NEYRON TARMOQLARI ASOSIDA SANOAT KORXONALARIDA IŞLAB ÇIQARIŞ JARAYONLARINING SAMARADORLIGINI INTELLEKTUAL BAHOLAŞ VA PROGNOZLAŞ

Abdurasulov Otabek Abdijalil o'g'li
Qarshi Davlat Texnika Universiteti
Axborot tizimlari yo'nalishi 1-bosqich magistranti
oabdurasulov928@gmail.com

ANNOTATSIYA

Uşbu maqolada sanoat korxonalarida işlab çiqariş jarayonlari samaradorligini neyron tarmoqlari yordamida intellektual baholaş va prognozlaş masalasi tadqiq etiladi. Korxona faoliyatiga ta'sir etuvçi işlab çiqariş hajmi, uskunalarning texnik holati, tōxtab qolişlar, energiya sarfi, mahsulot sifati va resurslardan foydalaniş kōrsatkiçlari yagona axborot-matematik model doirasida kōrib çiqiladi. Tadqiqotning metodik yeçimi sifatida kōp qatlamli perseptron (MLP) hamda vaqt qatorlari uçun LSTM arxitekturasini birlaştiruvçi gibrid yondaşuv taklif etiladi. Model kiruvçi ma'lumotlarni tayyorlaş, samaradorlikning integral indeksini şakllantiriş, qisqa muddatli prognoz tuziş va boşqaruv qarorlarini qōllab-quvvatlaş bosqiçlaridan iborat. Baholaş uçun MAE, RMSE, MAPE va R^2 metrikalari, şuningdek, OEE kōrsatkiçi tavsiya qilinadi. Maqola metodologik xarakterga ega bōlib, unda modelni amaliy sinovdan ōtkaziş protokoli va tekşiriladigan ilmiy farazlar bayon etiladi.

Kalit sōzlar: neyron tarmoqlari, sanoat korxonasi, işlab çiqariş samaradorligi, intellektual baholaş, prognozlaş, LSTM, kōp qatlamli perseptron, OEE, Industry 4.0.

АННОТАЦИЯ

В статье рассматривается задача интеллектуальной оценки и прогнозирования эффективности производственных процессов промышленных предприятий с использованием нейронных сетей. Предлагается гибридный подход на основе многослойного персептрона и

архитектуры LSTM, объединяющий многомерную оценку текущего состояния и прогнозирование временной динамики. Определены состав входных данных, интегральный индекс эффективности, метрики оценки качества прогноза и протокол экспериментальной проверки. Работа носит методологический характер; численные результаты реального промышленного эксперимента не заявляются.

Ключевые слова: нейронные сети, промышленное предприятие, эффективность производства, интеллектуальная оценка, прогнозирование, LSTM, OEE.

ABSTRACT

This paper examines the use of neural networks for intelligent assessment and forecasting of manufacturing process efficiency in industrial enterprises. A hybrid approach combining a multilayer perceptron and an LSTM architecture is proposed to integrate multidimensional assessment of the current production state with time-series forecasting. The study defines input variables, a composite efficiency index, forecasting metrics, and an experimental validation protocol. The paper is methodological in nature and does not claim numerical results from a real industrial experiment.

Keywords: neural networks, industrial enterprise, manufacturing efficiency, intelligent assessment, forecasting, LSTM, multilayer perceptron, OEE, Industry 4.0.

KIRIŞ

Raqamli transformatsiya şaroitida sanoat korxonalarining raqobatbardoşligi işlab çiqariş quvvatlaridan oqilona foydalaniş, mahsulot sifatini barqaror ta'minlaş, energiya sarfini kamaytiriş va uzilişlarni qisqartiriş bilan bevosita bog̃liq. An'anaviy boşqaruv tizimlarida samaradorlik kōpinça davriy hisobotlar va alohida iqtisodiy kōrsatkiçlar asosida baholanadi, bu esa jarayonlar ōrtasidagi murakkab noçiziqli va vaqt bōyiça ōzgaruvçan munosabatlarni tōliq oçib bera olmaydi.

Sanoat uskunalariga ōrnatilgan sensorlar, avtomatlaştirilgan boşqaruv tizimlari va korxona axborot tizimlari katta hajmdagi ma'lumotlarni şakllantirmoqda.

Uşbu ma'lumotlar kelajakdagi işlab çiqariş holatini oldindan baholaş, texnik nosozlik ehtimolini aniqlaş va resurslarni optimal taqsimlaş uçun muhim manba hisoblanadi; maşinaviy ōqitiş va çuqur ōrganiş usullari aynan şu imkoniyatlarni kengaytiradi [1–3].

Işlab çiqariş tizimlarida samaradorlikni baholaş kōp omilli masaladir: hajmning ortişi agar brak uluşi, energiya sarfi yoki uskunalarning bekor turiş vaqti ham ortsa, umumiy natijani salbiylaştiradi. Şu sababli samaradorlikni unumdorlik, sifat, mavjudlik, energiya tejamkorligi va resurslardan foydalaniş mezonlari majmuasi orqali baholaş maqsadga muvofiq. Ilmiy adabiyotlarda maşinaviy ōqitişning rejalashtiriş, monitoring, sifat nazorati va profilaktik texnik xizmatdagi qōllanilişi keng yoritilgan [1–4].

Tadqiqotning maqsadi — sanoat korxonalarida işlab çiqariş samaradorligini kōp omilli ma'lumotlar asosida intellektual baholaş va qisqa muddatli dinamikasini prognozlaşga mōljallangan neyron tarmoqli metodik yondaşuvni işlab çiqişdir. Tadqiqot vazifalari: kōrsatkiçlar tizimini şakllantiriş; ma'lumotlarni tayyorlaş va normallaştiriş; integral samaradorlik indeksini hisoblaş; MLP va LSTM asosidagi gibrid model arxitekturasini taklif etiş; baholaş mezonlari hamda boşqaruv qarorlarini qōllab-quvvatlaş yōllarini asoslaş. Ilmiy yangiligi joriy operatsion holatni MLP orqali baholaş va vaqt qatorlari dinamikasini LSTM yordamida prognozlaşni birlaştiruvçi ikki bosqiçli yondaşuvni taklif etişdan iborat.

2. TADQIQOT METODOLOGIYASI

2.1. Ma'lumotlar tarkibi va omillarni tanlaş

Modelning kiriş ma'lumotlari işlab çiqariş, texnik xizmat, sifat nazorati va energetika tizimlaridan olinib, bir xil vaqt oraliğiga (smena, soat yoki kun) sinxronlaştiriladi. Har bir yozuvda vaqt belgisi, uskuna identifikatori va ōlçovlar bōlişi lozim.

Asosiy kiriş omillari beş guruhga ajratiladi:

1 işlab çiqariş — reja va amaldagi hajm, sikl vaqti, liniya yuklanişi;

2 uskuna holati — işlaş vaqti, tōxtaşlar soni va davomiyligi, vibratsiya, harorat, bosim;

3 sifat — yaroqli mahsulot uluşi, brak, qayta işlaş;

4 energetika — elektr energiyasi va resurslar sarfi;

5 taşkiliy omillar — smena, xomaşyo partiyasi, buyurtma turi va profilaktika vaqti.

Ma'lumotlarni tayyorlaşda dublikatlar olib taşlanadi, vaqt belgilarining izçilligi tekşiriladi va ōlçov birliklari standartlaştiriladi. Yetişmayotgan qiymatlar interpolatsiya, median yoki maxsus belgi orqali qayta işlanadi; keskin çet qiymatlar esa haqiqiy nosozlikni ifodalaşi mumkinligi sababli mutaxassis bilan tekşiriladi. Belgilarni umumiy diapazonga keltiriş uçun min–max normallaştiriş (yoki çet qiymatlar kōp bōlsa, robust masştablaş) qōllanadi, parametrlar esa faqat ōqitiş tōplamidan hisoblanadi:

$$x_norm = (x - x_min) / (x_max - x_min) \quad (1)$$

2.2. Işlab çiqariş samaradorligini integral baholaş

Kompleks baholaş uçun OEE (Overall Equipment Effectiveness) tayanch operatsion mezon sifatida olinib, mavjudlik (A), unumdorlik (P) va sifat (Q) koeffitsiyentlarini [0, 1] uluşlarda birlaştiradi. Biroq OEE barcha iqtisodiy va ekologik jihatlarni qamrab olmagani sababli kengaytirilgan integral indeks (E_t) taklif etiladi:

$$OEE = A \times P \times Q;\ E_t = w_1 \cdot OEE_t + w_2 \cdot U_t + w_3 \cdot R_t + w_4 \cdot C_t \quad (2–3)$$

Bu yerda U_t — resurslardan foydalaniş samaradorligi; R_t — energiya tejamkorligi; C_t — reja bajarilişi; w_i — vazn koeffitsiyentlari ($w_1+w_2+w_3+w_4=1$). Salbiy yōnalişdagi omillar (brak, energiya sarfi, bekor turiş) teskari normallaştiriladi; vaznlar ekspert baholaşi yoki entropiya usuli bilan belgilanib, sezgirlik tahlili ōtkaziladi.

2.3. Neyron tarmoqli model arxitekturasi

Ikki bosqiçli gibrid arxitekturaning birinçi bosqiçida kōp qatlamli perseptron (MLP) joriy davrning kōp omilli vektorini qayta işlab, yaşirin qatlamlarda ReLU va çiqişda sigmoid funksiyasi orqali [0, 1] oraliğidagi integral indeksni baholaydi:

$h^{(1)} = ReLU(W_1x + b_1);\ h^{(2)} = ReLU(W_2h^{(1)} + b_2);\ \hat{E}_t = \sigma(W_3h^{(2)} + b_3)$ (4–5)

Ikkinçi bosqiçda LSTM tarmoği samaradorlik indeksi ketma-ketligi va operatsion omillar dinamikasini tahlil qilib, unutiş (f_t), kiriş (i_t) va çiqiş (o_t) darvozalari yordamida kelgusi davr qiymatini prognoz qiladi:

$f_t = \sigma(W_f[h_(t-1), x_t] + b_f);\ i_t = \sigma(W_i[h_(t-1), x_t] + b_i)$ (6)

$\tilde{C}_t = tanh(W_c[h_(t-1), x_t] + b_c);\ C_t = f_t \odot C_(t-1) + i_t \odot \tilde{C}_t$ (7)

$o_t = \sigma(W_o[h_(t-1), x_t] + b_o);\ h_t = o_t \odot tanh(C_t)$ (8)

Umumiy oqim: ma'lumotlarni yiğiş → tozalaş va sinxronlaştiriş → normallaştiriş → OEE va integral indeksni hisoblaş → MLP baholaşi → LSTM prognozi → ogohlantiriş va qarorlarni qōllab-quvvatlaş (zarur hollarda SHAP qiymatlari orqali izohlaş).

2.4. Modelni ōqitiş va tekşiriş tartibi

Vaqt qatorlarida kelajak ma'lumotlari sizib çiqmasligi uçun to‘plamlar tasodifiy emas, balki xronologik tartibda ajratiladi (masalan, 70/15/15 nisbatda ōqitiş, validatsiya va test). Prognoz xatosi MAE, RMSE, MAPE va R^2 metrikalari bilan baholanadi (nolga yaqin qiymatlarda sMAPE afzal):

$MAE = (1/n)\ \Sigma\ |y_i - \hat{y}_i|;\ RMSE = \sqrt{[(1/n)\ \Sigma\ (y_i - \hat{y}_i)^2]}$ (9–10)

$MAPE = (100/n)\ \Sigma\ |(y_i - \hat{y}_i)/y_i|;\ R^2 = 1 - [\Sigma(y_i - \hat{y}_i)^2 / \Sigma(y_i - \bar{y})^2]$ (11–12)

Model kamida uçta bazaviy yondaşuv (tarixiy ōrtaça/mavsumiy-naiv, regressiya/Random Forest, yakka MLP yoki LSTM) bilan bir xil test davrida taqqoslanadi va rolling-origin backtesting orqali sinovdan ōtkaziladi.

NATIJALAR

3.1. Taklif etilgan yondaşuvning metodik natijalari

Tadqiqot natijasida işlab çiqariş, texnik holat, sifat va energetika ma'lumotlarini birlaştirgan integral baholaş mexanizmi hamda MLP–LSTM ketma-ketligiga asoslangan yagona metodik arxitektura şakllantirildi. MLP joriy holatning kōp omilli kesimini baholaydi, LSTM esa vaqt dinamikasini hisobga olib, samaradorlik pasayişi tendensiyasini oldindan aniqlaş imkonini beradi.

1-jadval. Modelga kiritiladigan asosiy kōrsatkiçlar va ularning vazifasi

Kōrsatkiçlar guruhi	**Misol tariqasidagi belgilar**	**Modeldagi vazifasi**
Işlab çiqariş	mahsulot hajmi, sikl vaqti, liniya yuklanişi	unumdorlikni baholaş
Uskuna holati	işlaş vaqti, tōxtaşlar, vibratsiya, harorat	uziliş va nosozlik xavfini aniqlaş
Sifat	yaroqli mahsulot uluşi, brak, qayta işlaş	sifat komponentini hisoblaş
Energetika	elektr energiyasi sarfi, birligiga sarf	energiya samaradorligini baholaş
Taşkiliy omillar	smena, buyurtma turi, xomaşyo partiyasi	iş rejimi ōzgarişini hisobga oliş

3.2. Prognozlaş natijalarini taqdim etiş şakli

Amaliy sinovda natijalar quyidagi kōrinişlarda taqdim etiladi: joriy integral samaradorlik indeksi; keyingi smena, kun yoki hafta uçun prognoz; noaniqlik oraliği (kvantil prognozlaş yoki ansambl orqali); eng kuçli ta'sir kōrsatgan omillar va çegaradan çetlaniş bōyiça ogohlantiriş.

2-jadval. Model samaradorligini tekşiriş uçun tavsiya etiladigan mezonlar

Mezon	**Mazmuni**	**Kutiladigan talqin**
MAE	ōrtaça mutlaq xato	kiçik qiymat — prognoz xatosi past

RMSE	kvadratik xatoning ildizi	katta xatolarni kuçliroq jazolaydi
MAPE	foizdagi mutlaq xato	noldan uzoq qiymatlarda qulay
R^2	tuşuntirilgan dispersiya uluşi	1 ga yaqinlaşişi moslikni anglatadi
OEE	mavjudlik × unumdorlik × sifat	işlab çiqariş uskunasi samaradorligi

Maqolada real korxona ma'lumotlari mavjud bōlmagani sababli sonli tajriba natijalari keltirilmaydi; 2-jadvaldagi mezonlar modelni kelgusida real ma'lumotlarda xolis sinaş uçun belgilangan.

3.3. Tekşiriladigan ilmiy farazlar

Amaliy sinovlarda uçta asosiy faraz tekşiriladi: H1 — MLP va LSTMni birlaştirgan gibrid model samaradorlik prognozida yakka arxitekturadan past bōlmagan aniqlikni kōrsatadi; H2 — uskuna holati va energiya sarfi belgilarini kiritiş faqat hajmga asoslangan prognozga nisbatan xatoni kamaytiradi; H3 — xronologik test va rolling-origin tekşiruvi modelning yangi rejimlarga moslaşuvçanligini işonçliroq baholaydi.

MUHOKAMA

Taklif etilgan yondaşuvning asosiy afzalligi kōp mezonli baholaş va vaqt bōyiça prognozlaşni yagona tizimda birlaştirip, nochiziqli munosabatlar hamda takrorlanuvçi naqşlarni aniqlay olişidir [6, 7]. Biroq model sifati ma'lumotlar hajmi, aniqligi, sensorlar kalibrlanişi va rejim barqarorligiga bevosita bogliq; kam yoki sifatsiz ma'lumotlarda sodda statistik yoki daraxtga asoslangan modellar yaxşiroq natija berişi mumkin.

Amaliyotda ma'lumotlar siljişi (data drift) — xomaşyo, uskuna sozlamalari, buyurtma tarkibi yoki mavsumiy talab ōzgarişini kuzatiş va modelni davriy qayta ōqitiş zarur. Şuningdek, SHAP yoki permutation importance kabi izohlanuvçanlik

usullari statistik bog‌liqliklarni kōrsatsa-da, sabab-oqibatni avtomatik isbotlamaydi va texnolog nazoratini talab qiladi.

Joriy etiş bosqiçma-bosqiç bajarilişi lozim: pilot liniyada ma'lumotlar auditi → bazaviy model → MLP–LSTM sinovi → muhandislar verifikatsiyasi → boshqaruv paneliga integratsiya. Inson nazorati, kiberxavfsizlik va uskunaning xavfsiz işlaş talablari saqlanişi şart. Tadqiqotning asosiy çeklovi real korxona ma'lumotlari asosida empirik tasdiq yōqligi bōlib, bu kelgusi izlanışlarda amalga oşiriladi.

XULOSA

Tadqiqotda neyron tarmoqlari asosida sanoat korxonalarida işlab çiqariş jarayonlari samaradorligini intellektual baholaş va prognozlaşning metodik yondaşuvi işlab çiqildi. Işlab çiqariş hajmi, uskuna holati, sifat, energiya sarfi va taşkiliy omillarni yagona muhitda birlaştiriş asoslandi.

Samaradorlikni baholaş uçun OEE hamda resurslar, energiya tejamkorligi va reja bajarilişini qamrab oluvçi integral indeks, şuningdek, joriy holatni baholovçi MLP va dinamikani prognozlovçi LSTM gibrid arxitekturasi taklif etildi. Xronologik ajratiş, rolling-origin backtesting va MAE, RMSE, MAPE, R^2 metrikalari asosida tekşiriş hamda ma'lumotlar siljişini kuzatiş zarurligi kōrsatildi. Kelgusida modelni real korxona ma'lumotlarida sinab, texnik-iqtisodiy samarasini miqdoriy baholaş rejalaştiriladi.

FOYDALANILGAN ADABIYOTLAR

1. Ördek, B., Borgianni, Y., & Coatanea, E. (2024). Machine learning-supported manufacturing: a review and directions for future research. Production & Manufacturing Research, 12(1), 2326526. https://doi.org/10.1080/21693277.2024.2326526
2. Fatima, S. S. W., & Rahimi, A. (2024). A Review of Time-Series Forecasting Algorithms for Industrial Manufacturing Systems. Machines, 12(6), 380. https://doi.org/10.3390/machines12060380

3. Polverino, L., et al. (2023). Machine learning for prognostics and health management of industrial mechanical systems and equipment: A systematic literature review. International Journal of Engineering Business Management. https://doi.org/10.1177/18479790231186848
4. Fordal, J. M., Schjølberg, P., Helgetun, H., Skjermo, T. Ø., Wang, Y., et al. (2023). Application of sensor data based predictive maintenance and artificial neural networks to enable Industry 4.0. Advances in Manufacturing, 11, 248–263. https://doi.org/10.1007/s40436-022-00433-x
5. Vogl, G., Cornelius, A., & Jia, X. (2026). 2026 Roadmap on Artificial Intelligence and Machine Learning for Smart Manufacturing. NIST / IOP Publishing. https://doi.org/10.1088/3049-4761/ae5967
6. Jiang, P., Wang, Z., Li, X., Wang, X. V., Yang, B., & Zheng, J. (2023). Energy consumption prediction and optimization of industrial robots based on LSTM. Journal of Manufacturing Systems, 70, 137–148. https://doi.org/10.1016/j.jmsy.2023.07.009
7. A novel attention-based long short term memory and fully connected neural network approach for production energy consumption prediction under complex working conditions. (2024). Engineering Applications of Artificial Intelligence, 133, 108418. https://doi.org/10.1016/j.engappai.2024.108418