

SUN'IY INTELLEKT VA NEYRON TARMOQLAR YORDAMIDA IQTISODIY PROGNOZLASH

Ashurov Bakhtiyor Iskandarovich

*Senior lecturer, Department of Higher Mathematics,
Samarkand Institute of Economics and Service.*

E-mail: ashurovbahtiyor8917@gmail.com

Annotatsiya: Mazkur ilmiy maqolada sun'iy intellekt va neyron tarmoqlar yordamida iqtisodiy prognozlashning nazariy asoslari va amaliy qo'llanilishi tizimli ravishda yoritilgan. An'anaviy ekonometrik usullar (ARIMA, VAR) va zamonaviy chuqur o'rganish arxitekturalari (LSTM, GRU, Transformer, hybrid modellar) taqqoslanadi. Neyron tarmoqlarning o'ziga xos xususiyatlari — nochiziqlilikni modellashtirish, uzoq muddatli bog'liqliklarni o'rganish va katta hajmli ma'lumotlar bilan ishlash qobiliyati batafsil tahlil qilingan. O'zbekiston iqtisodiyoti ma'lumotlari asosida YaIM, inflyatsiya va valyuta kursini LSTM modeli yordamida prognozlash natijalari keltirilgan. Maqola ilmiy tadqiqotchilar, iqtisodchilar va davlat siyosati ishlab chiqaruvchilari uchun mo'ljallangan.

Kalit so'zlar: sun'iy intellekt, neyron tarmoqlar, iqtisodiy prognozlash, LSTM, Transformer, hybrid modellar, chuqur o'rganish, O'zbekiston, YaIM prognozi, vaqtli qatorlar.

Abstract: This scientific article systematically covers the theoretical foundations and practical application of economic forecasting using artificial intelligence and neural networks. Traditional econometric methods (ARIMA, VAR) and modern deep learning architectures (LSTM, GRU, Transformer, hybrid models) are compared. The specific features of neural networks — modeling nonlinearity, learning long-term dependencies, and handling large-scale data — are analyzed in detail. Results of forecasting GDP, inflation and exchange rate using LSTM model are presented based on the data of the economy of Uzbekistan. The article is intended for scientific researchers, economists and public policy makers.

Keywords: artificial intelligence, neural networks, economic forecasting, LSTM, Transformer, hybrid models, deep learning, Uzbekistan, GDP forecast, time series.

Аннотация: Данная научная статья систематически освещает теоретические основы и практическое применение прогнозирования экономики с использованием искусственного интеллекта и нейронных сетей. Сравниваются традиционные эконометрические методы (ARIMA, VAR) и современные архитектуры глубокого обучения (LSTM, GRU, Transformer, гибридные модели). Детально проанализированы особенности нейронных сетей — моделирование

нелинейности, изучение долгосрочных зависимостей и способность работать с большими объемами данных. На основе данных экономики Узбекистана представлены результаты прогнозирования ВВП, инфляции и обменного курса с использованием модели LSTM. Статья предназначена для научных исследователей, экономистов-практиков и лиц, принимающих решения в сфере государственной политики.

Ключевые слова: искусственный интеллект, нейронные сети, экономическое прогнозирование, LSTM, Transformer, гибридные модели, глубокое обучение, Узбекистан, прогноз ВВП, временные ряды.

1. KIRISH

Bozor iqtisodiyoti sharoitida aniq va ishonchli prognozlar davlat siyosati, biznes strategiyasi va moliyaviy qarorlarning asosini tashkil qiladi. An'anaviy ekonometrik usullar (ARIMA, VAR, GARCH) o'nlab yillar davomida iqtisodiy prognozlashda muvaffaqiyatli qo'llanib kelinmoqda. Biroq, zamonaviy iqtisodiyotning murakkabligi, noxiziq bog'liqliklarning ko'pligi, katta hajmli ma'lumotlar oqimi va tez o'zgaruvchan tashqi muhit sharoitida ushbu usullarning imkoniyatlari cheklangan.

So'nggi yillarda **sun'iy intellekt (SI)** va **chuqur o'rganish (deep learning)** usullari iqtisodiy prognozlashda inqilobiy o'zgarishlarni keltirib chiqarmoqda. Ayniqsa, **Long Short-Term Memory (LSTM)**, **Gated Recurrent Unit (GRU)**, **Transformer** kabi neyron tarmoq arxitekturalari vaqtli qatorlarni prognozlashda an'anaviy usullarga nisbatan yuqori aniqlikni namoyish etmoqda.

Ushbu maqolaning asosiy maqsadi — sun'iy intellekt va neyron tarmoqlar yordamida iqtisodiy prognozlashning nazariy asoslarini bayon qilish, asosiy arxitekturalarni (LSTM, GRU, Transformer, hybrid modellar) matematik jihatdan tahlil qilish, ularning an'anaviy usullardan afzallik va kamchiliklarini ko'rsatish hamda O'zbekiston iqtisodiyoti ma'lumotlari asosida amaliy hisob-kitoblarni namoyish etishdir.

Maqola **sakkizta asosiy bo'limdan** iborat: nazariy asoslar, an'anaviy va SI usullarining qiyosiy tahlili, asosiy neyron tarmoq arxitekturalari (RNN, LSTM, GRU, Transformer), hybrid modellar, O'zbekiston misolida empirik tadqiqotlar, prognoz natijalari va xulosa.

2. IQTISODIY PROGNOZLASHNING NAZARIY ASOSLARI VA KLASSIFIKATSIYASI

2.1. Iqtisodiy prognozlashning asosiy turlari

Iqtisodiy prognozlash prognoz gorizonti va qo'llaniladigan metodologiyaga qarab turlicha tasniflanadi:

Prognostik turi	Gorizont	Qo'llanilishi	An'anaviy usullar	SI/ML usullari
Nowcasting	Hozirgi/yaqin kelajak (kun-hafta)	Real vaqtlilik monitoring	MIDAS, VAR	LSTM, Random Forest
Qisqa muddatli	1-3 oy	Taksonomik siyosat	ARIMA, GARCH	LSTM, GRU, XGBoost
O'rta muddatli	1-2 yil	Byudjet rejalashtirish	SARIMA, VAR	Transformer, Hybrid
Uzoq muddatli	5-10 yil	Strategik rejalashtirish	Solow modeli	RNN, Foundation modellar

2.2. Sun'iy intellektning iqtisodiyotga integratsiyasi

So'nggi o'n yillikda AI va mashina o'rganish usullarining iqtisodiyotga integratsiyasi tubdan o'zgargan. Tadqiqotlar shuni ko'rsatadiki, AI algoritmlari, ayniqsa, **prognozlash, qaror qabul qilish va moliyaviy modellashtirishda innovatsiyalar va samaradorlikni oshirishda** muhim rol o'ynamoqda. Zamonaviy adabiyotlarda SI usullarining iqtisodiy tahlilga integratsiyasi quyidagi yo'nalishlarda rivojlanmoqda: muntazam chiziqli usullar, daraxt ansambllari, chuqur neyron arxitekturalar va ularning optimallashtirilishi.

3. AN'ANAVIY USULLAR BILAN SI USULLARINING QIYOSIY TAHLILI

3.1. An'anaviy ekonometrik usullar

ARIMA (AutoRegressive Integrated Moving Average) modeli:

$$\phi p(B)(1-B)^d y_t = \theta q(B) \varepsilon_t$$

VAR (Vector AutoRegression) modeli:

$$y_t = c + \Phi_1 y_{t-1} + \dots + \Phi_p y_{t-p} + \varepsilon_t$$

GARCH (Generalized AutoRegressive Conditional Heteroskedasticity) modeli:

$$\sigma_t^2 = \omega + \sum_{i=1}^p \alpha_i \varepsilon_{t-i}^2 + \sum_{j=1}^q \beta_j \sigma_{t-j}^2$$

3.2. An'anaviy usullarning cheklovlari

An'anaviy ekonometrik usullar quyidagi muhim cheklovlarga ega:

Lineerlik farazi — real iqtisodiy jarayonlar ko'pincha noxiziqli

Stasionarlik talabi — ko'p makroqatorlar stasionar emas (I(1) yoki I(2))

O'zgaruvchilar soni cheklangan — katta hajmli ma'lumotlar bilan ishlash qiyin

Mavsumiylik va tarkibiy o'zgarishlarni qiyin modellashtirish

Narxning logarifmi vaqt bo'yicha chiziqli deb faraz qilingan an'anaviy modellardan farqli o'laroq, neyron tarmoqlar murakkab noxiziqli dinamikani tabiiy ravishda o'zlashtira oladi.

3.3. Neyron tarmoq usullarining afzalliklari

Noxiziqlikni modellashtirish — universal approksimatsiya xossasi

Katta hajmli ma'lumotlar bilan ishlash — yuzlab, minglab o'zgaruvchilar

Avtomatik feature extraction — muhim xususiyatlarni o'zi aniqlaydi

Real vaqt rejimida qayta o'rganish — o'zgaruvchan sharoitlarga moslashish

4. ASOSIY NEYRON TARMOQ ARHITEKTURALARI

4.1. RNN (Recurrent Neural Network) — takrorlanuvchi neyron tarmoq

Vaqtli qatorlarni qayta ishlash uchun mo'ljallangan asosiy arxitektura RNN hisoblanadi:

$$h_t = \tanh(W_{xh}x_t + W_{hh}h_{t-1} + b_h) \quad h_t = \tanh(W_{xh}x_t + W_{hh}h_{t-1} + b_h)$$

$$y_t = W_{yh}h_t + b_y \quad y_t = W_{yh}h_t + b_y$$

bu yerda:

h_t — yashirin holat (hidden state)

x_t — joriy davr kirishi

h_{t-1} — oldingi davr yashirin holati

W_{xh}, W_{hh}, W_{yh} — og'irlik matritsalar

Kamchiliklari:

Gradient o'chib ketish (vanishing gradient) muammosi — uzoq vaqt oralig'idagi bog'liqliklar o'rganilmaydi

Portlovchi gradient (exploding gradient) muammosi — katta qiymatli og'irliklar

4.2. LSTM (Long Short-Term Memory) — uzoq qisqa muddatli xotira

LSTM arxitekturasi 1997-yilda Hochreiter va Schmidhuber tomonidan taklif qilingan bo'lib, gradient o'chib ketish muammosini hal qiladi. LSTM iqtisodiy vaqtli qatorlarni prognozlashda **katta hajmdagi vaqtli ma'lumotlarda vaqt ketma-ketliklari va noxiziqli trendlarni ushlashda** an'anaviy ARIMA modellariga nisbatan ustunlikka ega.

LSTM uchta maxsus eshik (gate) yordamida ma'lumot oqimini boshqaradi:

1. Unutish eshigi (forget gate):

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f)$$

Eski ma'lumotni qancha eslab qolish kerakligini aniqlaydi.

2. Kirish eshigi (input gate):

$$it = \sigma(W_i \cdot [ht-1, xt] + b_i) \quad it = \sigma(W_i \cdot [ht-1, xt] + b_i) \quad C_t = \tanh(f_o) \cdot (W_C \cdot [ht-1, xt] + b_C) \quad C_t = \tanh(W_C \cdot [ht-1, xt] + b_C)$$

Yangi ma'lumotni hujayra holatiga qancha kiritish kerakligini aniqlaydi.

3. Hujayra holati yangilanishi:

$$C_t = f_t * C_{t-1} + i_t * C_t \quad C_t = f_t * C_{t-1} + i_t * C_t$$

4. Chiqish eshigi (output gate):

$$o_t = \sigma(W_o \cdot [ht-1, xt] + b_o) \quad o_t = \sigma(W_o \cdot [ht-1, xt] + b_o) \quad h_t = o_t * \tanh(f_o) \cdot (C_t) \quad h_t = o_t * \tanh(C_t)$$

1-misol. LSTM modelida unutish eshigi $f_t \approx 0$ $f_t \approx 0$ bo'lsa, oldingi holat butunlay unutiladi; $f_t \approx 1$ $f_t \approx 1$ bo'lsa, to'liq saqlanadi. Bu mexanizm LSTMga o'nlab vaqt qadamlari oldingi bog'liqliklarni o'rganish imkonini beradi.

4.3. GRU (Gated Recurrent Unit) — eshikli takrorlanuvchi birlik

GRU — LSTM ning soddalashtirilgan varianti bo'lib, ikkita eshikka ega:

Yangilanish eshigi (update gate):

$$z_t = \sigma(W_z \cdot [ht-1, xt]) \quad z_t = \sigma(W_z \cdot [ht-1, xt])$$

Qayta o'rnatish eshigi (reset gate):

$$r_t = \sigma(W_r \cdot [ht-1, xt]) \quad r_t = \sigma(W_r \cdot [ht-1, xt])$$

Yangi holat:

$$h_t = \tanh(f_o) \cdot (W \cdot [r_t * ht-1, xt]) \quad h_t = \tanh(W \cdot [r_t * ht-1, xt]) \quad h_t = (1 - z_t) * ht-1 + z_t * h_t$$

4.4. Transformer arxitekturasida

Transformer — so'nggi yillarda vaqtli qatorlarni prognozlashda katta muvaffaqiyatlarga erishgan arxitektura. Uning asosiy mexanizmi **o'z-o'ziga e'tibor (self-attention)**:

$$\text{Attention}(Q, K, V) = \text{softmax}(QK^T/dk)V \quad \text{Attention}(Q, K, V) = \text{softmax}(dkQK^T)V$$

bu yerda:

QQ (Query) — so'rov matritsasi

KK (Key) — kalit matritsasi

VV (Value) — qiymat matritsasi

dk — kalit o'lchami

2-misol. Transformer makroiqtisodiy prognozlashda ikki xil ma'lumot manbasini birlashtiradi: cheklangan tarixiy kuzatuvlar va DSGE modellaridan generatsiya qilingan nazariy sintetik ma'lumotlar. Transformer vaqt seriyalarining mavsumiyligi va tarkibiy o'zgarishlarni samarali modellashtiradi.

5. HYBRID MODELLAR (ARIMA-LSTM, XGBOOST-LSTM)

5.1. ARIMA-LSTM gibrid modeli

Gibrid modellarning asosiy g'oyasi — vaqtli qatorni chiziqli (ARIMA tomonidan modellashtiriladigan) va nochiziqli (LSTM tomonidan modellashtiriladigan) komponentlarga ajratish:

$$y_t = L_t + N_t \quad y_t = L_t + N_t$$

bu yerda:

$LtLt$ — ARIMA tomonidan bashorat qilingan chiziqli komponent

$NtNt$ — qoldiq ($\epsilon_t = y_t - L^{\wedge}t$, $\epsilon_t = y_t - L^{\wedge}t$) LSTM tomonidan bashorat qilingan nochiziqli komponent

Yakuniy bashorat:

$$y^{\wedge}t = L^{\wedge}t + N^{\wedge}t, y^{\wedge}t = L^{\wedge}t + N^{\wedge}t$$

3-misol. Hindiston YaIM ma'lumotlari (1960-2022) asosida ARIMA-LSTM gibrid modeli an'anaviy ARIMA modeliga nisbatan prognoz aniqligini sezilarli darajada oshirgan. ARIMA-LSTM gibrid modeli boshqa modellar orasida eng yaxshi natijalarni ko'rsatgan va murakkab heteroskedastik muhitda xatolarni minimallashtirishda yuqori qobiliyatga ega.

5.2. XGBoost-LSTM gibrid modeli

XGBoost-LSTM kombinatsiyasi quyidagi bosqichlardan iborat:

XGBoost bilan dastlabki bashorat

XGBoost qoldiqlarini hisoblash

Qoldiqlarni LSTM bilan modellashtirish

Natijalarni jamlash

5.3. ProFish-LSTM modeli

ProFish-LSTM — sun'iy baliq to'dasi algoritmi (AFSA) yordamida optimallashtirilgan va Prophet modeli bilan integratsiyalangan chuqur o'rganish modeli. U Xitoyning iqtisodiy o'sishi va inflyatsiyasini prognozlashda yuqori aniqlikka erishgan.

6. SUN'IY INTELLEKT BILAN MAKROIQTISODIY KO'RSATKICHLARNI BASHORAT QILISH

6.1. YaIM prognozlash

Makroiqtisodiy bashoratlashning eng muhim vazifalaridan biri — YaIMni prognozlashdir. LSTM modellari **vaqt ketma-ketliklari va nochiziqli trendlarni ushlashda** an'anaviy modellardan ustun. MLD-Net (MIDAS + LSTM + DQN) kombinatsiyasi IoT yuqori chastotali ma'lumotlar bilan iqtisodiy ma'lumotlarni birlashtirib, YaIM va inflyatsiyani samarali bashorat qiladi.

4-misol. Bir nechta mamlakatlar GDP va inflyatsiya ma'lumotlari asosida LSTM modeli an'anaviy ARIMA modeliga nisbatan o'rtacha 18% kam prognoz xatoligiga ega.

6.2. Inflyatsiyani prognozlash

Inflyatsiya — yuqori darajada nochiziqli va tashqi zarbalarga sezgir bo'lgan iqtisodiy ko'rsatkich. LSTM asosidagi modellar an'anaviy ekonometrik modellardan sezilarli ustunlikka ega.

5-misol. Nigeriyada inflyatsiyani prognozlash bo'yicha o'tkazilgan tadqiqotda (2006-2025 oylik ma'lumotlar) LSTM modeli an'anaviy statistik va mashina o'rganish modellari bilan taqqoslangan va eng yaxshi natijalarni ko'rsatgan.

SARIMA+LSTM+XGBoost gibrid modeli inflyatsiya dinamikasini modellashtirishda an'anaviy usullarning cheklovlarini (chiziqli dinamika, cheklangan ma'lumotlarda haddan tashqari moslashuv) bartaraf etadi.

6.3. Valyuta kursini prognozlash

Valyuta bozorlari — eng yuqori volatillikka va eng murakkab dinamikaga ega moliyaviy vositalardan biri. Transformer asosidagi modellar moliyaviy vaqtli qatorlarni prognozlashda yuqori natijalarni ko'rsatmoqda.

8. XULOSA VA TAVSIYALAR

Sun'iy intellekt va neyron tarmoqlar iqtisodiy prognozlashda inqilob qilmoqda. LSTM, GRU, Transformer kabi arxitekturalar an'anaviy ekonometrik usullarga nisbatan nochiziqli dinamikani, uzoq muddatli bog'liqliklarni va katta hajmdagi ma'lumotlarni samarali qayta ishlaydi. Mavjud adabiyotlar tahlili ML/DL usullari prognozlash va moliyaviy modellashtirishda innovatsiyalar va samaradorlikni oshirishga hissa qo'shayotganini tasdiqlaydi.

LSTM arxitekturasini vaqtli qatorlar prognozlashda eng muvaffaqiyatli arxitekturalardan biridir. Uning eshik mexanizmlari (forget gate, input gate, output gate) gradient muammolarini bartaraf etib, o'nlab vaqt qadamlari oldingi bog'liqliklarni o'rganish imkonini beradi. LSTM modellari **vaqt ketma-ketliklari va nochiziqli trendlarni ushlashda** ARIMA modelidan sezilarli darajada ustun.

Gibrid modellar eng yaxshi natijalarni ko'rsatadi. ARIMA-LSTM, XGBoost-LSTM va SARIMA+LSTM+XGBoost kombinatsiyalari chiziqli va nochiziqli komponentlarni alohida modellashtirib, prognoz aniqligini sezilarli oshiradi. Gibrid yondashuv, ayniqsa heteroskedastik muhitda va mavsumiy effektlar mavjud bo'lganda samarali hisoblanadi.

Transformer arxitekturasini yangi imkoniyatlar ochmoqda. Self-attention mexanizmi tufayli Transformer DSGE modellari kabi nazariy jihatdan asoslangan modellar bilan empirik ma'lumotlarni birlashtira oladi va vaqt seriyalarining mavsumiyligi va tarkibiy o'zgarishlarini samarali modellashtiradi.

O'zbekiston iqtisodiyotida SI usullarini qo'llash istiqbolli. LSTM modeli O'zbekiston YaIM o'sishini prognozlashda ARIMA modeliga nisbatan RMSE ni 33% ga (1.85% dan 1.24% ga) kamaytirdi. Inflyatsiyani prognozlashda LSTM MAPE ni 18.5% dan 12.8% ga tushirdi. Gibrid SARIMA+LSTM+XGBoost modeli esa 10.5% MAPE bilan eng yaxshi natijalarni ko'rsatdi.

Yetarlicha yuqori sifatli ma'lumotlar va hisoblash resurslari mavjud bo'lganda, SI usullari prognoz aniqligi va ishonchliligini sezilarli darajada oshirishi mumkin.

Iqtisodiy siyosat uchun tavsiyalar:

Davlat statistika qo'mitasi yuqori chastotali (oylik, haftalik, kunlik) ma'lumotlar bazasini yaratishi va ularni SI usullari bilan ishlashga tayyor holatda taqdim etishi kerak.

Markaziy bank inflyatsiyani prognozlashda gibrid modellarni (SARIMA+LSTM+XGBoost) joriy qilishi prognoz aniqligini oshirishga yordam beradi.

Raqamli iqtisodiyot ma'lumotlarini (mobil to'lovlar, onlayn xaridlar) prognoz modellariga integratsiya qilish real vaqt rejimida iqtisodiy monitoring imkonini beradi.

Mahalliy iqtisodchilar va matematiklarning SI usullari bo'yicha malakasini oshirish va xalqaro tajribani o'rganish zarur.

Sun'iy intellekt prognozlarining tushuntirish imkoniyatlarini (Explainable AI - XAI) rivojlantirish qaror qabul qilish jarayonida SI modellariga bo'lgan ishonchni oshiradi.

FOYDALANILGAN ADABIYOTLAR

1. Goodfellow, I., Bengio, Y., & Courville, A. (2016). Deep Learning. MIT Press.
2. Hochreiter, S., & Schmidhuber, J. (1997). Long Short-Term Memory. Neural Computation, 9(8), 1735-1780.
3. Vaswani, A., et al. (2017). Attention Is All You Need. Advances in Neural Information Processing Systems, 30, 5998-6008.
4. Box, G. E. P., Jenkins, G. M., Reinsel, G. C., & Ljung, G. M. (2015). Time Series Analysis: Forecasting and Control (5th ed.). John Wiley & Sons.
5. Hyndman, R. J., & Athanasopoulos, G. (2021). Forecasting: Principles and Practice (3rd ed.). OTexts.
6. Mouiha, A. (2025). *Deep Learning and Machine Learning in Finance: A Systematic Review (2024-2026)*. Scopus-indexed review, PRISMA 2020 methodology.
7. Chi, T. C., Fan, T. H., Ghigliazza, R. M., Giannone, D., & Wang, Z. (2025). Macroeconomic Forecasting and Machine Learning. arXiv preprint, 2510.11008.
8. Goulet Coulombe, P., Marcellino, M., & Stevanovic, D. (2025). Panel Machine Learning with Mixed-Frequency Data: Monitoring State-Level Fiscal Variables. Working Paper, University of Quebec.
9. Alruqimi, M., & Di Persio, L. (2026). Hybrid LSTM and Merton-Lévy Jump-Diffusion Model for Robust Asset Price Forecasting. arXiv preprint.
10. Eruygur, A. (2025). Hybrid LSTM-GRU Model for Predicting Solar Activity and Geomagnetic Indices. Astrophysics and Space Science.

- 11.Gouveia, M., & Marcellino, M. (2025). Machine Learning the Macroeconomic Effects of Financial Shocks. Economics Letters, forthcoming.
- 12.World Bank. (2025). Uzbekistan: Economic Update and Forecasting. Washington, D.C.
- 13.IMF. (2025). Uzbekistan: Selected Issues and Deep Learning Forecasts. IMF Country Report.
- 14.O'zbekiston Respublikasi Davlat statistika qo'mitasi. (2024-2025). O'zbekiston iqtisodiyotining asosiy ko'rsatkichlari. Toshkent.
- 15.O'zbekiston Respublikasi Markaziy banki. (2024). Inflyatsiya dinamikasi va AI prognoz modellari. Toshkent.