

AUDİT 2026, 2 (52), səh. 61-72.

AUDIT 2026, 2 (52), pp. 61-72.

АУДИТ 2026, 2 (52), стр. 61-72.



<https://doi.org/10.30546/2707-2037.052.2.2026.1038>

*Əliyev Əli İmaş oğlu,
iqtisad üzrə fəlsəfə doktoru, dosent,
Bakı Biznes Universiteti,
E-mail: alialiyevstat@mail.com;*

*Quliyev Zakir Qəşəm oğlu
iqtisad üzrə fəlsəfə doktoru,
Bakı Biznes Universiteti,
E-mail: quliyev@inbox.ru
© Əliyev Ə.İ., Quliyev Z.Q. 2026*

JEL: C52, C53, C55, E37

UOT: 330.43:004.8

MAŞINLA ÖYRƏNMƏ TEXNOLOGİYALARI ƏSASINDA MAKROİQTİSADI GÖSTƏRİCİLƏRİN PROQNOZLAŞDIRILMASI: NAUKASTİNQ

X Ü L A S Ə

Tədqiqatın məqsədi - makroiqtisadi göstəricilərin proqnozlaşdırılmasında istifadə olunan metod və yanaşmaları, onların müqayisəli xarakteristikasını vermək, həmçinin naukastinq əsasında makroiqtisadi göstəricilərin proqnozlaşdırılması imkanlarını araşdırmaqdır.

Tədqiqatın metodologiyası - tədqiqatın ümumelmi və xüsusi metodlarının kombinasiyası, idarəetmə qərarlarının qəbul edilməsi proseslərində maşınla öyrənmə texnologiyalarının, həmçinin təhlil və proqnozlaşdırmada riyazi və statistik metodların tətbiqidir. Tədqiqatın fərziyyəsi yaxın perspektivdə naukastinqin alternativ makroiqtisadi təhlil metodu olacağından ibarətdir.

Tədqiqatın tətbiqi əhəmiyyəti - rəqəmsal transformasiya şəraitində maşınla öyrənmə texnologiyalarının iqtisadi tədqiqatlarda tətbiqi yeni paradıqmadır. Real vaxt rejimində mühüm makroiqtisadi meylləri aşkar etməyə imkan verən naukastinq yanaşmasının yüksək dəqiqlikdə proqnozların işlənilib hazırlanmasında mühüm praktiki əhəmiyyəti ola bilər.

Tədqiqatın nəticələri - tədqiqatın nəticələrinin yüksək praktiki əhəmiyyəti vardır. Belə ki, statistika təcrübəsində mühüm makroiqtisadi göstəricilərin əksəriyyəti rüblük əsasda təşkil edilir. Rüblük məlumatların üstünlüyü səbəbindən, ümumiləşdirilmiş məlumatlar üzrə rüblük ekonometrik modellər daha geniş yayılmışdır. Bu cür modellərin praktiki istifadəsində bir sıra problemlər, o cümlədən makroiqtisadi göstəricilərin yeni qiymətlərinin daxil edilməsində gecikmələr, fasilə tezlikləri bağlı olaraq dəyişənlərin dinamikasında məlumat itkisi və ilkin məlumatlara yenidən baxılması zərurəti yaranır. Ona görə də ilkin məlumatlara yenidən baxılması (vintage data) və real vaxt məlumatlarının (real time data) proqnozlara təsirinin qiymətləndirilməsi ilə bağlı məsələlərə iqtisadi tədqiqatlarda xüsusi diqqət yetirilir ki, bunlar da proqnozların dəqiqlik səviyyəsinin artırılmasında mühüm rol oynayır.

Tədqiqatın orijinallığı və elmi yeniliyi - makroiqtisadi göstəricilərin real vaxta yaxın dəqiqliklə proqnozlaşdırılmasına yönəlmiş yeni metodoloji yanaşma kimi naukastinq metodunun tətbiqinin uğurlu təcrübəsinin təsvir edilməsi və sistemləşdirilməsindən, həmçinin onun əsas prinsipi olan, yeni məlumatlar əldə olunduqca makroiqtisadi göstəricilərin daha dəqiq proqnozlaşdırılmasının həyata keçirilməsi mümkünliyünü əsaslandırmaqdan ibarətdir.

Açar sözlər: makroiqtisadi göstəricilər, proqnozlaşdırma, maşınla öyrənmə texnologiyaları, real vaxt rejimi, qısamüddətli proqnozlaşdırma, naukastinq.

GİRİŞ

Müasir makroiqtisadiyyat dəqiq və vaxtında proqnozlar tələb edən qlobal proseslərin artan mürəkkəbliyi ilə üzləşir. Ümumi Daxili Məhsul (ÜDM), işsizlik, inflyasiya və s. kimi göstəricilər makroiqtisadi siyasət və biznes sahəsində qərarlarının qəbul edilməsi üçün əsas göstəricilərdir. Lakin ənənəvi ekonometrik modellər çox vaxt gizli əlaqələri özündə ehtiva edən iri həcmli məlumatların (big data) təhlili üçün əlverişli olmur. Ona görə də son illərdə maşınla öyrənmə texnologiyaları iqtisadi tədqiqatlarda perspektivli istiqamətlərdən biri kimi geniş yayılmışdır. O, böyük həcmdə məlumatların emalına, qeyri-xətti əlaqələrin nəzərə alınmasına və dəyişən şəraitə uyğunlaşmağa imkan verir. Bu texnologiyalar tarixi məlumatları öyrənə və ənənəvi metodlarla müqayisədə daha dəqiq proqnozlar vermək üçün istifadə edə bilən alqoritmlərə əsaslanır. Məlumatlara əlçatanlığın artması və hesablama güclərinin inkişafı maşınla öyrənmə texnologiyalarının tətbiqi üçün əlverişli şərait yaradır.

Makroiqtisadi göstəricilərin proqnozlaşdırılmasında ekonometrik və maşın öyrənməsi metodlarının tətbiqi ilə bağlı tədqiqatlar müxtəlif elmi məktəblərdə formalaşan iki əsas yanaşmanın mövcudluğunu ortaya qoyur.

Ənənəvi ekonometrik modellər (məsələn, ARİMA, VAR, ECM və s.) ciddi statistik şərtlər və nəzəri fərziyyələr əsasında işlənib hazırlanır. Bu metodlar diqqəti struktur təhlilə, parametrlərin statistik əhəmiyyətinin yoxlanılmasına və iqtisadi şərhlərə yönəldir.

Son on illiklərdə məlumatların həcmnin və çeşidinin kəskin sürətdə artması müşahidə edilir. Bununla əlaqədar olaraq ənənəvi ekonometrik metodlar çox vaxt böyük həcmdə müxtəlif məlumatların işlənməsində çətinliklərlə üzləşir ki, bu da maşınla öyrənmə texnologiyalarının ortaya çıxmasına səbəb olmuşdur. Maşınla öyrənmə metodları funksional əlaqələr haqqındakı minimum fərziyyələrlə iri həcmli məlumatlar dəstindən qanunauyğunluqların əldə edilməsinə imkan verir. Belə yanaşmalar, xüsusilə qeyri-stasionar və qeyri-xətti proseslərlə işləyərkən yüksək dəqiqliyi təmin etməyə qadirdir.

Ümumiyyətlə, iqtisadi proqnozlaşdırma kontekstində klassik ekonometrik yanaşmanın və maşınla öyrənmə paradigmasının əsas metodoloji aspektlərinin müqayisəli xarakteristikası 1 sayılı cədvəldə təsvir edilmişdir (cədvəl 1). Bu fərqlərin nəzərə alınması elmi əsaslandırma üçün metodikanın seçilməsini, proqnozun dəqiqliyini, nəticələrin izah olunanlığını, həmçinin real iqtisadi proseslər şəraitində əlverişliliyi və adekvatlığı dərindən anlamağa imkan verir.

Cədvəl 1.

Əsas kriteriyalar üzrə metodologiyanın müqayisəsi

Kriteriyalar	Klassik ekonometrika	Maşınla öyrənmə
Nəzəri əsasları	Müəyyən edilmiş ciddi iqtisadi fərziyələr	Aprior nəzəriyyənin olmaması, məlumatlara istiqamətlənmə
Məlumat şərtləri	Statsionarlıq, xəttilik, qauss qalıqları	Qeyri-stasionarlığa çeviklik, qeyri-xəttilik, səs-küy
Modellərin seçilməsi	Nəzəriyyədən modellərə, deduktiv yanaşma,	Məlumatlardan modellərə, induktiv, iterativ yanaşma
Keyfiyyətin qiymətləndirilməsi	Statistik əhəmiyyətlik, izah olunanlıq	Proqnozun dəqiqliyi, xəta ölçüləri, çarpaz təsdiqləmə
İzah edilə bilənlik	Yüksək, iqtisadi əhəmiyyəti olan əmsallar	Aşağı, "qara qutu", Post-hoc izahı tələb edilir
Uyğunluq	Sabit şərt, uzunmüddətli proqnozlar	Dinamik mühit, qısamüddətli və yüksək tezlikli məlumatlar
Əsas məhdudiyyətlər	Ciddi şərtlər, çeviklik məhdudiyyəti	Aşağı nəzəri əsaslandırma, izah etmə mürəkkəbliyi

AUDİT 2026, 2 (52), səh. 61-72.

AUDIT 2026, 2 (52), pp. 61-72.

АУДИТ 2026, 2 (52), стр. 61-72.

Makroiqtisadi göstəricilərin proqnozlaşdırılmasında maşınla öyrənmənin tətbiqi geniş perspektivlər vəd edir. Mühüm istiqamətlərdən biri məlumatların artan mürəkkəbliyi ilə mübarizə apara biləcək yeni alqoritmlərin inkişafıdır. Transformerlər (ceviricilər) kimi dərininə öyrənmə modelləri artıq zaman sıralarının işlənməsi və çoxdəyişənli asılılıqların təhlili üçün yüksək potensiala malikdir. Eyni zamanda, ənənəvi ekonometrik və müasir maşınla öyrənmə metodlarının üstünlüklərini birləşdirən hibrid yanaşmaların yaradılmasına da böyük diqqət yetirilir.

1. Ədəbiyyatların icmalı

İqtisadi ədəbiyyatda artıq əlçatan və daha yüksək tezlikli məlumatlara əsaslanaraq makroiqtisadi göstəricilərin cari səviyyəsini operativ qiymətləndirməyi nəzərdə tutan naukasting istiqaməti sürətlə inkişaf edir. Naukasting, inkişaf etməkdə olan bazarlara xas olan yüksək qeyri-müəyyənlik və dəyişkənlik şəraitində, xüsusilə aktual olan iqtisadiyyatın cari vəziyyətinin daha dəqiq və vaxtında qiymətləndirilməyə imkan verir.

Makroiqtisadi göstəricilərin naukastingi üzrə ədəbiyyatda ənənəvi olaraq modellərin üç əsas növü - MIDAS (Mixed Data Sampling Models), MFBVAR (Mixed-Frequency Bayesian Vector Autoregression) və dinamik faktor modelləri (DFM - Dynamic Factors Models)- fərqləndirilir.

MIDAS modelləri məlumatların həcminə daha aşağı tələbləri, yüksək tezlikli və aparıcı indikatorların uğurlu istifadəsi baxımından əlverişlidir [13].

MFBVAR modelləri, xüsusən də nizamlama və dəyişənlərin seçilməsi metodlarından istifadə edərkən dəqiqlikdə üstünlüklər göstərir, lakin bu cür nəticələr çox vaxt bir ölkə və məhdud dəyişənlər dəsti ilə məhdudlaşır [5]. Dinamik faktor modelləri sabit iqtisadi şəraitdə səmərəli işləyir, lakin böhran dövrlərində zəif nəticə göstərir [14, s.39].

Son illərdə maşın öyrənmə metodları naukasting vəzifələrində (busting, elastik şəbəkələr və təsadüfi meşə alqoritmləri) fəal şəkildə tətbiq olunur və bu da ənənəvi modellərə nisbətən dəqiqlik üstünlüyünü nümayiş etdirir [9].

Onlayn (internet) məlumatlara əsaslanaraq istehlak səbətinin dəyərinin qısamüddətli proqnozlaşdırılması üçün maşınla öyrənmə metodlarından istifadə olunur [11,s.36].

Təsadüfi Meşə (Random Forest) və Qrادیент Busting (Gradient Boosting) daxil olmaqla, uzlaşdırılmış metodlar birdən çox modeli birləşdirərək yüksək dəqiqlik nümayiş etdirir. Təsadüfi meşə makroiqtisadi göstəricilərin dayanıqlı proqnozlaşdırılması üçün istifadə edilir. Qrادیент Busting müxtəlif növlü məlumatlarla səmərəli işləmək qabiliyyətinə görə iqtisadi tədqiqatlarda geniş yayılmışdır [16].

Dərin öyrənmə metodlarından, o cümlədən təkrarlanan neyron şəbəkələri (Recurrent Neural Network - RNN) və uzun qısamüddətli yaddaş (Long Short-Term Memory — LSTM) modellərindən istifadə ən perspektivli istiqamətlərdən biridir. Bu modellər zaman sıralarının təhlilində geniş tətbiq olunur. LSTM modelinin əsas üstünlüyü uzunmüddətli asılılıqları nəzərə almaq qabiliyyətidir ki, bu da makroiqtisadi təhlildə xüsusilə mühüm əhəmiyyət daşıyır [17].

MIDAS modelinin çoxsaylı modifikasiyaları mövcuddur. FA-MIDAS modeli balanslaşdırılmamış məlumat dəstlərindən istifadə etməyə imkan verir [8, s. 1183].

Maşın öyrənməsi metodları proqnozlaşdırma xətasının minimuma endirilməsinə yönəldilmişdir. Modellərin nəticələri orta kvadratik xəta (MSE), orta kvadratik xətanın kökü (RMSE), orta mütləq faiz xətası (MAPE) və orta mütləq xəta (MAE) kimi aydın və geniş istifadə olunan qiymətləndirmə meyarları əsasında alternativ modellərlə müqayisə edilir [12].

AUDİT 2026, 2 (52), səh. 61-72.

AUDIT 2026, 2 (52), pp. 61-72.

АУДИТ 2026, 2 (52), стр. 61-72.

Naukastingq proqnozlar, yalnız rəsmi məlumatların toplanması və emalı metodlarından istifadə edən standart statistik proqnozlaşdırma modelləri ilə müqayisədə keyfiyyətcə yeni bir səviyyəni özündə ifadə edir [7].

Maşın öyrənməsi alqoritmləri strukturlaşdırılmamış məlumat axınlarını fasiləsiz şəkildə öyrənərək gələcək ssenariləri modelləşdirməyə və gizli qanunauyğunluqları aşkar etməyə imkan verir [6, s. 17].

Maşınla öyrənmə endogenlik və qeyri-xətilik problemlərini həll edərək ekonometrik modelləri yaxşılaşdırır [3, s.689].

Naukastingq dedikdə ən yaxın keçmişin, cari vəziyyətin və yaxın gələcəyin proqnozlaşdırılması və qiymətləndirilməsi başa düşülür [10].

Son dövrlərdə ənənəvi ekonometrik modellərə alternativ yanaşma kimi maşın öyrənməsi alqoritmləri - Ridge, LASSO, Elastic Net, Boosting, Bagging, Random Forest, Support Vector Machine, Multilayer Perceptron, Recurrent Neural Network və s. — daha geniş tətbiq olunmağa başlamışdır [4].

Beləliklə, maşınla öyrənmənin əsas tətbiqi istiqaməti iqtisadi hadisə və proseslərin proqnozlaşdırılmasıdır. Maşınla öyrənmə iri həcmli məlumatların (big data) işlənməsi və dəqiq proqnozlar üçün metod və yanaşmalar təqdim edərək iqtisadi təhlilin metodologiyasını əsaslı şəkildə dəyişir. Qabaqcıl texnologiyaların köməyi ilə iri həcmli məlumatları işləmək və təhlil etmək, gizli qanunauyğunluqları (patterinləri) və meylləri aşkar etmək, həmçinin gələcək hadisələri proqnozlaşdırmaq mümkündür.

2. Məlumatların və naukastingq metodologiyasının təsviri

Maşın öyrənməsi alqoritmləri əsasında naukastingqın həyata keçirilməsi məqsədilə 2003–2025-ci illər üzrə Azərbaycan Respublikasının faktiki makroiqtisadi göstəricilərinə — real ÜDM-in artım tempinə və ÜDM deflyatoruna dair zaman sıralarından istifadə edilmişdir. Asılı dəyişənlər qismində rüblük tezliyə malik real ÜDM-in artım tempi və ÜDM deflyatoru çıxış edir. Zaman sıralarının əksəriyyəti qeyri-stasionarlığı aradan qaldırmaq məqsədilə mövsümi hamaralama, loqarifmləşdirmə və birinci dərəcəli fərqlərin hesablanması da daxil olmaqla ilkin statistik emaldan keçirilmişdir.

Maşınla öyrənmə texnologiyaları iqtisadi məlumatların xüsusiyyətlərinə uyğunlaşdırılmış geniş çeşidli metodları əhatə edir. İşdə naukastingq üçün üç ənənəvi metod bridge (körpü), MIDAS və faktorlu model götürülmüşdür. Müqayisə alternativ olaraq Ridj (ridge) və LASSO (Least Absolute Shrinkage and Selection Operator) reqressiyaları, Elastik tor (elastic net), gücləndirmə (boosting), biqqinq (bagging, bootstrap aggregating), təsadüfi meşə (random forest), dəstəkləyici vektorlar maşını (SVM -support vector machine), Çoxlaylı neyron şəbəkə (MLP – multilayer perceptron) və təkrarlanan neyron şəbəkə (RNN -recurrent neural network) kimi maşın öyrənmə metodları və alqoritmlərindən istifadə edilmişdir.

Proqnozlaşdırma xüsusiyyəti baxımından ən səmərəli naukastingq metodunu müəyyən etmək üçün bir sıra testlər aparılmışdır. Onların mahiyyəti zaman sıraları üzrə ümumi müşahidə sayının iki hissəyə - tədqiq edilən və test seçməyə - bölünməsindən ibarətdir. Birinci modelin parametrlərini qiymətləndirmək, ikinci isə maşınla öyrənmə və ekonometrik metodlarından istifadə etməklə əldə edilən qiymətləndirmələrin (proqnozların) dəqiqliyini faktiki qiymətlərlə müqayisə etmək üçün istifadə olunur. Proqnozların işlənilib hazırlanması prosesi reqressiya testlərinin təkrarlanan sxemi üzrə həyata keçirilir. Ən yaxşı vasitə, bu məqsədlər üçün seçilmiş funksiya itkisini (loss function) minimuma endirən hesab olunur. Funksiya itkisi maşınla öyrənmədə proqnoz modelləri ilə real məlumatlar arasındakı xətalara qiymətləndirən kəmiyyət

AUDİT 2026, 2 (52), səh. 61-72.

AUDIT 2026, 2 (52), pp. 61-72.

АУДИТ 2026, 2 (52), стр. 61-72.

ölçüsüdür. O, modelin nə qədər yaxşı işləmədiyini göstərir və məqsəd optimallaşdırma alqoritmlərinin köməyi ilə onun qiymətini minimumlaşdırmaqdır.

Test nəticələri göstərir ki, maşın öyrənməsi alqoritmləri vasitəsilə əldə olunan proqnozlar ənənəvi modellərin proqnoz nəticələri ilə müqayisədə daha yüksək dəqiqliyə malikdir. Ən səmərəli nəticələr LASSO reqressiyası, gücləndirmə (Boosting), təsadüfi meşə (Random Forest), dəstək vektorları metodu (Support Vector Machine) və təkrarlanan neyron şəbəkələri (Recurrent Neural Network) vasitəsilə əldə edilmişdir.

Bundan əlavə, Diebold-Mariano statistik testi LASSO reqressiyası, SVM və RNN ilə əldə edilən proqnoz qiymətləndirmələrin ənənəvi bridge (körpü) modelinin nəticələrindən əhəmiyyətli dərəcədə fərqləndiyini təsdiq edir. Bununla yanaşı, hesablamalar müxtəlif proqnozların kombinasiyasının fərdi metodlardan istifadə ilə müqayisədə naukasting dəqiqliyinin əlavə olaraq yaxşılaşdırmağa imkan verdiyini göstərir.

Ekonometrik modelləşdirmə MATLAB - da, maşınla öyrənmə alqoritmləri isə Python - da həyata keçirilmişdir.

Bridge avtoreqressiya modeli aşağıdakı kimi ifadə edilir:

$$y_{t_q} = a_0 + \sum_{i=1}^p a_i L^i y_{t_q} + \sum_{j=0}^{pq} b_j L^j x_{t_q} + \varepsilon_t$$

Burada, y_{t_q} – aztezlikli zaman sıralarını (asılı dəyişənlər), x_{t_q} -yüksək tezlikli zaman sıralarını (izahedici dəyişənlər), a_i və b_j modellərin bəlli olmayan parametrlərini göstərir.

Bridge modeli aşağı və yüksək tezlikli məlumatlar arasındakı əlaqəni müəyyən etməyə imkan verir. Tədqiqat çərçivəsində bu model naukasting üçün tətbiq olunan alternativ yanaşmaların müqayisəsində etalon model kimi istifadə edilir.

MIDAS modelinin fərqləndirici xüsusiyyəti yüksək tezlikli məlumatların emalı və aşağı tezlikli göstəricilərlə əlaqələndirilməsi üsuludur. MIDAS modelində aşağı və yüksək tezlikli məlumatlar arasındakı əlaqəni qurmaq üçün çoxhədli çəki funksiyasından istifadə olunur. Bu yanaşma MIDAS modelini birbaşa proqnozlaşdırma vasitəsinə çevirir.

Bir yüksək tezlikli göstərici üçün tətbiq edilən MIDAS baza modeli aşağıdakı kimi təsvir edilir:

$$y_{t+h}^L = a_h + b_h C\left(L^{\frac{1}{m}}; \theta\right) X_t^H + \varepsilon_{t+h}^L$$

Burada, a_h və b_h -modellərin bəlli olmayan parametrlərini, $C\left(L^{\frac{1}{m}}; \theta\right)$ – N dərəcəli çoxüzvü (polynomial) funksiyanın əmsallarını, $L^{1/m} X_t = X_{t-i/m}$ - keçikmə (lag) operatorunu göstərir.

Bridge və MIDAS modellərindən fərqli olaraq, amilli model nisbətən geniş ilkin məlumat bazasından istifadə edilməsinə əsaslanır. Bu metodologiya məlumatların səmərəli şəkildə sıxılmasına və gizli asılılıqların nəzərə alınmasına imkan verərək, böyük həcmli məlumat dəstindən məhdud sayda dinamik əsas komponentin (amillərin) əldə edilməsi üçün hazırlanmışdır.

Metodologiya iki mərhələdən ibarətdir. Birinci mərhələdə balanslaşdırılmış məlumatlar əsasında statistik əsas komponentlər hesablanır. Daha sonra həmin komponentlər Kalman filtri-nin ilkin şərtlərinin müəyyənləşdirilməsi üçün istifadə olunur. İkinci mərhələdə isə əldə edilmiş ilkin şərtlər əsasında Kalman filtri tətbiq edilir və dinamik əsas komponentlərin hesablanması üçün tərs hamaralama texnikasından istifadə olunur.

Bridge reqressiya modelinin əmsalları aşağıdakı düsturla hesablanılır:

AUDIT 2026, 2 (52), səh. 61-72.

AUDIT 2026, 2 (52), pp. 61-72.

АУДИТ 2026, 2 (52), стр. 61-72.

$$\hat{\beta} = \operatorname{argmin} \left[\sum_{i=1}^n \left(y_i - \sum_{j=1}^p x_{ij} \beta_j \right)^2 + \gamma \sum_{j=1}^p \beta_j^2 \right]$$

Burada, n müşahidələrin sayını, p -izahedici dəyişənlərin sayını, $\gamma \geq 0$ sıxılma kəmiyyətinə nəzarət edən parametri göstərir.

Əmsalların sıxılması üçün LASSO reqressiyasını tətbiq edərkən modelin mürəkkəbliyini azaldan üsullardan istifadə edilir.

Elastik Net, Ridge və LASSO reqressiya modellərinin çəkili kombinasiyasıdır və aşağıdakı optimallaşdırma düsturuna malikdir:

$$\hat{\beta} = \operatorname{argmin} \left[\sum_{i=1}^n \left(y_i - \sum_{j=1}^p x_{ij} \beta_j \right)^2 + \gamma \sum_{j=1}^p [(1 - \alpha) \beta_j^2 + \alpha |\beta_j|] \right]$$

Maşınla öyrənmənin birgə (ansambl) metodları qərarlar ağacı ilə əlaqəlidir. Qərarlar ağacının əsas vəzifəsi, ilkin müşahidələr çoxluğunu (ana qovşaqdan) iki altçoxluğa (və ya iki qız qovşağa) optimal şəkildə bölməkdir. Xətalərin kvadratlarının cəmi (RSS) aşağıdakı düsturla hesablanır:

$$RSS_m = \sum_{n \in N_m} (y_n - \bar{y}_m)^2$$

Burada, y_n - N_m qovşağında müşahidələri göstərir.

Bütün qərarlar ağacı üçün itki funksiyası RSS_T -dir. m -ci yarpağın indeksi I_m olarsa, onda bütün ağac üçün ümumi itki aşağıdakı düsturla hesablanacaqdır:

$$RSS_T = \sum_m \sum_{n \in N_m} I_m RSS_m$$

Optimal bölgünün əsas kriteriyası RSS_T göstəricisinin minimumlaşdırılmasıdır.

Bagging qərarlar ağacına əsaslanır və ona bir neçə mərhələ (butstrap (bootstrap) təkrarlanmaların ümumi sayı verilir (bir qayda olaraq sabit qərarlar ağacı proqnozunu almaq üçün 100 butstrap təkrarlanma kifayət edir), hər bir butstrap seçmə üçün qərarlar ağacı qurulur və asılı dəyişənini orta kəmiyyəti qiymətləndirilir, testləşdirilən seçmə əsasında asılı dəyişənin kəmiyyəti proqnozlaşdırılır və nəticə saxlanılır, nəhayət göstərilən ilk üç addım verilmiş butstraplar üçün təkrarlanır) daxildir.

Əgər beqinq (Bagging) təhlilə daxil edilən bütün izahedici dəyişənlər əsasında tətbiq edilsə, təsadüfi meşə alqoritmində (Random Forest) hər bir qərar ağacının qurulması zamanı izahedici dəyişənlərin yalnız təsadüfi seçilmiş bir hissəsindən istifadə olunur.

Büstinq (Boosting) də qərar ağacları əsasında qurulan ansambl öyrənmə metodudur. Bu yanaşmada ilkin çəkilər və butstrap seçmələrinin sayı müəyyən edilir, daha sonra müşahidə xətaləri və onların orta qiyməti hesablanır. Modelin etibarlılıq göstəricisi qiymətləndirilir, modelin çəki əmsalları yenilənir və yekun proqnoz qiymətləri formalaşdırılır. Müşahidə xətasının orta qiyməti 0,5-ə bərabər və ya ondan yüksək olduqda isə modelin proqnoz qabiliyyəti qənaətbəxş hesab edilmir.

Dəstək vektorları metodunun (Support Vector Machine - SVM) əsas ideyası təsnifat məsələlərində müxtəlif siniflərə aid müşahidələri maksimum dərəcədə ayıran, reqressiya məsələlərində isə dəyişənlər arasındakı əlaqəni minimal xəta ilə təxmin edən optimal hiperüstəvinin müəyyən edilməsidir. Makroiqtisadi naustastinq kontekstində bu metod, xüsusilə mühüm göstəricilər arasında qeyri-xətti və ya mürəkkəb qarşılıqlı əlaqələr mövcud olduqda tətbiq edilir.

Çoxlaylı neyron şəbəkəsi (Multilayer Perceptron - MLP) birlaylı neyron şəbəkələrinin ümumiləşdirilmiş formasıdır. Bu şəbəkə bir neçə qatdan ibarət olur və hər bir qat neyronları

AUDİT 2026, 2 (52), səh. 61-72.

AUDIT 2026, 2 (52), pp. 61-72.

АУДИТ 2026, 2 (52), стр. 61-72.

özündə birləşdirir. Giriş qatındakı neyronların sayı giriş dəyişənlərinin sayına uyğundur: $-x = (x_1, x_2 \dots x_n)$.

Giriş qatı ilə çıxış qatı arasında yerləşən qatlar gizli qatlar (hidden layers) adlandırılır. Hər bir gizli qatdakı neyron əvvəlki qatda yerləşən neyronların çıxışlarının çəkili xətti kombinasiyası əsasında formalaşır və daha sonra aktivləşdirmə funksiyası vasitəsilə emal edilir.

Neyronlar arasındakı qarşılıqlı əlaqə alqoritmi aşağıdakı kimi işləyir:

1. Birinci təbəqədə, hər bir neyron üçün proqnozlaşdırılan göstəricilərin sayından asılı olaraq çəkilər təsadüfi olaraq yaradılır.

2. İlk çəki matrisindən istifadə edərək, çəkiləri optimallaşdırmaq üçün istifadə olunan çıxış dəyişənləri hesablanır.

3. İlk çəkilər kimi çıxış edən çəki əmsallarının optimallaşdırılmış matrisləri növbəti təbəqəyə ötürülür.

4. Hər təbəqədə çəki əmsallarının optimallaşdırılması xətlərin tərs yayılma alqoritmi (backpropagation). əsasında həyata keçirilir.

Təkrarlanan neyron şəbəkəsi (recurrent neural network) zaman sıraları kimi ardıcıl məlumatların işlənməsi üçün neyron şəbəkə növüdür. Adi neyron şəbəkələrindən fərqli olaraq təkrarlanan neyron şəbəkəsi daxili yaddaşa malikdir ki, bu da cari qiymətlərin əvvəlki vəziyyətlərdən asılılığını nəzərə almağa imkan verir. Onun mühüm ideyası informasiyanın tsiklik ötürülməsidir. Yəni model hər bir addımda giriş qiymətlərini əldə edir və eyni vaxtda əvvəlki addımlardan toplanan gizli vəziyyətləri nəzərə alır. Bu təkrarlanan neyron şəbəkəsindən aralarında zaman asılılığı olan göstəricilərin proqnozlaşdırılması təcrübəsində geniş istifadə edilməsinə imkan verir.

3. Təhlilin nəticələri

Real vaxt rejimində naukastingin aparılmasının mühüm metodoloji çətinliyi cari rübün ayrı-ayrı ayları üzrə nəşr edilmiş yüksək tezlikli məlumatların olmaması ilə bağlıdır.

Naukasting metodunun proqnoz xüsusiyyətinin müqayisəsi üçün aşağıdakı mərhələləri əhatə edən regressiya testi həyata keçirilmişdir:

- mövcud yüksək tezlikli sıraların rüblük ölçüyə çevrilməsi nəticəsində 2003-cü ilin 2-ci rübündən 2025-ci ilin 4-cü rübünə qədər olan dövr üçün seçmə məlumatlar formalaşdırılmışdır (hər dəyişən üçün 91 müşahidə;

- əvvəlcə bütün seçmə iki hissəyə bölünmüşdür: öyrənilən (müşahidələrin ilk 70%-i, 2003-cü ilin 2-ci rübündən 2019-cu ilin 2-ci rübünə qədər, 65 müşahidə) və testləşdirilən (müşahidələrin qalan 30%-i, 2019-cu ilin 3-cü rübündən 2025-ci ilin 4-cü rübünə qədər, 26 müşahidə);

- öyrənilən seçmənin faktiki məlumatları əsasında modellər qiymətləndirilmişdir (2003-cü ilin 2-ci rübü–2019-cu ilin 2-ci rübü);

- yüksək tezlikli sıraların rüblük qiymətlərindən istifadə edərək bir rüb qabaq göstəricilərlə (birinci proqnozlaşdırılan dövr – 2019-cu ilin 3-cü rübü) naukasting həyata keçirilmişdir;

- öyrənilən seçmə bir rüb artırılmış (2003-cü ilin 2-ci rübündən 2019-cu ilin 3-cü rübünə qədər) və modelin parametrləri yenidən qiymətləndirilmişdir;

- yenidən qiymətləndirilmiş modellər vasitəsilə növbəti rübün naukastingi yerinə yetirilmişdir (2019-cu ilin 4-cü rübü);

- öyrənilən seçmənin 2025-ci ilin 3-cü rübünə qədər olan dövrü əhatə edənə qədər 5-6-cı addımlar təkrarlanmışdır;

- əldə edilmiş naukasting nöqtələri faktiki qiymətlərlə müqayisə edilmiş və itki funksiyaları (loss functions) olan proqnozun ikiölçülü dəqiqliyi hesablanmışdır.

AUDİT 2026, 2 (52), səh. 61-72.

AUDIT 2026, 2 (52), pp. 61-72.

АУДИТ 2026, 2 (52), стр. 61-72.

$$RMSE = \sqrt{\frac{\sum_{t=1}^n (y_t - \hat{y}_t)^2}{n}}$$

$$MAD = \frac{1}{n} \sum_{t=1}^n |y_t - \hat{y}_t|$$

Burada, y_t və $\hat{y}_t$ faktiki və proqnoz göstəriciləri, n – qiymətləndirmələrin ümumi sayını göstərir.

Real ÜDM-nin artım tempi və ÜDM deflyatoru üçün iki nöqtə arasındakı məsafənin orta kvadratik xətasının və median mütləq kəmiyyətin (MAD - Median Absolute Deviation) hesablanması nəticələr 2 və 3 sayılı cədvəllərdə əks etdirilmişdir (cədvəl 2).

Cədvəl 2.

Azərbaycanın real ÜDM-nun artım tempinin naukasting dəqiqliyinin qiymətləndirilməsi nəticələri (2019-cu ilin 3-cü rübündən 2025-ci ilin 4-cü rübünə qədər)

Modellər	RMSE	RMSE (Bridge nisbətən)	DM- stat	MAD	MAD (Bridge nisbətən)	DM-stat
Bridge	3,67	-	-	2,42	-	-
MIDAS	3,54	0,96	0,51	1,84	0,88	0,06
Factor model	3,18	1,07	0,34	1,65	1,12	1,13
Ridge	2,47	0,86	0,16	1,64	0,98	1,64
LASSO	3,63	0,99	0,45	1,81	1,09	0,55
Elastic Net	3,59	0,79	0,09	1,60	1,05	1,43
Boosting	2,65	0,74	0,43	1,58	1,02	0,78
Bagging	2,85	0,77	0,07	1,59	0,81	1,63
Random Forest	3,56	0,69	0,29	1,45	0,77	1,47
SVM	3,55	0,59	0,17	1,47	0,68	1,32
MLP	3,60	1,03	0,23	1,72	1,11	0,91
RNN	3,43	0,92	0,61	1,69	0,97	0,05

Cədvəl 3.

Azərbaycanın real ÜDM-nun deflyatorunun naukasting dəqiqliyinin qiymətləndirilməsi nəticələri (2019-cu ilin 3-cü rübündən 2025-ci ilin 4-cü rübünə qədər)

Modellər	RMSE	RMSE (Bridgeyə nisbətən)	DM-stat	MAD	MAD (Bridgeyə nisbətən)	DM-stat
Bridge	2,25	-	-	1,87	-	-
MIDAS	2,36	0,89	0,35	1,97	0,99	0,38
Factor model	2,21	0,99	0,33	1,88	0,89	0,18
Ridge	1,75	0,87	1,89	1,55	0,76	1,87**
LASSO	1,63	0,77	2,02*	1,47	0,69	2,16**
Elastic Net	1,59	0,75	2,11**	1,51	0,71	1,99*
Boosting	1,83	0,79	1,89*	1,50	0,82	1,86**
Bagging	1,69	0,83	1,74	1,64	0,78	1,75*
Random Forest	1,66	0,91	1,93*	1,53	0,75	1,89*
SVM	1,86	0,87	1,07	1,48	0,89	1,76*
MLP	1,92	0,91	1,58	1,50	0,79	1,69
RNN	1,58	0,71	2,67**	1,37	0,82	2,65**

*, **, *** - müvafiq olaraq 10%, 5% və 1% əhəmiyyətlik səviyyələrində əhəmiyyətlidir.

Y E K U N

Real ÜDM-un artım tempinin naukasting nəticələrini özündə əks etdirən 2 və 3 sayılı cədvəllərinin məlumatlarına görə RMSE ölçüsünə görə ən kiçik proqnozlaşdırma xətasına LASSO regressiyadan istifadə edərkən nail olunmuşdur. Üstəlik, əldə edilən qiymətlər naukastingin ənənəvi metodlarının nəticələrindən statistik olaraq fərqlənir.

ÜDM deflyatorunun naukasting nəticələri proqnozlaşdırmanın ən kiçik xətasının RNN alqoritmindən istifadədə nail olunduğunu göstərir. Bu dəyər göstəricilərinin dinamikasının modelləşdirilməsində həmin metodun yüksək səmərəliliyini nümayiş etdirir. Deməli, maşınla öyrənmə alqoritmləri naukasting xətalərini əhəmiyyətli şəkildə minimumlaşdırır ki, bu da onlarla müqayisədə naukastingin tətbiqinin dəqiq və məqsədəuyğun olduğunu deməyə əsas verir. Əldə edilmiş nəticələr maşınla öyrənmə metod və alqoritmlərinin naukastingin ənənəvi modelləri ilə müqayisədə təhlil edilən göstəricilərin dəyişmə vektorunu daha dəqiq müəyyənləşdirməyə imkan verir.

Qiymətləndirmənin dəqiqliyindəki fərqlərin əhəmiyyətini dəyərləndirmək üçün Dubalda-Mariano statistikasını tətbiq edilmişdir. Təhlil göstərir ki, real ÜDM-un artım tempi üçün ekonometrik modellərlə maşınla öyrənmə modelləri və alqoritmlər arasındakı fərqi statistik əhəmiyyətliyi aşkar edilməmişdir. Lakin ÜDM deflyatorunun proqnozlaşdırılmasında bir çox hallarda maşınla öyrənmə alqoritmləri ənənəvi yanaşmalarla müqayisədə daha əlverişli olmuşdur. Qeyd edilən alqoritmlərdən hansında RMSE və MAD göstəriciləri minimum qiymətlər alarsa, deməli praktiki məqsədlər üçün onlardan istifadə edilməsi məqsədəuyğun hesab edilir. Araşdırmanın nəticələri ÜDM-un artım tempi üçün LASSO və SVM, ÜDM deflyatoru üçün isə RNN ən yaxşı nəticəni göstərmişdir. Lakin dinamik şəraitdə modellərin keyfiyyətini müntəzəm olaraq yenidən qiymətləndirmək və zəruri hallarda onlar arasında keçid etmək məqsədəuyğundur. Alternativ həll yolu kimi müxtəlif metodların üstünlüklərini birləşdirən kombinasiyalı naukastingdən istifadə etmək olar.

İSTİFADƏ EDİLMİŞ ƏDƏBİYYAT SİYAHISI:

1. Azərbaycanın statistik göstəriciləri, ARDSK, Bakı, 695 s.
2. Azərbaycanın milli hesabları, ARDSK, Bakı, 135 s
3. Athey, S., & Imbens, G. W. 2019. Machine learning methods that economists should know about. Annual Review of Economics, 11, p. 685–725.

AUDİT 2026, 2 (52), səh. 61-72.

AUDIT 2026, 2 (52), pp. 61-72.

АУДИТ 2026, 2 (52), стр. 61-72.

4. Desai, A. 2023. Machine learning for economics research: when, what and how. Bank of Canada, Staff Analytical Note, p.16

5. Фокин Н.Д. 2023. Наукастинг и прогнозирование основных российских макро-экономических показателей с помощью MFBVAR-модели. Экономическая политика, №18(3), стр.110-135

6. Карпова, В. И. 2025. Влияние аналитики больших данных на трансформацию бизнес-моделей: экономико-математическое моделирование и прогнозирование / В. И. Карпова // Вестник евразийской науки. Т.17. -№2. стр.17

7. Carlo T. C., Marcal E. F. 2016. Forecasting brazilian inf lation by its aggregate and disaggregated data: a test of predictive power by forecast horizon // Applied Economics. Vol. 48, Issue 50. Pp. 4846–4860.

8. Jarde C., Meunier B. 2022. Nowcasting World GDP Growth with High-frequency Data. Journal of Forecasting, pp. 1181–1200,

9. Гареев М., Полбин А. 2022. Наукастинг: оценка изменения ключевых макро-экономических показателей с использованием методов машинного обучения. Вопросы экономики, №8, стр.133-157,

10. Малюгин В., Якубович А. 2020. Анализ и прогнозирование стоимости потребительской корзины в режиме реального времени. Экономика, моделирование, прогнозирование, №14, стр.235–241

11. Малюгин, В. 2024. Краткосрочное прогнозирование и наукастинг темпов роста инфляции на основе моделей по смешанным данным. Банковский вестник, №1/726, стр.35-42

12. Росси, С., Мангоне, Б. 2024. Комбинирование эконометрических моделей и методов машинного обучения для анализа экономической политики // Journal of Applied Econometrics. Т. 39. №3. стр. 425–449.

13. Zhemkov M. 2021. Nowcasting Russian GDP using forecast combination approach. International Economics, p.168

14. Зубарев А., Рыбак К. 2021. Наукастинг ВВП: динамическая факторная модель и официальные прогнозы. Экономическое развитие России, №12, стр.34-40.

15. <https://www.stat.gov.az>

16. [https:// neurohive. io/ru](https://neurohive.io/ru)

17. <https://habr.com/ru>

18. <https://www.imf.org>

AUDIT 2026, 2 (52), səh. 61-72.

AUDIT 2026, 2 (52), pp. 61-72.

АУДИТ 2026, 2 (52), стр. 61-72.

Ali Imash Aliyev
Ph.D. (Econ.), associate professor,
Baku Business University,
E-mail: alialiievstat@gmail.com;

Zakir Gashem Guliyev
Ph.D. (Econ.),
Baku Business University,
E-mail: guliev@inbox.ru
© A.I. Aliyev, Z.G. Guliyev, 2026

MACROECONOMIC FORECASTING BASED ON MACHINE LEARNING TECHNOLOGIES: NOWCASTING

A B S T R A C T

The purpose of the research is to compare methods and approaches used in forecasting macroeconomic indicators and to explore the potential of forecasting macroeconomic indicators using nowcasting.

The methodology of the research is based on combines general and specific research methods, the application of machine learning technologies in management decision-making, and mathematical and statistical methods of analysis and forecasting. The study's hypothesis is that nowcasting will become an alternative method of macroeconomic analysis in the near future.

The practical importance of the research lies in the fact that the application of machine learning technologies in economic research in the context of digital transformation represents a new paradigm. The nowcasting approach, which allows for the identification of important macroeconomic trends in real time, may have significant practical implications for the development of highly accurate forecasts.

The results of the research in statistical practice, most important macroeconomic indicators are systematized quarterly. Due to the prevalence of quarterly data, quarterly econometric models based on aggregated data are more common. The practical application of such models faces a number of challenges, including delays in entering new values for macroeconomic indicators, loss of information on variable dynamics due to frequent failures, and revisions of source data. Therefore, economic research places particular emphasis on issues related to the revision of source data (vintage data) and assessing the impact of real-time data on forecasts, which also play a significant role in improving forecast accuracy.

The originality and scientific novelty of the research lie in the description and systematization of successful applications of the short-term forecasting method as a new methodological approach aimed at forecasting macroeconomic indicators with near-real-time accuracy, as well as in the substantiation of its core principle-the possibility of implementing more accurate forecasts of macroeconomic indicators as new data becomes available.

Keywords: macroeconomic indicators, forecasting, machine learning technologies, real-time mode, short-term forecasting, nowcasting.

AUDİT 2026, 2 (52), səh. 61-72.

AUDIT 2026, 2 (52), pp. 61-72.

АУДИТ 2026, 2 (52), стр. 61-72.

Алиев Али Имаш оглы,
кандидат экономических наук, доцент,
Бакинский Университет Бизнеса,
E-mail: alialiievstat@gmail.com;

Гулиев Закир Гашем оглы,
кандидат экономических наук, доцент,
Бакинский Университет Бизнеса,
E-mail: guliev@inbox.ru
© Алиев А.И., Гулиев З.Г., 2026

ПРОГНОЗИРОВАНИЕ МАКРОЭКОНОМИЧЕСКИХ ПОКАЗАТЕЛЕЙ НА ОСНОВЕ ТЕХНОЛОГИЙ МАШИННОГО ОБУЧЕНИЯ: НАУКАСТИНГ

Р Е З Ю М Е

Целью исследования является сравнительное описание методов и подходов, используемых в прогнозировании макроэкономических показателей, а также изучение возможностей прогнозирования макроэкономических показателей на основе *наукастинга*.

Методология исследования представляет собой сочетание общих и специфических методов исследования, применение технологий машинного обучения в процессах принятия управленческих решений, а также математических и статистических методов анализа и прогнозирования. Гипотеза исследования заключается в том, что в ближайшем будущем наукастинг станет альтернативным методом макроэкономического анализа.

Практическая значимость исследования - применение технологий машинного обучения в экономических исследованиях в условиях цифровой трансформации представляет собой новую парадигму. Подход наукастинга, позволяющий выявлять важные макроэкономические тенденции в режиме реального времени, может иметь существенное практическое значение в разработке высокоточных прогнозов.

Результаты исследования – в статистической практике большинство важных макроэкономических показателей систематизируются поквартально. В связи с преобладанием квартальных данных, более распространены квартальные эконометрические модели, основанные на агрегированных данных. В практическом применении таких моделей возникает ряд проблем, включая задержки во вводе новых значений макроэкономических показателей, потерю информации о динамике переменных из-за частоты сбоев, пересмотр исходных данных. Поэтому в экономических исследованиях особое внимание уделяется вопросам, связанным с пересмотром исходных данных (*vintage data*) и оценкой влияния данных в реальном времени (*real time data*) на прогнозы, которые также играют важную роль в повышении точности прогнозов.

Оригинальность и научная новизна исследования заключаются в описании и систематизации успешного опыта применения метода краткосрочного прогнозирования как нового методологического подхода, направленного на прогнозирование макроэкономических показателей с точностью, близкой к реальному времени, а также в обосновании его основного принципа - возможности реализации более точного прогнозирования макроэкономических показателей по мере поступления новых данных.

Ключевые слова: макроэкономические показатели, прогнозирование, технологии машинного обучения, режим реального времени, краткосрочное прогнозирование, *наукастинг*.

Məqalə redaksiyaya daxil olmuşdur:
13.02.2026
Təkrar işlənməyə göndərilmişdir:
03.04.2026
Çapa qəbul olunmuşdur: 08.05.2026

Дата поступления статьи в
редакцию: 13.02.2026
Отправлено на повторную
обработку: 03.04.2026
Принято к печати: 08.05.2026

The date of the admission of the article
to the editorial office: 13.02.2026
Send for reprocessing: 03.04.2026
Accepted for publication: 08.05.2026