

Еркебулан Амандыкович Тулешов – кандидат технических наук, ассоциированный профессор кафедры «Робототехники и технических средств автоматизации», Satbayev University, г. Алматы, Казахстан; e-mail: y.tuleshov@satbayev.university. ORCID: <https://orcid.org/0000-0002-9146-7137>.

Айжан Есболовна Назырова – PhD, старший преподаватель кафедры «Технологий искусственного интеллекта», Евразийский национальный университет имени Л.Н. Гумилёва, г. Астана, Казахстан; e-mail: nazyrova_aye_1@enu.kz. ORCID: <https://orcid.org/0000-0002-9162-6791>.

Жанибек Назарбекулы Исабеков* – PhD, ассоциированный профессор кафедры «Робототехники и технических средств автоматизации», Satbayev University, г. Алматы, Казахстан; e-mail: z.issabekov@satbayev.university. ORCID: <https://orcid.org/0000-0003-2900-8025>.

Серикбек Елемесович Ибекеев – магистр технических наук, старший преподаватель кафедры «Электроники, телекоммуникации и космических технологий», Satbayev University, г. Алматы, Казахстан; e-mail: s.ibekeyev@satbayev.university. ORCID: <https://orcid.org/0000-0002-1991-8642>.

Information about the authors

Anar Khabai – PhD, Associate Professor of the Department of Electronics, Telecommunications and Space Technologies, Satbayev University, Almaty, Kazakhstan; e-mail: a.khabay@satbayev.university. ORCID: <https://orcid.org/0000-0002-0409-1531>.

Yerkebulan Tuleshov – Candidate of Technical Sciences, Associate Professor of the Department of Robotics and Engineering Tools of Automation, Satbayev University, Almaty, Kazakhstan; e-mail: y.tuleshov@satbayev.university. ORCID: <https://orcid.org/0000-0002-9146-7137>.

Aizhan Nazyrova – PhD, Senior Lecturer at the Department of Artificial Intelligence Technologies, L.N. Gumilyov Eurasian National University, Astana, Kazakhstan; e-mail: nazyrova_aye_1@enu.kz. ORCID: <https://orcid.org/0000-0002-9162-6791>.

Zhanibek Issabekov* – PhD, Associate Professor of the Department of Robotics and Engineering Tools of Automation, Satbayev University, Almaty, Kazakhstan; e-mail: z.issabekov@satbayev.university. ORCID: <https://orcid.org/0000-0003-2900-8025>.

Serikbek Ibekeyev – master technical science, Senior Lecturer of the Department of Electronics, Telecommunications and Space Technologies, Satbayev University, Almaty, Kazakhstan; e-mail: s.ibekeyev@satbayev.university. ORCID: <https://orcid.org/0000-0002-1991-8642>.

Редакцияға енуі 22.09.2025
Өңдеуден кейін түсуі 19.12.2025
Жариялауға қабылданды 09.01.2026

[https://doi.org/10.53360/2788-7995-2026-2\(22\)-4](https://doi.org/10.53360/2788-7995-2026-2(22)-4)



FTAXP: 50.47.00

Д.К. Сатыбалдина¹, Н.Б. Шмитов^{1*}, Н.М. Тешебаев², А.Ж. Закарина¹, К.С. Кульниязова¹

¹Л.Н. Гумилев атындағы Еуразия Ұлттық университеті,
010008, Қазақстан Республикасы, Астана қ., Сәтбаев көшесі, 2

²Әл-Фараби атындағы Қазақ ұлттық университеті,
050040, Қазақстан Республикасы, Алматы қ., Әл-Фараби даңғылы, 71

*e-mail: nurbol-970817@mail.ru

МАГИСТРАЛЬДЫҚ ҚҰБЫРЛАРДАҒЫ АҒЫП КЕТУ КООРДИНАТТАРЫН АНЫҚТАУ ҮШІН НЕЙРОНДЫҚ ЖЕЛІНІ ҚОЛДАНУ

Аңдатпа: Құбырлар суды, мұнайды, газды және басқа сұйық және газ тәрізді орталарды тасымалдау үшін кеңінен қолданылады. Құбыр жүйелерінде ағып кетудің пайда болуы табиғи ресурстардың айтарлықтай жоғалуына әкеледі және қоршаған ортаға және қоғамдық қауіпсіздікке қауіп төндіруі мүмкін. Осыған байланысты ағып кетуді уақтылы анықтау және оқшаулау міндеті мұнай-газ саласының өзекті мәселелерінің бірі болып табылады. Жұмыста қысым өлшеу деректері негізінде жасанды интеллект әдістерін пайдалана отырып, құбырдағы ағып кету координатын

©Д.К. Сатыбалдина, Н.Б. Шмитов, Н.М. Тешебаев, А.Ж. Закарина, К.С. Кульниязова, 2026

анықтау қарастырылады. MATLAB ортасында жүзеге асырылатын радиалды-базистік нейрондық желіні қолдана отырып, қысымның төмендеуінің ағып кету ағынына және ағып кету орнына дейінгі қашықтыққа тәуелділігін жуықтауға негізделген ағып кетуді оқшаулау тәсілі ұсынылды. Эксперименттік деректер әртүрлі ағып кету режимдерін имитациялау кезінде ағып кетуді анықтау жүйесін сынау арқылы алынады. Модельдеу нәтижелері әзірленген модель зерттелетін тәуелділіктің тиімді жуықтауын қамтамасыз ететінін және орташа және ірі ағып кетулер үшін шамамен 1,9 км орташа квадраттық қателікпен ағып кету координатын анықтауға мүмкіндік беретінін көрсетті, бұл құбыр жүйелерін бақылау кезінде нейрондық желі әдістерін қолдану перспективасын растайды.

Түйін сөздер: нейрондық желі, құбырдың ағуы, қысымның төмендеуі, функцияның жуықтауы, ағып кетуді анықтау жүйесі.

Кіріспе

Әлемнің әртүрлі елдерінде құбыржолдар қауіпсіздігін басқаруға және апаттардың алдын алуға деген қажеттілік артып келеді. Құбыржолдардағы ағып кетуді анықтайтын тиімді жүйені құру ағып кетумен байланысты апаттардың туындауын және олардың орналасуын уақтылы анықтауға мүмкіндік береді, сондай-ақ экономикалық шығындар мен қоршаған ортаның ластануын азайтуға немесе толықтай болдырмауға жағдай жасайды. Қазіргі уақытқа дейін құбыржолдардағы ағып кетулерді анықтау және олардың орнын белгілеу мәселелеріне арналған бірқатар жан-жақты шолу мақалалар жарияланған [1]. Өлшеу сигналдарын алу тәсілдері мен ағып кету орнын анықтау қағидалары тұрғысынан құбыржолдардағы ағып кетуді анықтау жүйелерін кең мағынада сыртқы және ішкі әдістерге бөлуге болады [2]. Сыртқы әдістер құбыржолдың сыртқы параметрлерін, мысалы акустикалық сигналдарды [3] және талшықты-оптикалық кабельдерді [4] бақылауға негізделеді. Ал ішкі әдістер, әдетте, қысым, шығын және температура сияқты параметрлердің сигналдарын жинауға негізделіп, нақты уақыттағы өтпелі процестерді модельдеу [5], теріс қысым толқыны әдісі [6], қысымның тірек нүктелері бойынша талдау және ағындар теңгерімі әдістерін қамтиды.

Құбыржолдардағы ағып кетулерді анықтаудың қолданыстағы тәсілдері мен әдістемелеріне жүргізілген сыни талдау қазіргі таңда ағып кетуді анықтауға арналған әртүрлі жүйелердің көптігіне қарамастан, әмбебап әдістеменің әлі де қалыптаспағанын көрсетті. Әрбір әдіс белгілі бір кемшіліктерге ие. Негізгі кемшіліктерге жүзеге асырудың жоғары құны, локализация дәлдігінің төмендігі, жалған іске қосылулар санының көптігі және жүзеге асырудың күрделілігі жатады. Осыған байланысты ағып кетулерді анықтаудың жаңа тәсілдерін зерттеу мәселесі өзектілігін сақтап отыр.

Төртінші өнеркәсіптік революциядан кейінгі кезеңде деректерге негізделген машиналық оқыту әдістері, дәстүрлі тәсілдермен салыстырғанда жоғары дәлдігі және графикалық процессорларға арналған тензорлық есептеулердің дамуы арқасында тиімді іске асырылуы себепті кеңінен таралуда. Осы тұрғыда құбыржол жүйелеріндегі ағып кетулерді анықтау үшін терең оқыту әдістері [7] кеңінен қолданылып келеді, өйткені олар салыстырмалы түрде кіші диаметрлі ағып кетулерді де анықтауда жоғары тиімділік көрсетеді [8]. Мұндай тәсілдер деректерді уақыттық аймақта [9] немесе жиіліктік аймақта [10] өңдеу арқылы жүзеге асырылады. Сонымен қатар, автокодтаушылар – белгіленбеген деректер негізінде оқытылып, жүйенің номиналды күйінен ауытқуларды анықтай алатын нейрондық желілер класы – құбыржолдардағы ақауларды диагностикалауда тиімді құрал ретінде қарастырылады [11]. Ал сверткіш нейрондық желілер (CNN) деректерден маңызды белгілерді бөліп алу үшін қолданылады және бірқатар сүзгілер арқылы оқытылып, деректердегі мәнді ерекшеліктерді анықтайды.

Құбыржолдардағы ағып кетулерді анықтау және локализациялаудың қолданыстағы әдістерінің кең ауқымына қарамастан, олардың көпшілігі енгізудің жоғары құнымен, жұмыс режиміндегі ауытқуларға сезімталдығымен және нақты пайдалану жағдайларында дәлдігінің шектеулілігімен сипатталады. Бұл өз кезегінде өлшеу деректерінің шектеулі көлемінде және күрделі математикалық модельдерді қолданбай-ақ сенімді локализацияны қамтамасыз ететін жаңа тәсілдерді әзірлеу қажеттілігін негіздейді. Аталған жұмыста қысым өлшемдері негізінде ағып кету координатасын анықтау мәселесі жасанды интеллект әдістерін қолдану арқылы қарастырылады. Ұсынылған тәсіл қысымның төмендеуі, ағып кету шығыны және ағып кету орнына дейінгі қашықтық арасындағы тәуелділікті аппроксимациялауға негізделген. Бұл

тәуелділік әртүрлі ағып кету режимдерін имитациялау арқылы алынған эксперименттік деректер негізінде оқытылған радиалды-базистік нейрондық желі көмегімен анықталады. Жұмыстың ғылыми жаңалығы желі құрылымының локализация дәлдігіне әсерін зерттеуде және қайта оқыту құбылысын болдырмайтын, тұрақты нәтижелерді қамтамасыз ететін минималды архитектураны негіздеуде көрініс табады. Ұсынылған әдістің қолданыстағы шешімдерден айырмашылығы – күрделі гидродинамикалық модельдерді қажет етпейді және қысымның шектеулі өлшемдерімен жұмыс істейді.

Мақала келесі түрде ұйымдастырылған. 2-бөлімде мұнай құбырындағы ағып кетудің координатасын тасымалдау процесінің өлшенетін параметрлері негізінде анықтау есебі тұжырымдалып, кіріс деректері мен ағып кету координатасы арасындағы тәуелділікті аппроксимациялауға арналған нейрондық желіге негізделген тәсіл сипатталады. Сонымен қатар, қойылған есепті шешу үшін қолданылатын радиалды-базистік нейрондық желінің архитектурасы келтіріледі. 3-бөлімде MATLAB ортасында жүргізілген есептеу экспериментінің нәтижелері ұсынылады, оның ішінде радиалды-базистік нейрондық желі параметрлерінің ағып кету орнын анықтау дәлдігіне әсері талданады. 4-бөлімде зерттеудің негізгі қорытындылары тұжырымдалып, мұнай құбырлары жүйелеріндегі ағып кетуді локализациялау дәлдігі мен тұрақтылығын арттыру мақсатында нейрондық желілердің басқа архитектураларын және гибридік тәсілдерді қолдануға байланысты болашақ зерттеу бағыттары айқындалады.

Зерттеу әдістері

Мұнай өнімдерін құбыржол арқылы тасымалдау жүйесіне келесі негізгі элементтер кіреді: мұнай өңдеу зауытынан бас айдау станциясына дейінгі қосалқы құбыржолдар; сұйықтықты айдауды және қажетті қысымды қамтамасыз ететін резервуарлық паркі бар бас айдау станциясы; желілік құрылыстарымен бірге магистральдық мұнай құбырының желілік бөлігі; қысымды ұстап тұруға арналған аралық айдау станциялары; аралық тұтынушыларға арналған тармақтар; мұнай өнімдерін қабылдау, сақтау және әрі қарай жөнелту немесе айдау үшін арналған мұнай құбырының соңғы пункті [12-14].

Тасымалдаудың стационарлық режимінде ағып кету орын алған жағдайда, технологиялық процестің өзгермейтін параметрлері ретінде тек құбыржол учаскесінің басындағы және соңындағы қысым мәндерін қарастыруға болады (тиісінше – бас айдау станциясының резервуарынан шығу нүктесінде және соңғы пункт резервуарына кіріс нүктесінде). Қалған құбыржол инфрақұрылымының жұмыс параметрлері ағып кету туындаған кезде белгілі бір дәрежеде өзгеріске ұшырайды [13, 14].

Құбыржолдағы берілген шығын Q_0 кезінде координатасы L_x болатын технологиялық учаскенің кез келген x нүктесіндегі арын h_x келесі түрде өрнектелуі мүмкін:

$$h_x(Q_0) = h_{\text{kipic}} + \sum_{i=0}^n H_i(Q_0) - [\sum_{i=0}^f h_i^{mc}(Q_0) + \sum_{i=1}^k h_i^{ca}(Q_0)], \quad (1)$$

мұндағы: h_{kipic} – технологиялық учаскенің кірісіндегі (резервуардан шығу нүктесіндегі) қысым биіктігі, м; $H_i(Q_0)$ – берілген Q_0 шығын кезінде L_x нүктесіне дейін орналасқан сорғы тудыратын қысым биіктігі, м; n – L_x нүктесіне дейін орналасқан сорғылар саны; $h_i^{mc}(Q_0)$ – берілген Q_0 шығын кезінде L_x нүктесіне дейін орналасқан жергілікті кедергідегі қысым биіктігінің жоғалуы, м; f – L_x нүктесіне дейін орналасқан жергілікті кедергілер саны; $h_i^{ca}(Q_0)$ – берілген шығын Q_0 кезінде L_x нүктесіне дейін орналасқан сызықтық аралықтағы қысым биіктігінің жоғалуы, м; k – L_x нүктесіне дейін орналасқан сызықтық учаскелер саны.

Ағып кету $Q_{\text{ак}}$ шығынымен және координатасы $L_{\text{ак}}$ нүктесінде орын алған жағдайда, ағып кету нүктесіне дейінгі шығын Q_1 мәніне дейін артады, ал ағып кету нүктесінен кейін Q_2 мәніне дейін азаяды. Аталған шығындар анықтама бойынша келесі қатынаспен байланысты:

$$Q_1 - Q_2 = Q_{\text{ак}}. \quad (2)$$

Әрі қарай анықтылық үшін ағып кету нүктесіне дейін орналасқан x_1 еркін нүктесіндегі қысымның төмендеуін есептеу жағдайын қарастырайық. Құбыржолдағы шығын Q_1 мәніне дейін артқан кезде, ағып кету нүктесіне дейінгі (координатасы L_{x1} болатын нүктеде) қысымның төмендеуі ΔP_{x1} келесіні құрайды:

$$\Delta P_{x1} = P_{x1}(Q_0) - P_{x1}(Q_1). \quad (3)$$


Жалпы түрде ΔP_{x1} функциясы Q -ға қатысты сызықтық емес болып табылады және оны келесі түрде көрсетуге болады [14, 15]:

$$\Delta P_{x1} = f(Q_{\text{ак}}, l_{\text{ак}}, t_{\text{ак}}, X, Y, K, L, T^0, x_1), \quad (4)$$

мұндағы: Q_{ak}, l_{ak}, t_{ak} – сәйкесінше ағып кетудің шығыны, координатасы және пайда болу уақыты; X, Y – негізгі және қосалқы (подпорлық) сорғылар параметрлерінің векторлары (айналу жылдамдығы, қосылу және өшірілу уақыты); K – мұнай өнімдерінің сапа параметрлерінің векторы (мысалы, тығыздық, тұтқырлық); L – желілік учаскедегі ысырмалар параметрлері (ысырманың орны, ашылу/жабылу уақыты, ысырманың нөлдік нүктеге қатысты координатасы); T^0 – мұнай өнімінің температурасы; x_1 – қысымның төмендеуі ΔP_{x1} есептелетін нүктенің координатасы; f – қысымның төмендеуі ΔP тәуелділігін сипаттайтын функция.


Белгілі f тәуелділігі бойынша, қысымның төмендеуі ΔP шамасын және мұнай өнімін тасымалдау процесінің қалған параметрлерінің мәндерін біле отырып, ағып кету орнының координатасын l_{ak} анықтауға болады. Анықтау дәлдігі параметрлерді өлшеу дәлдігіне және f функциясын аппроксимациялау сапасына тәуелді болады. Аталған функцияны аппроксимациялау есебін жасанды нейрондық желілерді қолдану арқылы шешуге болады.

Белгілі болғандай, q шығынымен ағып кетудің пайда болуы құбыржолдағы сұйықтың қысым биіктігінің, сәйкесінше қысымының төмендеуіне алып келеді (1-сурет). Құбыржолдың кез келген нүктесіндегі қысымның төмендеуі ΔP жалпы түрде (4) формуламен сипатталуы мүмкін. ΔP -ны (4) формула бойынша есептеу үшін f функциясын аппроксимациялау қажет.



Сурет 1 – q шығынымен ағып кету кезінде құбыржолдағы қысым биіктігінің төмендеуі

Берілген функцияны аппроксимациялау үшін көпқабатты тікелей таралатын нейрондық желілер класына жататын радиалды-базистік нейрондық желі (*RBFN, Radial Basis Function Networks*) қолданылады. Радиалды-базистік желі R кіріс бар екі қабатты нейрондық желі болып табылады. Әрбір кіріс бірнеше элементтен тұруы мүмкін (2-сурет) [7].



Сурет 2 – Радиалды-базистік нейрондық желінің құрылымдық сұлбасы

Радиалды-базистік нейрондық желілерді қолдану олардың бірқатар артықшылықтарымен түсіндіріледі. Атап айтқанда, RBF-желілер сызықтық емес тәуелділіктерді аппроксимациялауда жоғары қабілетке ие, бұл құбыржол жүйелеріндегі күрделі процестерді модельдеу кезінде ерекше маңызды. Сонымен қатар, олар оқыту процесінің жылдам жинақталуымен, параметрлерін баптаудың қарапайымдылығымен, сондай-ақ кіріс деректеріндегі шу мен өлшеу қателіктеріне төзімділігімен сипатталады. Осы қасиеттерінің арқасында радиалды-базистік желілер техникалық жүйелердегі идентификация, аппроксимация және болжау есептерін шешуде тиімді қолданылады.

Жасырын қабат нейрондарының беру функциясы келесі түрде анықталатын симметриялы қоңырау тәрізді функция болып табылады:

$$radbas(n) = e^{-n^2}. \quad (5)$$

Шығыс қабаты нейрондарының беру функциясы ретінде *purelin* сызықтық функциясы қолданылады. Кіріс қабатының салмақтау функциясы кіріс матрицасының әрбір бағаны мен салмақтар матрицасының әрбір жолы арасындағы евклидік қашықтықты анықтайды [15–17]:

$$dist(w_i, p_j) = \sqrt{(w_i - p_j)^2} \quad (6)$$

Радиалды-базистік нейрондық желіні модельдеу және оны оқыту MATLAB бағдарламалық ортасында Neural Network Toolbox құралдар жинағын пайдалану арқылы жүзеге асырылды. Жалпы түрдегі радиалды-базистік желілерді модельдеу және салмақтар мен ығысу параметрлерін автоматты түрде баптау үшін *newrbe* және *newrb* функциялары қолданылады:

net = newrbe(P, T, SPREAD), net = newrb(P, T, GOAL, SPREAD),


мұндағы: *GOAL* – квадраттық қателіктің орташа мәнінің талап етілетін шамасы (әдепкі мәні – 0); *SPREAD* – *radbas* функциясының тіктігін анықтайтын әсер ету параметрі (әдепкі мәні – 1); *P* – өлшемі $R \times Q$ болатын кіріс деректер массиві, мұнда R – кіріс параметрлерінің саны, Q – оқыту таңдамасындағы векторлар саны; *T* – өлшемі $S \times Q$ болатын мақсатты мәндер массиві, мұнда S – шығыс параметрлерінің немесе кластар саны.

Зерттеу нәтижелері

Қысым датчигі арқылы мұнай өнімін іріктеу сәтінде тіркелген қысым өзгерістерінің эксперименттік деректерін қарастырайық. Бұл деректер ағып кету орны мен қысым датчигі арасындағы әртүрлі қашықтықтарда, сондай-ақ ағып кету шығынының әртүрлі мәндерінде алынған (1-кесте) [14-16]. Деректер магистральдық құбыржолдағы ағып кетуді анықтау жүйесін (ҚАКАЖ) сынау барысында эксперименттік жолмен алынған. Сынақтар барысында ҚАКАЖ жұмысы құбыржолдан сұйықтықтың ағып кетуін имитациялау арқылы тексерілді, яғни мұнай өнімі магистральдық құбыржолдан қысымсыз сыйымдылыққа іріктеліп алынды. Имитацияланған ағып кету мөлшері Ду 25 Ру 16 МПа шарлы кранының көмегімен реттелді (3-сурет).

Кесте 1 – ағып кету шығынының әртүрлі мәндері мен ағып кету орны мен қысым датчигі арасындағы қашықтыққа байланысты қысымның төмендеуі, кгс/см²

Ағып кету шығыны, л/мин	Ағып кету орны мен қысым датчигі арасындағы қашықтық, км				
	79	60	53	44	40
160	0,0355	0,0450	0,0500	0,0570	0,0625
120	0,0350	0,0385	0,0430	0,0495	0,0535
100	0,0290	0,0360	0,0400	0,0465	0,0500
80	0,0265	0,0278	0,0284	0,0300	0,0315
60	-	-	-	0,0240	0,0248
40	-	-	-	-	0,0195




Сурет 3 – Магистральдық құбыржолдан мұнай өнімін іріктеу сұлбасы

3-суретте магистральдық құбыржолдан мұнай өнімін іріктеу сұлбасы көрсетілген, мұнда: 1 – ауыстырмалы дроссельдік шайбаларды орнатуға арналған фланецті қосылыс; 2 – магистральдық мұнай құбыры; 3 – фланецті қосылыс; 4 – ажыратқыш кран; 5 – ауаны шығару краны; 6 – МО-160 манометрі (0–60 кгс/см²), дәлдік класы 0,4; 7, 8 – Ду 25 Ру 16 МПа шарлы крандар; 9 – жоғары қысымды шланг; 10 – қысымсыз бак; 11 – Ду 100 ысырма; 12 – Ду 100-ден Ду 25-ке өтпелі қосылыс.


Зерттелетін тәуелділікті аппроксимациялау үшін радиалды-базистік архитектуралы нейрондық желі қолданылады (2-сурет). SPREAD әсер ету параметрінің мәнін өзгерту арқылы берілген функцияны ең жоғары дәлдікпен аппроксимациялауды қамтамасыз ететін радиалды-базистік желінің құрылымы таңдалды.

Бірінші кезеңде нейрондық желі қысым датчигінен 40, 53, 60 және 79 км қашықтықтарда орын алған ағып кетулер кезінде алынған эксперименттік деректер негізінде оқытылды. Осыдан кейін ағып кету координатасын анықтау арқылы нейрондық желінің дәлдігі тексерілді, яғни ағып кету 44 км қашықтықта және шығындары 80, 100, 120 және 160 л/мин болған жағдайда бағаланды (1-кесте). Бастапқы экспериментте SPREAD параметрінің мәні 0,1-ге тең деп қабылданды. Модельдеу нәтижелері бойынша аппроксимацияланатын функцияның графигі тұрғызылып, қателік есептелді.

Нәтижелерді талдау (4-сурет) көрсеткендей, SPREAD параметрінің кіші мәнінде (SPREAD = 0,1) радиалды-базистік нейрондық желі аппроксимацияның жеткілікті сапасын қамтамасыз етпейді: дәл нәтижелер тек желі оқытылған деректер үшін ғана алынады. Аппроксимация дәлдігін арттыру мақсатында SPREAD параметрі кең ауқымда (1-ден 100-ге дейін) өзгертілді. Нәтижесінде есептеу қателігінің SPREAD параметріне тәуелділік графигі тұрғызылды (5-сурет).




Сурет 4 – SPREAD = 0,1 кезінде радиалды-базистік нейрондық желіні қолдану арқылы алынған $\Delta P = f(Q_{ак}, l_{ак})$ тәуелділік графигі



Сурет 5 – Модельді 44 км қашықтықта тексеру кезінде радиалды-базистік нейрондық желінің есептеу қателігінің SPREAD параметріне тәуелділігі

Алынған нәтижелерді талдау ағып кету координатасын анықтаудың ең аз қателігі (1,5-2 км) SPREAD параметрінің 18-29 және 33-41 аралықтарындағы мәндерінде қол жеткізілетінін көрсетеді. SPREAD параметрінің оңтайлы мәні таңдалғаннан кейін екі айнымалыдан тұратын аппроксимацияланатын функцияның графигі тұрғызылды (6-сурет).



Сурет 6 – SPREAD = 35 кезінде радиалды-базистік нейрондық желіні қолдану арқылы алынған $\Delta P = f(Q_{ак}, l_{ак})$ тәуелділік графигі

Ғылыми нәтижелерді талқылау

Модельдеу нәтижелерін талдау радиалды-базистік нейрондық желінің қысымның төмендеуі, ағып кету шығыны және ағып кету орнына дейінгі қашықтық арасындағы зерттелетін тәуелділікті жоғары дәлдікпен аппроксимациялауға мүмкіндік беретінін көрсетеді. Алынған екі айнымалы функция күрт өзгерістерсіз бірқалыпты сипатқа ие және оқыту таңдамасының нүктелерінде де, тексеру нүктелерінде де жоғары аппроксимация дәлдігін қамтамасыз етеді. Сонымен қатар, қысым датчигінен 79 км қашықтықта ағып кету шығынының кіші мәндерінде (40 л/мин) функцияның белгілі бір ауытқуы байқалады. Бұл ауытқу аталған параметрлер аймағында эксперименттік деректер санының жеткіліксіздігімен түсіндіріледі. Алынған нәтижелер радиалды-базистік архитектураға негізделген әзірленген нейрондық желі моделінің ағып кету салдарынан туындайтын қысымның төмендеуі ΔP мен ағып кету шығыны $Q_{ум}$ және ағып кету орнына дейінгі қашықтық $l_{ум}$ арасындағы тәуелділікті жеткілікті дәлдікпен сипаттай алатынын көрсетеді.

Әзірленген модель орташа және ірі ағып кетулер кезінде ағып кету координатасын орташа квадраттық қателігі шамамен 1,9 км деңгейінде анықтауға мүмкіндік береді. Нейрондық желі моделін қолдану ағып кетуді анықтаудың параметрлік жүйесінің тиімділігін арттыруға ықпал етеді, өйткені ағып кету координатасын анықтау дәлдігі жоғарылайды. Ұсынылған модельді енгізу қолданыстағы бақылау жүйелерін елеулі жаңғыртуды талап етпейтінін атап өткен жөн, себебі оны бар қысым датчиктері мен контроллерлерді пайдалану арқылы жүзеге асыруға болады. Алайда, нейрондық желі моделінің аз ағып кетулер кезіндегі дәлдігін бағалау үшін қосымша эксперименттік зерттеулер жүргізу қажет.

Қорытынды

MATLAB ортасында әртүрлі шығын мәндері кезінде алынған эксперименттік деректер негізінде құбыржолдағы ағып кету координатасын анықтауға арналған радиалды-базистік нейрондық желі әзірленіп, жүзеге асырылды. Ұсынылған модель қысымның төмендеуі, ағып кету шығыны және ағып кету орнына дейінгі қашықтық арасындағы тәуелділікті тиімді аппроксимациялайды және орташа және ірі ағып кетулер үшін шамамен 1,9 км деңгейіндегі орташа квадраттық қателікті қамтамасыз етеді. Модельді іске асыру қолданыстағы ағып кетуді анықтау жүйелерін елеулі жаңғыртуды талап етпейді және ағып кету координатасын анықтау дәлдігін арттыруға мүмкіндік береді. Кіші ағып кетулер үшін қосымша эксперименттік тексерулер жүргізу қажет. Алынған нәтижелерді құбыржол тасымалдау жүйесін интеллектуалды мониторингтеу және диагностика жүйелерін әзірлеуде қолдануға болады. Болашақ зерттеулердің перспективалары нейрондық желілердің басқа архитектураларын, соның ішінде терең, рекурренттік және сверткіш модельдерді талдау және салыстырмалы бағалаумен, сондай-ақ нейрондық желілерді сигналдар теориясы мен статистикалық

талдаудың классикалық әдістерімен біріктіретін гибридік тәсілдерді зерттеумен байланысты. Бұл өз кезегінде құбыржол жүйелерінің әртүрлі жұмыс режимдерінде ағып кету координатасын анықтаудың дәлдігі мен тұрақтылығын арттыруға мүмкіндік береді.

Әдебиеттер тізімі

1. Adegboye M.A. Recent advances in pipeline monitoring and oil leakage detection technologies: Principles and approaches / M.A. Adegboye, W.K. Fung, A. Karnik // *Sensors*. – 2019. – Vol. 19. – 2548. <https://doi.org/10.3390/s19112548>.
2. Arifin B. M. S., Li Z., Shah S. L., Meyer G. A., Colin A. A novel data-driven leak detection and localization algorithm using the Kantorovich distance // *Computers & Chemical Engineering*. – 2018. – Vol. 108. – P. 300-313. <https://doi.org/10.1016/j.compchemeng.2017.09.022>.
3. Li S.Z. Leak detection of water distribution pipeline subject to failure of socket joint based on acoustic emission and pattern recognition / S.Z. Li, Y.J. Song, G.Q. Zhou // *Measurement*. – 2018. – Vol. 115. – P. 39-44. <https://doi.org/10.1016/j.measurement.2017.10.021>.
4. Zhang S. Pipeline deformation monitoring using distributed fiber optical sensor / S. Zhang, B. Liu, J. He // *Measurement*. – 2019. – Vol. 133. – P. 208-213. <https://doi.org/10.1016/j.measurement.2018.10.021>.
5. Pipeline rupture detection using real-time transient modelling and convolutional neural networks / J. Smith et al // *Proceedings of the 12th International Pipeline Conference (IPC 2018)*, Calgary, Canada. – New York, NY: ASME, 2018. <https://doi.org/10.1115/IPC2018-78426>.
6. A novel location algorithm for pipeline leakage based on the attenuation of negative pressure wave / J. Li et al // *Process Safety and Environmental Protection*. – 2019. – Vol. 123. – P. 309-316. <https://doi.org/10.1016/j.psep.2019.01.010>.
7. Deeppipe: A deep-learning method for anomaly detection of multi-product pipelines / J. Zheng et al // *Energy*. – 2022. – Vol. 259. – 125025. <https://doi.org/10.1016/j.energy.2022.125025>.
8. A small leakage detection approach for gas pipelines based on CNN / J. Li et al // *Proceedings of the CAA Symposium on Fault Detection, Supervision and Safety for Technical Processes (SAFEPROCESS)*, Xiamen, China. – 2019. – P. 390-394. <https://doi.org/10.1109/SAFEPROCESS45799.2019.9213371>.
9. A two-stage deep-learning based detection method for pipeline leakage and transient conditions / I. Amini et al // *Proceedings of the IEEE Electric Power and Energy Conference (EPEC)*, Edmonton, Canada. – 2020. – P. 1-5. <https://doi.org/10.1109/EPEC48502.2020.9320021>.
10. Deep learning identifies leak in water pipeline system using transient frequency response / Z. Liao et al // *Process Safety and Environmental Protection*. – 2021. – Vol. 155. – P. 355-365. <https://doi.org/10.1016/j.psep.2021.09.033>.
11. Cody R. Detecting leaks in water distribution pipes using a deep autoencoder and hydroacoustic spectrograms / R. Cody, B. Tolson, J. Orchard // *Journal of Computing in Civil Engineering*. – 2020. – Vol. 34. – 4020001. [https://doi.org/10.1061/\(ASCE\)CP.1943-5487.0000881](https://doi.org/10.1061/(ASCE)CP.1943-5487.0000881).
12. Лурье М.В. Проектирование и эксплуатация нефтепроводов: учебник для студентов технических вузов / М.В. Лурье, Б.Н. Мастобаев, А.Е. Сощенко. – М.: Инфра-Инженерия, 2023. – 384 с.
13. Беккер А.А. Трубопроводный транспорт нефти и газа: учебное пособие / А.А. Беккер, В.А. Иванов. – СПб.: Лань, 2020. – 256 с.
14. Peabody R. (Ed.) *Handbook of pipeline engineering*. – Cham: Springer, 2023.
15. Булатов А.Ф. Повышение эффективности автоматизированной системы обнаружения утечек из нефтепродуктопроводов на основе интеллектуальных технологий / А.Ф. Булатов. – Уфа: УГАТУ, 2015. – 235 с.
16. Osiadacz A. *Flow modelling and control in pipeline systems: A formal systematic approach* / A. Osiadacz. – Cham: Springer, 2021. <https://doi.org/10.1007/978-3-030-59246-2>.
17. *Pipeline inspection and health monitoring technology: The key to integrity management* / H. Lu et al. – Singapore: Springer, 2023. <https://doi.org/10.1007/978-981-19-6798-6>.

References

1. Adegboye M.A. Recent advances in pipeline monitoring and oil leakage detection technologies: Principles and approaches / M.A. Adegboye, W.K. Fung, A. Karnik // *Sensors*. – 2019. – Vol. 19. – 2548. <https://doi.org/10.3390/s19112548>. (In English).

2. Arifin B. M. S., Li Z., Shah S. L., Meyer G. A., Colin A. A novel data-driven leak detection and localization algorithm using the Kantorovich distance // Computers & Chemical Engineering. – 2018. – Vol. 108. – P. 300-313. <https://doi.org/10.1016/j.compchemeng.2017.09.022>. (In English).
3. Li S.Z. Leak detection of water distribution pipeline subject to failure of socket joint based on acoustic emission and pattern recognition / S.Z. Li, Y.J. Song, G.Q. Zhou // Measurement. – 2018. – Vol. 115. – P. 39-44. <https://doi.org/10.1016/j.measurement.2017.10.021>. (In English).
4. Zhang S. Pipeline deformation monitoring using distributed fiber optical sensor / S. Zhang, B. Liu, J. He // Measurement. – 2019. – Vol. 133. – P. 208-213. <https://doi.org/10.1016/j.measurement.2018.10.021>. (In English).
5. Pipeline rupture detection using real-time transient modelling and convolutional neural networks / J. Smith et al // Proceedings of the 12th International Pipeline Conference (IPC 2018), Calgary, Canada. – New York, NY: ASME, 2018. <https://doi.org/10.1115/IPC2018-78426>. (In English).
6. A novel location algorithm for pipeline leakage based on the attenuation of negative pressure wave / J. Li et al // Process Safety and Environmental Protection. – 2019. – Vol. 123. – P. 309-316. <https://doi.org/10.1016/j.psep.2019.01.010>. (In English).
7. Deeppipe: A deep-learning method for anomaly detection of multi-product pipelines / J. Zheng et al // Energy. – 2022. – Vol. 259. – 125025. <https://doi.org/10.1016/j.energy.2022.125025>. (In English).
8. A small leakage detection approach for gas pipelines based on CNN / J. Li et al // Proceedings of the CAA Symposium on Fault Detection, Supervision and Safety for Technical Processes (SAFEPROCESS), Xiamen, China. – 2019. – P. 390-394. <https://doi.org/10.1109/SAFEPROCESS45799.2019.9213371>. (In English).
9. A two-stage deep-learning based detection method for pipeline leakage and transient conditions / I. Amini et al // Proceedings of the IEEE Electric Power and Energy Conference (EPEC), Edmonton, Canada. – 2020. – P. 1-5. <https://doi.org/10.1109/EPEC48502.2020.9320021>. (In English).
10. Deep learning identifies leak in water pipeline system using transient frequency response / Z. Liao et al // Process Safety and Environmental Protection. – 2021. – Vol. 155. – P. 355-365. <https://doi.org/10.1016/j.psep.2021.09.033>. (In English).
11. Cody R. Detecting leaks in water distribution pipes using a deep autoencoder and hydroacoustic spectrograms / R. Cody, B. Tolson, J. Orchard // Journal of Computing in Civil Engineering. – 2020. – Vol. 34. – 4020001. [https://doi.org/10.1061/\(ASCE\)CP.1943-5487.0000881](https://doi.org/10.1061/(ASCE)CP.1943-5487.0000881). (In English).
12. Lur'e M.V. Proektirovanie i ehkspluatatsiya nefteprovodov: uchebnik dlya studentov tekhnicheskikh vuzov / M.V. Lur'e, B.N. Mastobaev, A.E. Soshchenko. – M.: Infra-Inzheneriya, 2023. – 384 s. (In Russian).
13. Bekker A.A. Truboprovodnyi transport nefti i gaza: uchebnoe posobie / A.A. Bekker, V.A. Ivanov. – SPb.: Lan', 2020. – 256 s. (In Russian).
14. Peabody R. (Ed.) Handbook of pipeline engineering. – Cham: Springer, 2023. (In English).
15. Bulatov A.F. Povyshenie ehffektivnosti avtomatizirovannoi sistemy obnaruzheniya utechek iz nefteproduktoprovodov na osnove intellektual'nykh tekhnologii / A.F. Bulatov. – Ufa: UGATU, 2015. – 235 s. (In Russian).
16. Osiadacz A. Flow modelling and control in pipeline systems: A formal systematic approach / A. Osiadacz. – Cham: Springer, 2021. <https://doi.org/10.1007/978-3-030-59246-2>. (In English).
17. Pipeline inspection and health monitoring technology: The key to integrity management / H. Lu et al. – Singapore: Springer, 2023. <https://doi.org/10.1007/978-981-19-6798-6>. (In English).

Алғыс білдіру

Зерттеу Қазақстан Республикасы Ғылым және жоғары білім министрлігінің Ғылым комитеті тарапынан қаржыландырылды (грант № AP26197893).

Д.К. Сатыбалдина¹, Н.Б. Шмитов^{1*}, Н.М. Тешебаев², А.Ж. Закарина¹, К.С. Кульниязова¹

¹Евразийский национальный университет им. Л.Н. Гумилева,
010008, Республика Казахстан, г. Астана, ул. Сатпаева, 2

²Казахский национальный университет им. Аль-Фараби,
050040, Республика Казахстан, г. Алматы, пр. Аль-Фараби, 71

*e-mail: nurbol-970817@mail.ru

ПРИМЕНЕНИЕ НЕЙРОННОЙ СЕТИ ДЛЯ ОПРЕДЕЛЕНИЯ КООРДИНАТЫ УТЕЧКИ В МАГИСТРАЛЬНЫХ ТРУБОПРОВОДАХ

Трубопроводы широко используются для транспортировки воды, нефти, газа и других жидких и газообразных сред. Возникновение утечек в трубопроводных системах приводит к значительным потерям природных ресурсов и может создавать угрозу окружающей среде и общественной безопасности. В связи с этим задача своевременного обнаружения и локализации утечек является одной из актуальных проблем нефтегазовой отрасли. В работе рассматривается задача определения координаты утечки в трубопроводе на основе данных измерений давления с использованием методов искусственного интеллекта. Предложен подход к локализации утечек, основанный на аппроксимации зависимости падения давления от расхода утечки и расстояния до места утечки с применением радиально-базисной нейронной сети, реализованной в среде MATLAB. Экспериментальные данные получены в ходе испытаний системы обнаружения утечек при имитации различных режимов утечки. Результаты моделирования показали, что разработанная модель обеспечивает эффективную аппроксимацию исследуемой зависимости и позволяет определять координату утечки со среднеквадратичной погрешностью около 1,9 км для средних и крупных утечек, что подтверждает перспективность применения нейросетевых методов в задачах мониторинга трубопроводных систем.

Ключевые слова: Нейронная сеть, утечка в трубопроводе, падение давления, аппроксимация функции, система обнаружения утечек.

D.K. Satybaldina¹, N.B. Shmitov^{1*}, N.M. Teshebayev², A.Zh. Zakarina¹, K.S. Kulniyazova¹

¹L.N. Gumilyov Eurasian National University,
010008, Republic of Kazakhstan, Astana, 2 Satpayev St.

²Al-Farabi Kazakh National University,
050040, Republic of Kazakhstan, Almaty, 71 Al-Farabi Ave.

*e-mail: nurbol-970817@mail.ru

APPLICATION OF A NEURAL NETWORK FOR DETERMINING THE LEAK LOCATION IN MAIN PIPELINES

Pipelines are widely used for the transportation of water, oil, gas, and other liquid and gaseous media. The occurrence of leaks in pipeline systems leads to significant losses of natural resources and may pose a threat to the environment and public safety. In this regard, the problem of timely leak detection and localization remains one of the most important challenges in the oil and gas industry. This paper addresses the problem of determining the leak location in a pipeline based on pressure measurement data using artificial intelligence methods. An approach to leak localization is proposed based on approximating the relationship between pressure drop, leak flow rate, and the distance to the leak location using a radial basis function neural network implemented in the MATLAB environment. Experimental data were obtained during testing of a leak detection system under simulated leak conditions with different operating modes. The simulation results demonstrate that the developed model provides an effective approximation of the studied relationship and allows the leak location to be determined with a root-mean-square error of approximately 1.9 km for medium and large leaks, confirming the potential of neural network-based methods for pipeline monitoring applications.

Key words: neural network, pipeline leak, pressure drop, function approximation, leak detection system.

Авторлар туралы мәліметтер

Дана Каримтаевна Сатыбалдина – қауымдастырылған профессор, техника ғылымдарының кандидаты, «Жүйелік талдау және басқару» кафедрасының профессор м.а., Л.Н. Гумилев атындағы Еуразия ұлттық университеті, Қазақстан Республикасы; e-mail: satybaldina_dk@enu.kz. ORCID: <https://orcid.org/0000-0001-5445-4516>.

Нурбол Бейбитович Шмитов* – «Автоматтандыру және басқару» мамандығы бойынша докторант, «Жүйелік талдау және басқару» кафедрасы, Л.Н. Гумилев атындағы Еуразия ұлттық университеті, Қазақстан Республикасы; e-mail: nurbol-970817@mail.ru. ORCID: <https://orcid.org/0000-0002-6402-9633>.

Нұрдаулет Мұратбекұлы Тешебаев – «Интеллектуалды басқару жүйелері» мамандығы бойынша докторант, Жасанды интеллект және Big Data кафедрасы, Өл-Фараби атындағы Қазақ ұлттық университеті, Қазақстан Республикасы; e-mail: nurdauletteshebaev@gmail.com. ORCID: <https://orcid.org/0000-0002-6560-6578>.

Айна Жанузаковна Закарина – PhD, «Жүйелік талдау және басқару» кафедрасының аға оқытушысы, Л.Н. Гумилев атындағы Еуразия ұлттық университеті, Қазақстан Республикасы; e-mail: zakarina_azh@enu.kz. ORCID: <https://orcid.org/0009-0006-3875-2883>.

Корлан Сагындыковна Кульниязова – «Жүйелік талдау және басқару» кафедрасының аға оқытушысы, Л.Н. Гумилев атындағы Еуразия ұлттық университеті, Қазақстан Республикасы; e-mail: kulniyazova_ks@enu.kz. ORCID: <https://orcid.org/0000-0002-8320-2091>.

Сведения об авторах

Дана Каримтаевна Сатыбалдина – ассоциированный профессор, кандидат технических наук, и.о. профессора кафедры «Системный анализ и управление», Евразийский национальный университет им. Л.Н. Гумилева, Республика Казахстан; e-mail: satybalдина_dk@enu.kz. ORCID: <https://orcid.org/0000-0001-5445-4516>.

Нурбол Бейбитович Шмитов* – докторант, специальность «Автоматизация и управление» кафедры «Системный анализ и управление», Евразийский национальный университет им. Л.Н. Гумилева, Республика Казахстан; e-mail: nurbol-970817@mail.ru. ORCID: <https://orcid.org/0000-0002-6402-9633>.

Нурдаулет Муратбекулы Тешебаев – докторант, специальность «Интеллектуальные системы управления» кафедры Искусственного интеллекта и Big Data, Казахский национальный университет им. Аль-Фараби, Республика Казахстан; e-mail: nurdauletteshebaev@gmail.com. ORCID: <https://orcid.org/0000-0002-6560-6578>.

Айна Жанузаквна Закарина – PhD, старший преподаватель кафедры «Системный анализ и управление»; Евразийский национальный университет им. Л.Н. Гумилева, Республика Казахстан; e-mail: zakarina_azh@enu.kz. ORCID: <https://orcid.org/0009-0006-3875-2883>.

Корлан Сагындыковна Кульниязова – старший преподаватель кафедры «Системный анализ и управление»; Евразийский национальный университет им. Л.Н. Гумилева, Республика Казахстан; e-mail: kulniyazova_ks@enu.kz. ORCID: <https://orcid.org/0000-0002-8320-2091>.

Information about the authors

Dana Karimtaevna Satybalдина – Associate Professor, Candidate of Technical Sciences, Acting Professor of the Department of Systems Analysis and Control, L.N. Gumilyov Eurasian National University, Republic of Kazakhstan; e-mail: satybalдина_dk@enu.kz. ORCID: <https://orcid.org/0000-0001-5445-4516>.

Nurbol Beibitovich Shmitov* – PhD student in Automation and Control, Department of Systems Analysis and Control, L.N. Gumilyov Eurasian National University, Republic of Kazakhstan; e-mail: nurbol-970817@mail.ru. ORCID: <https://orcid.org/0000-0002-6402-9633>.

Nurdaulet Muratbekuli Teshebayev – PhD student in Intelligent Control Systems, Department of Artificial Intelligence and Big Data, Al-Farabi Kazakh National University, Republic of Kazakhstan; e-mail: nurdauletteshebaev@gmail.com. ORCID: <https://orcid.org/0000-0002-6560-6578>.

Aina Zhanuzakovna Zakarina – PhD, Senior Lecturer of the Department of Systems Analysis and Control, L.N. Gumilyov Eurasian National University, Republic of Kazakhstan; e-mail: zakarina_azh@enu.kz. ORCID: <https://orcid.org/0009-0006-3875-2883>.

Korlan Sagyndykovna Kulniyazova – Senior Lecturer of the Department of Systems Analysis and Control, L.N. Gumilyov Eurasian National University, Republic of Kazakhstan; e-mail: kulniyazova_ks@enu.kz. ORCID: <https://orcid.org/0000-0002-8320-2091>.

Редакцияға енуі 30.03.2026

Өңдеуден кейін түсуі 23.04.2026

Жариялауға қабылданды 27.04.2026

[https://doi.org/10.53360/2788-7995-2026-2\(22\)-5](https://doi.org/10.53360/2788-7995-2026-2(22)-5)



MPHTI: 50.43.15

Р.С. Бекбаева, М.Д. Сарбаева*, К.С. Бекбаев, Г.Б. Абдилова, Н.А. Айманбетов

Шәкәрім университеті,

071412, Қазақстан Республикасы, Семей қаласы, Глинка көшесі, 20А

*e-mail: sarbayeva0104@mail.ru

РАЗРАБОТКА И ВНЕДРЕНИЕ АВТОМАТИЗИРОВАННОЙ СИСТЕМЫ УПРАВЛЕНИЯ ПРОЦЕССОМ ИЗВЛЕЧЕНИЯ САХАРОВ ИЗ ПШЕНИЧНОЙ СОЛОМЫ НА ОСНОВЕ МАТЕМАТИЧЕСКОГО МОДЕЛИРОВАНИЯ КИСЛОТНОГО И ФЕРМЕНТАТИВНОГО ГИДРОЛИЗА

Аннотация: Представлена разработка и экспериментальная верификация автоматизированной системы управления двухстадийным гидролизом пшеничной соломы, реализованной на основе интеграции динамической кинетической модели в контур модельно-предиктивного управления. Объект управления характеризуется нелинейной динамикой, наличием

©Р.С. Бекбаева, М.Д. Сарбаева, К.С. Бекбаев, Г.Б. Абдилова, Н.А. Айманбетов, 2026