

## LSTM TARMOQLARINING MOHIYATI VA MOLIYAVIY PROGNOZLASHDAGI AHAMIYATI

*Umarov Bekzod Azizovich*

*Farg‘ona davlat universiteti amaliy matematika va informatika*

*kafedrasi o‘qituvchisi*

*[ubaumarov@mail.ru](mailto:ubaumarov@mail.ru)*

*Ro‘zimatov Jasurbek Islomjon o‘g‘li*

*Farg‘ona davlat universiteti talabasi*

*[rozimatovjasurbek18@gmail.com](mailto:rozimatovjasurbek18@gmail.com)*

### Аннотация

Ushbu maqolada LSTM (Long Short-Term Memory) tarmoqlarining mohiyati va ularning moliyaviy prognozlashdagi qo‘llanilishi haqida tushuncha berilgan. LSTM tarmoqlarining vaqt bo‘yicha ketma-ketlikdagi ma’lumotlarni samarali qayta ishlash xususiyati moliyaviy prognozlashda yuqori natijadorlikka ega ekanligi tahlil qilinadi. Shuningdek, bu tarmoqlarning imkoniyatlari va cheklovlari ham ko‘rib chiqiladi.

**Kalit so‘zlar:** LSTM, moliyaviy prognozlash, vaqt seriyalari, uzoq muddatli xotira, sun‘iy neyron tarmoq, deep learning, ketma-ketlik, overfitting, real vaqtli prognozlash, hybrid model

### Annotation

This article provides an understanding of the nature of LSTM (Long Short-Term Memory) networks and their application in financial forecasting. It is analyzed that the feature of efficient processing of time series data of LSTM networks has high efficiency in financial forecasting. The possibilities and limitations of these networks are also discussed.

**Key words:** LSTM, financial forecasting, time series, long-term memory, artificial neural network, deep learning, sequence, overfitting, real-time forecasting, hybrid model

### Аннотация

Эта статья дает представление о природе сетей LSTM (длинной краткосрочной памяти) и их применении в финансовом прогнозировании. Проанализировано, что особенность эффективной обработки данных временных рядов сетей LSTM обладает высокой эффективностью при финансовом прогнозировании. Также обсуждаются возможности и ограничения этих сетей.

**Ключевые слова:** LSTM, финансовое прогнозирование, временные ряды, долговременная память, искусственная нейронная сеть, глубокое обучение, последовательность, переобучение, прогнозирование в реальном времени, гибридная модель.

## Kirish

LSTM (Long Short-Term Memory) tarmoqlari vaqt bo'yicha ketma-ketlikka ega bo'lgan ma'lumotlarni qayta ishlash uchun sun'iy neyron tarmoq turi sifatida keng qo'llaniladi. Ularning arxitekturasi 1997-yilda Hochreiter va Schmidhuber tomonidan taklif etilgan bo'lib, an'anaviy RNN (Recurrent Neural Network) tarmoqlarining muhim kamchiliklarini bartaraf etish uchun ishlab chiqilgan. Asosan, LSTM tarmoqlari uzoq muddatli ketma-ketlikni eslash va qayta ishlash imkoniyatini beradi, bu esa vaqt seriyalari prognozlash, tabiiy tilni qayta ishlash (NLP) va boshqalar uchun nihoyatda foydali. Ularning asosi bu ma'lumotlarni o'zlarining ichki xotirasida saqlash va bu xotirani keyingi bosqichlarga o'z vaqtida uzatishda yotadi.

LSTM tarmoqlarining asosiy xususiyati ular o'rganayotgan ma'lumotlarning vaqtga bog'liq elementlarini eslab qolish qobiliyatidir. Ular qator davr mobaynida ketma-ket kiritilgan ma'lumotlar asosida uzoq muddatli va qisqa muddatli xotira hosil qilishadi. Asosiy ish jarayonida har bir ketma-ketlik elementiga nisbatan quyidagi uchta jarayon amalga oshadi:

- **Unutilish eshigi** (Forget Gate): Bu eshik hujayra xotirasidagi avvalgi ma'lumotning qanchalik saqlanishini yoki unutilishini belgilaydi.
- **Kirish eshigi** (Input Gate): Ushbu eshik yangi ma'lumotni kirish xotirasiga kiritish yoki o'tkazmaslikka qaror qiladi.
- **Chiqish eshigi** (Output Gate): Bu eshik qayta ishlangan xotirani natija sifatida chiqishda namoyish etish uchun qanday qiymatlarni chiqarishni belgilaydi.

Har bir eshik uchun matematik hisoblar aktivatsiya funksiyalari yordamida amalga oshiriladi. Bu eshiklar LSTM hujayralarining ichki holatini moslashtirish va ma'lumotni optimal boshqarish imkonini beradi.

LSTM tarmoqlari bilan an'anaviy RNN tarmoqlari o'rtasidagi asosiy farq — vaqt bo'yicha uzoq muddatli bog'liqlikni eslash qobiliyatidir. An'anaviy RNN tarmoqlari ham vaqt bo'yicha ketma-ketlikka ega ma'lumotlar bilan ishlay oladi, lekin ular uzoq muddatli bog'lanishlarni eslab qolishda qiynaladi. Bu cheklov "gradientning yo'qolishi" (vanishing gradient) deb ataluvchi muammo tufayli yuzaga keladi, bu esa uzoq davrlardagi ketma-ketlikdagi aloqalarni eslashni deyarli imkonsiz qiladi.

LSTM tarmoqlari esa bu muammoni ichki hujayra tuzilmasi va eshiklar tizimi orqali hal qiladi. Ular o'zlarining xotira hujayralarida ma'lumotni saqlash orqali uzoq muddatli ketma-ketliklar bilan samarali ishlay oladi. Shu sababli, LSTM tarmoqlari uzoq muddatli vaqt ketma-ketliklarini eslab qolishda ko'proq samaradorlikka ega.

LSTM tarmoqlarining muvaffaqiyatini ta'minlaydigan asosiy xususiyatlar quyidagilardir:

<b>Uzoq muddatli xotira</b>	LSTM tarmoqlari uzoq vaqt davomida kelgan ketma-ket ma'lumotni eslab qolish qobiliyatiga ega.
<b>Gradient yo'qolishi muammosini kamaytirish</b>	Ularning ichki strukturalari gradientni uzoq vaqt davomida saqlab qolishga yordam beradi, bu esa ketma-ketliklarga o'rganishni samarali qiladi.
<b>Moslashuvchanlik</b>	LSTM tarmoqlari tabiatiga ko'ra, vaqt bo'yicha o'zgaruvchan ma'lumotlar bilan moslashuvchan ishlay oladi, masalan, tabiiy tilni qayta ishlash va moliyaviy prognozlashda.
<b>Barcha turdagi ketma-ketlik ma'lumotlarga mos</b>	LSTM tarmoqlari bir vaqtning o'zida o'rganilgan qisqa va uzoq muddatli xotiralarni birlashtirgan holda ishlaydi, bu esa turli turdagi ketma-ketliklarga nisbatan kuchli yondashuvni yaratadi.

LSTM tarmoqlarining ana shunday o'ziga xosligi ularni moliyaviy prognozlash kabi kompleks vazifalar uchun ideal qiladi.

### LSTM tarmoqlarining arxitekturasi

LSTM tarmoqlarining arxitekturasi murakkab hisoblanadi, chunki ularning asosiy vazifasi ketma-ketlikdagi uzoq muddatli bog'liqliklarni saqlab qolishdir. LSTM arxitekturasi RNN tarmog'idan farqli o'laroq, xotira hujayralari va bir nechta eshiklarni o'z ichiga oladi. Har bir LSTM hujayrasi ichida "hujayra holati" va uchta asosiy eshik mavjud: **kirish eshigi**, **unutilish eshigi**, va **chiqish eshigi**. Ushbu komponentlar LSTM hujayrasining kelgan ma'lumotni qanday saqlashi yoki unutishi va natijani qanday chiqarishini belgilaydi.

#### 1. Hujayra holati (Cell State)

Hujayra holati LSTM arxitekturasidagi eng asosiy komponent hisoblanadi. Bu holat vaqt bo'yicha ketma-ketlikdagi asosiy xotirani ifodalaydi va har bir ketma-ket o'zgarishda moslashib boradi. Hujayra holati o'zini axborot oqimi kabi tutadi, va unga kiritilgan ma'lumot vaqt o'tishi bilan unutilish yoki yangilanish orqali modifikatsiyalanadi. Hujayra holati yangi ma'lumot va oldingi xotiraga moslashgan holda, vaqt bo'yicha ketma-ketlikdagi uzluksiz bog'liqlikni saqlab turadi.

#### 2. Unutilish eshigi (Forget Gate)

Unutilish eshigi LSTM hujayrasining eng asosiy qismidir. Bu eshik orqali hujayra xotirasidan qaysi ma'lumot unutilishi yoki saqlanishi kerakligi belgilanadi. Har bir ketma-ketlik elementi kirganda, unutilish eshigi kirish va chiqish qiymatlaridan foydalanib, o'tgan davrlardagi ma'lumotlarni qanchalik saqlashni hisoblab chiqadi. Unutilish eshigi quyidagi matematik operatsiyalar orqali ishlaydi:

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

Bu yerda,  $f_t$  - unutilish eshigining chiqishi,  $\sigma$  - sigmoid funksiya,  $W_f$  va  $b_f$  - og'irlik va offset parametrlari,  $h_{t-1}$  va  $x_t$  - oldingi va hozirgi davr qiymatlari. Sigmoid funksiya orqali chiqarilgan qiymat (0 dan 1 gacha) unutilish darajasini belgilaydi.

### 3. Kirish eshigi (Input Gate)

Kirish eshigi yangi ma'lumotning hujayra xotirasiga kirish darajasini boshqaradi. Bu eshik ketma-ketlikdagi kirgan yangi qiymatning qanchalik darajada saqlanishi yoki hujayra holatiga ta'sir qilishini aniqlaydi. Kirish eshigi quyidagicha ishlaydi:

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

Bu yerda,  $i_t$  - kirish eshigining chiqishi,  $W_i$  va  $b_i$  - og'irlik va offset parametrlari. Ushbu eshik orqali yangi ma'lumotning hujayra holatiga qanday ta'sir qilishini boshqarish mumkin.

Bundan tashqari, yangi nomzod xotira  $\tilde{C}_t$  ni yaratiladi:

$$\tilde{C}_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c)$$

Shu orqali kirish eshigi va yangi nomzod xotira birgalikda ishlaydi.

### 4. Chiqish eshigi (Output Gate)

Chiqish eshigi hujayra xotirasidagi ma'lumotning qaysi qismi keyingi qatlamlarga chiqishi kerakligini aniqlaydi. Bu eshik orqali qayta ishlangan ma'lumot natijasi olingan holda, vaqt bo'yicha ketma-ketlik davomida foydalaniladi. Chiqish eshigi quyidagicha ishlaydi:

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o)$$

Bu yerda,  $o_t$  - chiqish eshigining qiymati,  $W_o$  va  $b_o$  - og'irlik va offset parametrlari. Chiqish eshigi orqali hujayra holati va kirish ma'lumotlari kombinatsiyalanib, umumiy natija hosil qilinadi.

Yakuniy chiqish qiymati:

$$h_t = o_t \cdot \tanh(C_t)$$

Bu yerda,  $h_t$  - vaqt bo'yicha olingan natija.

LSTM tarmoqlarida ushbu uch eshik va hujayra holati orasidagi o'zaro bog'liqlik orqali ketma-ketlikdagi ma'lumotlarni saqlash yoki chiqarish boshqariladi. Har bir eshik o'ziga xos vazifani bajaradi va ketma-ketlik davomida ma'lumotning qay darajada unutilishi, qaysi qismi yangi ma'lumot bilan yangilanishi va qanday natija

chiqarilishi kabi vazifalarni belgilaydi. Shu orqali LSTM tarmoqlari ketma-ketlikdagi uzoq muddatli bog‘liqlikni saqlab, uzoq davom etuvchi ketma-ket ma’lumotlar uchun samarali prognozlash imkoniyatini yaratadi.

LSTM tarmoqlari vaqt bo‘yicha o‘zgaruvchan va ketma-ket ma’lumotlar bilan ishlash uchun juda qulay arxitekturaga ega. Ayniqsa, moliyaviy prognozlash sohasida bu tarmoqlar vaqt seriyalari, aksiyalar narxlari, valyuta kurslari va boshqa ketma-ketlikka ega ma’lumotlarni bashorat qilish uchun samarali hisoblanadi. Moliyaviy ma’lumotlarning o‘ziga xos xususiyatlaridan biri - bu ma’lumotlarning vaqt o‘tishi bilan ketma-ket bog‘liqligidir, ya’ni, o‘tgan davrlardagi ma’lumot kelgusi davrni prognozlash uchun muhim hisoblanadi. LSTM tarmoqlari ana shu bog‘liqliklarni saqlashda katta imkoniyatlar yaratadi.

Moliyaviy ma’lumotlar doimiy ravishda o‘zgarib turadi, va bu o‘zgarishlar bir-biriga bog‘liq. Masalan, aksiyalar narxi bir kun ichida bir necha marta o‘zgarishi mumkin, va bu o‘zgarishlar oldingi holatlarning natijasi sifatida shakllanadi. An’anaviy neyron tarmoqlar va RNNlar uzoq muddatli bog‘liqlikni saqlay olmagani uchun moliyaviy prognozlashda muvaffaqiyatsizlikka uchrashi mumkin. LSTM tarmoqlari esa unutilish va kirish eshiklari orqali uzoq muddatli bog‘liqliklarni samarali saqlab, vaqt bo‘yicha ketma-ket ma’lumotlarni tushunish va qayta ishlash imkonini beradi.

LSTM tarmoqlari quyidagi afzalliklari bilan moliyaviy prognozlash uchun yaroqli:

<b>Vaqt seriyalarining uzoq muddatli bog‘liqligini eslab qolish</b>	LSTM tarmoqlari uzoq muddat davomida o‘zgarib kelayotgan narxlar va ularning vaqt bo‘yicha ketma-ket o‘zgaruvchanligini saqlay oladi.
<b>Dinamik o‘zgarishlarga tez moslashish</b>	Moliyaviy bozorlar tez-tez o‘zgaradi. LSTM tarmoqlari ketma-ket ma’lumotni qayta ishlash imkoniyati bilan ushbu o‘zgarishlarga dinamik tarzda moslasha oladi.
<b>Progressiv tahlil</b>	Bu tarmoqlar uzoq muddatli ma’lumotlarni saqlagan holda, har bir yangi ma’lumotni ketma-ket ishlatish orqali prognozlashni takomillashtiradi. Bu esa vaqt bo‘yicha rivojlanayotgan hodisalarning o‘zgarishlarini tahlil qilish imkonini beradi.

LSTM tarmoqlarining asosiy afzalliklaridan biri – uzoq muddatli xotira bilan ishlash qobiliyatidir. Moliyaviy prognozlashda ma'lumotlarning uzoq muddat davomida saqlanishi katta ahamiyatga ega, chunki aksiyalar narxi yoki valyuta kursi kabi vaqt seriyalari avvalgi ma'lumotlar asosida shakllanadi va bashorat qilinadi. LSTM tarmoqlaridagi hujayra holati vaqt o'tishi bilan muhim ma'lumotlarni saqlab qoladi va zarur bo'lganida ularni chiqaradi. Masalan:

- **Aksiyalar narxini bashorat qilishda:** Oldingi kunlar, oylar yoki hatto yillar davomida yig'ilgan ma'lumotlarni LSTM tarmoqlari uzoq muddatli xotirada saqlaydi. Bu esa narxning mavsumiy o'zgarishlari, uzoq muddatli trendlar va vaqt davomida yuzaga kelgan boshqa muhim bog'liqliklarni tushunishga imkon beradi.
- **Valyuta kurslari va inflyatsiya ko'rsatkichlarini prognozlashda:** Moliyaviy tizimlar uchun LSTM tarmoqlari vaqt davomida to'plangan katta miqdordagi tarixiy ma'lumotlarni tahlil qilib, kelajakdagi kurs o'zgarishlarini bashorat qilish imkonini beradi.

LSTM tarmoqlari uzoq muddatli va qisqa muddatli bog'liqliklarni birgalikda saqlay olgani sababli, moliyaviy prognozlashni samarali qiladi. Bu prognozlash jarayonida LSTM tarmoqlari nafaqat hozirgi ketma-ketlikdagi ma'lumotlarga, balki oldingi davrlar ma'lumotlariga ham asoslanib, bashorat qilish imkonini beradi.

Moliyaviy prognozlashda LSTM tarmoqlarining ushbu imkoniyatlari quyidagicha namoyon bo'ladi:

<b>Narxlar trendini oldindan bilish</b>	LSTM tarmoqlari vaqt seriyalarini analiz qilish orqali yuqori va past ko'rsatkichlarni oldindan bilib olishga yordam beradi.
<b>Prognozlashning aniqligi</b>	Ketma-ketlikdagi uzoq muddatli bog'lanishni eslab qolish bilan LSTM tarmoqlari moliyaviy prognozlash natijalarini ancha aniqroq qilishga imkon yaratadi.
<b>Xavfni kamaytirish</b>	Bozor o'zgarishlarini oldindan bilish imkoniyati investorlar va kompaniyalarga xavfni kamaytirish va to'g'ri qarorlar qabul qilishda yordam beradi.

Shunday qilib, LSTM tarmoqlari moliyaviy prognozlash jarayonida vaqt bo'yicha o'zgaruvchan va ketma-ket bog'langan ma'lumotlar bilan ishlash imkoniyatlarini oshiradi. Ular uzoq muddatli xotira orqali tarixiy ma'lumotlarni eslab

qoladi va natijalarni prognozlashni yanada samarali qiladi, bu esa moliyaviy qaror qabul qilish jarayonida katta ahamiyat kasb etadi.

LSTM tarmoqlarini moliyaviy prognozlash uchun qo'llashda ma'lumotlarni tayyorlash va o'rgatish jarayoni juda muhimdir. Ma'lumotlar to'plami LSTM tarmog'ining aniqligi va samaradorligiga katta ta'sir ko'rsatadi, chunki ketma-ketlikdagi ma'lumotlar aynan vaqt bo'yicha o'zgaruvchan hodisalarning xususiyatlarini ochib beradi. LSTM tarmog'ini muvaffaqiyatli o'rgatish uchun quyidagi bosqichlarni ko'rib chiqish mumkin:

### 1. Ma'lumotlarni tayyorlash

Moliyaviy prognozlash uchun ishlatiladigan ma'lumotlar odatda vaqt seriyalari ko'rinishida bo'ladi. Ushbu ma'lumotlarni LSTM tarmog'iga moslash uchun bir nechta muhim tayyorlash bosqichlarini o'tkazish zarur:

- **Ma'lumotlarni yig'ish va tanlash:** Aksiyalar narxlari, valyuta kurslari, inflyatsiya darajasi yoki boshqa moliyaviy ko'rsatkichlar ma'lumotlarini to'plash. Ushbu ma'lumotlar ketma-ketlikdagi o'zgarishlarni aks ettirishi va tahlil qilish imkoniyatini yaratishi kerak.
- **Ma'lumotlarni tozalash:** Moliyaviy ma'lumotlarda odatda yo'qolgan yoki noto'g'ri qiymatlar uchraydi. Bu qiymatlarni to'ldirish yoki tozalash LSTM tarmog'ining samaradorligi uchun muhim.
- **Ma'lumotlarni masshtablash (normallashtirish):** Ma'lumotlarni standart diapazonga (masalan,  $[0, 1]$  yoki  $[-1, 1]$ ) kiritish LSTM tarmoqlari uchun foydali bo'ladi. Bu ma'lumotlarni qayta ishlash va tarmoqni tezroq va barqaror o'rganishga yordam beradi.

### 2. Ma'lumotlar to'plamini tanlash va bo'lish

LSTM tarmog'ini o'rgatishda ma'lumotlar to'plamini bir necha qismga ajratish zarur. Asosan, ma'lumotlar quyidagi to'plamlarga bo'linadi:

- **O'qitish to'plami:** Bu to'plam tarmoqni o'rgatish uchun ishlatiladi. Odatda, mavjud ma'lumotlarning 70-80% qismini tashkil etadi.
- **Sinov to'plami:** O'rgatish jarayonidan so'ng tarmoqning umumiylik baholash qobiliyatini baholash uchun ishlatiladi. Ma'lumotlarning qolgan 20-30% qismini tashkil etishi mumkin.
- **Validatsiya to'plami (ixtiyoriy):** O'qitish vaqtida parametrlarni tuzatish va tarmoqning overfittingdan saqlanishini ta'minlash uchun ishlatiladi.

### 3. LSTM tarmog'ini o'rgatish

LSTM tarmog'ini o'rgatish uchun uning arxitekturasi va parametrlarini moslash kerak. Moliyaviy ma'lumotlar uchun quyidagi parametrlar tarmoqning optimal ishlashiga ta'sir ko'rsatadi:

- **Eshiklar soni:** Hujayralarning ichki eshiklari orqali o'tkaziladigan ketma-ketlik va qachon unutilishi kerakligini belgilash.

- **Epochlar:** Bu o‘qitish sikllari sonini ifodalaydi. Ko‘proq epochlar tarmoqni chuqurroq o‘rgatadi, lekin overfitting xavfini ham oshirishi mumkin.
- **Batch hajmi:** Ma’lumotlarni qayta ishlashda qancha elementni bir vaqtda ishlatishni belgilaydi.

LSTM tarmoqlarining o‘qitish jarayonida har bir epoch davomida yo‘qotish funksiyasi baholanadi va har safar yangilangan og‘irliklar bilan tarmoqni takomillashtirish maqsadida gradient bo‘yicha tushish (gradient descent) algoritmi qo‘llanadi.

#### 4. Modelni baholash va sinovdan o‘tkazish

Modelni baholash jarayoni sinov to‘plamiga asoslangan holda amalga oshiriladi. Baholash jarayonida LSTM modelining prognozlashdagi aniqligi tekshiriladi va modelning umumiy natijadorligi haqida tushuncha beradi. Baholash uchun qo‘llaniladigan ko‘rsatkichlar quyidagilardan iborat:

- **Yo‘qotish funksiyasi (Loss Function):** Bu funksiya modelning har bir prognozidagi xatoni ko‘rsatadi. MSE (Mean Squared Error) yoki MAE (Mean Absolute Error) kabi yo‘qotish funksiyalari odatda vaqt seriyali ma’lumotlar uchun qo‘llaniladi.
- **Prognoz aniqligi:** Sinov ma’lumotlari asosida haqiqiy va prognozlangan qiymatlar o‘rtasidagi aniqlikni o‘lchash. Model qanchalik aniq prognoz bersa, shunchalik samarador hisoblanadi.

#### 5. Modelni tahlil qilish va hozirgi vaziyatga moslashtirish

LSTM modeli tayyor bo‘lgach, uni haqiqiy sharoitlarda foydalanishga va bozor o‘zgarishlariga moslashishga tayyorlash kerak. Modellarning yangilanib turishi va bozor sharoitlariga moslashuvi uchun LSTM tarmoqlarini vaqt o‘tishi bilan qayta o‘rgatish lozim bo‘ladi. Bu jarayon yangi ma’lumotlarni qo‘shish orqali amalga oshiriladi.

LSTM tarmoqlarini o‘rgatish va sinovdan o‘tkazish orqali moliyaviy prognozlash jarayonini yanada aniq va samarali qilish mumkin.

#### Xulosa

LSTM tarmoqlari moliyaviy prognozlashda katta imkoniyatlar yaratadi, chunki ular vaqt bo‘yicha ketma-ketlikda kelgan ma’lumotlarni samarali qayta ishlay oladi. Bu tarmoqlar uzoq muddatli va qisqa muddatli xotiralarni birlashtirgan holda, aksiyalar narxлари, valyuta kurslari va boshqa moliyaviy ko‘rsatkichlarni bashorat qilishda yuqori aniqlikka ega natijalar berishi mumkin. Ushbu xususiyatlar moliyaviy sohadagi ko‘plab operatsiyalarni yanada samarali va xavfsizroq qilish imkoniyatini beradi. LSTM tarmoqlari moliyaviy qarorlarni qabul qilish jarayonini soddalashtirish, xavflarni kamaytirish va investitsiya prognozlarini yaxshilash kabi turli maqsadlarda keng qo‘llanmoqda.



LSTM tarmoqlari moliyaviy prognozlashda katta imkoniyatlarga ega bo‘lib, moliyaviy qaror qabul qilish jarayonlarini avtomatlashtirish va tezlashtirishga yordam beradi. Bu texnologiyaning rivojlanishi va yangi tadqiqotlar ushbu sohada yanada ko‘proq imkoniyatlar ochib beradi.

### Foydalanilgan Adabiyotlar

1. Hochreiter, S., & Schmidhuber, J. (1997). Long Short-Term Memory. *Neural Computation*, 9(8), 1735-1780.
2. Gers, F. A., Schmidhuber, J., & Cummins, F. (2000). Learning to forget: Continual prediction with LSTM. *Neural Computation*, 12(10), 2451-2471.
3. Graves, A. (2013). Generating sequences with recurrent neural networks. *arXiv preprint*, arXiv:1308.0850.
4. Siami-Namini, S., Tavakoli, N., & Siami Namin, A. (2018). The performance of LSTM and BiLSTM in forecasting time series. *Proceedings of the IEEE International Conference on Big Data*.
5. Fischer, T., & Krauss, C. (2018). Deep learning with long short-term memory networks for financial market predictions. *European Journal of Operational Research*, 270(2), 654-669.
6. Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep Learning*. MIT Press.
7. Brownlee, J. (2017). *Deep Learning for Time Series Forecasting: Predict the Future with MLPs, CNNs and LSTMs in Python*. Machine Learning Mastery.
8. Wu, Y., & Tan, H. (2016). Short-term load forecasting based on LSTM recurrent neural network. *IEEE International Conference on Control and Automation*.
9. Malhotra, P., Vig, L., Shroff, G., & Agarwal, P. (2015). Long short term memory networks for anomaly detection in time series. *Proceedings of the European Symposium on Artificial Neural Networks, Computational Intelligence and Machine Learning*.
10. Chung, J., Gulcehre, C., Cho, K., & Bengio, Y. (2014). Empirical evaluation of gated recurrent neural networks on sequence modeling. *arXiv preprint*, arXiv:1412.3555.