VAQTLI KETMA-KETLIKLAR BASHORATI UCHUN NEYRON TARMOQ MODELLARINING ARXITEKTURASINI OPTIMALLASHTIRISH

Abdullayeva Umida Farhadovna
E-mail: umidafarhadovna11_07g@mail.ru

Qabul qilindi: 30.09.2025
Ko‘rib chiqildi: 01.10.2025
Tasdiqlandi: 02.10.2025

Kalit so‘zlar:
neyron tarmoq, vaqtli ketma-ketlik, bashorat, LSTM, GRU, Transformer, arxitektura optimallashtirish, chuqur o‘rganish

Annotatsiya
Mazkur maqolada vaqtli ketma-ketliklar bashorati masalasi uchun neyron tarmoq modellari arxitekturasini optimallashtirish usullari ko‘rib chiqilgan. LSTM, GRU va Transformer kabi chuqur o‘rganishga asoslangan modellar samaradorligi tahlil qilinadi hamda bashorat aniqligini oshirishga qaratilgan arxitektura va parametrlar tanlovi bo‘yicha tavsiyalar beriladi. Eksperimental natijalar asosida optimal yondashuvlar aniqlanadi.

Kirish. Vaqtli ketma-ketliklar real hayotda keng uchraydigan ma’lumotlar toifasidir. Ular vaqt bo‘yicha tartiblangan kuzatuvlar yig‘indisini ifodalaydi. Masalan, moliya bozoridagi narxlar dinamikasi, ob-havo ko‘rsatkichlari, energetika tizimidagi yuklama yoki tibbiyotdagi biomarkerlar vaqtli ketma-ketliklar sirasiga kiradi. Bunday ma’lumotlarni bashorat qilish iqtisodiyot, sog‘liqni saqlash, iqlimshunoslik va boshqa ko‘plab sohalarda muhim ahamiyatga ega.
Sun’iy intellekt va neyron tarmoqlar yordamida bashoratlarning aniqligi sezilarli darajada oshirilishi mumkin.

An’anaviy statistik yondashuvlarda ARIMA, ETS kabi modellardan foydalaniladi. Ular qisqa muddatli prognozlarda samarali bo‘lishi mumkin, ammo murakkab va nolinear jarayonlarni yaxshi ifodalay olmaydi. Mashinaviy o‘rganish modellari regressiya va ansambl usullarini qo‘llaydi, lekin vaqtli bog‘lanishlarni chuqur o‘rganishda cheklangan. Chuqur o‘rganish modellari esa (RNN, LSTM, GRU) vaqt bo‘yicha murakkab naqshlarni o‘rganishda yuqori samaradorlik ko‘rsatadi.

Oddiy RNN modellari vaqtli ketma-ketliklarni qayta ishlashga imkon beradi, ammo uzoq muddatli bog‘lanishlarni eslab qolishda qiyinchiliklarga duch keladi.
Shu sababli LSTM (Long Short-Term Memory) va GRU (Gated Recurrent Unit)

arxitekturalari ishlab chiqilgan bo‘lib, ular uzoq muddatli xotira bilan ishlashda samaraliroq.

CNN (Konvolyutsion neyron tarmoqlar) ham vaqtli ketma-ketliklarni segmentlarga bo‘lib o‘rganishda qo‘llaniladi.

So‘nggi yillarda Transformer arxitekturalari ham mashhurlashib, murakkab ketma-ketliklarni bashorat qilishda yuqori natija ko‘rsatmoqda.

Materiallar va metodlar. Ushbu tadqiqotda vaqtli ketma-ketliklarni bashorat qilish uchun chuqur o‘rganishga asoslangan neyron tarmoq modellarining samaradorligini tahlil qilish va ularning arxitekturasini optimallashtirish maqsad qilingan. Asosiy e’tibor LSTM (Long Short-Term Memory), GRU (Gated Recurrent Unit) va Transformer arxitekturalariga qaratildi.

Tajribalarda foydalanilgan ma’lumotlar to‘plami sifatida real vaqtda to‘plangan vaqtli ketma-ketlik ma’lumotlari tanlandi (masalan, iqlim, moliyaviy yoki ishlab chiqarish ko‘rsatkichlari). Ma’lumotlar normalizatsiya qilindi va modelga mos formatda tayyorlandi. Har bir model uchun qatlamlar soni, neyronlar soni, faollashtirish funksiyalari (ReLU, tanh) va chiqish qatlamlari moslashtirildi. Hiperparametrlarni optimallashtirish uchun grid search va random search usullari qo‘llanildi.

Modellar 70% trening va 30% test to‘plamlari asosida o‘rgatildi. Optimizatsiya uchun Adam algoritmi ishlatildi, yo‘qotish funksiyasi sifatida esa MSE (Mean Squared Error) tanlandi. Model natijalari MAE (Mean Absolute Error), RMSE (Root Mean Squared Error) va R^2 (Determination Coefficient) mezonlari orqali baholandi. Modellar orasida solishtirma tahlil olib borildi.

Neyron tarmoqlar samaradorligini oshirish uchun arxitekturani optimallashtirish zarur. Bunda giperparametrlarni (learning rate, batch size, qatlamlar soni) to‘g‘ri tanlash katta rol o‘ynaydi. Overfittingning oldini olish uchun Dropout, L2 normallashtirish kabi regularizatsiya usullari qo‘llaniladi. Shuningdek, model murakkabligi va hisoblash samaradorligini muvozanatlash muhim. So‘nggi yondashuvlardan biri AutoML va Neyron arxitektura qidiruvi (NAS) bo‘lib, ular avtomatik tarzda eng yaxshi model tuzilishini topishga yordam beradi. Vaqtli ketma-ketliklarni bashorat qilishning amaliy qo‘llanmalari juda keng.

Moliyaviy bozorlarni bashorat qilishda neyron tarmoqlar aksiyalar narxini oldindan aniqlash uchun ishlatiladi.

Tadqiqot natijalari va muhokama. Ushbu tadqiqotda LSTM, GRU va Transformer modellarining vaqtli ketma-ketliklar (time series) bilan ishlashdagi samaradorligi sinovdan o‘tkazildi. Modellarning har biri turli parametrlar va

arxitektura konfiguratsiyalarida o‘rganilib, ularning bashorat aniqligi va hisoblash samaradorligi tahlil qilindi. Tajriba natijalari shuni ko‘rsatdiki, Transformer modeli murakkab arxitekturaga ega bo‘lishiga qaramay, uzoq muddatli bog‘liqliklarni aniqlashda yuqori aniqlik namoyon etdi. Biroq, u hisoblash resurslariga yuqori talab qo‘ydi va trening vaqti boshqa modellar bilan solishtirganda ancha uzoq bo‘ldi.

LSTM modeli barqaror va izchil natijalarni ko‘rsatdi, ayniqsa, o‘rta uzunlikdagi ketma-ketliklarda. GRU modeli esa LSTM ga nisbatan tezroq o‘qitildi va ba’zi hollarda o‘xshash bashorat aniqligiga erishdi, bu esa uni hisoblash resurslari cheklangan tizimlar uchun qulay qiladi.

Shuningdek, modellar uchun tanlangan giperparametrlar (qatlamlar soni, neyronlar soni, o‘rganish tezligi va boshqalar) bashorat natijalariga sezilarli ta’sir ko‘rsatdi. Grid search va random search usullari orqali optimal parametrlar aniqlandi. Baholash mezonlari sifatida MAE, RMSE va R^2 ko‘rsatkichlari asosida o‘tkazilgan tahlil modellar o‘rtasidagi farqlarni aniq ko‘rsatdi. Natijalar shuni ko‘rsatdiki, har bir modelning samaradorligi ma’lumotlar to‘plamining tabiati va ketma-ketlikdagi o‘zgarish darajasiga bog‘liq bo‘lib, “barcha holatlarga mos bitta universal model” mavjud emas.

Energiya tizimida yuklama prognozi ishlab chiqarishni samarali rejalashtirishga yordam beradi. Iqlimshunoslikda ob-havo bashoratlari va iqlim o‘zgarishlarini kuzatishda qo‘llaniladi. Shuningdek, sog‘liqni saqlashda bemorlarning sog‘liq ko‘rsatkichlarini tahlil qilish va kasalliklarni erta aniqlashda ham qo‘llaniladi.

Xulosa. Vaqtli ketma-ketliklarni bashorat qilish uchun neyron tarmoq arxitekturalarini optimallashtirish dolzarb ilmiy muammo hisoblanadi. To‘g‘ri tanlangan arxitektura va giperparametrlar prognozlarning aniqligini sezilarli oshiradi. Kelajakda AutoML va Transformer modellariga asoslangan yondashuvlar yanada keng qo‘llanishi kutilmoqda. Bu esa iqtisodiyotdan tortib sog‘liqni saqlashgacha bo‘lgan turli sohalarda samarali qarorlar qabul qilish imkonini beradi.

Foydalanilgan adabiyotlar ro’yxati

1. Hochreiter, S., & Schmidhuber, J. (1997). Long short-term memory. Neural Computation, 9(8), 1735–1780. https://doi.org/10.1162/neco.1997.9.8.1735
2. Cho, K., Van Merriënboer, B., Gulcehre, C., Bahdanau, D., Bougares, F., Schwenk, H., & Bengio, Y. (2014). Learning phrase representations using RNN encoder-decoder for statistical machine translation. arXiv preprint arXiv:1406.1078. https://arxiv.org/abs/1406.1078
3. Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. N., ... & Polosukhin, I. (2017). Attention is all you need. In Advances in

Neural Information Processing Systems (pp. 5998–6008). https://papers.nips.cc/paper_files/paper/2017/hash/3f5ee243547dee91fbd053c1c4a845aa-Abstract.html

4. Brownlee, J. (2018). Deep learning for time series forecasting: Predict the future with MLPs, CNNs and LSTMs in Python. Machine Learning Mastery.

5. Bergmeir, C., & Benítez, J. M. (2012). On the use of cross-validation for time series predictor evaluation. Information Sciences, 191, 192–213. https://doi.org/10.1016/j.ins.2011.12.028
6. Zhang, G., Eddy Patuwo, B., & Hu, M. Y. (1998). Forecasting with artificial neural networks: The state of the art. International Journal of Forecasting, 14(1), 35–62. https://doi.org/10.1016/S0169-2070(97)00044