UDK 621.311

SANOAT KOROXONALARINING KO‘P OMILLI KIRISH MA’LUMOTLARI ASOSIDA ELEKTR ENERGIYASI YUKLAMASINI LSTM ORQALI BASHORATLASH

K.Sh.Kadirov
O'zbekistor Respublikasi fanlar akademiyasi Energetika muammolari instituti
Farg‘ona davlat texnika universiteti
A.A To‘xtashev
O'zbekistor Respublikasi fanlar akademiyasi Energetika muammolari instituti
Farg‘ona davlat texnika universiteti
T. F.Musurmonov
O'zbekistor Respublikasi fanlar akademiyasi Energetika muammolari instituti
Farg‘ona davlat texnika universiteti

Annotatsiya: Ushbu maqolada sanoat korxonasining sutkalik elektr yuklamasini prognozlash (keyingi kun uchun) masalasi Long Short-Term Memory (LSTM) neyron tarmoqlari asosida tadqiq etildi. Tadqiqotda korxonaning bir yillik elektr energiyasi iste’moli bo‘yicha ma’lumotlar 30 daqiqalik vaqt intervalida shakllantirilib, ishlab chiqarishning texnologik va boshqaruv smenalari, tashqi havo harorati hamda elektr energiyasi iste’mol tariflarining vaqt bo‘yicha o‘zgarishi bilan birgalikda kiruvchi ko‘rsatkichlar sifatida qo‘llanildi. Prognozlash modeli Python dasturlash muhitida ishlab chiqilib, ikki qatlamli LSTM arxitekturasi asosida o‘qitildi. Tadqiqot natijalari LSTM modeli yuklamaning vaqt bo‘yicha dinamikasini va tig‘iz yuklama davrlarini yuqori aniqlikda bashorat qila olishini ko‘rsatdi. Olingan natijalar sanoat korxonalarida elektr energiyasi iste’molini rejalashtirish, tig‘iz davrlarda yuklamani boshqarish va raqamli energiya boshqaruvi tizimlarini joriy etishda amaliy ahamiyatga ega.

Kalit so‘zlar: Elektr yuklamasi prognozi, LSTM neyron tarmog‘i, sutkalik yuklama grafigi, vaqt qatorlari, energiya boshqaruvi, sanoat korxonasi, sun’iy intellekt, energiya samaradorligi

Аннотатция: В данной статье исследована проблема прогнозирования суточной нагрузки электроэнергии промышленного предприятия (на следующий день) на основе нейронных сетей с долговременной кратковременной памятью (LSTM). В исследовании использовались данные о годовом потреблении электроэнергии предприятия с 30-минутным интервалом, а в качестве входных показателей — технологические и управленческие изменения производства, температура наружного воздуха и изменения тарифов на электроэнергию во времени. Модель прогнозирования была разработана в среде программирования Python и обучена на основе

ISSN 3030-3907

двухслойной архитектуры LSTM. Результаты исследования показали, что модель LSTM может с высокой точностью прогнозировать динамику нагрузки во времени и пиковые периоды нагрузки. Полученные результаты имеют практическое значение при планировании потребления электроэнергии на промышленных предприятиях, управлении нагрузкой в пиковые периоды и внедрении цифровых систем управления энергопотреблением.

Ключевые слова: Прогнозирование электрической нагрузки, нейронная сеть LSTM, график суточной нагрузки, временные ряды, управление энергопотреблением, промышленное предприятие, искусственный интеллект, энергоэффективность

Abstract: In this article, the problem of forecasting the daily electricity load of an industrial enterprise (for the next day) was studied based on Long Short-Term Memory (LSTM) neural networks. In the study, data on the enterprise's annual electricity consumption were formed in a 30-minute time interval, and together with technological and management shifts of production, outdoor air temperature, and changes in electricity consumption tariffs over time were used as input indicators. The forecasting model was developed in the Python programming environment and trained based on a two-layer LSTM architecture. The results of the study showed that the LSTM model can predict the dynamics of the load over time and peak load periods with high accuracy. The results obtained are of practical importance in planning electricity consumption in industrial enterprises, managing load during peak periods, and implementing digital energy management systems.

Keywords: Electrical load forecasting, LSTM neural network, daily load graph, time series, energy management, industrial enterprise, artificial intelligence, energy efficiency

KIRISH.

Zamonaviy sanoat korxonalarida elektr energiyasi iste’molini samarali boshqarish, yuklama rejimlarini optimallashtirish hamda energiya resurslaridan oqilona foydalanish masalalari tobora dolzarb ahamiyat kasb etmoqda. Korxonalarning elektr yuklamasi vaqt bo‘yicha notekis taqsimlanishi, ishlab chiqarish jarayonlarining texnologik xususiyatlari, smenali ish rejimi hamda tashqi omillarga bog‘liqligi elektr ta’minoti tizimlarida rejalashtirish va boshqaruvni murakkablashtiradi. Shu sababli sutkalik yuklama grafigini oldindan aniq prognozlash energiya samaradorligini oshirish, elektr tarmoqlariga tushadigan maksimal yuklamalarni kamaytirish va ekspluatatsiya xarajatlarini optimallashtirishda muhim vosita hisoblanadi [1].

ISSN 3030-3907

An’anaviy statistik va regressiya asosidagi prognozlash usullari ko‘p hollarda elektr yuklamasining murakkab nolinear xususiyatlarini, uzoq muddatli vaqt bog‘liqliklarini hamda ko‘p sonli ta’sir etuvchi omillarni yetarli darajada hisobga ola olmaydi. So‘nggi yillarda sun’iy intellekt va chuqur o‘rganishga asoslangan algoritmlarning rivojlanishi vaqt qatorlarini tahlil qilish va bashoratlash sohasida yangi imkoniyatlarni ochib berdi. Xususan, Long Short-Term Memory (LSTM) neyron tarmoqlari vaqt bo‘yicha uzoq muddatli bog‘liqliklarni saqlab qolish va murakkab dinamik jarayonlarni modellashtirish qobiliyati tufayli elektr yuklamasini prognozlash masalalarida samarali yechim sifatida keng qo‘llanilmoqda [2].

Ushbu ilmiy maqolada sanoat korxonasining ertangi kunlik sutkalik elektr yuklamasini prognozlash masalasi LSTM asosida ko‘rib chiqiladi. Prognozlash aniqligini oshirish maqsadida modelga bir nechta muhim kiruvchi parametrlar kiritilgan. Jumladan, korxonaning bir yillik tarixiy elektr yuklamasi ma’lumotlari 30 daqiqalik vaqt intervalida shakllantirilgan bo‘lib, bu sutkalik yuklama dinamikasining real o‘zgarishini batafsil aks ettiradi. Bundan tashqari, ishlab chiqarish jarayonlarining texnologik xususiyatlari va boshqaruv smenalariga oid yillik ma’lumotlar hisobga olinib, yuklamaning ishlab chiqarish rejimlariga bog‘liqligi inobatga olingan.

Shuningdek, elektr yuklamasiga sezilarli ta’sir ko‘rsatuvchi tashqi omillardan biri sifatida tashqi havo haroratining mos vaqt intervallaridagi qiymatlari modelga kiritilgan. Bu, ayniqsa, isitish yoki sovitish tizimlari faol ishlatiladigan korxonalarda yuklama o‘zgarishlarini to‘g‘ri aks ettirish imkonini beradi. Elektr energiyasi iste’mol tariflarining vaqt bo‘yicha o‘zgarishi ham alohida parametr sifatida qaralib, tarif omilining yuklama shakllanishiga ta’siri baholanadi. Ushbu ko‘p omilli yondashuv LSTM modelining prognozlash imkoniyatlarini kengaytirishga xizmat qiladi.

Maqolada keltirilgan barcha kiruvchi ma’lumotlar Python dasturlash muhitida qayta ishlanib, LSTM neyron tarmog‘i asosida o‘qitiladi va natijada korxonaning ertangi sutkalik elektr yuklamasi bashorat qilinadi. Olingan prognoz natijalari elektr ta’minoti tizimlarini rejalashtirish, energiya menejmenti qarorlarini qabul qilish hamda yuklama cho‘qqilarini oldindan aniqlashda amaliy ahamiyatga ega. Tadqiqot natijalari sanoat korxonalarida raqamli energiya boshqaruvi tizimlarini joriy etish uchun metodik asos bo‘lib xizmat qilishi mumkin.

METODOLOGIYA. Ushbu tadqiqotda sanoat korxonasining ertangi kunlik sutkalik elektr yuklamasini prognozlash uchun chuqur o‘rganishga asoslangan Long Short-Term Memory (LSTM) neyron tarmog‘i modeli qo‘llanildi. Tadqiqot metodologiyasi bir necha ketma-ket bosqichlardan iborat bo‘lib, ular

ISSN 3030-3907

ma’lumotlarni tayyorlash, modelni shakllantirish, o‘qitish hamda prognoz natijalarini olish jarayonlarini qamrab oladi.

ASOSIY QISM. Korxonaning elektr energiyasi yuklamasini prognozlash samaradorligini optimallashtirish uchun oldindan ishlangan . Elektr energiyasi iste'moli haqidagi ma'lumotlar Hududiy elektr tarmiqlarining energiya nazarati va hisobining avtomatlashtirilgan tizimi tomonidan shakllantirildi. Ushbu olingan ma’lumotlar 2024-yil 1-sentyabrdan 2025-yil 31-avgustgacha bo‘lgan vaqt oralig‘ida 15 daqiqalik interval bilan qayd etilgan. Xom ma’lumotlar to‘plamida vaqt belgilari (yil, oy, kun, soat va 30 daqiqa) va mos keladigan quvvat sarfi qiymatlari mavjud edi.

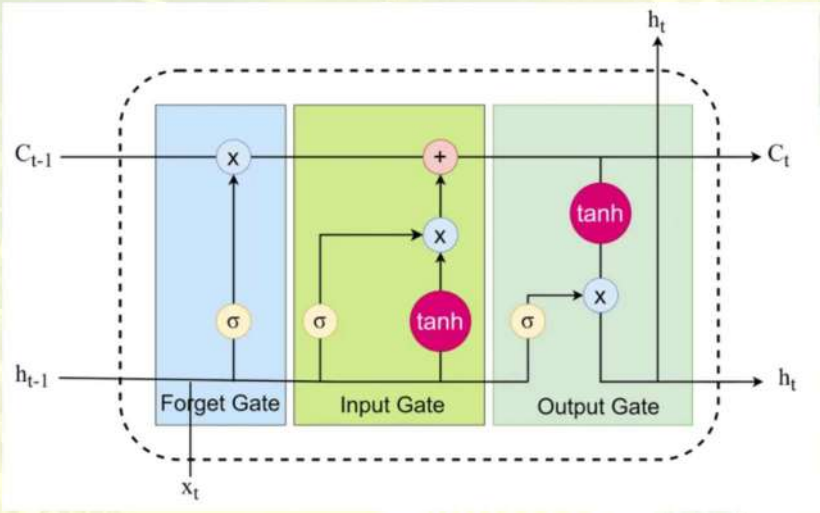
Bashorat qilishning aniqligini oshirish uchun quvvat sarfiga ta'sir qiluvchi qo'shimcha funktsiyalar kiritilgan. Bularga meteorologik o‘zgaruvchilar harorat, ish kuni dam olish kunlari ko‘rsatkichlari va korxonaning elektr energiyasi iste’mol tarifi to’lovining sutkalik vaqt intervalidagi o’zgarish indeksi ham kiradi. Shuningdek korxonaning quvvat sarfi qiymatlari o'rtasida chiziqli interpolyatsiya qo'llanildi. Ushbu usul ma'lumotlar uzluksizligini saqlaydi va qisqa vaqt oralig'ida bo'shliqlarni samarali boshqaradi, modelni o'qitish uchun ma'lumotlar to'plamining ishonchliligini ta'minlaydi. Bundan tashqari, vaqt seriyasi ma'lumotlarini model tomonidan samarali qayta ishlashni ta'minlash uchun slayd oynasi algoritmi qo'llanildi. Ushbu algoritm ma'lumotlar to'plamini 10 martalik qat'iy uzunligi bo'lgan ketma-ketliklarga qayta tuzib, hisoblash samaradorligini saqlab qolgan holda model uchun yetarli kontekstni ta'minladi.

LSTM ketma-ket ma'lumotlarni qayta ishlash uchun mo'ljallangan takrorlanuvchi neyron tarmoqlarining (RNN) rivojlangan variantidir, masalan, vaqt seriyali ma'lumotlar to'plami bunga misol bo’lishi mumkin.[3]. An'anaviy RNNlar kelajakdagi qiymatlarni bashorat qilish uchun o'tmishdagi ma'lumotlarga tayansa-da, ular uzoq muddatli bog'liqliklarni samarali qo'lga kiritish qobiliyatini cheklaydigan yo'qolib borayotgan gradient muammosidan aziyat chekmoqda [4]. LSTM vaqt o'tishi bilan ma'lumotni tanlab saqlaydigan yoki yo'qotadigan xotira hujayralarini o'z ichiga olgan holda ushbu cheklovni yengib chiqadi, bu esa modelga uzoq masofali bog'liqliklarni an'anaviy RNNlarga qaraganda samaraliroq o'rganish imkonini beradi [5].

LSTM tarmoqlari quyida 1-rasmda ko'rsatilganidek, axborot oqimini tartibga solish uchun uchta asosiy gatelardan (Eshiklardan) - input gate (kirish eshigi), forget gate (unutish eshigi) va output gate (chiqish eshigidan) foydalanadi. Kirish eshigi xotira yacheykasiga qancha yangi ma'lumot qo'shilishini nazorat qiladi, unutish eshigi esa oldingi hujayra holatidan qaysi ma'lumotlarni o'chirish kerakligini belgilaydi [6]. Chiqish eshigi joriy hujayra holatiga asoslangan oxirgi

ISSN 3030-3907

yashirin holatni yaratadi. Bu eshiklar sigmasimon faollashtirish funksiyalaridan *(σ)* 0 dan 1 gacha qiymatlarni hosil qilish uchun foydalanadi va shu bilan ma'lumot qay darajada saqlanishi yoki unutilishini nazorat qiladi. Bundan tashqari, giperbolik tangent funktsiyasi (tanh) xotira katakchasini yangilash uchun nomzod qiymatlarni yaratish uchun ishlatiladi [4, 7].



1-rasm. LSTM tarmog'ining tuzilishi, uchta asosiy eshikni ko'rsatadi: kirish eshigi, unutish eshigi va chiqish eshigi *(σ:* sigmasimon faollashtirish funktsiyasi, tanh: giperbolik tangens funksiyasi, x_t :vaqt bosqichida kirish, i_t: kirish eshigining chiqishi, f_t: unutish eshigining chiqishi, *ft* : unutish eshigi, $\widetilde{C_t}$: chiqish eshigining chiqishi va h_t: yashirin holat).

LSTM neyron tarmog‘i quyidagi asosiy bosqichlar orqali ishlaydi [4, 8].

Forget gate (unutish darvozasi)

Oldingi xotira holati C_{t-1} dan qanchalik ma’lumot saqlab qolinishini aniqlaydi. Bu jarayon oldingi yashirin holat h_{t-1} va joriy kirish signali x_t asosida amalga oshiriladi:

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

Input gate (kiritish darvozasi)

Xotira hujayrasiga qancha yangi ma’lumot qo‘shilishini belgilaydi:

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (2)$$

Candidate cell state (nomzod xotira holati)

Giperbolik tangens funksiyasi yordamida yangi xotira holati uchun nomzod qiymat hisoblanadi:

$$\tilde{C}_t = \tanh\left(W_c \cdot [h_{t-1}, x_t] + b_c\right) \quad (3)$$

Memory cell update (xotira holatini yangilash)

Unutish darvozasi natijasi va yangi nomzod qiymat kombinatsiyasi orqali xotira holati yangilanadi:

$$C_t = f_t \cdot C_{t-1} + i_t \cdot \tilde{C}_t \quad (4)$$

ISSN 3030-3907

Output gate (chiqish darvozasi)

Yangilangan xotira holati asosida yakuniy yashirin holat h_t aniqlanadi:

Yangilangan xotira holati asosida yakuniy yashirin holat h_t aniqlanadi:

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (5)$$

$$h_t = o_t \cdot \tanh(C_t) \quad (6)$$

Yuqoridagi tenglamalarda har bir b mos keladigan eshik yoki hujayra holati uchun noaniq atamani ifodalaydi (masalan, b_f unutish eshigi uchun, b_i kirish eshigi uchun, b_C nomzod katak holati uchun va b_o chiqish eshigi uchun). Ushbu jarayon har bir vaqt bosqichida takrorlanadi, bu LSTM ga ketma-ket ma'lumotlarda uzoq muddatli bog'liqliklarni samarali qo'lga kiritish imkonini beradi.

Vaqt seriyali ma'lumotlarda quvvat sarfini bashorat qilish muammolarini hal qilish uchun moslashtirilgan LSTM modeli ishlab chiqilgan va amalga oshirilgan. Ushbu model ko'p o'lchovli kirish xususiyatlarini qayta ishlash va qisqa muddatli va uzoq muddatli bog'liqliklarni o'rganish orqali aniq bashoratlarni yaratish uchun mo'ljallangan.

Har bir kirish ketma-ketligi 10 ta ketma-ket vaqt qadamlarini o'z ichiga oladi, har bir vaqt bosqichida 14 xususiyat, jumladan:

- Vaqtinchalik atributlar (yil, oy, kun, soat va daqiqa);
- Atrof-muhit harorati;
- Operatsion ko'rsatkichlar (ish kuni/ishlamaydigan kun ko'rsatkichi;
- Quvvat iste'moli ma'lumotlari:
- Korxonaning elektr energiyasi iste'moli tarifi koeffitsienti.

datetime	P_kVt	Q_kVar	T_ext	Tech_shift	Office_shift	hour	dow	slot
2024-01-13 00:00:00	607.58136	157.50000	-0.345	1	0	0	5	0
2024-01-13 00:30:00	649.07964	152.99784	0.490	1	0	0	5	1
2024-01-13 01:00:00	644.70636	149.37516	1.355	1	0	1	5	2
2024-01-13 01:30:00	627.40152	146.20788	2.220	1	0	1	5	3
2024-01-13 02:00:00	629.11836	152.58348	2.875	1	0	2	5	4

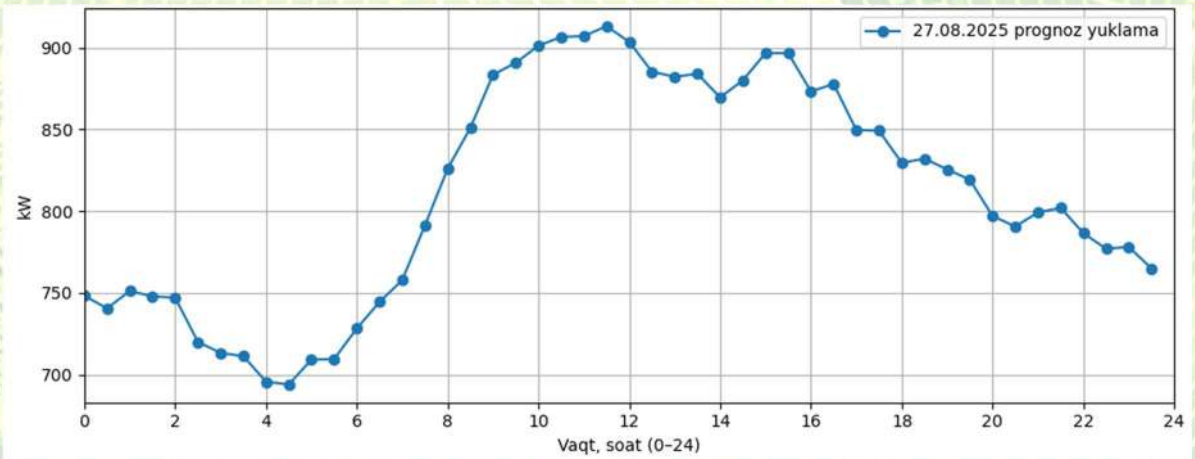
2-rasm. LSTM modelning kirish parametrlari

Bu xususiyatlar energiyadan foydalanishga ta'sir qiluvchi ekologik va operatsion omillarni qo'lga kiritish uchun tanlangan. LSTM asosidagi prognozlash modeli rasmda ko‘rsatilgan arxitekturaga muvofiq ketma-ket joylashgan ikkita LSTM qatlamidan tashkil etildi. Birinchi LSTM (128) qatlam kirish ketma-ketligini vaqt bo‘yicha qayta ishlab, har bir vaqt bosqichi uchun yashirin holatlarni shakllantirdi **(**return_sequences=True**),** natijada chiqish o‘lchami (None,336,128) (None,\336,\128) (None, 336, 128) ko‘rinishida hosil bo‘ldi. Bu qatlamdan keyin haddan tashqari moslashishni kamaytirish maqsadida Dropout qo‘llanildi. Keyingi

ISSN 3030-3907

bosqichda ikkinchi LSTM (64) qatlam birinchi qatlamdan chiqqan ketma-ket xususiyatlarni umumlashtirib, faqat yakuniy yashirin holatni hosil qildi; chiqish o‘lchami (None,64) (None,\64)(None,64) bo‘ldi. Ushbu qatlamdan so‘ng ham umumlashuvni yaxshilash uchun Dropout qatlamidan foydalanildi. So‘ngra modelning regressiya bosqichi to‘liq bog‘langan Dense(64) qatlami orqali amalga oshirilib, yakuniy chiqish Dense(48) qatlami bilan shakllantirildi. Bu yerda 48 ta chiqish qiymati korxonaning ertangi sutkalik yuklamasini 30 daqiqalik interval bo‘yicha ifodalaydi, ya’ni model natijasi bir sutka uchun to‘liq prognoz profilini beradi. O‘qitish jarayonida LSTM ichki holatlari har bir ketma-ketlik boshida nolga tenglashtirilgan (boshlang‘ich holat sifatida) va vaqt bo‘yicha ketma-ket hisoblash davomida dinamik yangilanib bordi. Model bashorat qilingan va haqiqiy yuklama qiymatlari orasidagi tafovutni minimallashtirish uchun yo‘qotish funksiyasi sifatida o‘rtacha kvadrat xato (MSE) dan foydalangan holda o‘qitildi. Optimallashtirish uchun esa Adam optimizatori tanlanib, adaptiv o‘rganish tezligi hisobiga konvergentsiya barqarorligi va o‘qitish samaradorligi oshirildi.

NATIJA. Taklif etilgan LSTM asosidagi prognozlash modeli yordamida korxonaning ertangi kunlik sutkalik elektr yuklamasi 30 daqiqalik vaqt intervalida bashorat qilindi. Modelni o‘qitish jarayoni bir yillik tarixiy ma’lumotlar asosida amalga oshirilib, o‘qitish va sinov to‘plamlari o‘rtasida vaqt bo‘yicha izchillik saqlangan holda ajratildi. Bu yondashuv modelning real ekspluatatsiya sharoitlaridagi ishlash qobiliyatini baholash imkonini berdi. O‘qitilgan LSTM modeli yordamida olingan prognoz natijalari sutka davomida yuklamaning asosiy qonuniyatlarini aniq aks ettirdi. Xususan, ishlab chiqarish jarayonlari faol bo‘lgan vaqt oralig‘ida yuklama oshishi, smena almashinuvi davrlarida esa yuklamaning qisqa muddatli o‘zgarishlari model tomonidan to‘g‘ri aniqlangan. Tungi va past faoliyat davrlarida yuklamaning pasayish tendensiyasi ham prognoz natijalarida yaqqol kuzatildi. Bu holat model tarixiy ma’lumotlardagi vaqt bo‘yicha bog‘liqliklarni muvaffaqiyatli o‘zlashtirganini ko‘rsatadi.



3-rasm. LSTM orqali bashoratlangan korxonaning sutkalik yuklama grafigi

ISSN 3030-3907

Sutkalik yuklama grafigi tahlili shuni ko‘rsatdiki, LSTM modeli yuklamaning umumiy dinamikasini yuqori aniqlikda takrorlaydi. Xususan, tungi past yuklama davrlari (0:00–5:00), ertalabki yuklama o‘sishi (6:00–9:00), kunduzgi maksimal yuklama oralig‘i (10:00–13:00) hamda kechki yuklama pasayish bosqichlari model tomonidan to‘g‘ri aniqlangan. Cho‘qqi yuklama qiymatlari va ularning vaqt bo‘yicha joylashuvi real yuklama grafigiga yaqin mos kelishi modelning qisqa muddatli prognozlash qobiliyati yuqori ekanini tasdiqlaydi.

Kuzatilgan kichik og‘ishlar asosan yuklamaning keskin o‘zgarishi sodir bo‘lgan vaqt oralig‘larida yuzaga kelgan bo‘lib, bu holatlar texnologik jarayonlarning favqulodda ishga tushirilishi yoki tashqi omillarning qisqa muddatli ta’siri bilan izohlanadi.

Modelning prognozlash sifati prognoz qilingan va real yuklama qiymatlari orasidagi farq asosida baholandi. Bunda asosiy mezon sifatida o‘rtacha kvadrat xato (MSE) ishlatildi, shuningdek aniqlik ko‘rsatkichlari foizlarda ifodalandi. Aniqlik quyidagi umumiy yondashuv asosida hisoblandi: har bir vaqt nuqtasida real va prognoz qiymatlari o‘rtasidagi nisbiy xato aniqlanib, so‘ngra ularning o‘rtacha qiymati olinadi. Natijada sutka bo‘yicha umumiy prognoz aniqligi baholandi.

Hisoblash natijalari quyidagi ko‘rsatkichlarni berdi:

O‘rtacha aniqlik (Average Accuracy) – 91.20 %

Maksimal aniqlik (Maximum Accuracy) – 92.42 %

Minimal aniqlik (Minimum Accuracy) – 82.03 %

Ushbu qiymatlar LSTM modelining real yuklama grafigiga yuqori darajada mos kelishini ko‘rsatadi. Ayniqsa, o‘rtacha aniqlikning 90 % dan yuqori bo‘lishi sanoat korxonalarida qisqa muddatli energiya prognozlari uchun yetarli darajada ishonchli natija hisoblanadi.

Real yuklama bilan solishtirish natijalari shuni ko‘rsatdiki, LSTM modeli yuklamaning vaqt bo‘yicha bog‘liqliklarini va tashqi omillar ta’sirini samarali o‘zlashtirgan. Prognoz aniqligining yuqori bo‘lishi tarixiy yuklama ma’lumotlari, smena rejimlari, tashqi harorat va tarif o‘zgarishlari kiruvchi parametrlar sifatida kompleks tarzda hisobga olingani bilan izohlanadi. Shu bilan birga, minimal aniqlik qiymatlari yuklamaning keskin o‘zgarishi kuzatilgan vaqt oralig‘lariga to‘g‘ri kelgani aniqlanib, bu holatlar kelgusida modelni qo‘shimcha parametrlar bilan boyitish zarurligini ko‘rsatadi. Korxona yuklamasi 48 ta nuqtadan iborat prognoz qilingan sutkalik yuklama profili real yuklama grafigi bilan solishtirilganda, cho‘qqi yuklama qiymatlari va ularning vaqt bo‘yicha joylashuvi yuqori aniqlik bilan mos kelgani aniqlandi. Ayniqsa, maksimal yuklama

ISSN 3030-3907

kuzatiladigan vaqt oralig‘ini oldindan bashorat qilish imkoniyati energiya boshqaruvi nuqtai nazaridan muhim natija hisoblanadi.

Umuman olganda, olingan natijalar taklif etilgan LSTM asosidagi yondashuv sanoat korxonalarining ertangi sutkalik elektr yuklamasini yuqori aniqlikda prognozlash imkonini berishini va energiya boshqaruvi masalalarida amaliy jihatdan samarali ekanini tasdiqlaydi.

XULOSA. Ushbu tadqiqotda sanoat korxonasining ertangi kunlik sutkalik elektr yuklamasini prognozlash masalasi chuqur o‘rganishga asoslangan Long Short-Term Memory (LSTM) neyron tarmoqlari yordamida hal etildi. Tadqiqot doirasida bir yillik tarixiy yuklama ma’lumotlari, 30 daqiqalik vaqt diskretligida shakllantirilib, ishlab chiqarishning texnologik va boshqaruv smenalari, tashqi havo harorati hamda elektr energiyasi tariflarining vaqt bo‘yicha o‘zgarishi bilan kompleks ravishda hisobga olindi. Ushbu ko‘p omilli yondashuv elektr yuklamasining real dinamikasini aniqroq modellashtirish imkonini berdi.

Python dasturlash muhitida ishlab chiqilgan ikki qatlamli LSTM modeli sutkalik yuklamaning asosiy tendensiyalari va cho‘qqi yuklama davrlarini yuqori aniqlikda bashorat qila olishini namoyish etdi. Olingan natijalar real sutkalik yuklama grafigi bilan solishtirilganda, yuklamaning vaqt bo‘yicha o‘zgarish shakli, maksimal va minimal qiymatlari hamda ularning joylashuvi o‘rtasida yaqin moslik mavjudligi aniqlandi. Prognozlash sifatining baholanishi MSE ko‘rsatkichlari asosida amalga oshirilib, o‘rtacha aniqlikning 90 % dan yuqori bo‘lishi taklif etilgan yondashuvning amaliy jihatdan ishonchli ekanini tasdiqladi. Umuman olganda, ushbu tadqiqot sanoat korxonalarida raqamli energiya boshqaruvi va qisqa muddatli elektr yuklamasini prognozlash masalalarini hal etishda LSTM asosidagi yondashuvning yuqori samaradorligini ko‘rsatdi. Kelgusida modelga qo‘shimcha tashqi omillarni kiritish, uzoqroq prognoz ufqlarini o‘rganish hamda qayta tiklanuvchi energiya manbalari va energiya saqlash tizimlari bilan integratsiya qilish orqali tadqiqotni yanada rivojlantirish mumkin.

ADABIYOTLAR

1. Timur, O., & Üstünel, H. (2025). Short-Term Electric Load Forecasting for an Industrial Plant Using Machine Learning-Based Algorithms. Energies. https://doi.org/10.3390/en18051144.

2. Kakkar, R.; Agrawal, S.; Tanwar, S. A systematic survey on demand response management schemes for electric vehicles. Renew. Sustain. Energy Rev. 2024, 203, 114748.

3. Yu, Y.; Si, X.; Hu, C.; Zhang, J. A review of recurrent neural networks: LSTM cells and network architectures. Neural Comput.2019, 31, 1235–1270.

ISSN 3030-3907

4. DiPietro, R.; Hager, G.D. Deep learning: RNNs and LSTM. In Handbook of Medical Image Computing and Computer Assisted Intervention; Elsevier: Amsterdam, The Netherlands, 2020; pp. 503–519.
5. Ullah, F.U.M.; Ullah, A.; Haq, I.U.; Rho, S.; Baik, S.W.J.I.A. Short-Term Prediction of Residential Power Energy
6. Consumption via CNN and Multilayer Bi-directional LSTM Networks; IEEE: Piscataway, NJ, USA, 2019.
7. Deb, C.; Zhang, F.; Yang, J.; Lee, S.E.; Shah, K.W. A review on time series forecasting techniques for building energy consumption. Renew. Sustain. Energy Rev. 2017, 74, 902–924. [CrossRef]
8. Kim, K.-H.; Cho, S.-B. Modular Bayesian Networks with Low-Power Wearable Sensors for Recognizing Eating Activities. Sensors 2017, 17, 2877.

ISSN 3030-3907