшылық көрсетті. Азық-түлікке жатпайтын инфляция үшін RMSE төмендеуі әсіресе байқалады, бұл қазіргі экономикалық қиындықтар мен тұрақсыздық жағдайында ML тәсілінің жоғары дәлдігі мен икемділігін көрсетеді. Дегенмен, сервистік инфляция сегментінде жаңартылған модель төмен болжамды қатені қамтамасыз ете отырып, көшбасшылықты сақтап қалды. Бұл инфляцияның тұрақты және баяу өзгертін компоненттерін болжау үшін дәстүрлі тәсілдердің өзекті болып қала беретінін растайды. Жалпы инфляция бойынша ML моделі RMSE көрсеткішін 23,8%-ға төмендетіп, жаңа экономикалық сын-қатерлер жағдайында өзінің бейімделгіштігін көрсетті.

Машиналық оқыту әдістерін пайдалану инфляцияны болжау дәлдігін айтарлықтай арттыруға мүмкіндік береді (5–8-суреттер). Алайда, жаңартылған модельге негізделген дәстүрлі әдістер қызмет инфляциясы сияқты кейбір

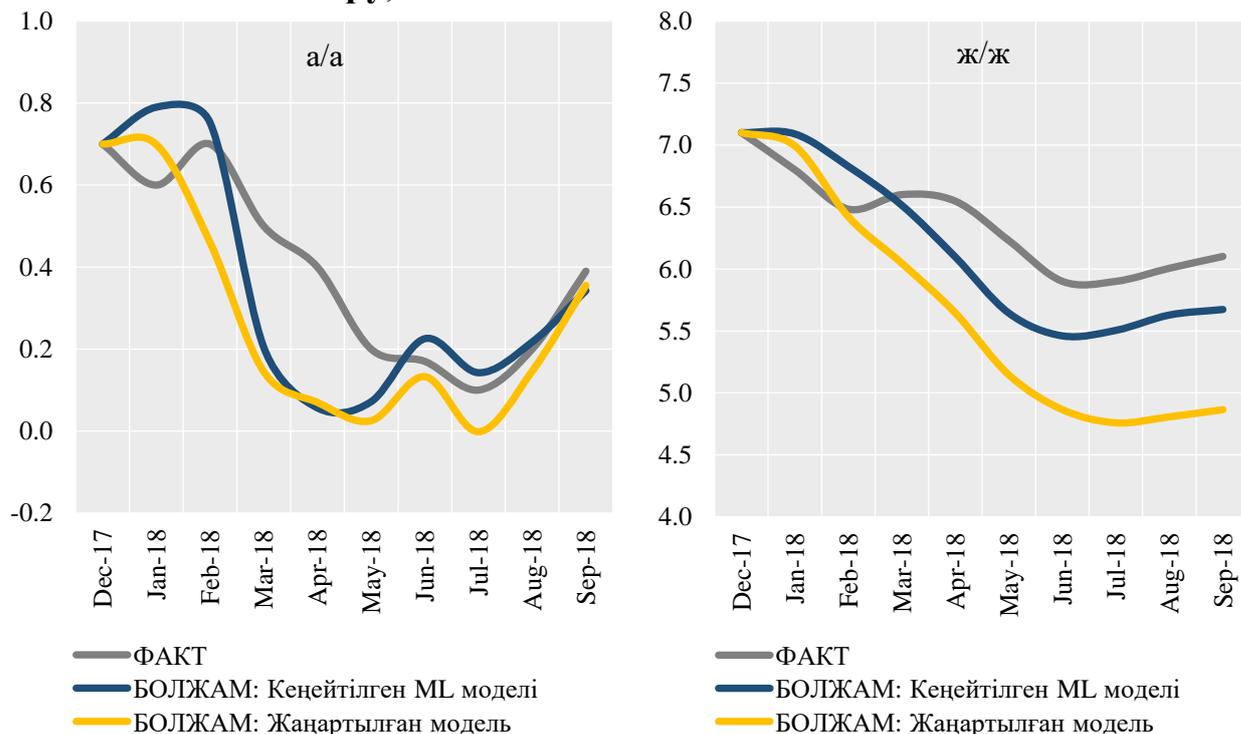
сегменттерде тиімділігін сақтап қана қоймай, кешенді болжау тәсілінде ML модельдерін үйлесімді түрде толықтыра алады.

**5-сурет. 2016 жылғы наурыздан қарашаға дейін SSCIF бойынша Қазақстандағы инфляцияны фактімен және нақты-іріктеуден тыс болжаммен салыстыру, %**



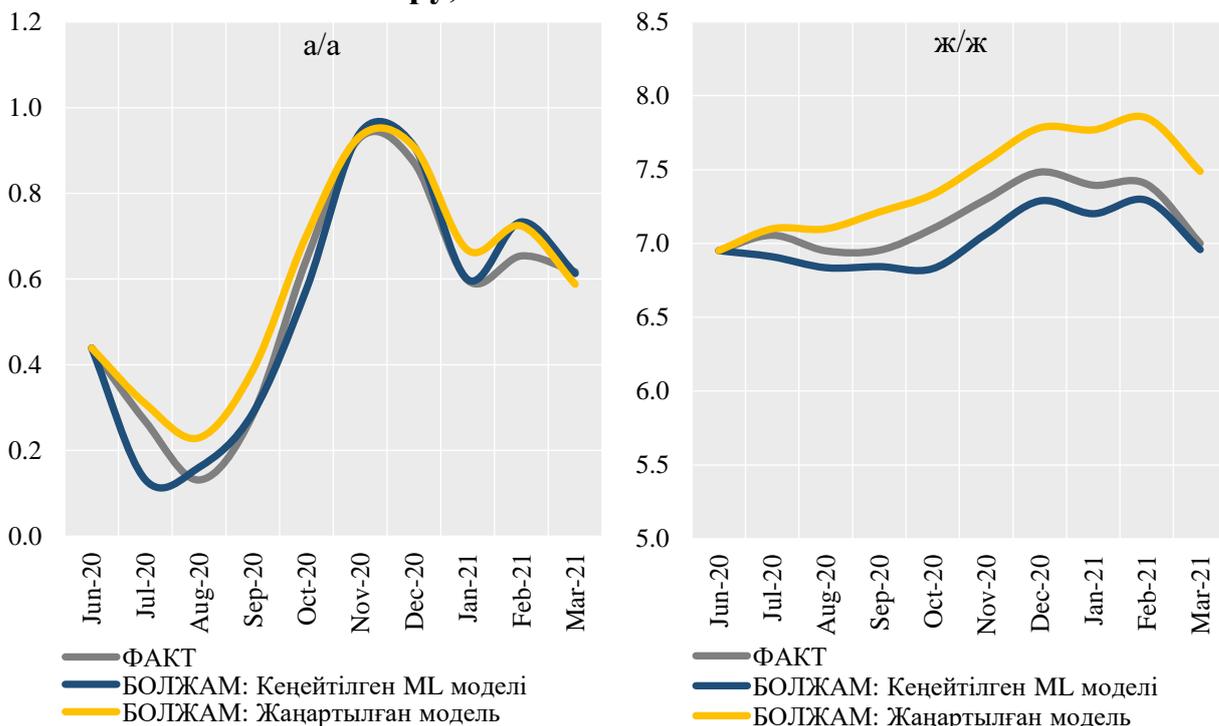
Дереккөзі: ҚР СЖРА ҰСБ, автордың есептеулері

**6-сурет. 2018 жылғы қаңтардан қыркүйекке дейін SSCIF бойынша Қазақстандағы инфляцияны фактімен және нақты-іріктеуден тыс болжаммен салыстыру, %**



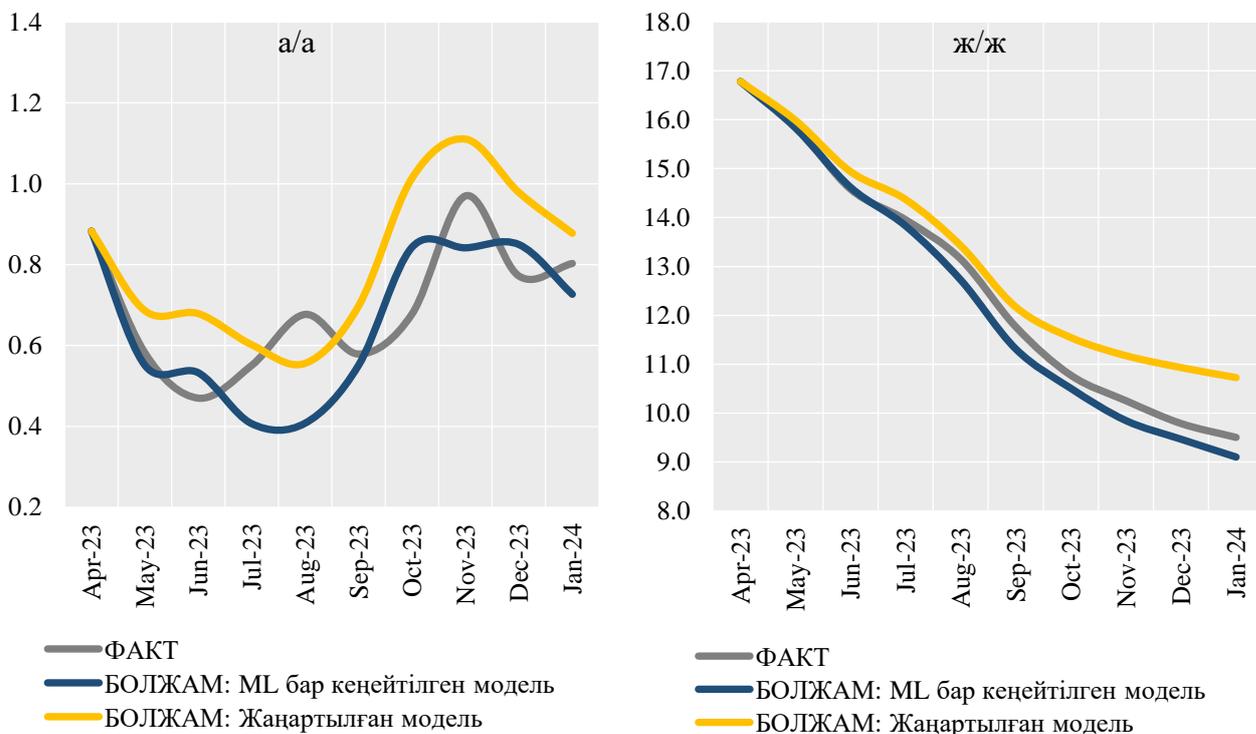
Дереккөзі: ҚР СЖРА ҰСБ, автордың есептеулері

**7-сурет. 2020 жылғы шілдеден 2021 жылғы наурызға дейін SSCIF бойынша Қазақстандағы инфляцияны фактімен және нақты-іріктеуден тыс болжаммен салыстыру, %**



Дереккөзі: ҚР СЖРА ҰСБ, автордың есептеулері

**8-сурет. 2023 жылғы мамырдан 2024 жылғы қаңтарға дейін SSCIF бойынша Қазақстандағы инфляцияны фактімен және нақты-іріктеуден тыс болжаммен салыстыру, %**



Дереккөзі: ҚР СЖРА ҰСБ, автордың есептеулері

Осылайша, дәстүрлі модельдер инфляцияның тұрақты компоненттерін, әсіресе ерте уақыт аралықтарында, болжауда өз артықшылықтарын сақтайды. Сонымен қатар, машиналық оқыту (ML) модельдері кейінгі кезеңдерде болжау дәлдігінің айтарлықтай жақсарғанын көрсетеді, бұл олардың экономикалық факторлардың кең ауқымын ескеру, өзгермелі жағдайларға бейімделу және деректердің анағұрлым кең жиынтығын оқу үшін пайдалану қабілетімен байланысты.

## 5 Тұжырым

Осы зерттеу Қазақстандағы инфляцияның қысқа мерзімді болжамдарының дәлдігін арттыру үшін инфляцияны селективті-біріктірілген болжау жүйесіне (SSCIF) машиналық оқыту әдістерін (ML) интеграциялаудың жоғары әлеуетін көрсетті. SSCIF моделіне енгізілген өзгерістер және ML алгоритмдерін енгізу оның болжамды тиімділігін едәуір жақсартты, орташа квадраттық қатені (RMSE) төмендетіп, экономикалық айнымалылар арасындағы қатынастарды тиімдірек есепке алу арқылы негізгі көрсеткіштерді бағалау сенімділігін арттырды.

Нәтижелерді талдау дәстүрлі эконометрикалық тәсілдер мен заманауи ML алгоритмдерін біріктіретін гибриді модельдер, әсіресе макроэкономикалық тұрақсыздық пен жоғары құбылмалылық жағдайында RMSE айтарлықтай төмендетуге қабілетті екенін көрсетті. Атап айтқанда, SSCIF-ке Ridge Regression, Lasso Regression және Elastic Net сияқты ML әдістерін қосу кейінгі тестілеу алаңында азық-түлік, азық-түлікке жатпайтын және жалпы инфляцияны болжауда жаңартылған эконометрикалық модельден артықшылығын көрсетті. Бұл алгоритмдердің макроэкономикалық деректердегі жасырын сызықтық емес қатынастарды анықтауға жоғары бейімділігі мен қабілеті бар.

Сонымен қатар, дәстүрлі эконометрикалық тәсілдер сервистік инфляцияны болжауда тиімді болып қала береді, бұл олардың инфляцияның тұрақты және баяу өзгертін компоненттерін талдау құралы ретіндегі құндылығын көрсетеді.

ML-алгоритмдерінің интеграциясы макроэкономикалық факторлардың кең спектрін, соның ішінде бөлшектелген өнеркәсіптік бағалар мен жаһандық тауар индекстерін ескеруге мүмкіндік берді, бұл модельдің аналитикалық мүмкіндіктерін едәуір кеңейтті. Сонымен қатар, байес векторлық авторегрессиясы (VAR) сияқты дәстүрлі әдістердің элементтерін сақтау шектеулі деректер жағдайында модельдердің интерпретациясы мен тұрақтылығын қамтамасыз ету үшін маңызды болып қала береді.

Алынған нәтижелердің макроэкономикалық болжау құралдарын әзірлеу және ақша-кредит саясатының тиімділігін арттыру үшін маңызды практикалық мәні бар. Гибридік тәсілдер қабылданатын шешімдердің сапасын жақсартуға ықпал етуі мүмкін, бұл әсіресе Қазақстан сияқты белгісіздік деңгейі жоғары экономикалар үшін өзекті. ML тәсілдерін және жаңартылған SSCIF сияқты дәстүрлі эконометрикалық модельдерді кешенді

қолдану әр тәсілдің артықшылықтарын ескере отырып, барынша теңдестірілген және тиімді болжау құралын ұсынады: ML модельдерінің бейімділігі мен икемділігі және дәстүрлі әдістердің тұрақтылығы.

Зерттеу нәтижелері ML әдістерін экономикалық талдау мен болжауға одан әрі дамыту және біріктіру қажеттілігін көрсетеді. Болашақ зерттеулер модельдердің интерпретациясын арттыруға, стационарлық емес деректерге бейімделуге және қайта оқыту қаупін азайтуға бағытталған ML-әдістерін макроэкономикалық болжамға біріктіруді оңтайландыруға бағытталуы керек. Бұл экономикалық болжамдардың сапасын және шешім қабылдаудың тиімділігін арттыруға мүмкіндік береді, бұл әсіресе әлемдік экономиканың жоғары белгісіздігі мен тұрақсыздығы жағдайында маңызды.

## 6 Пайдаланылган әдебиет тізімі

1. Bai, J., & Ng, S. (2008). Forecasting economic time series using targeted predictors. *Journal of Econometrics*, 146, 304–317.
2. Garcia, M.G.P., Medeiros, M.C., & Vasconcelos, G.F.R. (2017). Real-time inflation forecasting with high-dimensional models: The case of Brazil. *International Journal of Forecasting*, 33(3), 679-693.
3. Hoerl, A. E., & Kennard, R. W. (1970). Ridge regression: Biased estimation for nonorthogonal problems. *Technometrics*, 12(1), 55-67.
4. Kim, H. H., & Swanson, N. R. (2018). Mining big data using parsimonious factor, machine learning, variable selection and shrinkage methods. *International Journal of Forecasting*, 34(2), 339-354.
5. Kohlscheen, E. (2021). What does machine learning say about the drivers of inflation? BIS Working Papers 980.
6. Maehashi, K., & Shintani, M. (2020). Macroeconomic forecasting using factor models and machine learning: an application to Japan. *Journal of the Japanese and International Economies*, 58, 101104.
7. Medeiros, M. C., Vasconcelos, G. F., Veiga, A., & Zilberman, E. (2021). Forecasting inflation in a data-rich environment: The benefits of machine learning methods. *Journal of Business & Economic Statistics*, 39(1), 98-119.
8. Medeiros, M. C., & Vasconcelos, G. F. R. (2016). Forecasting macroeconomic variables in data-rich environments. *Economics Letters*, 138, 50-52.
9. Mullainathan, S., & Spiess, J. (2017). Machine learning: An applied econometric approach. *Journal of Economic Perspectives*, 31(2), 87-106.
10. Smeekes, S., & Wijler, E. (2018). Macroeconomic forecasting using penalized regression methods. *International Journal of Forecasting*, 34(3), 408-430.
11. Stock, J. H., & Watson, M. W. (2003). Forecasting output and inflation: The role of asset prices. *Journal of Economic Literature*, 41(3), 788-829.
12. Tibshirani, R. (1996). Regression shrinkage and selection via the Lasso. *Journal of the Royal Statistical Society: Series B (Methodological)*, 58(1), 267-288.

## 7 Қосымша

### 1-кесте. SSCIF бастапқы деректері

| Азық-түлік тауарлары бағасының субиндекстері (13 субиндекс) | Азық-түлік емес тауарлар бағасының субиндекстері (23 субиндекс)                                       | Қызмет бағасының ішкі индекстері (30 субиндекс)                | Экзогендік айнымалылар                      |
|---|---|--|---|
| Нан-тоқаш өнімдері мен жарма                                | Киім жасауға арналған материалдар   | Киімді тазалау, жөндеу және жалға беру                         | Brent маркалы мұнай бағасы                  |
| Ет  | Сыртқы киім   | Аяқ киімді жөндеу және жалға беру                              | Номиналды айырбас бағамы USD/KZT            |
| Балық және теңіз өнімдері                                   | Киімнің басқа да заттары мен киім аксессуарлары   | Нақты тұрғын үйді жалдау ақысы                                 | Номиналды айырбас бағамы RUB/KZT            |
| Сүт өнімдері, ірімшік және жұмыртқа                         | Батеңке, туфли және өзге де аяқ киім  | Тұрғын үй-жайларға қызмет көрсету және жөндеу жөніндегі қызмет | Номиналды айырбас бағамы USD/RUB            |
| Майлар мен тоңмайлар  | Тұрғын үй-жайларға қызмет көрсетуге және жөндеуге арналған материалдар                                | Сумен жабдықтау  | Ресейдегі азық-түлік инфляциясы             |
| Жемістер  | Қатты отын  | Қоқыс жинау  | Ресейдегі азық-түлікке жатпайтын инфляция   |
| Көкөністер  | Жиһаз, тұрмыстық заттар, кілемдер және басқа еден жабындары, оларды жөндеу                            | Кәріз  | Ресейдегі сервистік инфляция                |
| Қант, джем, бал, шоколад және кондитерлік өнімдер           | Үй шаруашылығында қолданылатын тоқыма бұйымдары   | Тұрғын үй-жайларды ұстауға байланысты өзге де қызмет           | Қазақстандағы өнеркәсіптегі бағалар         |
| Басқа санаттарға жатпайтын тамақ өнімдері                   | Тұрмыстық аспаптар  | Электр энергиясы   | Қазақстандағы өңдеу өнеркәсібіндегі бағалар |
| Кофе, шай және какао  | Шыны бұйымдар, асхана құралдары және үйге арналған ыдыстар  | Газ  | Қазақстандағы тенгедегі ақша массасы        |
| Минералды су, салқын сусындар, жеміс пен көкөніс шырындары  | Күнделікті өмірде және көгалдандыруда қолданылатын құралдар мен құрылғылар                            | Жылу энергиясы   | Қазақстандағы нақты ақшалай табыс           |
| Алкогольді сусындар   | Үй шаруашылығын жүргізуге пайдаланылатын тауар мен қызмет   | Амбулаториялық қызмет  | FAO Cereals индексі                         |
| Темекі өнімдері   | Дәрі-дәрмектер, емдеу жабдықтары мен аппаратура   | Аурухана қызметті  |   |
|   | Автокөлік құралдарын сатып алу  | Жеке көлік құралдарына техникалық қызмет көрсету және жөндеу   |   |
|   | Жеке көлік құралдарына арналған қосалқы бөлшектер мен керек-жарақтар                                  | Жеке көлік құралдарымен байланысты өзге де қызмет              |   |
|   | Жеке көлік құралдарына арналған жанар-жағармай материалдары   | Көлік қызметі  |   |
|   | Аудиовизуалды жабдық және фотоаппаратура, ақпаратты өңдеуге арналған жабдық                           | Байланыс   |   |
|   | Демалыс пен мәдени іс-шараларды ұйымдастыруға арналған басқа да ұзақ мерзімді пайдаланылатын тауарлар | Демалыс, ойын-сауық және мәдениет саласындағы қызмет           |   |
|   | Демалыс, спорт, бау-бақша және үй жануарларына арналған басқа тауарлар мен жабдықтар                  | Кешенді демалысты ұйымдастыру                                  |   |
|   | Газеттер, кітаптар және кеңсе тауарлары   | Мектепке дейінгі және бастауыш білім беру                      |   |
|   | Жеке пайдалануға арналған электр аспаптары  | Орта білім   |   |
|   | Жеке пайдалануға арналған өзге де заттар, аспаптар және тауарлар                                      | Жалғастырылған орта білім                                      |   |
|   | Басқа санаттарға жатқызылмаған жеке күтім заттары   | Жоғары білім   |   |
|   |   | Сатылар бойынша бөлінбеген білім                               |   |
|   |   | Қоғамдық тамақтандыру қызметі                                  |   |
|   |   | Қонақ үй қызметі   |   |
|   |   | Шаштараздар мен жеке қызмет көрсету мекемелерінің қызметі      |   |
|   |   | Сақтандыру   |   |
|   |   | Басқа санаттарға жатқызылмаған қаржылық қызмет                 |   |
|   |   | Басқа санаттарға жатқызылмаған өзге де қызмет                  |   |

Дереккөз: Тулеуов (2017) және ҚР СЖРА ҰСБ-ның, Қазақстан Ұлттық Банкінің, Ресей Мемлекеттік статистика бойынша федералды қызметінің деректері бойынша авторлары құрастырған