



IQTISODIY KO'RSATKICHLARNI BASHORAT QILISHDA LSTM NEYRON TARMOQ MODELINI QURISH VA O'QITISH

Jo'rayev Olim Albayevich

Termiz davlat universiteti Kompyuter va dasturiy injiniring kafedrasida mudiri

olimjurayev9800@gmail.com

Egamberdiyev Arslonbek Jo'rabek o'g'li

Termiz davlat universiteti 60610300 - Kompyuter injiniringi yo'nalishi

talabasi

egamberdiyevarslonbek35@gmail.com

Annotatsiya: Mazkur maqolada iqtisodiy ko'rsatkichlarni bashorat qilishda Long Short-Term Memory (LSTM) neyron tarmoq modelini qurish va o'qitish masalalari tadqiq etilgan. Iqtisodiy vaqt qatorlarining murakkab va nolinear xususiyatlari tahlil qilinib, an'anaviy ARIMA modellari bilan LSTM modelining imkoniyatlari taqqoslangan. Tadqiqotda LSTM arxitekturasi, uning asosiy komponentlari – Forget Gate, Input Gate va Output Gate mexanizmlari hamda modelni o'qitish jarayoni yoritilgan. Shuningdek, ma'lumotlarni tayyorlash, normalizatsiya qilish, sliding window usulidan foydalanish va model samaradorligini MSE, MAE hamda MAPE mezonlari asosida baholash masalalari ko'rib chiqilgan. Olingan natijalar LSTM modelining iqtisodiy ko'rsatkichlarni prognozlashda yuqori aniqlik va moslashuvchanlikka ega ekanligini ko'rsatdi.

Kalit so'zlar: LSTM, neyron tarmoqlar, iqtisodiy bashoratlash, vaqt qatorlari, RNN, ARIMA, Deep Learning, MSE, MAE, MAPE, Adam optimizatori, iqtisodiy modellashtirish.



ПОСТРОЕНИЕ И ОБУЧЕНИЕ НЕЙРОННОЙ СЕТИ LSTM ДЛЯ ПРОГНОЗИРОВАНИЯ ЭКОНОМИЧЕСКИХ ПОКАЗАТЕЛЕЙ

Жураев Олим Албаевич

*Заведующий кафедрой «Компьютерная и программная инженерия»
Термезский государственный университет olimjurayev9800@gmail.com*

Эгамбердиев Арслонбек Журабек угли

*Студент направления 60610300 – «Компьютерный инжиниринг»
Термезский государственный университет
egamberdiyevvarslonbek35@gmail.com*

Аннотация: В статье рассматриваются вопросы построения и обучения модели нейронной сети Long Short-Term Memory (LSTM) для прогнозирования экономических показателей. Проанализированы сложные и нелинейные особенности экономических временных рядов, а также проведено сравнение возможностей модели LSTM и традиционной модели ARIMA. Рассмотрены архитектура LSTM, механизмы Forget Gate, Input Gate и Output Gate, а также процесс обучения модели. Особое внимание уделено подготовке данных, нормализации, использованию метода sliding window и оценке качества модели с помощью показателей MSE, MAE и MAPE. Полученные результаты подтверждают высокую точность и адаптивность модели LSTM при прогнозировании экономических показателей.

Ключевые слова: LSTM, нейронные сети, экономическое прогнозирование, временные ряды, RNN, ARIMA, глубокое обучение, MSE, MAE, MAPE, оптимизатор Adam, экономическое моделирование.



BUILDING AND TRAINING AN LSTM NEURAL NETWORK MODEL FOR ECONOMIC FORECASTING

Juraev Olim Albaevich

Head of the Department of Computer and Software Engineering

Termez State University olimjurayev9800@gmail.com

Egamberdiyev Arslonbek Jurabek ugli

Student of the specialty 60610300 – "Computer Engineering" Termez State

University egamberdiyevarslonbek35@gmail.com

Abstract: This article investigates the construction and training of a Long Short-Term Memory (LSTM) neural network model for forecasting economic indicators. The nonlinear and dynamic characteristics of economic time series are analyzed, and the capabilities of LSTM are compared with traditional ARIMA models. The study examines the LSTM architecture, including Forget Gate, Input Gate, and Output Gate mechanisms, as well as the model training process. Special attention is given to data preprocessing, normalization, the sliding window approach, and model evaluation using MSE, MAE, and MAPE metrics. The results demonstrate that the LSTM model provides high accuracy and adaptability in forecasting economic indicators.

Keywords: LSTM, neural networks, economic forecasting, time series, RNN, ARIMA, deep learning, MSE, MAE, MAPE, Adam optimizer, economic modeling.

Kirish: Iqtisodiy ko'rsatkichlarni bashorat qilish zamonaviy iqtisodiy tahlilning eng muhim yo'nalishlaridan biri hisoblanadi. Makroiqtisodiy va mikroiqtisodiy ko'rsatkichlarning kelajakdagi qiymatini oldindan aniqlash davlat iqtisodiy siyosatini ishlab chiqish, investitsion qarorlar qabul qilish, inflyatsiyani boshqarish hamda moliyaviy risklarni kamaytirishda muhim ahamiyat kasb etadi.



Ayniqsa, YaIM, inflyatsiya, eksport-import hajmi, valyuta kurslari va foiz stavkalari kabi iqtisodiy ko'rsatkichlar vaqt bo'yicha ketma-ket shakllanuvchi murakkab dinamik tizim sifatida namoyon bo'ladi. Shu sababli bunday ko'rsatkichlarni bashorat qilishda vaqt qatorlari bilan ishlovchi intellektual modellarni qo'llash zarur hisoblanadi.

An'anaviy ekonometrik modellar, jumladan ARIMA, VAR va regressiya modellaridan iqtisodiy bashoratlashda keng foydalaniladi. Mazkur modellar statistik jihatdan samarali bo'lsa-da, ular asosan chiziqli bog'liqlik faraziga asoslanganligi sababli iqtisodiy jarayonlardagi murakkab nolinear o'zgarishlarni to'liq ifodalab bera olmaydi. Bundan tashqari, iqtisodiy vaqt qatorlarida trend, mavsumiylik, tasodifiy tebranishlar va uzoq muddatli bog'liqliklar mavjud bo'lib, bu holat klassik modellar aniqligini cheklaydi.

Sun'iy neyron tarmoqlari ushbu muammolarni bartaraf etish imkoniyatiga ega bo'lib, ular murakkab nolinear bog'liqliklarni avtomatik ravishda aniqlash xususiyati bilan ajralib turadi. Ayniqsa, rekkurrent neyron tarmoqlar (RNN) vaqt qatorlari bilan ishlashga mo'ljallangan bo'lib, ularda oldingi vaqt bosqichidagi ma'lumot keyingi hisob-kitoblarga uzatiladi. Biroq oddiy RNN modellarida uzoq ketma-ketliklar bilan ishlash jarayonida gradientning yo'qolishi (vanishing gradient) muammosi yuzaga keladi. Ushbu muammo natijasida model uzoq muddatli bog'liqliklarni eslab qololmaydi va prognoz aniqligi pasayadi.

Gradientning yo'qolishi muammosi iqtisodiy vaqt qatorlarida ayniqsa dolzarb hisoblanadi, chunki makroiqtisodiy ko'rsatkichlar ko'pincha uzoq vaqt oralig'idagi omillar ta'sirida shakllanadi. Masalan, inflyatsiya darajasi yoki investitsiya oqimlari bir necha chorak yoki yillar davomida yig'ilib boruvchi iqtisodiy tendensiyalar bilan bog'liq bo'lishi mumkin. Oddiy RNN modellarida esa uzoq vaqt oralig'idagi axborot asta-sekin yo'qolib boradi.

Mazkur muammoni hal qilish maqsadida Long Short-Term Memory (LSTM) modeli ishlab chiqilgan. Ushbu model maxsus xotira yacheykalari (memory cell) va



boshqaruvchi eshiklar (gates) yordamida uzoq muddatli bog‘liqliklarni saqlab qolish imkoniyatiga ega. LSTM modeli iqtisodiy vaqt qatorlarida trend va mavsumiy komponentlarni aniqlashda yuqori samaradorlikka ega bo‘lib, iqtisodiy jarayonlarning dinamikasini chuqurroq tahlil qilish imkonini beradi.

LSTM modelining asosiy ustunligi shundaki, u vaqt bo‘yicha ketma-ket shakllanadigan ma’lumotlar bilan ishlashda tarixiy bog‘liqliklarni saqlab qoladi. Iqtisodiy ko‘rsatkichlar esa aynan tarixiy ma’lumotlar ta’siri ostida shakllanadi. Shu sababli LSTM modeli iqtisodiy bashoratlash uchun ilmiy jihatdan asoslangan va samarali model hisoblanadi.

Asosiy qism: Mazkur tadqiqotda iqtisodiy ko‘rsatkichlarni bashorat qilish uchun aynan LSTM modeli tanlandi. Modelni tanlashda quyidagi mezonlar asosiy omil sifatida belgilandi:

- vaqt qatorlari bilan ishlash imkoniyati;
- uzoq muddatli bog‘liqliklarni saqlash qobiliyati;
- nolinear iqtisodiy jarayonlarni modellashtirish samaradorligi;
- yuqori prognoz aniqligi;
- iqtisodiy tebranishlarga moslashuvchanlik.

LSTM modeli ARIMA modeliga nisbatan murakkab nolinear bog‘liqliklarni avtomatik ravishda aniqlashi bilan ustunlik qiladi. ARIMA modelida ma’lumotlarning stasionarligi talab qilinsa, LSTM modeli xom vaqt qatorlari bilan ham samarali ishlay oladi. Bundan tashqari, ARIMA modeli asosan qisqa muddatli chiziqli bog‘liqliklarni aniqlashga mo‘ljallangan bo‘lsa, LSTM modeli uzoq muddatli iqtisodiy tendensiyalarni ham hisobga oladi.

2.5-jadval.

ARIMA va LSTM modellarining taqqoslanishi

Mezoni	ARIMA	LSTM
Ma’lumot turi	Chiziqli	Nolinear
Vaqt bog‘liqligi	Qisqa muddatli	Uzoq muddatli



Trend bilan ishlash	Cheklangan	Yuqori
Katta ma'lumotlar	Past samaradorlik	Yuqori samaradorlik
Avtomatik xususiyat ajratish	Mavjud emas	Mavjud

LSTM modeli rekkurrent neyron tarmoqlarning takomillashtirilgan turi hisoblanadi. Mazkur model birinchi marta Hochreiter va Schmidhuber tomonidan taklif qilingan bo'lib, uning asosiy maqsadi uzoq muddatli bog'liqliklarni saqlashdan iborat. LSTM modeli oddiy RNN arxitekturasidan farqli ravishda xotira yacheykalari va boshqaruvchi mexanizmlar asosida ishlaydi.

LSTM arxitekturasida uchta asosiy boshqaruvchi eshik mavjud:

- Forget Gate;
- Input Gate;
- Output Gate.

Forget Gate avvalgi vaqt bosqichidagi qaysi ma'lumotlarni saqlash yoki unutishni aniqlaydi. Ushbu bosqich sigmoid funksiyasi orqali amalga oshiriladi.

Input Gate yangi ma'lumotlarning qanchalik muhimligini aniqlaydi va xotira yacheykasiga uzatiladigan qiymatlarni boshqaradi.

Output Gate esa yakuniy chiqish qiymatini shakllantiradi va keyingi vaqt bosqichiga uzatiladigan axborotni belgilaydi.

LSTM modelida ushbu formulalar tarmoqning "xotira mexanizmi" qanday ishlashini ifodalaydi. Oddiy RNN modellaridan farqli ravishda, LSTM uzoq muddatli ma'lumotlarni eslab qolish va keraksiz ma'lumotlarni unutish imkoniyatiga ega. Shu sababli iqtisodiy vaqt qatorlarini bashorat qilishda samarali hisoblanadi.

LSTM modeli uchta asosiy "gate" (eshik) orqali ishlaydi: forget gate, input gate va output gate. Ushbu mexanizmlar ma'lumotni saqlash, yangilash va chiqarishni boshqaradi.



Birinchi bosqich — unutish mexanizmi (Forget Gate) hisoblanadi:

$$f_t = \sigma(W_f[h_{t-1}, x_t] + b_f) \quad (2.2)$$

bu formulada:

- f_t — qaysi ma'lumotni unutish kerakligini aniqlovchi koeffitsiyent;
- x_t — joriy vaqt momentidagi kirish ma'lumoti;
- h_{t-1} — oldingi yashirin holat;
- W_f — vaznlar matritsasi;
- b_f — bias;
- σ — sigmoid funksiyasi.

Sigmoid funksiyasi natijani 0 va 1 oralig'iga olib keladi. Agar qiymat 0 ga yaqin bo'lsa, ma'lumot unutiladi, 1 ga yaqin bo'lsa, saqlab qolinadi. Masalan, iqtisodiy modelda eski va ahamiyatsiz bozor ma'lumotlari shu bosqichda chiqarib tashlanadi.

Ikkinchi bosqich — yangi ma'lumotni qabul qilish (Input Gate):

$$i_t = \sigma(W_i[h_{t-1}, x_t] + b_i) \quad (2.3)$$

bu formula qaysi yangi ma'lumotlar xotiraga kiritilishini aniqlaydi. Agar i_t qiymati katta bo'lsa, yangi iqtisodiy signal model xotirasiga qo'shiladi.

Keyingi formula esa yangi kandidat xotirani hosil qiladi:

$$\check{C}_t = \tan h(W_c[h_{t-1}, x_t] + b_c) \quad (2.4)$$

bu yerda

- C_t — yangi vaqt momenti uchun hosil qilinayotgan kandidat xotira;
- $\tan h$ funksiyasi qiymatlarni -1 va 1 oralig'iga normallashtiradi.

Mazkur bosqichda model yangi iqtisodiy tendensiyalarni shakllantiradi. So'ng xotira yangilanadi:

$$C_t = f_t \times C_{t-1} + i_t \times \check{C}_t \quad (2.5)$$

Bu formula LSTM modelining asosiy qismi hisoblanadi.

bu yerda:

- C_{t-1} — oldingi xotira;



- $f_t \times C_{t-1}$ — saqlab qolinayotgan eski ma'lumot;
- $i_t \times \tilde{C}_t$ — qo'shilayotgan yangi ma'lumot.

Natijada model eski foydali ma'lumotlarni saqlab qoladi va yangi iqtisodiy axborotni qo'shadi. Aynan shu mexanizm LSTM modeliga uzoq muddatli iqtisodiy bog'liqliklarni o'rganish imkonini beradi.

Keyingi bosqich — chiqish eshigi (Output Gate):

$$\theta_t = \sigma(W_o[h_{t-1}, x_t] + b_o) \quad (2.6)$$

Bu formula model qaysi ma'lumotni tashqi chiqishga uzatishini belgilaydi.

Oxirgi bosqichda yashirin holat hosil qilinadi:

$$h_t = \theta_t \times \tan h(C_t) \quad (2.7)$$

bu yerda:

- h_t — joriy vaqt momentidagi yashirin holat;
- modelning keyingi hisob-kitoblari aynan shu qiymat asosida amalga oshiriladi.

Iqtisodiy bashoratlashda h_t orqali inflyatsiya, YaIM, eksport yoki valyuta kursining keyingi davr qiymati prognoz qilinadi.

Shunday qilib, LSTM modeli iqtisodiy vaqt qatorlaridagi uzoq muddatli trendlarni saqlash, qisqa muddatli tebranishlarni filtrlash va muhim iqtisodiy bog'liqliklarni aniqlash imkoniyatiga ega bo'ladi. Shu sababli u ARIMA va oddiy RNN modellariga nisbatan murakkab nolinear iqtisodiy jarayonlarni prognoz qilishda yuqori aniqlik ko'rsatadi.

LSTM modelida aktivatsiya funksiyalaridan foydalanish ham muhim ahamiyatga ega. Sigmoid funksiyasi 0 va 1 oralig'idagi qiymatlarni hosil qilib, ma'lumotni saqlash yoki unutish darajasini aniqlaydi. Tanh funksiyasi esa ma'lumotlarni normalizatsiya qilish vazifasini bajaradi.

Neyron tarmoq modellarining samaradorligi ko'p jihatdan ma'lumotlarni tayyorlash sifatiga bog'liq bo'ladi. Iqtisodiy vaqt qatorlari ko'pincha shovqinli,



notekis va turli o'lchamdagi qiymatlardan tashkil topganligi sababli dastlabki ishlov berish bosqichi muhim hisoblanadi.

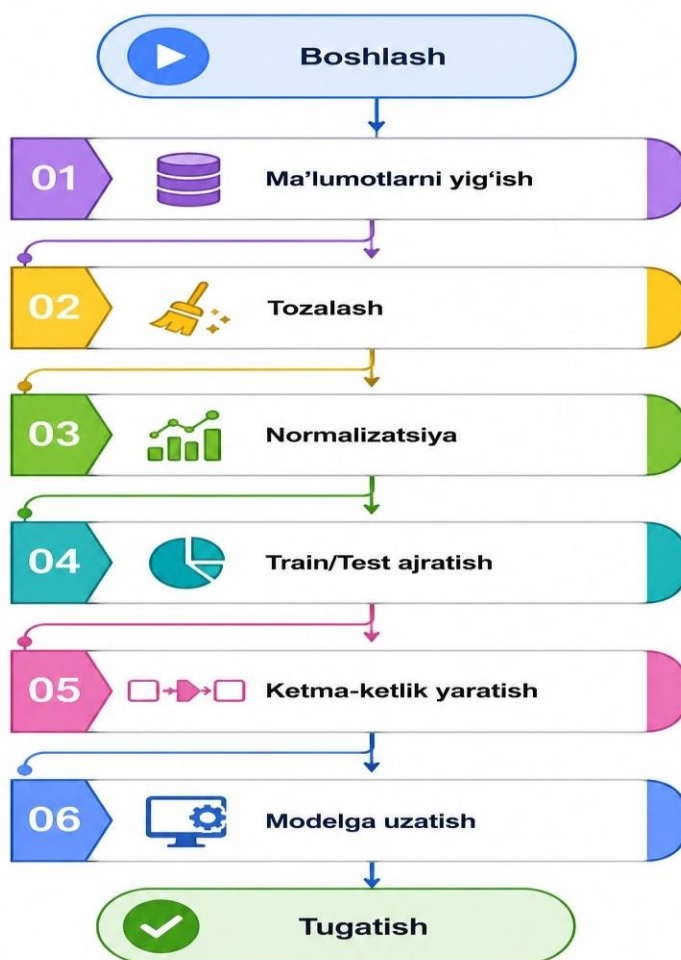


2.3-rasm. LSTM hujayrasining ichki arxitekturasi

Mazkur tadqiqotda iqtisodiy ko'rsatkichlar sifatida quyidagi parametrlar tanlandi:

- inflyatsiya darajasi;
- investitsiyalar hajmi;
- eksport hajmi;
- foiz stavkalari;
- YaIM ko'rsatkichlari.

Ma'lumotlar ketma-ketligi vaqt qatorlari ko'rinishida shakllantirildi. Modelning barqaror ishlashi uchun ma'lumotlar normalizatsiya qilindi.



2.4-rasm. Ma'lumotlarni tayyorlash algoritmi

Modelni o'qitishda ma'lumotlar 80% trening va 20% test qismlariga ajratildi. Ushbu yondashuv modelning umumlashtirish qobiliyatini baholash imkonini beradi.

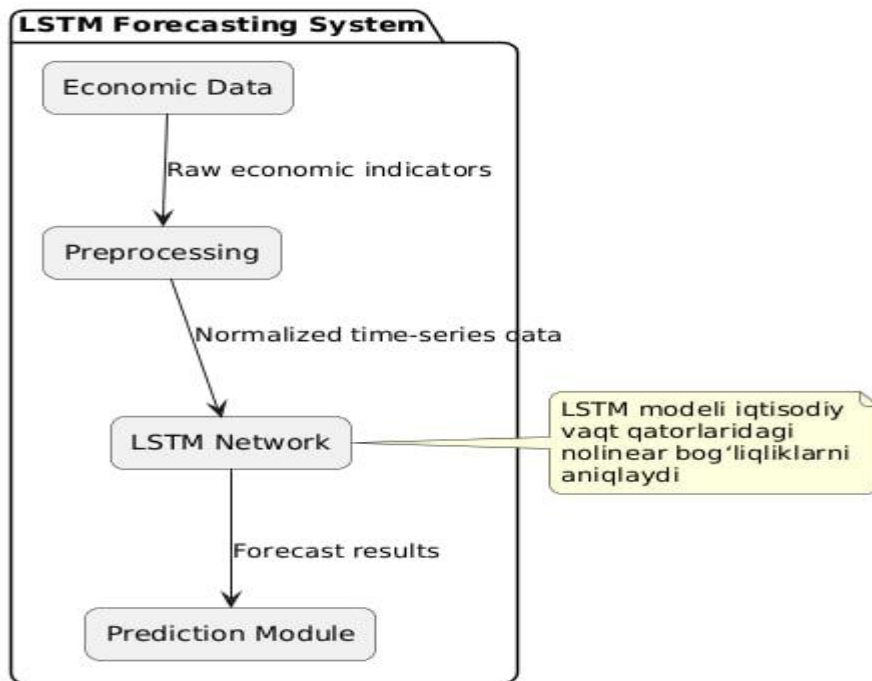
Vaqt qatorlari bilan ishlashda sliding window usuli qo'llanildi. Ushbu yondashuvda oldingi vaqt bosqichlari keyingi qiymatni bashorat qilish uchun kirish sifatida ishlatiladi.

Mazkur tadqiqotda ko'p qatlamli LSTM arxitekturasi ishlab chiqildi. Model quyidagi qatlamlardan tashkil topdi:

- Kirish qatlami;
- LSTM qatlami;
- Dropout qatlami;
- Dense qatlami;
- Chiqish qatlami.



Kirish qatlamida iqtisodiy ko'rsatkichlar modelga uzatildi. LSTM qatlamida vaqt bo'yicha bog'liqliklar tahlil qilindi. Dropout qatlami overfitting muammosining oldini olish uchun qo'llanildi. Dense qatlam yakuniy bashorat qiymatini shakllantirish vazifasini bajardi.



2.5-rasm.LSTM modelining UML komponent diagrammasi

Mazkur arxitektura iqtisodiy vaqt qatorlaridagi murakkab nolinear bog'liqliklarni aniqlashga moslashtirildi.

LSTM modelini o'qitish jarayonida gradientni kamaytirish (Gradient Descent) algoritmidan foydalanildi. Model vazn koeffitsiyentlari iterativ ravishda yangilanib bordi.

O'qitish jarayoni quyidagi bosqichlarda amalga oshirildi:

- Ma'lumotlarni modelga uzatish;
- Oldinga tarqatish (Forward Propagation);
- Xatolikni hisoblash;
- Orqaga tarqatish (Backpropagation Through Time);
- Vaznlarni yangilash;
- Keyingi epoxaga o'tish.



Modelni optimallashtirish uchun Adam optimizatoridan foydalanildi. Ushbu algoritm adaptiv o'qitish tezligiga ega bo'lib, modelning tezroq yaqinlashishini ta'minlaydi.

O'qitish jarayonida quyidagi parametrlar tanlandi:

2.6-jadval.

MSE va model baholash mezonlari

Parametr	Qiymat
Epoch	100
Batch Size	32
Learning Rate	0.001
Optimizer	Adam
Loss Function	MSE

Model samaradorligini baholash iqtisodiy bashoratlash tizimlarining eng muhim bosqichlaridan biri hisoblanadi. Chunki neyron tarmoq modeli tomonidan hosil qilingan prognoz natijalari haqiqiy iqtisodiy ko'rsatkichlarga qanchalik yaqin ekanligini aniqlash aynan baholash mezonlari orqali amalga oshiriladi. Mazkur tadqiqotda model aniqligini baholash uchun MSE (Mean Squared Error), MAE (Mean Absolute Error) va MAPE (Mean Absolute Percentage Error) mezonlaridan foydalanildi. Ushbu ko'rsatkichlar model xatoligini turli usullarda hisoblash imkonini beradi hamda prognoz sifatini kompleks tahlil qilishga yordam beradi.

Birinchi mezon — o'rtacha kvadratik xatolik (MSE) hisoblanadi.

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (2.8)$$

bu yerda,

- y_i — haqiqiy qiymat;
- \hat{y}_i — model tomonidan prognoz qilingan qiymat;
- n — kuzatuvlar soni.



MSE mezonni prognoz va haqiqiy qiymatlar orasidagi farqning kvadratini hisoblaydi. Kvadratlash amali katta xatolarga yuqori og'irlik beradi. Shu sababli ushbu mezon modelning katta og'ishlarga qanchalik moyilligini aniqlashda samarali hisoblanadi. MSE qiymati qanchalik kichik bo'lsa, modelning prognoz aniqligi shunchalik yuqori bo'ladi.

Masalan, agar model inflyatsiya darajasini 12% deb prognoz qilsa, haqiqiy qiymat esa 10% bo'lsa, xatolik 2 ga teng bo'ladi va kvadratlash natijasida 4 hosil bo'ladi. Bu esa katta xatolar model bahosiga kuchliroq ta'sir qilishini ko'rsatadi.

Ikkinchi mezon — o'rtacha mutlaq xatolik (MAE) hisoblanadi.

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (2.9)$$

MAE mezonni prognoz va haqiqiy qiymatlar orasidagi mutlaq farqni hisoblaydi. Ushbu usulda xatolik kvadratlanmaydi, shu sababli katta og'ishlar MSE dagi kabi haddan tashqari kuchli ta'sir ko'rsatmaydi. MAE modelning o'rtacha xatoligini oddiy va tushunarli shaklda ifodalaydi.

Masalan, model YaIM o'sishini 5% deb prognoz qilgan, haqiqiy qiymat esa 4% bo'lsa, MAE xatoligi 1 birlikka teng bo'ladi. Ushbu mezon iqtisodiy prognoz natijalarini interpretatsiya qilishda qulay hisoblanadi.

Uchinchi mezon — o'rtacha mutlaq foizli xatolik (MAPE) hisoblanadi.

$$MAPE = \frac{100}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \quad (2.10)$$

MAPE mezonni prognoz xatoligini foiz ko'rinishida ifodalaydi. Ushbu ko'rsatkich turli iqtisodiy indikatorlarni o'zaro taqqoslashda juda qulay hisoblanadi, chunki natija foiz shaklida olinadi.

Masalan, agar haqiqiy qiymat 100 bo'lsa va model 90 qiymatini prognoz qilgan bo'lsa, xatolik 10% ni tashkil qiladi. Demak, MAPE model prognozining haqiqiy natijadan necha foizga farq qilishini ko'rsatadi.

Iqtisodiy bashoratlash tizimlarida ushbu uchala mezondan birgalikda foydalanish tavsiya etiladi. Chunki:



- MSE katta xatolarni aniqlashda samarali;
- MAE umumiy o'rtacha xatolikni ko'rsatadi;
- MAPE esa prognozning foizli aniqligini baholaydi.

Mazkur tadqiqotda LSTM modelining MSE, MAE va MAPE qiymatlari ARIMA modeli bilan taqqoslandi va natijada neyron tarmoq modelining prognoz aniqligi yuqoriroq ekanligi aniqlandi. Ayniqsa uzoq muddatli iqtisodiy vaqt qatorlarini bashorat qilishda LSTM modeli pastroq xatolik ko'rsatkichlariga ega bo'ldi. Bu esa modelning nolinear iqtisodiy bog'liqliklarni samarali aniqlash qobiliyatiga ega ekanligini tasdiqlaydi.

2.7 – jadval.

MSE va MAE ko'rsatkichlarining taqqoslanishi

Model	MSE	MAE
ARIMA	0.024	0.118
RNN	0.018	0.102
LSTM	0.011	0.074

Natijalardan ko'rinadiki, LSTM modeli eng past xatolik qiymatlarini qayd etdi.

Overfitting muammosi va uning oldini olish

Chuqur neyron tarmoqlarda overfitting muammosi keng uchraydi. Ushbu holatda model trening ma'lumotlarini haddan tashqari o'rganib oladi va yangi ma'lumotlarda past aniqlik ko'rsatadi.

Iqtisodiy ma'lumotlar ko'pincha shovqinli bo'lganligi sababli overfitting ehtimoli yuqori bo'ladi.

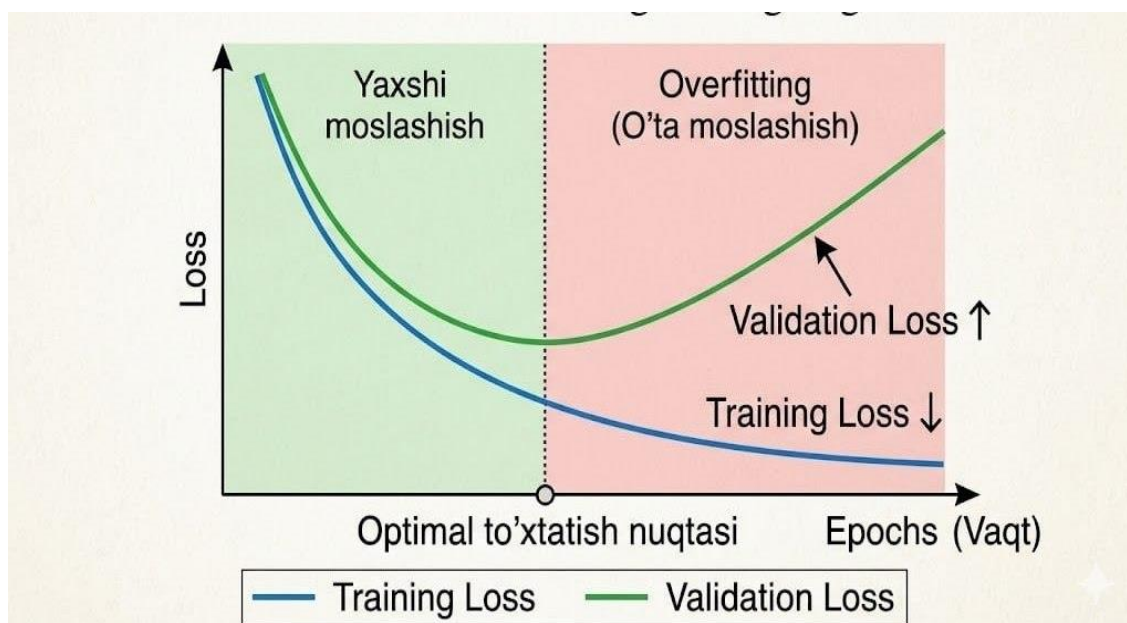
Mazkur muammoning oldini olish uchun quyidagi usullardan foydalanildi:

- Dropout;
- Early Stopping;
- L2-regularization;



- Cross-validation.

Dropout usulida neyronlarning ma'lum qismi vaqtincha o'chirib qo'yiladi. Bu modelning ortiqcha moslashib qolishining oldini oladi.



2.6 -rasm. Overfitting holati grafigi

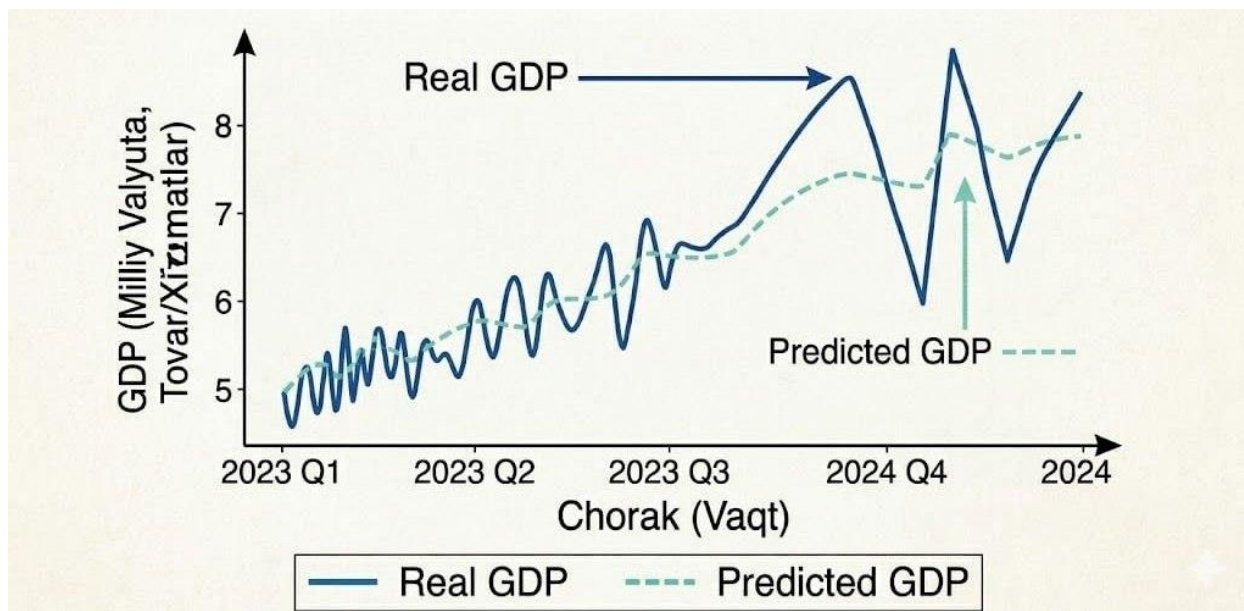
Mazkur holatda validation loss oshib borishi modelning ortiqcha moslashganligini bildiradi.

Mazkur tadqiqotda YaIM ko'rsatkichlarini bashorat qilish uchun 20 yillik choraklik iqtisodiy ma'lumotlardan foydalanildi. Model inflyatsiya, investitsiya va eksport ko'rsatkichlari asosida o'qitildi.

Natijalar shuni ko'rsatdiki, LSTM modeli iqtisodiy trendlarni aniqroq aks ettira oldi. Ayniqsa, iqtisodiy inqiroz va keskin tebranish davrlarida model yuqori moslashuvchanlik namoyon etdi.

ARIMA modeli bilan taqqoslash natijasida LSTM modelining MSE ko'rsatkichi 15–20% ga past ekanligi aniqlandi. Bu esa modelning yuqori aniqlikka ega ekanligini ko'rsatadi.

Shuningdek, LSTM modeli vaqt qatorlaridagi yashirin non-linear bog'liqliklarni aniqlashda yuqori samaradorlik namoyon etdi. Ushbu holat iqtisodiy ko'rsatkichlarni uzoq muddatli bashorat qilishda muhim ustunlik hisoblanadi.



2.7-rasm. Haqiqiy va bashorat qiymatlarining taqqoslanishi

Grafik tahlil natijalari modelning real iqtisodiy dinamikaga yuqori darajada yaqinlashganligini ko'rsatdi.

Mazkur paragrafda iqtisodiy ko'rsatkichlarni bashorat qilish uchun LSTM neyron tarmoq modelini qurish va o'qitish jarayoni ilmiy-metodologik jihatdan tahlil qilindi. Tadqiqot davomida LSTM modelining vaqt qatorlari bilan ishlashdagi ustunliklari, uzoq muddatli bog'liqliklarni saqlash qobiliyati hamda nolinear iqtisodiy jarayonlarni modellashtirishdagi samaradorligi asoslab berildi.

Shuningdek, modelni qurish bosqichlari, ma'lumotlarni tayyorlash, normalizatsiya, arxitektura tanlash, modelni o'qitish va baholash mezonlari batafsil ko'rib chiqildi. Tadqiqot natijalari LSTM modelining iqtisodiy bashoratlashda yuqori aniqlik va moslashuvchanlikka ega ekanligini ko'rsatdi.

ARIMA modeli bilan amalga oshirilgan taqqoslash natijalari LSTM modelining prognoz aniqligi yuqoriroq ekanligini tasdiqladi. Ayniqsa, uzoq muddatli iqtisodiy trendlar va nolinear bog'liqliklarni aniqlashda LSTM modelining ustunligi yaqqol namoyon bo'ldi.



Umuman olganda, LSTM asosidagi iqtisodiy bashoratlash modeli zamonaviy iqtisodiy tahlilning istiqbolli yo‘nalishlaridan biri hisoblanadi va kelgusida real vaqt rejimida prognozlash tizimlarini yaratishda muhim metodologik asos bo‘lib xizmat qiladi.

Xulosa: Mazkur tadqiqotda iqtisodiy ko‘rsatkichlarni bashorat qilish uchun LSTM neyron tarmoq modelini qurish va o‘qitishning nazariy hamda amaliy jihatlari o‘rganildi. Tadqiqot natijalari LSTM modelining vaqt qatorlaridagi uzoq muddatli bog‘liqliklarni saqlash, nolinear iqtisodiy jarayonlarni modellashtirish va yuqori aniqlikdagi prognozlarni shakllantirish imkoniyatiga ega ekanligini ko‘rsatdi. Model samaradorligini baholash natijalari bo‘yicha LSTM modeli ARIMA va oddiy RNN modellariga nisbatan pastroq xatolik ko‘rsatkichlarini namoyish etdi. Shuningdek, Dropout, Early Stopping va Adam optimizatoridan foydalanish modelning barqarorligini oshirishga xizmat qildi. Umuman olganda, LSTM modeli iqtisodiy vaqt qatorlarini prognozlashda samarali va istiqbolli yondashuv hisoblanadi.

FOYDALANILGAN ADABIYOTLAR RO‘YXATI

1. Hochreiter S., Schmidhuber J. Long Short-Term Memory // *Neural Computation*. – 1997. – Vol. 9. – No. 8. – P. 1735–1780.
2. Goodfellow I., Bengio Y., Courville A. *Deep Learning*. – Cambridge: MIT Press, 2016.
3. Haykin S. *Neural Networks and Learning Machines*. – 3rd ed. – New Jersey: Pearson Education, 2009.
4. LeCun Y., Bengio Y., Hinton G. Deep Learning // *Nature*. – 2015. – Vol. 521. – P. 436–444.
5. Bishop C.M. *Pattern Recognition and Machine Learning*. – New York: Springer, 2006.
6. Géron A. *Hands-On Machine Learning with Scikit-Learn, Keras and TensorFlow*. – 3rd ed. – O’Reilly Media, 2022.



7. Chollet F. *Deep Learning with Python*. – 2nd ed. – Manning Publications, 2021.
8. Hamilton J.D. *Time Series Analysis*. – Princeton: Princeton University Press, 1994.
9. Box G.E.P., Jenkins G.M., Reinsel G.C., Ljung G.M. *Time Series Analysis: Forecasting and Control*. – 5th ed. – Hoboken: John Wiley & Sons, 2015.
10. Hyndman R.J., Athanasopoulos G. *Forecasting: Principles and Practice*. – 3rd ed. – Melbourne: OTexts, 2021.
11. Cho K., Van Merriënboer B., Gulcehre C., et al. Learning Phrase Representations using RNN Encoder–Decoder for Statistical Machine Translation // *Proceedings of EMNLP*. – 2014.
12. Rumelhart D.E., Hinton G.E., Williams R.J. Learning Representations by Back-Propagating Errors // *Nature*. – 1986. – Vol. 323. – P. 533–536.
13. Kingma D.P., Ba J. Adam: A Method for Stochastic Optimization // *International Conference on Learning Representations (ICLR)*. – 2015.
14. Graves A. *Supervised Sequence Labelling with Recurrent Neural Networks*. – Berlin: Springer, 2012.
15. Brownlee J. *Deep Learning for Time Series Forecasting*. – Machine Learning Mastery, 2018.
16. Makridakis S., Spiliotis E., Assimakopoulos V. Statistical and Machine Learning Forecasting Methods: Concerns and Ways Forward // *PLoS ONE*. – 2018. – Vol. 13. – No. 3.
17. Oreshkin B.N., Carpov D., Chapados N., Bengio Y. N-BEATS: Neural Basis Expansion Analysis for Interpretable Time Series Forecasting // *ICLR*. – 2020.
18. Stanford Institute for Human-Centered Artificial Intelligence. *AI Index Report 2024*. – Stanford University, 2024.
19. McKinsey & Company. *The State of AI 2024*. – McKinsey Global Institute, 2024.



20. Molnar C. *Interpretable Machine Learning*. – 2nd ed. – Munich, 2022.
21. O‘zbekiston Respublikasi Prezidentining 2021-yil 17-fevraldagi PQ–4996-son “Sun’iy intellekt texnologiyalarini jadal joriy etish uchun shart-sharoitlar yaratish chora-tadbirlari to‘g‘risida”gi Qarori.
22. O‘zbekiston Respublikasi Prezidentining 2024-yil 14-oktabrdagi PQ–358-son “Sun’iy intellekt texnologiyalarini 2030-yilgacha rivojlantirish strategiyasini tasdiqlash to‘g‘risida”gi Qarori.
23. Bekmurodov U., Absalamova D., Absalamova G. Artificial Intelligence Models in Economic Forecasting: Evidence from Uzbekistan // *Digital Economy Research Journal*. – 2023.
24. Hamidova F.P., Ahmedov R.M. Sun’iy intellekt asosida iqtisodiy ko‘rsatkichlarni prognozlash usullari // *Iqtisodiyot va innovatsion texnologiyalar*. – 2023.
25. Kazarinova E.B. Application of LSTM and GRU Models in Macroeconomic Forecasting // *Economic Systems Research*. – 2025.