

ФИЗИКАЛЫҚ ПРОЦЕСТЕР МЕН МЕХАНИКАЛЫҚ ЖҮЙЕЛЕРДІ МОДЕЛЬДЕУ

МОДЕЛИРОВАНИЕ ФИЗИЧЕСКИХ ПРОЦЕССОВ И МЕХАНИЧЕСКИХ СИСТЕМ

MODELING OF PHYSICAL PROCESSES AND MECHANICAL SYSTEMS

ГТАХР 50.47.29

10.51889/2959-5894.2024.88.4.008

А.Қ. Жұмабаева^{*1}, Б.Т. Иманбек¹, З.М. Абдияхметова¹, Г.А. Тюлепбердинова¹

¹әл-Фараби атындағы Қазақ ұлттық университеті, Алматы, Қазақстан

*e-mail: kalybaikyzy@inbox.ru

АНАЭРОБТЫ РЕКТОРЛАРДАҒЫ БИОГАЗ ӨНДІРУ ЖЫЛДАМДЫҒЫНЫҢ КВАНТТЫҚ РЕГРЕССИЯСЫНА АРНАЛҒАН МАШИНАЛЫҚ ОҚЫТУ

Аңдатпа

Анаэробты ашыту-тазартылмаған тұнбаны өңдеуге арналған ағынды суларды тазарту станцияларында жақсы қалыптасқан құрал; оны анаэробты реакторларда биогаз жинау арқылы жаңартылатын энергия үшін де пайдалануға болады. Температура сияқты жұмыс параметрлерін әдетте қондырғы операторлары сараптамалық білімге сәйкес белгілейді. Операциялық басқару әлеуетін толық пайдалану үшін бұл зерттеуде біз алты жылдық өмірдегі уақыт қатарының деректері, сондай-ақ мемлекеттік мерекелер сияқты категориялық сипаттамалар негізінде жаңа уақытша синтез түрлендіргішін калибрледік. Дәстүрлі деректерге негізделген әдістерден айырмашылығы, модель дизайны бірнеше факторларды есепке алу арқылы нәтижелердің өзара алмастырылуын қамтамасыз етеді. Биогаз өндірісінің орташа көрсеткіштерін алдағы жеті күнге болжаумен қатар, біздің модель сандық мәндерді де береді, бұл оны күшті ауытқуларға азырақ бейім етеді. Нұсқаулық ретінде біз белгілі үш статистикалық әдісті қолдандық. Біздің болжау тәсіліміздің орташа абсолютті пайыздық қателігі 8% - дан аз.

Түйін сөздер: Анаэробты ашыту, биореактор, уақытша біріктіру трансформаторы, машиналық оқыту.

А.Қ. Жұмабаева¹, Б.Т. Иманбек¹, З.М. Абдияхметова¹, Г.А. Тюлепбердинова¹
Казахский национальный университет им.аль-Фараби, г.Алматы, Казахстан
**МАШИНОЕ ОБУЧЕНИЕ ДЛЯ КВАНТИЛЬНОЙ РЕГРЕССИИ СКОРОСТЕЙ
ПРОИЗВОДСТВА БИОГАЗА В АНАЭРОБНЫХ РЕАКТОРАХ**

Аннотация

В этой статье рассматривается применение машинного обучения к квантовой регрессии скорости производства биогаза в анаэробных реакторах. Анаэробная ферментация-это хорошо зарекомендовавший себя инструмент на очистных сооружениях для обработки сырого осадка. Его также можно использовать для возобновляемых источников энергии, собирая биогаз в анаэробных котлах. Операторы установки обычно устанавливают рабочие параметры, такие как температура, в соответствии с экспертными знаниями. Чтобы полностью использовать потенциал оперативного управления, в этом исследовании мы откалибровали новый темпоральный термоядерный трансформатор на основе данных временных рядов шкалы жизни за шесть лет вместе с категориальными признаками, такими как государственные праздники. Дизайн модели обеспечивает взаимозаменяемость выходных данных по сравнению с традиционными методами данных, которые

используют больше внимания. Помимо прогнозирования средних темпов производства биогаза в течение следующих семи дней, наша модель также дает квантили, что делает ее менее подверженной сильным колебаниям. В качестве руководства мы использовали три известных статистических метода. Средняя абсолютная процентная погрешность нашего прогнозируемого подхода составляет менее 8%.

Ключевые слова: анаэробное брожение, биореактор, темпоральный термонуклеарный трансформатор, машинное обучение.

A.K. Zhumabaeva, B.T. Imanbek, Z.M. Abdiakhmetova, G.A. Tyulepberdinova
Al-Farabi Kazakh National University, Almaty, Kazakhstan

MACHINE LEARNING FOR QUANTILE REGRESSION OF BIOGAS PRODUCTION RATES IN ANAEROBIC REACTORS

Abstract

This article discusses the application of machine learning to the quantum regression of biogas production rate in anaerobic reactors. Anaerobic fermentation is a well-proven tool in wastewater treatment plants for the treatment of raw sludge. It can also be used for renewable energy sources by collecting biogas in anaerobic boilers. Installation operators usually set operating parameters, such as temperature, according to expert knowledge. In order to fully exploit the potential of operational management, in this study we calibrated a new temporal thermonuclear transformer based on data from the time series of the life scale over six years, along with categorical features such as public holidays. The design of the model ensures the interchangeability of the output data compared to traditional data methods that use more attention. In addition to predicting average biogas production rates over the next seven days, our model also provides quantiles, which makes it less susceptible to strong fluctuations. We used three well-known statistical methods as a guide. The average absolute percentage error of our predicted approach is less than 8%.

Keywords: anaerobic fermentation, bioreactor, temporal thermonuclear transformer, machine learning.

Кіріспе

Анаэробты ашыту (АА) көптеген Ағынды суларды тазарту қондырғыларында (АСТҚ) тұнбаны тазарту шеңберінде де, жаңартылатын энергия көзі ретінде де маңызды рөл атқарады. Алынған биогаз, аз мөлшерде қоспалардан басқа, екеуінің де тіркесімі болып табылады, мысалы, газ қозғалтқыштарындағы электр энергиясы түрінде энергия өндіру үшін пайдаланылуы мүмкін[1]. Алайда Ағынды суларды тазарту қондырғыларында жұмыс істейтін толық масштабты пештерде АА жұмыс параметрлерін тәжірибе жасауға және конфигурациялауға батылы бармайды. Жалпы шешім – модельдерді зертханада калибрлеу немесе нақты деректер жиынтығын пайдалану, содан кейін әртүрлі айнымалыларды түзету кезінде оларды бақылау. Зерттеу кезінде инженерлік қоғамдастықта кеңінен талқыланған және танымал көп қабатты жасанды нейрондық желілерді (ЖНЖ) қолдандық. Көп қабатты ЖНЖ көптеген АА жұмыс параметрлерін өңдей алады. Биохимиялық процестер, сыртқы параметрлер қатты әсер ететін әртүрлі шамалар арасындағы күрделі өзара әрекеттесулермен байланысты. Осылайша, бұл зерттеуде біз биогаз өндірісінің жылдамдығын болжау үшін уақытша біріктіру трансформаторы (УБТ) деп аталатын жаңа МО архитектурасын үйреттік. УБТ категориялық және үздіксіз айнымалыларды өңдей алады. Сондай - ақ назар аудару механизмі УБТ болжау кезінде ең көп сүйенетін жеке ерекшеліктерді көрсетуге мүмкіндік береді. УБТ кванттық жоғалту функциясы арқылы калибрленеді. Биогаз өндірісінің жылдамдығын нүктелік бағалау шығудың белгісіздігін көрсететін интервалдармен ауыстырылады.

Зерттеу әдіснамасы

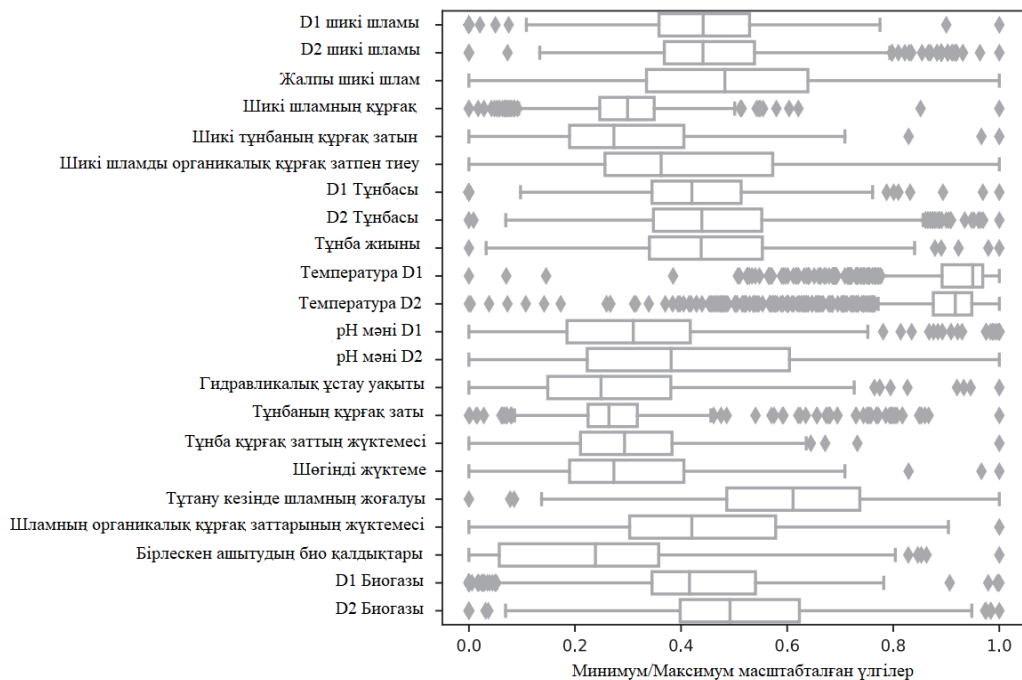
Бұл зерттеуде біз жасанды зертханалық деректер жинағын емес, нақты пештен алынған өнеркәсіптік деректер жинағын қолдандық. Әрі қарайғы қадамдар уақыт сериясының деректерін тазарту мен алдын-ала өңдеуді қамтыды. Машиналық оқыту (МО) моделінің архитектурасы және оның артықшылықтары сипатталған. Калибрлеуден кейін біз модель

ұсынған өнімділік пен болжау қабілетінің артуын көрсету үшін алынған нәтижелерді анықтамалық модельдің нәтижелерімен салыстырдық [2].

Ағынды суларды тазарту қондырғылары (АСТК) жағдайлық зерттеуі кезінде экономикасы айқын ауылшаруашылық сипатына ие және маңызды экономикалық қозғаушы күш-жазғы және қысқы туризм болатын аймақты қарастырамыз. Тұнба туризм, өнеркәсіп және ауыл шаруашылығы қалдықтарының 73% құрайды. Қалған 27 %-ы 10,020 кг d-1 жалпы биохимиялық оттегі қажеттілігі (БОК) бар муниципалитеттер мен үй шаруашылықтарымен біріктірілген. АСТК типтік өңдеу қадамдарын, содан кейін екі сатылы белсенді тұнба процесін қамтиды. Бірінші кезең-екі реактордағы белсендірілген сіңірудің жаңа ауыспалы кезеңі, ал екінші кезең-әдеттегі аноксиялық/аэробты емдеу. Содан кейін алынған қалдықтар сусыздандырылады және анаэробты ашыту цистерналарында өңделеді. Анаэробты ашыту процесінде пайда болатын биогаз жылу мен энергияны өндіру үшін қолданылады. АСТК энергия тиімділігін арттыру үшін оңтайландырылғандықтан, қондырғының жұмыс істеуі үшін тұрақты биогаз өндірісі өте маңызды. Көлемі 2500 м³ құрайтын анаэробты қоршаған орта жағдайында 35 ° С температурада жұмыс істейтін жұмыртқа тәрізді екі бірдей қазандық жұмыс істейді. Олардың биіктігі 24 м және диаметрі 15,4 м және араластыру мақсатында резервуардың ішіндегі тұнбаны қайта өңдеу үшін орнатылған сорғыш құбыры болады. Ашыту аяқталғаннан кейін екі біріктірілген жылу энергиясы қондырғысы 940 кВт қуат өндіреді.

Қазіргі уақытта тазарту қондырғыларының көпшілігі тазалау процесі туралы деректерді, сондай-ақ қазандықтардың ішкі күйі туралы деректерді жинайтын заманауи датчиктермен жабдықталған [3]. Дегенмен, бұл өлшеу құралдарының көпшілігі сезімтал электроникаға қарсы қысқыл, ылғалды немесе ыстық ортада жұмыс істеуіне байланысты жабдықтар тез істен шығады. Адамның қателігінен басқа, бұл жетіспейтін мәндермен бүлінген сапасыз деректер жиынтығына әкеледі. Осылайша, алдын-ала өңдеу қандай модельдер қолданылғанына қарамастан, кез-келген деректерге негізделген тәсілдің ажырамас бөлігі болды. Анаэробты ашыту динамикалық процесс болғандықтан, қатысатын айнымалылар тек тарихи мәндерге ғана емес, сонымен қатар басқа анаэробты ашыту параметрлеріне де тәуелді; сондықтан өткізіп алған мәндер мен шығарындыларды өңдеу одан да күрделі болады [4].


Әрбір жеке белгі бойынша шығарындыларды сапалы талдауға мүмкіндік беретін бастапқы деректердің таралуын визуалды түрде салыстыру үшін 1-суретте көрсетілген диаграммаға жүгінейік.



Сурет 1. Қоран Диаграммалары

Назар аударып қарасақ, әр нысанды \min - \max масштабтағаннан кейін олар $[0, 1]$ интервалында орналасады, бұл графиктерді жалпы X осі бойынша сәйкестендіруге мүмкіндік береді. Температура сипаттамасында сәйкесінше минималды және максималды мәндері $22,41^\circ\text{C}$ және $98,71^\circ\text{C}$ болатын шығарындылардың ең көп саны болды. Екі пештің де орташа жұмыс температурасы $38,15^\circ\text{C}$ болғандықтан, біз бұл шығарындыларды қате өлшемдерге жатқыза аламыз.

Пайдалану параметрлерінің тәуелділіктерін табу үшін біз 2- суретте көрсетілгендей барлық жұптық корреляцияларды есептедік. Екі пештен де біз төрт бірдей оң және бір теріс корреляциялық жұп белгілерді таптық. Тұнба жүктемесі, сондай-ақ шикі тұнбаның органикалық құрғақ затының жүктемесі шикі тұнба құрғақ затымен өте оң корреляцияланды. Тұнба құрамындағы органикалық құрғақ заттардың мөлшері тұнба құрамындағы құрғақ заттармен тығыз байланысты болды. Ақырында, гидравликалық ұстау уақыты шикі тұнбаның жалпы мөлшерімен теріс корреляцияланды. Екі қатты теріс немесе оң корреляциялық белгілер болған кезде, олардың біреуін деректер жиынтығынан алып тастауға болады, өйткені қосымша ақпарат жоғалмайды және модельді калибрлеу жеделдетіледі. Осылайша, жоғарыда аталған функциялар оқыту, валидация және тестілік деректер жиынтығынан алынып тасталды.



Сурет 2. Корреляциялық матрица

Біз k-NN-де анаэробты реактордағы биогаз өндірісінің жылдамдығын болжау үшін негізгі негізді қамтамасыз ететін анықтамалық модельдер ретінде авторегрессиялық интеграцияланған жылжымалы орташа (ARIMA) және өзгертілген ЖНЖ шығардық.

k-NN бар регрессия - белгілі және жиі қолданылатын әдіс. Берілген деректер жиынтығы (x_j, y_j) кейбір y_j атрибуты бар x_j белгілері және евклидтік қашықтық сияқты метрика; k-NN сәйкестігі келесідегідей анықталады:

$$\hat{y}(x) = \frac{1}{k} \sum_{x_j \in N_k(x)} y_j \quad (1)$$

мұндағы $N_k(x)$ - оқу деректерінің x -ге ең жақын k нүктелерінің жиынтығы. K гиперпараметрінің жоғарылауы мен төмендеуі сәйкесінше төмен және қайта оқытуға әкеледі, сондықтан k қолда бар деректерге сәйкес реттелуі керек. Біздің жағдайда біз $K = 8$ шамадан тыс және жеткіліксіз дайындық арасындағы оңтайлы тепе-теңдік екенін анықтадық.

ARIMA-классикалық статистикадан алынған модель, көбінесе болжау мақсатында уақыт серияларының деректеріне қолданылады [5]. Модель бақылау мен кейбір алдын-ала анықталған артта қалған бақылаулар арасындағы тәуелді байланысты пайдаланады, оны уақыттың кешігуі деп те атайды. Ол уақыт қатарын тұрақты ету үшін шикі бақылауларды пайдаланады және қалдық қате мен бақылаулар арасындағы байланысты пайдаланады. P , d және q айнымалылары сәйкесінше артта қалған бақылаулар санын, айырмашылық дәрежесін және жылжымалы орташа терезенің өлшемін білдіреді.

$$\left(1 - \sum_{j=1}^p \phi_j L^j\right) (1 - L)^d X_t = \delta + \left(1 + \sum_{j=1}^q \theta_j L^j\right) \varepsilon_t \quad (2)$$

Біз Дикки-Фуллердің кеңейтілген критерийін қолдана отырып, уақыт қатарының стационарлық екенін зерттедік және $d = 0$ орнаттық. Бастапқы және сараланған уақыт қатарларының автокорреляциялық графиктеріне қарап, біз $P = 5$ және $q = 1$ екенін анықтадық, нәтижесінде $Arima(5,0,1)$ моделі біздің жарнамалық деректер жиынтығымызға жақсы сәйкес келеді. ARIMA соңғы бақылауларды бастапқы деректер жинағында оқығанда ғана алға жылжытуды үйренгендіктен, біз қосымша алдын ала өңдеу қадамы ретінде дифференциацияны қостық.

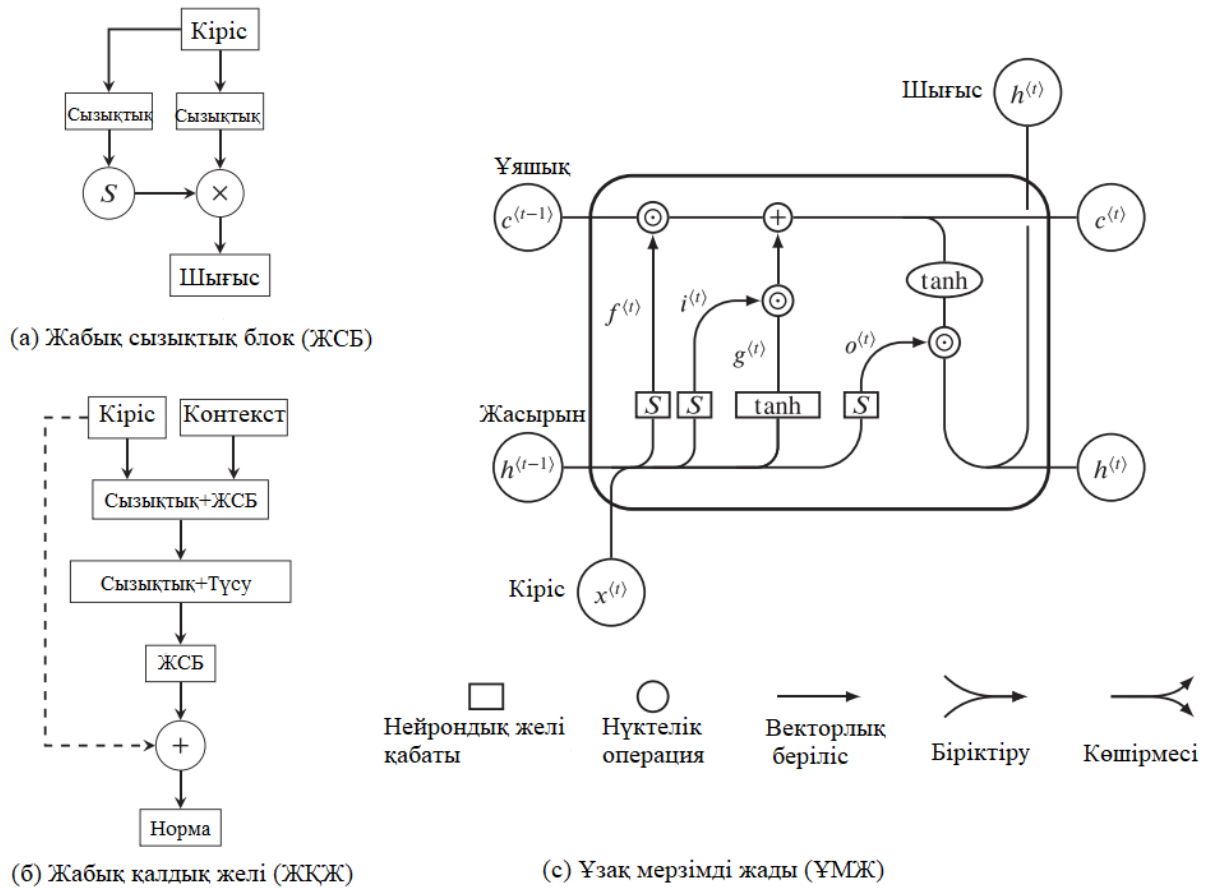
Лим Б., Арик С.О. интерпретацияланған көп көлденең уақыт сериясын болжауды орындау үшін трансформаторға негізделген УБТ әзірледі [10]. Соңғы энергетикалық зерттеулер УБТ-ді күн сәулесінен фотоэлектрлік энергияны бір күн бұрын немесе желдің жылдамдығын болжау үшін пайдаланады.

УБТ категориялық айнымалыларды, сондай-ақ статикалық метадеректерді ендіруде қолданады. Әрбір объект a -да көрсетіледі D -өлшемді вектор, мұндағы $d = 8$ біздің жағдайда жеткілікті үлкен. Осыдан кейін кірістірілген сандық емес деректер де, тұрақты уақыт қатарлары да біріктіріліп, УБТ-ге жіберіледі. Біз жаттығу кезінде осы ендіру функциясының параметрлерін УБТ салмағымен бірге калибрледік.

Кіріс векторының барлық элементтері бірдей маңызды емес. Демек, УБТ 3(a)- суретте көрсетілгендей ақпарат ағынын басқаратын сызықтық блоктар сүйенеді. Вектор көшірілген, сызықтық қабат арқылы жіберілген және $[0, 1]$ интервалында жату үшін $S(x) = (1 + \exp(-x))^{-1}$ сигма тәрізді функциясымен қалыпқа келтірілген. Нөлге жақын мәндер маңызды емес бөліктерді білдіреді және керісінше болуы мүмкін. Нүктелік көбейту УБТ-дің кішігірім кіріс сипаттамаларын одан әрі өңдеуге жол бермейді, оларды нөлге орнатады.

Кіріс және қосымша контекстік вектор сызықтық емес түрлендіріліп, сызықтық блоктарға жіберіледі. Содан кейін нәтиже бастапқы кіріс векторына қосылады. Уақыт қатарының күрделілігі одан әрі сызықтық емес өңдеуді қажет етпейді деп есептесек, сызықтық блоктардың шығыстары нөлге жақын және сызықтық қабаттарды өшіреді. Осылайша, УБТ әртүрлі деректер жиынтығына бейімделеді және модельдің өзіндік күрделілігін реттейді, бұл оны қайта оқытуға төзімді етеді.

УБТ дизайны softmax функциясын статикалық метадеректерге де, айнымалылардың шағын таңдау желілері ішіндегі уақыт қатарының деректеріне де қолдана отырып, әр уақыт қадамында сәйкес функцияларды таңдауға мүмкіндік береді [7].



Сурет 3. УТТ құрылыс блоктары

Бұл вектор бірлікпен жинақталады және оны барлық ковариаттардың маңыздылық шкаласы ретінде түсіндіруге болады.

$$\sigma: IR^K \rightarrow [0,1]^K: z \mapsto \sigma(z)_j = \frac{e^{z_j}}{\sum_{k=1}^K e^{z_k}}, j=1, \dots, K \quad (3)$$

Жақында Васвани трансформаторды МО архитектурасын енгізді, ол назар аудару механизміне толығымен сүйене отырып, қайталанатын қатынастардан аулақ болады[8]. Назар аудару модельге қажет болған жағдайда кіріс тізбегінің тиісті бөліктеріне назар аударуға мүмкіндік береді. Ол маңызды функцияларды қолдайтын және кішігірім функцияларды таң қалдыратын фильтр ретінде әрекет етеді. Тарихи коварианттық деректердің x массивін ескере отырып, біз $Q = XW_1$, $sұрауын$, $K = XW_2$ кілтін және $V = XW_3$ мәндерінің матрицасын есептейміз. W_j матрицалары реттелетін параметрлер болып табылады және оларды оқу деректер жиынтығы негізінде калибрлеу керек. SoftMax (1) функциясын қолдану зейін ұпайларын береді, олардың мәндері келесідегідей өлшенеді:

$$\text{Attention}(Q, K, V) = \sigma\left(\frac{QK^T}{\sqrt{n}}\right)V, \quad (4)$$

Біз осы мақалада келтірілген сандық нәтижелерді жасау үшін Python 3.10.8-де МО құбырын орнаттық. УБТ оңтайландырудың негізгі кітапханалары PyTorch 1.12.1 және PyTorch Forecasting 0.10.3 болды. Бастапқы код ашық қол жетімді.

УБТ гиперпараметрлерін орнату үшін біз Акиба Т., Сано С.-дың «Ortuna» атты еңбегіне сүйендік, бұл Машиналық оқыту үшін арнайы жасалған гиперпараметрлерді

оңтайландырудың автоматты бағдарламалық платформасы. Ол жоғары модульділікпен ерекшеленеді, бұл бізге гиперпараметрлерді іздеу кеңістігін динамикалық түрде құруға мүмкіндік берді [9]. Барлығы біз торлы іздеу әдісімен гиперпараметрлердің әртүрлі комбинацияларын сынау арқылы 200-ден астам УБТ үйреттік. 1-кестеде біз жеке параметрлерге арналған диапазондарды, сондай-ақ соңғы УБТ моделін оқыту үшін пайдаланылған ең тиімдісін тізімдейміз.

Кесте 1. Оқытылған УТТ болжау көрсеткіштерін үш анықтамалық модельдің көрсеткіштерімен салыстыру

Гиперпараметр	Рейтинг		Үздік
	Қайдан	Қай жаққа	
Партия мөлшері	1	2048	128
Жасырын өлшем	2	12	12
Жасырын үздіксіз өлшем	2	12	10
Бас көлеміне назар	1	4	1
Түсу	0.0	0.1	0.006
Оқу жылдамдығы	0.001	0.1	0.001
LSTM қабаттары	1	4	1
Болжамдар тарихы	7	14	14

Валидация жоғалуы 16 дәуірден аспаған кезде оқу жылдамдығы бақыланды және он есе төмендеді. Партияның мөлшері 128-ге тең деп белгіленді, өйткені оның ұлғаюы да, азаюы да шығындарға айтарлықтай оң әсер еткен жоқ. Дәуірлердің максималды саны 256 деп белгіленді, бірақ біз валидация шығындары бұдан былай жақсармаған немесе тіпті қайта даярлау нәтижесінде көбейген кезде 32 шыдамдылықпен ерте тоқтауды қолдандық. Біз ең жақсы УБТ жасырын өлшемі он екі, жасырын үздіксіз өлшемі он, назар аударатын бас өлшемі бір, 0,006, бір LSTM қабаты, 14 ретроспективалық қадам және 0,001 оқу жылдамдығы бар екенін анықтадық. Модельді оқыту үшін көп басты назар аударатын параллелизацияның жоғары дәрежесіне байланысты бар болғаны 1 мин және 20 сек қажет болды.

Зерттеу нәтижелері

Жоғарғы бөлімде сипатталған модель УБТ-ге деген көзқарасымызға негіз болды. Біз продукт-момент Пирсон корреляциясы арқылы модель шығысы мен мақсатты мәндердің корреляциясын есептедік. УБТ үшін барлық анықтамалық модельдер сияқты, Р-мәні $p < 0,05$ -ке сәйкес келді, бұл нөлдік сынақ гипотезасын жоққа шығарды. Біз есептелген корреляция барлық төрт модель үшін 95% сенімділік интервалында екенін анықтадық. Кез келген модель өте жақсы жұмыс істей алады деп болжау шындыққа жанаспайтындықтан, әсіресе жарнамалық деректермен жұмыс істегенде, біз оңтайлы нәтижеден $\pm 10\%$ және $\pm 25\%$ ауытқуларды көрсетеміз. ARIMA алгоритмі ең төменгі балл жинады, нәтижелердегі ауытқулар күтілетін өндіріс жылдамдығының теріс 25% сызығынан едәуір төмен болды. Қарапайым k-NN тәсілі тарихи деректерді орташаландыру қабілетінің арқасында ARIMA-дан асып түсті. Біз декодер- ЖНЖ ды неғұрлым күрделі градиентті оңтайландыру схемасына және УБТ сияқты кіріс сипаттамаларына үйреткенімізге қарамастан, нәтижелер бұрын хабарланғаннан да нашар болды. УБТ 0,91-ге тең r^2 анықтау коэффициенті 2-кестеде келтірілген көрсеткіштерді көрсетеді. 2 минуттан аз уақыт ішінде УБТ маңызды экзогендік айнымалыларды, олардың арасындағы уақыттық қатынастарды табуы және биогаз өндірісінің жылдамдығы үшін маңызды квантильдерді шығаруды үйренді.

Кесте 2. Біздің оқытылған УБТ болжау көрсеткіштерін үш анықтамалық модельдің көрсеткіштерімен салыстыру

Үлгі	MAE		MAPE		SMAPE		RMSE
	μ	σ	μ	σ	μ	σ	
<i>k-ең жақын көрші</i>	339.58	252.98	0.17	0.14	0.16	0.12	423.42
<i>Арима</i>	420.13	384.81	0.15	0.12	0.17	0.12	569.67
<i>Декодер-ЖНЖ</i>	272.17	211.60	0.12	0.10	0.12	0.09	344.72
<i>Уақытша біріктіру трансформаторы</i>	189.55	157.10	0.08	0.07	0.08	0.06	246.17

Дискуссия

Калибрлеуден кейін біздің болашақ биогаз өндірісінің ең ықпалды көрсеткіші соңғы екі аптадағы тарихи көрсеткіш болып табылады. УБТ маңызды деп санайтын шикі тұнбаның құрғақ затпен жүктелуі және тұтану кезінде тұнбаның жоғалуы ас қорыту үшін қол жетімді органикалық заттардың мөлшеріне тікелей байланысты. Олардың жиынтық әсері шамамен 25 % құрайды, бұл ақылға қонымды болып табылады, өйткені биогаз мөлшері бастапқы шикізат мөлшеріне тура пропорционалды. Әсіресе қыста және мереке күндері аймақта туристік ағын жоғары болады, бұл түнеу санының артуына, сондай-ақ ағынды сулардың көбеюіне және биогаз өндірісінің артуына әкеледі. УБТ сонымен қатар анаэробты реактор ішіндегі температураны маңызды кіріс ретінде қарастырады. Бұл маңызды кіріс айнымалысы ретінде болуы мүмкін, өйткені кенеттен болатын өзгерістер ең төтенше жағдайларда биогаз өндірісінің толық тоқтауына әкелуі мүмкін. Нұсқаулық ретінде біз рейтинг айнымалыларын Ван Л., Лонг Ф. «Анаэробты ашыту тиімділігін болжау және машиналық оқыту алгоритмдерін қолдана отырып, маңызды пайдалану параметрлерін анықтау» атты еңбегінің нәтижелерімен салыстырамыз [6]. Олар АА үшін маңызды жұмыс параметрлерін табу үшін әртүрлі МО алгоритмдерін талдады. Метан өндірісінің ең ықпалды екі сипаттамасы-жалпы көміртегі жүктемесі және температура болып табылады. Шикі шламның құрғақ затының жүктемесі де, тұтану кезіндегі шламның жоғалуы да негізінен көміртектен тұратын органикалық заттармен байланысты. УБТ моделінде температура да өте маңызды. Осылайша, олардың нәтижелері маңызды кіріс параметрлерін анықтаудың ішкі қабілеттілігінен алынған УБТ рейтингімен жақсы сәйкес келеді.

Қорытынды

Зерттеу кезінде УТТ әртүрлі көрсеткіштері бар анықтамалық модельмен салыстырғанда жақсы нәтиже көрсетті. 0,91-ге тең r^2 ЖНЖ, k -NN және ARIMA тәсілдерімен салыстырғанда болжаудың жоғары нәтижелерін көрсетті.

УБТ жаңалықтары үш есе. Тек сандық емес, сонымен қатар категориялық және реттік белгілерді қосу арқылы біртұтас тәсілді қолдануға болады. УБТ-ны мемлекеттік мерекелер мен түндермен қамтамасыз ету жүктеменің орташа деңгейінен асатын жауын-шашынның биогаз өндірісінің жылдамдығына қалай әсер ететінін жақсы түсінуге әкелді. Екіншіден, кванттық шығын функциясы болжамдардың белгісіздігінің қосымша өлшемін қамтамасыз етеді. Үшіншіден, УБТ-ге тән айнымалыларды бақылаусыз автоматты түрде рейтингтеу мүмкіндігі және оның түсіндірілетін нәтижелері бұл үшін өте қажет құралды қамтамасыз етті.

Оқытылған УТТ туралы қосымша ақпарат сезімталдықты талдау және ішінара тәуелділік графиктеріндегі нәтижелерді визуализациялау арқылы алынды. Біз температураны немесе рН-ны оңтайлы мезофильді диапазоннан тыс реттегенде биогаз өндірісінің төмендеуін байқауға болатынын анықтадық. Бұл УБТ негізгі биохимиялық процестерді және химиялық компоненттер арасындағы байланысты мұра ете алатындығын көрсететін сенімді нәтиже. Осы мақалада келтірілген нәтижелер мәліметтер негізінде АА-ны одан әрі зерттеудің бастапқы нүктесі болып табылады.

References

- [1] *Analysis of accidents in biogas production and upgrading* / V. C. Moreno u др. *Renewable Energy*. - 2016. - m. 96. - c. 1127-1134.
- [2] *Jardine A. K., Lin D., Banjevic D. A review on machinery diagnostics and prognostics implement condition-based maintenance Mechanical systems and signal processing*. - 2006. - r. 20, 7. - c.
- [3] *Rafal Figaj. Energy and Economic Sustainability of a Small-Scale Hybrid Renewable Energy System Powered by Biogas, Solar Energy, and Wind*.
- [4] *Kairbekov ZH.K., Emelyanova V.C., Shakieva T.N., Mylytkbayeva Zh.K., Baisynbayeva R. Kataliticheskoe anaerobnoe sbrazhivanie biomassy// International Journal of Applied and Fundamental Research*.-2013. – № 10-2. – С. 243-243;
- [5] *Abu Qdais, H., Bani Hani, K., Shatnawi, N., 2010. Modeling and optimization of biogas production from a waste digester using artificial neural network and genetic algorithm. Resour. Conserv. Recycl. 54, 359–363. <https://doi.org/10.1016/j.resconrec.2009.08.012>.*
- [6] *Wang, L., Long, F., Liao, W., Liu, H., 2020. Prediction of anaerobic digestion performance and identification of critical operational parameters using machine learning algorithms. Bioresour. Technol. 298, 122495. <https://doi.org/10.1016/j.biortech.2019.122495>*
- [7] *Machine learning methods for the modelling and optimisation of biogas production from anaerobic digestion: a review . Jordan Yao Xing Ling, Yi Jing Chen, Jiawen Chen, Daniel Jia Sheng Chong, Angelina Lin Li Tan, Senthil Kumar Arumugasamy & Phei Li Lau 7. T.Pajak. Systemy termicheskoi obrabotki bytovyx otxodov v Kazakhstane- uslovia, plany, realizhatsya, New Energy, 1, 2008,2-10.*
- [8] *Tufaner, F., Demirci, Y., 2020. Prediction of biogas production rate from anaerobic hybrid reactor by artificial neural network and nonlinear regressions models. Clean Techn. Environ. Policy 22, 713–724.*
- [9] *Renisha Karki, Wachiranon Chuenchart, K.C. Surendra, Shiva Shrestha, Lutgarde Raskin, Shihwu Sung, Andrew Hashimoto, Samir Kumar Khanal. Anaerobic co-digestion: current status and perspectives, Bioresour. Technol., 330 (2021), Article 125001*
- [10] *10 Chekalkin A. Mokrushin S., automation of the process of anaerobic fermentation of organic waste, 2015 - AiP No. 1 - 39b.*