

ҚАЗАҚСТАН РЕСПУБЛИКАСЫ ҒЫЛЫМ ЖӘНЕ ЖОҒАРЫ БІЛІМ
МИНИСТРЛІГІ

“Қ.И. Сәтбаев атындағы Қазақ ұлттық техникалық зерттеу университеті” коммерциялық
емес акционерлік қоғамы

Автоматика және ақпараттық технологиялар институты

Электроника, телекоммуникация және ғарыштық технологиялар кафедрасы

Барысова Әмина Ниетқызы

Машиналық оқыту негізінде талшықты – оптикалық сенсорлардағы сигналдарды тану
және өңдеу

МАГИСТРЛІК ДИССЕРТАЦИЯ

7M06201 – «Телекоммуникация» білім беру бағдарламасы

Алматы 2026

ҚАЗАҚСТАН РЕСПУБЛИКАСЫ ҒЫЛЫМ ЖӘНЕ ЖОҒАРЫ БІЛІМ МИНИСТРЛІГІ

«Қ.И. Сәтбаев атындағы Қазақ ұлттық техникалық зерттеу университеті»

коммерциялық емес акционерлік қоғамы

Автоматика және ақпараттық технологиялар институты

ӘОЖ 621.396.946 (043)

Қолжазба құқығында

Барысова Әмина Ниетқызы


Магистр академиялық дәрежесін алу үшін
МАГИСТРЛІК ДИССЕРТАЦИЯ


Диссертация атауы


Машиналық оқыту негізінде талшықты – оптикалық
сенсорлардағы сигналдарды тану және өндеу

Дайындау бағыты

7М06201 – «Телекоммуникация»

Ғылыми жетекшісі,
PhD докторы, профессор
 Смайлов Н.К.
«20» 01 2026 ж.

Пікір беруші,
Energo university,
«Телекоммуникациялық
инженерия» кафедрасының
қауым. профессоры, PhD, т.ғ.к
 Ермекбаев М.М.
«21» 01 2026 ж.

Норма бақылаушы,
ЭТЖҒТ каф. аға оқытушысы,
Т.ғ.м.
 Марксұлы С.
«20» 01 2026 ж



Алматы 2026

ҚАЗАҚСТАН РЕСПУБЛИКАСЫ ҒЫЛЫМ ЖӘНЕ ЖОҒАРЫ БІЛІМ МИНИСТРЛІГІ

«Қ.И. Сәтбаев атындағы Қазақ ұлттық техникалық зерттеу университеті»
коммерциялық емес акционерлік қоғамы

Автоматика және ақпараттық технологиялар институты

Электроника, телекоммуникация және ғарыштық технологиялар кафедрасы



Магистрлік диссертацияны орындауға ТАПСЫРМА

Білім алушы: Барысова Әмина Ниетқызы

Тақырыбы «Машиналық оқыту негізінде талшықты – оптикалық сенсорлардағы сигналдарды тану және өңдеу».

Университет ректорының «28» наурыз 2024 ж. № 133-П/Ө бұйрығымен бекітілген.

Аяқталған жұмысты тапсыру мерзімі:

Магистрлік диссертацияның бастапқы деректері: *DAS* сенсорынан алынған деректер жинағы, *Машиналық Оқыту* арқылы сигналдарды тану және өңдеу.

Магистрлік диссертацияда әзірленуге жататын мәселелердің тізбесі:

а) *Талшықты-оптикалық сенсорлар* жұмысының іргелі негіздерін және сейсмикалық сигналдарды тану және өңдеу үшін қолданылатын *Машиналық Оқыту* әдістерін зерттеу және әдебиеттерге шолу жасау;

б) *DAS* сигналдарын алдын ала өңдеу;

в) *DAS* сенсорынан алынған деректер жинағын (*сигналдарды*) *машиналық оқыту* арқылы зерттеу жүргізу.

Графикалық материалдардың тізімі: зерттеу нәтижелері бар кемінде 15 слайд.

Ұсынылатын негізгі әдебиеттер:

[1] Wu, Huan, et al. "Vibration detection in distributed acoustic sensor with threshold-based technique: A statistical view and analysis." *Journal of Lightwave Technology* 39.12 (2021): 4082-4093.


- [2] Shatalin, Sergey, Tom Parker, and Mahmoud Farhadiroushan. "High definition seismic and microseismic data acquisition using distributed and engineered fiber optic acoustic sensors." *Distributed acoustic sensing in geophysics: Methods and applications* (2021): 1-32.
- [3] D. Wamriew, R. Pevzner, E. Maltsev, & D. Pissarenko, "Deep neural networks for detection and location of microseismic events and velocity model inversion from microseismic data acquired by distributed acoustic sensing array", *Sensors*, vol. 21, no. 19, p. 6627, 2021. <https://doi.org/10.3390/s21196627>
- [4] D. Wamriew, D. Dorhjie, D. Bogoev, R. Pevzner, E. Maltsev, M. Chararaet al., "Microseismic monitoring and analysis using cutting-edge technology: a key enabler for reservoir characterization", *Remote Sensing*, vol. 14, no. 14, p. 3417, 2022. <https://doi.org/10.3390/rs14143417>
- [5] Meier, M., Ross, Z., Ramachandran, A., Balakrishna, A., Nair, S., Kundzicz, P., ... & Yue, Y. (2019). Reliable real-time seismic signal/noise discrimination with machine learning. *Journal of Geophysical Research Solid Earth*, 124(1), 788-800. <https://doi.org/10.1029/2018jb016661>
- [6] P. Hernández, J. Ramírez, & M. Soto, "Deep-learning-based earthquake detection for fiber-optic distributed acoustic sensing", *Journal of Lightwave Technology*, vol. 40, no. 8, p. 2639-2650, 2022. <https://doi.org/10.1109/jlt.2021.3138724>
- [7] F. Liu, M. Wang, M. Zhang, X. Dong, G. Zhu, & X. Zhou, "Intelligent microseismic events recognition in fiber-optic microseismic monitoring system compared with electronic one", *Ieee Photonics Journal*, vol. 14, no. 2, p. 1-5, 2022. <https://doi.org/10.1109/jphot.2022.3148315>
- [8] M. Malfante, M. Mura, J. Métaixian, J. Mars, O. Macedo, & A. Inza, "Machine learning for volcano-seismic signals: challenges and perspectives", *Ieee Signal Processing Magazine*, vol. 35, no. 2, p. 20-30, 2018. <https://doi.org/10.1109/msp.2017.2779166>
- [9] Yamashita, Y., Tanoue, E. Production of bio-refractory fluorescent dissolved organic matter in the ocean interior. *Nature Geosci* 1, 579–582 (2008). <https://doi.org/10.1038/ngeo279>
- [10] <https://news.cgtn.com/news/2022-03-17/M7-4-earthquake-hits-NE-Japan-killing-at-least-four-18tnP2lai76/index.html>

Магистрлік диссертацияны дайындау
КЕСТЕСІ

Бөлімдер атауы, қарастырылатын мәселелер тізімі	Ғылыми жетекшіге және кеңесшілерге көрсету мерзімі	Ескерту
Принциптері және теориялық негіздері	15.01.2025 ж. – 14.06.2025 ж.	Орындалды
DAS деректерін алдын ала өңдеу және сигналдарды тану әдістемесі	17.06.2025 ж. – 15.10.2025 ж.	Орындалды
DAS сенсорынан алынған деректер жинағын алдын ала өңдеу және машиналық оқыту арқылы зерттеу нәтижелері	15.10.2025 ж. – 20.12.2025ж.	Орындалды

Магистрлік диссертация бөлімдерінің кеңесшілері мен
норма бақылаушының аяқталған жұмысқа қойған
қолтаңбалары

Бөлімдер атауы	Кеңесшілер (аты, әкесінің аты, тегі, ғылыми дәрежесі, атағы)	Қол қойылған күні	Қолы
DAS деректерін алдын ала өңдеу және сигналдарды тану әдістемесі	Н.К. Смайлов, PhD, ЭТЖҒТ кафедрасының профессоры	15.10.2024	
DAS сенсорынан алынған деректер жинағын алдын ала өңдеу және машиналық оқыту арқылы зерттеу нәтижелері	Н.К. Смайлов, PhD, ЭТЖҒТ кафедрасының профессоры	20.12.25	
Норма бақылау	С. Марксұлы, ЭТЖҒТ кафедрасының аға оқытушысы, т.ғ.м.	20.01.2026	

Ғылыми жетекшісі  Н.К. Смайлов

Тапсырманы орындауға алған білім алушы  Ә.Н. Барысова

Күні “30” 03. 2024 ж.

АНДАТПА

Магистрлік диссертациялық жұмыс таратылған талшықты-оптикалық сенсорлардан алынатын сейсмикалық сигналдарды машиналық оқыту әдістері негізінде тану және өңдеу мәселелерін зерттеуге арналған.

Эксперименттік бөлімде DAS деректер жинағы қолданылып, сигналдарды алдын ала өңдеу кезеңдері жүзеге асырылды. Сигналдарды тану және классификациялау үшін қадағаланатын машиналық оқыту әдісі қолданылды. Модельдің тиімділігі Accuracy, Precision, Recall және F1-score көрсеткіштері арқылы бағаланды.

Зерттеу нәтижелері ұсынылған тәсілдің DAS деректеріндегі сейсмикалық сигналдарды шуылдан тиімді ажырата алатынын және оны жер сілкіністерін ерте анықтау мен геофизикалық мониторинг жүйелерінде қолдануға болатынын көрсетті.

АННОТАЦИЯ

Магистерская диссертационная работа посвящена исследованию методов распознавания и обработки сейсмических сигналов, получаемых с распределённых волоконно-оптических сенсоров с применением методов машинного обучения.

В экспериментальной части использован набор данных DAS, выполнены этапы предварительной обработки сигналов. Для распознавания и классификации сигналов применены методы контролируемого машинного обучения. Эффективность модели оценивалась с использованием показателей Accuracy, Precision, Recall и F1-score.

Полученные результаты подтверждают возможность эффективного выделения сейсмических сигналов из шума и практическую применимость предложенного подхода в системах раннего обнаружения землетрясений и геофизического мониторинга.

ANNOTATION

This master's thesis is devoted to the study of recognition and processing of seismic signals acquired from distributed fiber-optic sensing systems using machine learning methods.

In the experimental part, a DAS dataset is used and signal preprocessing procedures are performed. Supervised machine learning methods are applied for signal recognition and classification. Model performance is evaluated using Accuracy, Precision, Recall, and F1-score metrics.

The results demonstrate that the proposed approach effectively distinguishes seismic signals from noise and can be practically applied in early earthquake detection systems and geophysical monitoring.

МАЗМҰНЫ

Кіріспе	8
1 Принциптері және теориялық негіздері	8
1.1 Талшықты-оптикалық датчиктердің жұмыс принциптері	10
1.2 Сейсмикалық сигналдың физикалық табиғаты	16
1.3 Distributed Acoustic Sensing (DAS) технологиясының стандартты сейсмикалық деректермен салыстырмалы талдауы	20
1.4 Машиналық оқытудың теориялық негіздері	26
1.5 Сейсмикалық сигналдарды машиналық оқыту арқылы өңдеудің заманауи тәсілдері	33
1 бөлім бойынша қорытынды	39
2 DAS деректерін алдын ала өңдеу және сигналдарды тану әдістемесі	40
2.1 Таратылған талшықты-оптикалық сенсордың (DOFS) деректер жиынтығы	40
2.2 DAS деректерін алдын ала өңдеу – сүзгілеу	43
2.3 Сүзгілеу әдістерінің тиімділігін бағалау	49
2.4 Сигналдарды тану және өңдеу үшін машиналық оқыту моделінің архитектурасы	51
2 бөлім бойынша қорытынды	
3 DAS сенсорынан алынған деректер жинағын алдын ала өңдеу және машиналық оқыту арқылы зерттеу нәтижелері	53
3.1 Деректерді сүзгілеу нәтижелері	54
3.2 1D-CNN моделін оқыту және нәтижелері	57
3 бөлім бойынша қорытынды	59
Қорытынды	60
Пайдаланылған әдебиеттер тізімі	
Қосымша А	62
	66

КІРІСПЕ

Қазіргі таңда жер сілкіністері адам өміріне, инфрақұрылымға және экономикалық тұрақтылыққа елеулі қауіп төндіретін ең жойқын табиғи апаттардың бірі болып табылады. Жыл сайын әлемнің әртүрлі аймақтарында тіркелетін күшті сейсмикалық оқиғалар мыңдаған адам шығынына, тұрғын үйлер мен өндірістік нысандардың қирауына, сондай-ақ көлік, энергетика және байланыс жүйелерінің істен шығуына әкеліп соғады. Осыған байланысты жер сілкіністерін уақтылы анықтау, олардың дамуын бақылау және ықтимал қауіптерді алдын ала бағалау мәселесі қазіргі ғылым мен инженериядағы ең өзекті бағыттардың бірі болып отыр. Осы талаптарға сәйкес келетін таралған талшықты-оптикалық сенсорлар (DOFS) талшық бойымен деформацияның ең шағын өзгерістерін тіркей отырып, сейсмикалық процестерді зерттеу үшін жоғары сезімтал эксперименттік база ұсынады [1,2].

Зерттеулер DOFS арқылы тіркелетін микросейсмикалық сигналдарды анықтау және классификациялау тапсырмаларында терең оқыту әдістерінің, әсіресе CNN типті нейрондық желілердің жоғары тиімділігін көрсетеді. CNN модельдерін сейсмикалық деректерге қолдану сигналдың маңызды ерекшеліктерін басым шудан ажыратып, сейсмикалық оқиғаларды дәл тануға мүмкіндік береді [3,4]. Терең оқыту алгоритмдерінің DOFS технологиясымен интеграциялануы дәстүрлі алгоритмдерге қарағанда жоғары нәтижелер көрсететіні дәлелденген, әсіресе табиғи ортаға тән күшті шу жағдайларында [5]. Сонымен қатар, талшықты-оптикалық технологияның жоғары кеңістіктік айқындығы стандартты әдістермен қол жеткізу мүмкін емес деңгейдегі детализацияны қамтамасыз етеді, бұл коллектор сипаттамаларын анықтау, оқиға орнын локализациялау және жер сілкіністерін тіркеу секілді қолданбаларда дәлдікті арттыруға мүмкіндік береді [6].

Машиналық оқыту алгоритмдері, соның ішінде опорлық векторлар әдісі (SVM) және терең оқыту архитектуралары, сейсмикалық оқиғаларды классификациялау үшін кеңінен қолданылуда. Бірқатар зерттеулерде ML модельдерінің өнімділігі дәстүрлі электрондық жүйелермен салыстырылып, тиісті дайындықтан кейін талшықты-оптикалық мониторинг жүйелері әлдеқайда жоғары классификация дәлдігін көрсете алатыны анықталған [7]. Энергия энтропиясы сияқты статистикалық ерекшеліктерді пайдалану ML модельдеріне әртүрлі сейсмикалық сигналдарды тиімді ажыратуға мүмкіндік береді, бұл геофизикалық мониторинг пен пайдалы қазбаларды барлау салаларында деректерді жинау мен талдаудың тиімді стратегияларын дамытуға септігін тигізеді [7].

DOFS пен машиналық оқытуды біріктіре қолданудың маңыздылығы үлкен көлемдегі деректерді өңдеу және интерпретациялау мүмкіндігінің артуымен айқындалады, ал мұндай деректерді дәстүрлі қолмен өңдеу әдістерімен талдау іс жүзінде мүмкін емес [8]. Сейсмикалық мониторингтің күрделі талаптарына сай болу үшін жүйелердің дәлдігін, сенімділігін және жылдамдығын үздіксіз арттыру қажет; осы тұрғыдан алғанда DOFS пен ML

интеграциясы сигналдарды автоматты тану, нақты уақыт режимінде шешім қабылдауды қолдау мүмкіндіктерін едәуір күшейтеді. Бұл тәсіл табиғи апаттарға дайындық, инфрақұрылымды қорғау және ресурстарды басқару сияқты салаларда айтарлықтай пайда әкеледі [6].

Сонымен қатар, көптеген ғылыми зерттеулер ірі жер сілкіністерінің алдында амплитудасы төмен, әлсіз және қысқа мерзімді дірілдер - форшоктар (foreshocks) жиі пайда болатынын дәлелдейді. Мысалы, 2011 жылғы Тохоку жер сілкінісіне (M9.0) дейін бірнеше апта бойы жүздеген әлсіз сейсмикалық тербелістер тіркелген, ал негізгі дүмпуден екі күн бұрын M7.3 көлеміндегі айқын форшок байқалған [9]. Сондай-ақ 2022 жылғы Фукусима маңындағы M7.4 жер сілкінісіне дейін бірнеше сағат бұрын M5–6 деңгейіндегі алдын ала дірілдер тіркелгені USGS мәліметтерінде көрсетілген. Бұл фактілер жер сілкінісінің алдында механикалық тербелістердің әлсіз формалары пайда болатынын ғылыми түрде дәлелдейді [10].

Жұмыстың мақсаты – таратылған талшықты-оптикалық сенсорлардан (DOFS/DAS) алынатын уақыттық сигналдарды автоматты түрде анықтау және жіктеу үшін машиналық оқыту модельдерінің тиімділігін зерттеу және салыстырмалы талдау жүргізу.

Жұмыстың міндеттері:

- Талшықты-оптикалық сенсорлар жұмысының іргелі негіздерін және сейсмикалық сигналдарды тану және өңдеу үшін қолданылатын Машиналық Оқыту әдістерін зерттеу және әдебиеттерге шолу жасау;

- DAS сигналдарын алдын ала өңдеу;

- DAS сенсорынан алынған деректер жинағын (сигналдарды) машиналық оқыту арқылы зерттеу жүргізу.

Зерттеу объектісі – таратылған талшықты-оптикалық сенсорлар арқылы алынатын сейсмикалық сигналдар.

Зерттеу пәні – DOFS/DAS деректерін машиналық оқыту әдістері негізінде тану және өңдеу тәсілдері.

Жұмыстың ғылыми жаңалығы DAS сенсорынан алынатын сейсмикалық сигналдарды машиналық оқыту алдында алдын ала сүзгілеудің сейсмикалық сигналдарды тану дәлдігін арттыратынын тәжірибелік түрде көрсету.

Жұмыстың практикалық маңызы. Зерттеу нәтижелері жер сілкіністерін ерте анықтау жүйелерінде, инженерлік нысандардың құрылымдық күйін мониторингілеуде және төтенше жағдайлардың алдын алу мақсатында қолданылуы мүмкін.


Магистрлік диссертация 68 беттен, 3 бөлімнен, 2 кестеден, 28 суреттен, 1 қосымшадан және 48 әдеби көзден тұрады.

1 Принципітері және теориялық негіздері

1.1 Талшықты-оптикалық датчиктердің жұмыс принциптері

Талшықты-оптикалық датчиктер оптикалық талшықтар арқылы жарықтың таралуы және жарықтың қоршаған ортаның өзгеруімен әрекеттесуі принципі бойынша жұмыс істейді. Негізгі механизм штамм, температура, қысым және тербеліс сияқты әртүрлі физикалық параметрлер әсер етуі мүмкін жарық сигналдарының модуляциясын қамтиды. Ең көп қолданылатын датчиктер Талшықты Брагг Торларына негізделген сенсорлар (FBGs) және таратылған талшықты-оптикалық сенсорлар болып табылады.

FBG негізіндегі талшықты-оптикалық сенсорлар жарық толқындарының белгілі бір толқын ұзындығын ғана шағылдырып, қалғандарын өткізетін арнайы құрылымға негізделген. Бұл құрылым талшық өзегінің сыну көрсеткішін белгілі бір аралықпен (периодпен) өзгерту арқылы жасалады. Яғни, бір модаль талшық өзегінде жарықты шағылдыратын микроскопиялық «айна» қабаттары қалыптасады (1.1-сурет) [11].



1.1 - сурет – FBG құрылымының эскизі, оның ішінде кіріс/шығыс спектрлері және позиция функциясы ретінде негізгі сыну көрсеткіші [11]

Жарық сол жақтан талшық ішіне енген кезде, ол Брэгг торы бар аймақтан өтеді. Осы аймақта жарық толқыны тордың әрбір қабатымен өзара әсерлесіп, шашырайды. Егер жарықтың толқын ұзындығы Брэгг шартын қанағаттандырса, онда әр қабаттан шашыраған толқындар бір-бірімен қосылып, күшейеді. Нәтижесінде талшық арқылы кері бағытта шағылған спектрлік пик (шегініс толқын ұзындығы) пайда болады. Дәл осы толқын ұзындығы Брэгг толқын ұзындығы деп аталады.

Бұл толқын ұзындығы тордың периодына (Λ) және талшық өзегінің тиімді сыну көрсеткішіне (n_{eff}) байланысты болады. Егер жарық Брэгг шартын қанағаттандырмаса, онда толқындар бір-бірімен күшеймей, жай ғана талшық бойымен өте береді.

Брэгг шарты келесі теңдеумен өрнектеледі (1.1-теңдеу):

$$\lambda_B = 2n_{eff}; \quad (1.1)$$

мұндағы:

λ_B - Брэгг толқын ұзындығы (шағылатын жарықтың орталық толқын ұзындығы);

n_{eff} - талшықтың тиімді сыну көрсеткіші;

Λ - тор периодына тең арақашықтық.

Осы қасиетке байланысты FBG сенсорлары температура, деформация (strain), қысым сияқты сыртқы әсерлерге өте сезімтал. Себебі сыртқы әсерлер кезінде сыну көрсеткіші мен тор периоды өзгереді, нәтижесінде шағылған жарықтың толқын ұзындығы да өзгеріп, оны өлшеу арқылы физикалық шамаларды анықтауға болады [11].

DOFS технологиясы классикалық нүктелік сейсмикалық станциялармен салыстырғанда арзан, сенімді және кең аумақты қамтитын мониторинг жүйесін құруға мүмкіндік береді. DOFS жүйесінің жұмыс істеу принципі жарықтың талшық ішінде таралу кезіндегі шашырау құбылыстарына негізделеді. Негізгі үш типті шашырау – Rayleigh, Brillouin және Raman эффектілері – әртүрлі физикалық параметрлерді (деформация, температура, акустикалық тербеліс) өлшеуге мүмкіндік береді [12]. Rayleigh шашырауы жарық толқынының кері бағытта шағылысуы арқылы микро-деформациялар мен тербелістерді анықтауға мүмкіндік берсе, Brillouin шашырауы температура мен созылуды өлшеуде тиімді, ал Raman шашырауы көбінесе температураны тіркеу үшін қолданылады [12,13]. Осы принциптерге сәйкес DOFS жүйелері екі негізгі түрге бөлінеді: DAS (Distributed Acoustic Sensing) және DTS (Distributed Temperature Sensing).

DAS (Distributed Acoustic Sensing) әдісі жер бетімен немесе жер астына көміліп төселген ұзын талшықты-оптикалық кабельді датчик ретінде пайдаланады. Бұл кабельді шартты түрде бойына сансыз көп «микрофондары» бар сызықтық сенсор ретінде елестетуге болады. Кабель арнайы құрылғы — интеррогаторға (лазерлік бақылау жүйесі) қосылады. Интеррогатор талшыққа белгілі бір жиілікте қысқа жарық импульстарын жібереді. Талшық ішіндегі микроскопиялық құрылымдық ауытқулар мен кішкене ақаулар жарық импульсының бір бөлігін кері шашыратады. Бұл құбылыс Рэлеевтік кері шашырау (Rayleigh backscattering) деп аталады. Осы шашыраған жарық толқындары бастапқы көзге - интеррогаторға қайта оралады. Интеррогатор бұл сигналдарды қабылдап, талдап, кабельдің әрбір нүктесінде не болып жатқанын анықтауға мүмкіндік береді. Жер сілкінісі сияқты сейсмикалық толқындар талшыққа жеткен кезде, олар кабель бойымен механикалық деформация тудырады (1.2-сурет) [14].

Нәтижесінде талшықтың сыну көрсеткіші мен оптикалық ұзындығы өзгеріп, Рэлеевтік кері шашырау сигналдарының фазасы ығысады. Интеррогатор осы фазалық өзгерістерді өлшеу арқылы деформацияның орын

алған нүктесін дәл анықтай алады. Қайта оралған сигналдардың амплитудасы, жиілігі және келу уақыты сияқты параметрлерін талдау арқылы біз кабельдің қай бөлігінде механикалық әсер болғанын анықтаймыз. Осы ақпарат негізінде сейсмикалық толқындардың параметрлерін (амплитуда, жылдамдық, пайда болу уақыты) анықтап, тіпті жер сілкінісінің эпицентрін есептеуге болады. Егер осындай бірнеше кабельдер немесе ұзын кабельдің бірнеше аймағы қолданылса, сейсмикалық оқиғаның орналасқан жерін нақты анықтауға болады.



1.2 - сурет – DAS (Distributed Acoustic Sensing) технологиясының жұмыс істеу принципі

DAS арқылы тіркелетін сигналдар табиғатына қарай әртүрлі формада, жиілікте және ұзақтығында болуы мүмкін. Сигналдың табиғатын анықтау үшін оның жиілік диапазоны, дауыс ұзақтығы, амплитудасы, сондай-ақ уақыттық өзгеріс ерекшеліктері талданады. Мысалы, теңіз түбіне төселген талшықты-оптикалық кабель арқылы киттің дыбыстық дабылы (blue whale call) шамамен 10–40 Гц жиілік диапазонында болады және 10–30 секундқа дейін созылады. Ал сейсмикалық толқындар әлдеқайда кең жиілік диапазонын қамтып, белгілі бір физикалық заңдылықтармен таралады.

DAS технологиясы тек сейсмикалық толқындарды ғана емес, сонымен қатар мұнай-газ бұрғылау жұмыстарын, кемелер қозғалысын, теңіз фаунасының акустикалық сигналдарын, мұздықтардың жылжу динамикасын, тіпті инфрақұрылымдық дірілдерді де анықтай алады [14]. Сол арқылы DAS

жүйесі қоршаған ортаны мониторингілеу, геофизикалық процестерді бақылау және табиғи апаттарды ерте анықтау салаларында кеңінен қолданылуда.

1.3-суреттегі карта телекоммуникациялық және инфрақұрылымдық талшықты-оптикалық желілердің DAS технологиясын қолдану арқылы әлемнің әртүрлі аймақтарында кеңінен пайдаланылып отырғанын көрсетеді. Көрсетілген инсталляциялар жүздеген және мыңдаған километрге дейін созылатын оптикалық талшықтарда жүзеге асырылған және мұнай-газ инфрақұрылымы, көлік жүйелері, телекоммуникация, сондай-ақ қауіпсіздік және мониторинг салаларын қамтиды. Мұндай ауқымды желілердің болуы DAS технологиясын тек жергілікті емес, аймақтық және тіпті жаһандық деңгейде сейсмикалық және геодинамикалық құбылыстарды бақылау үшін қолдануға мүмкіндік береді. Осы карта DAS негізіндегі мониторинг жүйелерінің кең таралғанын және олардың сейсмологияда, соның ішінде жер сілкіністерін тіркеу мен талдауда, перспективалы құрал екенін дәлелдейді.



1.3 - сурет – DAS технологиясы қолданылатын инфрақұрылымдық талшықты-оптикалық желілердің жаһандық таралуы

Талшықты-оптикалық үлестірілген температураны зондтау (DTS) -бұл жоғары кеңістіктік және уақыттық ажыратымдылықты ұсына отырып, талшықты-оптикалық кабель бойымен температураны ұзақ қашықтықта өлшеуге мүмкіндік беретін технология. DTS-тің жұмыс принципі, ең алдымен, оптикалық талшықтар арқылы берілетін лазерлік импульстің нәтижесінде Жарықтың шашырауын, атап айтқанда Раман шашырауын талдауды қамтиды [15,16]. DTS-тегі соңғы жетістіктер кеңістіктік ажыратымдылығы 0,125 м-ге дейінгі дәлдікті өлшеуге және температураның 0,01 °C-қа дейінгі ауытқуларын анықтауға мүмкіндік берді [17]. Бұл жоғары дәлдік пен сенімділік DTS-ті энергетика, құрылыс, қоршаған ортаны бақылау және


мұнай-газ салаларын қоса алғанда, әртүрлі салаларда баға жетпес құралға айналдырады.

Раман эффектісін қолданатын талшық бойымен температураны өлшеу технологиясы (DTS – Distributed Temperature Sensing) алғаш рет 1984 жылы ұсынылған. Бұл әдісте температураны анықтау үшін жарық импульстары талшық бойымен таралып, Стокс және анти-Стокс Раман шашырау сигналдарының қарқындылығы салыстырылады. Себебі анти-Стокс сигналдарының амплитудасы қоршаған ортаның температурасына қатты тәуелді болады. Дегенмен, бұл сигналдар өте әлсіз (сорғы лазер қуатынан шамамен 60-70 дБ төмен), сондықтан бастапқы кезде Раманға негізделген DTS жүйелерін қолдану техникалық тұрғыдан қиын болды.

Алайда, уақыт өте келе жоғары қуатты лазерлердің, эрбиймен легирленген талшықты күшейткіштердің (EDFA), жоғары сезімтал APD фотодетекторлардың және сигналды тиімді өңдеу алгоритмдерінің (мысалы, орташа мәнге келтіру, толқындық деноизация) дамуы Раман сигналдарының сапасын айтарлықтай жақсартты. Соның нәтижесінде DTS жүйелерінің сигнал/шу қатынасы артты және өлшеу дәлдігі мен кеңістіктік рұқсаттылығы жоғарылады.

Раманға негізделген DTS жүйесінің типтік эксперименттік құрылымы 1.4(a)-суретте көрсетілген. Жүйеде үздіксіз (CW) лазерлік жарық АОМ (Acousto-Optic Modulator) көмегімен оптикалық импульстарға түрлендіріледі. Бұл импульстар EDFA арқылы күшейтіліп, одан кейін 3×1 толқын ұзындығын бөлу/біріктіру құрылғысына (MUX/DEMUX) жіберіледі. MUX/DEMUX құрылғысының 1, 2 және 3 порттары сәйкесінше сорғы лазерінің толқын ұзындығына, Стокс және анти-Стокс Раман сигналдарына арналған. Төртінші порт арқылы осы үш сигнал бір әрі ортақ талшыққа беріледі. Күшейтілген оптикалық импульстар MMF (multimode fiber) бойымен таралған кезде, Раман шашырауынан пайда болған Стокс және анти-Стокс сигналдары кері бағытта шағылысып қайтады. Бұл кері шашыраған сигналдар MUX/DEMUX арқылы толқын ұзындығы бойынша бөлініп, әрқайсысы жеке APD детекторында қабылданып, кейін деректер жинау жүйесіне (DAQ) тіркеледі.

1.4(b) және 1.4(c) суреттерінде бөлме температурасында орналасқан стандартты 50/125 μm MMF талшығында өлшенген анти-Стокс және Стокс сигналдарының үлгілік графиктері көрсетілген [16].



1.4 - сурет – (а) Раман негізіндегі талшықты–оптикалық DTS Жүйесін Эксперименттік орнату. Бөлме температурасында жазылған Анти–Стокс (b) және Стокс (c) Раман сигналының мысалдары [16].

Осы үш сенсор – FBG, DAS және DTS – талшықты-оптикалық сезу технологияларының негізгі өкілдері болып табылады. Олардың әрқайсысы талшық бойымен әртүрлі физикалық параметрлерді (температура, деформация немесе сейсмикалық тербеліс) өлшеуге арналғанымен, сейсмикалық сигналдарды анықтау қабілеті жағынан айтарлықтай ерекшеленеді. Төменде сейсмикалық сигналдарды анықтауға арналған сенсорлардың салыстырмалы техникалық кестесі көрсетілген (1.1 - кесте).

Кесте 1.1 – Сейсмикалық сигналдарды анықтауға арналған сенсорлардың салыстыру

Сенсор түрі	Өлшейтін параметрі	Жиілік диапазоны (Гц)	Сейсмикалық сигналды анықтау қабілеті	Ерекшелігі
DTS	Температура	0 Гц	Қабілеті жоқ (тек статикалық температураны өлшейді)	Сейсмикаға арналмаған

1.1 кестенің жалғасы

FBG	Нүкелік strain (деформация), температура	0–200 Гц	Шектеулі (тек белгілі бір нүктелерде)	Дәл, бірақ дискретті (distributed емес)
DAS	Акустика, вибрация, strain	0.1–5000 Гц	Өте жоғары (үздіксіз, таратылған сенсор)	10 км–100 км бойында сейсмикалық толқындарды анықтайды

DTS жүйесі тек температураның статикалық өзгерістерін тіркейді және динамикалық сейсмикалық толқындарды өлшей алмайды. FBG сенсорлары деформация мен температураны жоғары дәлдікпен анықтайды, бірақ олар нүктелік (discrete) сенсор болғандықтан, кеңістікте таралатын сейсмикалық толқындарды толық қамти алмайды. Ал DAS технологиясы Rayleigh шашырауына негізделіп, талшық бойымен үздіксіз (distributed) және нақты уақыт режимінде сейсмикалық, акустикалық және вибрациялық сигналдарды тіркей алады. Сондықтан DAS жүйесі сейсмикалық мониторинг пен жер сілкінісін ерте анықтау үшін ең қолайлы сенсор болып саналады.

1.2 Сейсмикалық сигналдың физикалық табиғаты

Сейсмикалық сигналдар табиғи ортада пайда болатын механикалық тербелістер мен толқындық процестердің нәтижесі болып табылады. Олар Жер қабаттарында энергияның кенет босатылуынан немесе жасанды техногендік әрекеттерден туындайтын серпімді толқындар түрінде таралады. Механикалық тербеліс - дененің тепе-теңдік қалпынан ауытқып, уақыт бойынша қайталанып отыратын қозғалысы, ал сейсмикалық толқындар - осы тербелістердің кеңістікте таралуы [18].

Сейсмикалық тербелістер шығу табиғатына қарай екіге бөлінеді:

- 1) табиғи (жер сілкінісі, вулкандық белсенділік, жер қыртысының қозғалысы) және
- 2) жасанды немесе техногендік (жарылыс, бұрғылау, көлік қозғалысы, инфрақұрылымдық вибрация).

Табиғи сейсмикалық тербелістер негізінен жер қыртысындағы тектоникалық плиталардың қозғалысы, мантиядағы қысым өзгерістері немесе жер асты жыныстарының жарылуы нәтижесінде пайда болады [19]. Осындай процестер кезінде үлкен көлемдегі механикалық энергия босап, кеңістікте серпімді толқын түрінде таралады. Бұл толқындардың негізгі жиілік диапазоны 0.1-100 Гц аралығында болады және олар Жердің ішкі құрылымын зерттеу, жер сілкінісін ерте анықтау және сейсмикалық қауіпсіздікті бағалау үшін қолданылады [20].

Жасанды сейсмикалық сигналдар көлік қозғалысы, өндірістік діріл, бұрғылау станоктары немесе мұнай-газ индустриясындағы сейсмикалық барлау кезінде пайда болады. Мұндай толқындардың жиілік диапазоны табиғиға қарағанда әлдеқайда кең - 10 Гц-тен 2000 Гц-ке дейін болуы мүмкін.

Техногендік тербелістер көбіне қысқа қашықтықта таралады және олардың амплитудасы табиғи сейсмикалық толқындарға қарағанда төмен. Соған қарамастан, олар құрылыс, көпірлер, тоннельдер және инфрақұрылымдық нысандардың дірілге тұрақтылығын бағалауда аса маңызды.

Сейсмикалық сигналдардың негізгі физикалық қасиеттеріне амплитуда (A), жиілік (f), фаза (φ), энергия (E) және таралу жылдамдығы (v) жатады. Толқынның кеңістікте таралуы төмендегі теңдеумен сипатталады:

$$x(t) = A \sin(\omega t + \varphi) ; \quad (1.2)$$

мұндағы $\omega = 2\pi f$ - бұрыштық жиілік.

Ал толқынның жылдамдығы келесі формуламен анықталады:

$$v = \lambda \cdot f ; \quad (1.3)$$

мұндағы λ — толқын ұзындығы.

Сонымен, сейсмикалық сигнал — бұл табиғи немесе жасанды жолмен пайда болатын механикалық тербелістің кеңістікте таралатын серпімді толқындық формасы. Оның жиілік, амплитуда және уақыттық параметрлерін талдау арқылы Жер қойнауындағы процестерді немесе жер бетінде орналасқан объектілердің қозғалысын анықтауға болады. Қазіргі таңда сейсмикалық сигналдарды тіркеу үшін классикалық геофондармен қатар DAS жүйесі сияқты талшықты-оптикалық таратылған сенсорлар кеңінен қолданылуда [20].

Жер сілкінісі болған кезде босап шыққан энергия жер қойнауы арқылы толқын түрінде таралады. Бұл сейсмикалық толқындар жерді қатты шайқап, кей жағдайларда саз, құм сияқты жұмсақ жыныстардың қоймалжың болып, сұйықтыққа ұқсап кетуіне (ликвация) себеп болады. *Сейсмикалық* деген атау гректің *seismos* – «жер сілкінісі» деген сөзінен шыққан. Сейсмикалық толқындар көбінесе литосфералық плиталардың қозғалысынан түзіледі, алайда оларды жанартау атқылауы, көшкіндер немесе жасанды жарылыстар да тудыруы мүмкін. Бұл толқындардың қасиеттерін зерттейтін ғалымдарды сейсмологтар деп атайды. Олар сейсмограф құралдарының көмегімен толқындардың Жердің әртүрлі қабаттары арқылы өту уақытын тіркейді. Толқындар әртүрлі тығыздық пен серпімділікке ие жыныстарға тап болғанда, олар шағылысып немесе сынуға ұшырайды. Сейсмикалық толқындардың пайда болу механизмі, олардың ошақтан қалай таралатыны 1.5 - суретте көрсетілген.

Толқындардың осындай мінез-құлқына қарап, сейсмологтар олардың қандай жыныстар арқылы өткенін анықтай алады. Бұл ақпарат Жердің ішкі құрылысының сызбасын жасауға және жарықшақ жазықтарын, сондай-ақ оларға әсер ететін кернеулер мен деформацияларды анықтауға мүмкіндік береді. Сейсмикалық толқындардың қасиеттерін тек ірі масштабта ғана емес, шағын аумақтарда да қолдануға болады. Мысалы, арнайы жарылыстар немесе

дірілдеткіш құрылғылар арқылы жасанды толқындар тудырып, мұнай мен газ қорларын іздеуде қолданады [21].



1.5 - сурет – Сейсмикалық толқындардың пайда болу механизмі [21]

Сейсмикалық толқындар үш негізгі түрге бөлінеді: Р-толқындар, S-толқындар және беткі толқындар. Олардың ішінде Р және S толқындары жер қыртысының ішкі қабаттары арқылы таралатындықтан, денелік толқындар (body waves) деп аталады.

Р-толқындар немесе алғашқы (қысу) толқындар – жылдамдығы ең жоғары сейсмикалық толқындар. Жер сілкінісі кезінде сейсмограф ең алдымен дәл осы толқындарды тіркейді. Ауада олар дыбыс толқыны сияқты шамамен 330 м/с жылдамдықпен таралса, ал гранит сияқты қатты жыныстарда жылдамдығы 5000 м/с-қа дейін жетеді. Бұл толқындар ортаны кезекпен сығып және созу арқылы тарайды, яғни бөлшектердің тербелісі толқын қозғалысына параллель бағытта жүреді. Бұны созылған серіппені алға-артқа жылжытқандағы қозғалысқа ұқсатуға болады.

S-толқындар немесе екінші (кию, сілкіну) толқындар Р-толқындарға қарағанда баяу қозғалады. Бұл толқындардың ерекшелігі – бөлшектердің қозғалысы толқын таралу бағытына перпендикуляр бағытта жүреді. Яғни, олар көлденең толқындар (transverse waves) болып табылады. Мұны түсіну үшін созылған серіппенің бір бөлігін жоғары көтеріп, қайта түсірсеңіз, көлденең толқын түзіліп, серіппенің бойымен таралады - бұл S-толқындардың қозғалысына ұқсас. S-толқындар тек қатты заттар арқылы ғана таралады, сондықтан олар Жердің ішкі құрылымын анықтауда маңызды рөл атқарады. S толқындары ауа немесе су арқылы өте алмайды, бірақ амплитудасы үлкен болғандықтан Р - толқындарына қарағанда жойқын [22].


Беткі толқындар Жердің ең жоғарғы қабаты бойымен таралып, су бетіндегі толқындарға ұқсайды. Олар көбінесе жер сілкінісінің ошағы жер бетіне жақын болған жағдайда түзіледі. Жылдамдығы S-толқындарға

қарағанда төмен болғанымен, амплитудасы әлдеқайда үлкен, сондықтан олар ең қауіпті және бүлдіргіш сейсмикалық толқындар болып саналады. Беткі толқындар екі түрге бөлінеді:

1) Рэйлей толқындары (Rayleigh waves) жер бетінде судағы толқын секілді домалақ қозғалыс жасайды. Күшті жер сілкінісі кезінде ашық алаңдарда (мысалы, автотұрақтарда) автокөліктердің жоғары-төмен шайқалғанын байқаған куәгерлер болған.

2) Лав толқындары (Love waves) жерді көлденең бағытта, яғни оңға-солға қарай сілкіндіреді. Бұл толқындар Рэйлей толқындарынан аздап жылдам және вертикалды қозғалыс тудырмайды. Көлденең ығыстыру әсерінен ғимараттар мен құрылыстарға үлкен зиян келтіреді. Сейсмикалық толқындардың негізгі түрлерінің жер арқылы таралу механизмдері 1.6 – суретте көрсетілген.

Сейсмикалық толқындардың әртүрлі типтерін талдау арқылы ғалымдар Жердің ішкі құрылымын зерттейді. Р және S толқындарының станцияға жету уақытын салыстыру арқылы жер сілкінісінің қаншалықты қашықтықта болғанын анықтауға болады. Егер сейсмографтар S-толқындарын тіркей алатындай жақын болмаса, онда әртүрлі нүктелерден тіркелген Р-толқындардың мәліметтері компьютерлік модельдер арқылы өңделіп, жер сілкінісінің шамамен орналасқан орны есептеледі [21].



1.6 - сурет – Сейсмикалық толқындардың негізгі түрлерінің (Р-толқын, S-толқын, Rayleigh толқыны, Love толқыны) жер арқылы таралу механизмдері [21]

1.3 Distributed Acoustic Sensing (DAS) технологиясының стандартты сейсмикалық деректермен салыстырмалы талдауы

Стандартты сейсмикалық деректер деп біз әдетте сейсмометрлер немесе геофондар арқылы тіркелген ақпаратты атаймыз. Әрине, бұл құрылғылардың әрқайсысының өзіндік ерекшеліктері бар, бірақ біздің мақсатымыз үшін олардың екеуі де жер бетінің тербеліс жылдамдығын нақты бір нүктеде өлшейтін аспаптар екенін түсіну жеткілікті. Мұны есте сақтау маңызды, өйткені классикалық сейсмикалық талдау әдістерінің басым бөлігі нүктелік өлшеулерге негізделген.

Ал DAS технологиясында жағдай басқаша - онда өлшеу бір нүктеде емес, үздіксіз талшық бойымен таралған кеңістіктік ұзындықта орындалады. Механикалық деформация (strain) - бұл зат бөлшектерінің бастапқы күйінен ығысуымен (displacement) байланысты физикалық шама. Ал деформация жылдамдығы (strain rate) мен жылдамдық (velocity) арасындағы байланыс - кеңістіктік градиент арқылы сипатталады. Математикалық түрде ол келесідей жазылады [23]:

$$\varepsilon_z = \frac{du_z}{dz} ; \quad (1.4)$$

мұндағы u_z = жылдамдық немесе орын ауыстыру; ε_z = z позициясындағы деформация.

Басқаша айтқанда, DAS жүйесі арқылы өлшенетін деформация немесе деформация жылдамдығы — дәстүрлі сейсмикалық аспаптар (геофон немесе сейсмометр) тіркейтін орын ауыстыру (displacement) немесе жылдамдықтың (velocity) кеңістіктік градиентімен тікелей байланысты. Мұқият қараған адам байқайтыны — бұл түсіндіруде мен деформация тензорының тек бір ғана компонентін келтірдім. Алайда, жалпы жағдайда талдау дұрыс болуы үшін деформация тензоры талшықтың бойымен бағыттас етіп айналдырылады.

Осы тұжырымды алдыңғы бөлімде келтірілген усреднение теңдеуімен біріктіре отырып, датчиктің ұзындығының кез келген нүктесінде орналасқан жылдамдық немесе орын ауыстыру мәндерінің негізінде DAS арқылы өлшенетін деформация немесе деформация жылдамдығының жалпыланған теңдеуін алуға болады:

$$\varepsilon'(r) = \frac{1}{L_g} \left[u \left(r + \frac{L_g}{2} \right) - u \left(r - \frac{L_g}{2} \right) \right]; \quad (1.5)$$

мұндағы r - талшық бойымен қашықтық, ε_z - z позициясындағы штамм, L_g - өлшеуіштің ұзындығы

Жоғарыда берілген теңдеу негізінде, DAS жүйесі өлшейтін деформация (strain) немесе деформация жылдамдығы (strain rate) – датчиктің екі шетінде орналасқан жылдамдық немесе орын ауыстыру датчиктерінің мәндерінің

айырмасын, талшықтың ұзындығына бөлу арқылы алынады дегенді білдіреді. Осы идеяны дамыту арқылы DAS деректерін симуляциялауға мүмкіндік туады. Ол үшін талшықтың екі шетіне дәстүрлі сейсмикалық датчиктерді (мысалы, геофон немесе сейсмометр) қойып, олардың сигналдарын салыстыру жеткілікті.

Тағы бір маңызды тұсы - DAS деректерін талдауда жиі біз датчиктің ортасындағы мәнге сүйенеміз, бірақ іс жүзінде жүйенің шығу сигналы талшықтың екі шетінде болып жатқан процестерге тәуелді. Сонымен қатар, бұл теңдеу DAS технологиясындағы сезімталдықтың (sensitivity) бұрыштық тәуелділігін түсіндіруге негіз береді. Бұл тәуелділік өте жалпы сипатта: ол толқын түріне (бойлық, көлденең және т.б.) байланысты болжамдарды қажет етпейді. Формула талшық түзу бағытталған деп есептейді, дегенмен аз ғана өзгерістер енгізу арқылы оны иілген немесе қисық талшықтарға да қолдануға болады. Қорытындылай келе, бұл теңдеу DAS технологиясын әрі қарай нақты жағдайлар үшін талдауға және модельдеуге жақсы теориялық негіз береді.

DAS деректерін нүктелік сенсордың (геофон немесе сейсмометр) деректеріне түрлендіру теориялық тұрғыда мүмкін, және мұндай әрекеттер DAS пен дәстүрлі сейсмикалық датчиктердің сигналдарын салыстыру мақсатында бірнеше зерттеушілер тарапынан жүзеге асырылған [24]. Алайда, жоғарыда келтірілген математикалық өрнек мұндай түрлендіруді кейбір жорамалдарсыз орындау мүмкін еместігін көрсетеді.

Бұл мәселені түсіндіру үшін, талшықтың екі шетіндегі геофонның жауап сигналы DAS арқылы алынған деформациялық өлшемдермен математикалық байланыста қарастырылады. Мұндай байланыс сызықтық инверсиялық есеп (linear inverse problem) ретінде сипатталады және оны матрицалық түрде көрсетуге болады. Жалпы түрде, DAS өлшемдері сол жақта орналасып, ал оң жақтағы вектор талшықтың ұштарында тіркелуі мүмкін орын ауыстыру немесе жылдамдық мәндерін білдіреді. Осы екі жақты байланыстыратын матрица – айырмалар матрицасы (difference matrix) болып табылады, ол кеңістіктік градиентті есептеуге негізделген. Сол жақтағы вектор DAS арқылы өлшенген деректерді білдіреді, ал оң жақтағы вектор талшықтың ұштарында орналасқан нүктелік датчиктердегі ықтимал орын ауыстыру немесе жылдамдық мәндерін көрсетеді. Бұл шамалар айырмалар матрицасы (differencing matrix) арқылы өзара байланысады. Алайда, осы оң жақтағы векторды анықтау үшін айырмалар матрицасынан алынған ішкі көбейтінді матрицасын (inner product matrix) инверсиялау қажет. Бұл матрица жеткіліксіз рангке ие, яғни оның кем дегенде бір нөлдік меншікті мәні (eigenvalue) болады. Мұндай жағдай модельдер кеңістігі деректер кеңістігінен үлкен екенін, басқаша айтқанда, жылдамдық немесе орын ауыстыру сигналдарының кейбір компоненттері DAS арқылы тіркелмейтінін білдіреді.

Мұндай сигналдардың қарапайым мысалы - DC-shift, яғни тұрақты жылдамдық немесе тұрақты орын ауыстыру. Теориялық тұрғыда мұндай сигналды нүктелік сенсор тіркей алады (арнайы жабдық арқылы), алайда DAS жүйесі мұндай өзгерісті анықтай алмайды, себебі DAS тек кеңістіктік өзгерісті

(градиентті) өлшейді. Дегенмен, геофизикалық зерттеулерде бізге қажет сигналдардың көпшілігі дәл осы тіркеле алмайтын компоненттерге жатпайды. Сондықтан мұндай дұрыс қойылмаған инверсиялық есептерді (ill-posed inverse problems) шешу үшін SVD (singular value decomposition), Tikhonov regularization немесе қосымша шектеулер (constraints) сияқты математикалық әдістер қолданылады. Осы тәсілдердің көмегімен DAS деректерінен нүктелік датчиктің ықтимал жауап сигналын қалпына келтіруге болады. Бірақ бұл әдістің математикалық тұрғыда толық емес екенін естен шығармаған жөн.


Практикалық тұрғыда DAS пен геофон немесе сейсмометр деректерін тиімді салыстырудың шынайырақ тәсілі — кері емес, тура есепті шешу, яғни нүктелік жылдамдық немесе орын ауыстыру деректері негізінде DAS сигналының моделін есептеу. Бұл әдіс салыстыруды дәлірек және физикалық тұрғыдан негізделген етеді.

1.3.1 DAS жауаптарын алу

Жоғарыда жүргізілген талдауға сүйене отырып, енді біз DAS жүйесінің P және S толқындарына жауап қайтару ерекшеліктерін қарастырамыз. Бұл талдау барысында DAS технологиясына тән екі эмпирикалық тұжырымды (DAS'isms) математикалық тұрғыдан дәлелдейміз:

- DAS жүйесінің P-толқынға сезімталдығы түсу бұрышының косинусының квадратына тәуелді;
- S-толқынға сезімталдығы түсу бұрышының екі еселенген мәнінің синусына тәуелді.

Мұндағы түсу бұрышы - толқынның таралу бағытына перпендикуляр (нормаль) мен талшықтың бағыты арасындағы бұрыш. Шындығында, бұл тұжырымдар тек жуықталған түрдегі сипаттама болып табылады. DAS талшықтарының нақты жауабы тек бұрышқа ғана емес, сонымен қатар толқынның жиілігіне де тәуелді және оның схемасы 1.7 – суретте көрсетілген [23].




1.7 - сурет – DAS технологиясының толқын сезімталдығының бұрышқа тәуелділік схемасы

Р-толқын жағдайындағы DAS жауабы. Жоғарыда келтірілген туындыларды және жазықтық инцидентінің формуласын Қолдану Р-толқынның орын ауыстыруы:

$$u_r^p(r) = \cos(\theta) A^p(r) e^{-i\omega T(r)} ; \quad (1.6)$$

мұндағы Р - толқыннан туындайтын орын ауыстыру, θ - толқынның түсу бұрышы, $A^p(r)$ - Р-толқын амплитудасы, ω - бұрыштық жиілік, $T(r)$ - толқынның келу уақыты, v - толқын таралу жылдамдығы.

Берілген өрнектегі жақша ішіндегі мүше DAS жүйесінің геофонға қарағанда кеңістіктік және жиіліктік сүзгі рөлін атқаратынын білдіреді. Геофонда сигнал тек түсу бұрышының косинусы мен амплитуданың көбейтіндісі түрінде қабылданады, ал DAS жүйесінде одан кейінгі қосымша мүшелер кеңістіктік-жиіліктік сүзгі ретінде әрекет етіп, сигналдың пішінін өзгертеді. Бұл сүзгілеу процесі толқынның талшыққа келу бұрышына және оның жиіліктік спектріне тәуелді. Сондықтан DAS талшығы арқылы тіркелген сигналдың нақты формасы толқынның жиілігі мен түсу бұрышының функциясы болып табылады. Осы тәуелділік негізінде жазық толқын үшін DAS жүйесінің амплитудалық жауап спектрін жиілік пен түсу бұрышының функциясы ретінде есептеуге болады (1.8 - сурет).




1.8 - сурет – Жиілік пен түсу бұрышының функциясы ретінде Р-толқынының түсетін жазықтығына DAS талшығының амплитудалық жауап спектрі

Жоғарыдағы суретті құрастыру барысында өлшеу ұзындығы (gauge length) 10 метр және Р-толқынның таралу жылдамдығы 2500 м/с деп алынды. Графиктен байқалатыны - егер толқын талшыққа 90° бұрышпен, яғни перпендикуляр бағытта келсе, DAS талшығының жауабы нөлге жуықтайды. Керісінше, ең жоғары сезімталдық толқын талшық бойымен параллель (0° немесе 180° бұрышпен) таралған жағдайда байқалады. Сонымен қатар, жиілік пен толқын санының әсері де анық көрінеді: төмен жиілікті сигналдар әлсірейді, себебі талшықтың екі ұшындағы сигналдар арасындағы айырмашылық аз болады. Бұл DAS жүйесінің кеңістіктік сүзгі ретіндегі табиғатын көрсетеді. Егер осы графиктен жиілік тұрақты болған жағдайда көлденең қима алсақ, нәтижесінде алынған функция түсу бұрышының косинусының квадратына пропорционал болады. Бұл - DAS технологиясына тән бірінші эмпирикалық тұжырымның (first DAS'ism) математикалық негізін құрайды.

S - толқын жағдайындағы DAS жауабы. Дәл осындай тәсілді S-толқын үшін де қолдануға болады. Алайда бұл жағдайда, талшықтың жауабын анықтау үшін толқынның орын ауыстыру немесе жылдамдық векторы талшықтың бағытына проекциялануы керек. Яғни, S-толқынның бастапқы векторлық табиғатын ескере отырып, оның талшық бойындағы компонентін ғана есепке аламыз. Нәтижесінде алынған өрнек DAS талшығының S-толқынға бұрыштық сезімталдығының негізін құрайды:

$$u_r^S(r) = -\sin(\theta) A^S(r) e^{-i\omega T^S(r)}; \quad (1.7)$$

Шын мәнінде, DAS жүйесінің жауап сүзгісі бұрынғы жағдаймен бірдей болып қалады. Бұл орынды, себебі талшықтың геометриялық орналасуы өзгерген жоқ. Айырмашылық тек S-толқынның бастапқы орын ауыстыру немесе жылдамдық сипаттамасына қатысты бастапқы мүшелерде ғана болады. Осы негізде жиілік пен талшық бойына қатысты көлденең бағыттағы (incident cosine) бұрыштық тәуелділіктің функциясы ретінде амплитудалық жауап есептелгенде, төменде көрсетілген спектр алынады (1.9 - сурет).



1.9 - сурет – Жиілік пен түсу бұрышының функциясы ретінде S-толқынының түсетін жазықтығына DAS талшығының амплитудалық жауап спектрі

Бұл есепте бұрынғыдай өлшеу ұзындығы (gauge length) 10 метр деп алынды, бірақ толқын жылдамдығы нақтырақ мәнді көрсету үшін Р-толқынның орнына S-толқынға тән 1560 м/с жылдамдық пайдаланылды. S-толқын жағдайында, Р-толқыннан айырмашылығы, талшық бойына параллель түскен кезде сигнал нөлге жақындайды, себебі бұл жағдайда бөлшектердің қозғалысы талшықтың бойлық бағытымен сәйкес келмейді. Сол сияқты, толқын талшыққа перпендикуляр (90°) түскенде де DAS жүйесі жауап бермейді, өйткені бұл кезде өлшеу ұзындығының екі шеті арасында салыстырмалы орын ауыстыру болмайды. Графиктің жиілік тұрақты болғандағы көлденең қимасын қарастырғанда, талшықтың S-толқынға сезімталдығы бұрышқа тәуелді синус функциясының екі еселенген түрімен ($\sin 2\theta$) сипатталатыны анықталады. Бұл DAS технологиясына тән екінші эмпирикалық заңдылықты (second DAS'ism) құрайды. Алайда график амплитудалық жауап спектрін көрсететіндіктен, мұнда фазалық полярлықтың ауысуы көрінбейді, ол тек фазалық спектрде көрініс табады [23].


1.4 Машиналық оқытудың теориялық негіздері

Машиналық оқыту (Machine Learning) – статистикалық әдістер мен компьютерлік ғылымдардың тоғысынан пайда болған бағыт. Бұл ұғымды алғаш рет 1959 жылы Артур Самуэль енгізген. Бүгінде машиналық оқыту жасанды интеллекттің (Artificial Intelligence, AI) маңызды ішкі саласы ретінде қарастырылады, оның негізгі мәні - компьютерлердің алдын ала берілген үлкен көлемді деректер негізінде жаңа ақпаратты автоматты түрде өңдеуі, талдауы және классификациялауы. Мұндай жүйелер нақты тапсырмаларды толық бағдарламаламай-ақ, үйренген математикалық модельдерге сүйене отырып, болжамдар жасай алады.

Машиналық оқыту алгоритмдері үлгілік (training) деректер жиынын пайдаланып, математикалық модельдер құрастырады, осының нәтижесінде компьютерлер күрделі процестердің нәтижесін өздігінен болжай алады. Яғни, егер қандай да бір қиын есеп бойынша прогноз жасау қажет болса, міндетті түрде бүкіл логиканы қолмен кодтау талап етілмейді; алгоритмге тиісті деректерді ұсыну жеткілікті, ал модель осы деректер негізінде болжам жасайтын математикалық құрылым қалыптастырады. Жалпы алғанда, машиналық оқыту үш негізгі санатқа бөлінеді - Қадағаланатын оқыту (Supervised Learning), қадағаланбайтын оқыту (Unsupervised Learning), күшейтілген оқыту (Reinforcement Learning). Бұл құрылым схемалық түрде 1.10 - суретте көрсетілген [25].

Қадағаланатын оқытуда модельді үйрету үшін алдын ала белгіленген (labeled) үлгілік деректер жиыны пайдаланылады. Оқыту кезеңінде алгоритм кіріс пен шығыс арасындағы байланысты үйренеді, ал кейіннен жаңа деректер үшін нәтижені болжауға қабілетті болады. Бұл тәсілдің негізінде «supervision» ұғымы жатыр, яғни алгоритм белгілі бір эталон дұрыс жауаптармен бағыттталып отырады. Мұндай әдіс модельді дайындау барысында адам тарапынан белгілі бір дәрежеде белгілеу жұмысын талап етеді, бірақ соның нәтижесінде күрделі тапсырмаларды жылдам әрі автоматты орындауға қол жеткізіледі.

Қадағаланатын оқыту машиналық оқытудың ең кең қолданылатын түрлерінің бірі болып табылады. Бұл санат өз ішінде екі топқа бөлінеді: регрессия және классификация алгоритмдері [25].



1.10 - сурет – Машиналық оқыту алгоритмдерінің жіктелуі [25]


Support Vector Machine (SVM) - классификация міндеттерінде кеңінен қолданылатын әдістердің бірі. Оның жұмыс істеу принципі деректерді ажырататын margin шамасын максимизациялауға негізделеді. Бұл тәсіл жоғары өлшемді белгілер кеңістігінде объектілерді әртүрлі класстарға бөлу үшін гипержазықтықты (hyperplane) немесе гипержазықтықтар жиынтығын құруға мүмкіндік береді. Бастапқыда SVM тек екі классты классификациялау (binary classification) міндеттерін шешуге арналған болатын. Алайда кейінгі зерттеулерде бірнеше гипержазықтықтарды бірлесіп қолдану арқылы көпклассты (multi-class) классификация есептерін шешуге мүмкіндік беретін кеңейтілген алгоритмдер ұсынылды. SVM жұмысы 1.11 – суретте көрсетілген [26].



1.11 - сурет - SVM жұмысы [26]

K-Nearest Neighbors (K-NN) - машиналық оқытудың қадағаланатын (supervised) әдістерінің бірі және ең қарапайым әрі кең қолданылатын классификация алгоритмдерінің бірі. Оның негізгі идеясы - жаңа берілген нүктені оған ең жақын тұрған k көрші деректердің классына қарай жіктеу. K-NN алдын ала модель құрмайды, сондықтан *lazy learner* деп аталады: барлық оқу деректері тек сақталады, ал нақты классификация жаңа нүкте келген кезде ғана жүзеге асады. Алгоритм *non-parametric*, яғни кіріс пен шығыс арасында алдын ала берілген математикалық байланыс болмайды; шешім тек қашықтық өлшемі арқылы қабылданады.

K-NN классификацияда кеңінен қолданылады, сонымен қатар регрессия және жетіспейтін мәндерді толтыру (*imputation*) үшін де тиімді. Жаңа белгісіз нүкте өзінің көршілеріне қаншалық жақын екеніне байланысты белгілі бір класқа жатқызылады. Алгоритм деректер белгіленген (*labeled*) және шуыл деңгейі төмен болған жағдайларда жақсы нәтиже береді. K-NN алгоритмінің қалай жұмыс істейтінін көрсететін жіктеу мысалы 1.12 – суретте көрсетілген [25].



1.12 - сурет – Көршілерге негізделген жаңа деректер нүктесінің жіктелуі [25]

Қадағаланбайтын оқыту - белгіленбеген (unlabeled) деректермен жұмыс істейтін машиналық оқыту әдістерінің жиынтығы. Бұл тәсілде модель кіріс деректердің ішкі құрылымын, жасырын байланыстарын немесе топтарын автоматты түрде анықтайды. Оқыту процесі деректердің өз ерекшеліктеріне негізделгендіктен, модельге қандай нәтижені күту керектігі жөнінде нақты нұсқау берілмейді.

Қадағаланбайтын оқыту көбінесе кластерлеу және өлшемділікті азайту (dimensionality reduction) сияқты міндеттерді шешуге қолданылады. Бұл санаттағы ең танымал алгоритмдерге K-means кластерлеуі, негізгі компоненттер әдісі (PCA), иерархиялық кластерлеу модельдері, жасырын Марков модельдері (НММ) және әртүрлі нейрондық желілер жатады.


Күшейтілген оқыту - агенттің ортадан алған кері байланысы негізінде үйренуін сипаттайтын әдіс. Бұл тәсілде жүйе дұрыс әрекет жасағаны үшін сыйақы (reward) алады, ал қате қадам үшін жаза (penalty) беріледі. Осындай үздіксіз бағалау механизмінің арқасында агент өзінің стратегиясын жетілдіріп, уақыт өте келе әрекетінің тиімділігін арттырады. Бұл типтегі оқытуда агент қоршаған ортамен тікелей әрекеттесіп, оның қасиеттерін тәжірибе арқылы зерттейді [25].

Алдыңғы бөлімде атап өтілгендей, қадағаланатын оқыту екі негізгі санатқа бөлінеді: регрессия және классификация. Регрессия алгоритмдері кіріс айнымалылары мен үздіксіз мақсатты айнымалы арасындағы байланысты моделдеу үшін қолданылады. Мысалы, қор нарығындағы өзгерістерді болжау немесе халық санының ұзақ мерзімді динамикасын анықтау. Классификация алгоритмдері нәтижесі категориялық сипатта болатын есептерде тиімді. Мысалы: «дөңгелек немесе үшбұрыш», «шын немесе жалған», «оңға немесе солға», «иә немесе жоқ» сияқты шешімдер [25].

Машиналық оқытудың классикалық әдістері көптеген практикалық есептерді тиімді шешкенімен, күрделі, жоғары өлшемді және құрылымы

айқын емес деректерді өңдеу кезінде олардың мүмкіндігі шектеулі болуы мүмкін. Осындай жағдайда машиналық оқытудың дамыған әрі тереңдетілген бағыты – терең оқыту (Deep Learning) алдыңғы қатарға шығады. Терең оқыту көп қабатты нейрондық желілерге сүйене отырып, деректердегі маңызды белгілерді автоматты түрде анықтайды және дәстүрлі әдістер талап ететін қолмен feature engineering қадамдарын қажет етпейді. Сондықтан ол бейсызық, көпөлшемді және үлкен көлемді деректерге негізделген есептерді шешуде машиналық оқытудың табиғи жалғасы әрі келесі даму кезеңі болып саналады.

Терең нейрондық желілер (Deep Neural Networks) көбіне алға бағытталған нейрондық желілер (Feed-Forward Neural Networks, FFNN) түрінде құрылады. Мұндай архитектурада ақпарат кіріс қабатынан бастап жасырын қабаттар арқылы шығыс қабатына қарай тек бір бағытпен өтеді және кері бағытта қозғалыс болмайды. Қабаттар арасындағы байланыстар біржақты болғандықтан, сигнал бұрынғы нейрондарға қайта оралмайды және ешбір түйін (node) қайталанып өңделмейді (1.13 - сурет) [27].




1.13 - сурет – Терең нейрондық желілер архитектурасы

Терең оқытуда ең кең тараған архитектуралар қатарына конволюциялық нейрондық желілер (CNN), рекурренттік нейрондық желілер (RNN), LSTM және GRU үлгілері, сондай-ақ автоэнкодерлер (Autoencoders) мен трансформерлік модельдер (Transformers) жатады. CNN кеңістіктік құрылымды, мысалы, спектрограммалар немесе суреттерді өңдеуде тиімді болса, LSTM және GRU уақыттық қатарлармен, соның ішінде сейсмикалық сигналдар мен DAS өлшемдерімен жұмыс істеуде жоғары нәтижелер көрсетеді [27].

Конволюциялық нейрондық желілер (CNN) – терең оқыту саласында ең кең таралған және қарқынды қолданылатын архитектуралардың бірі. CNN-нің басты артықшылығы - маңызды белгілерді деректердің өзінен автоматты

түрде бөліп алуы, яғни feature extraction кезеңінде адам тарапынан қосымша өңдеуді қажет етпеуі. Осы қабілетінің арқасында CNN компьютерлік көру, дауысты өңдеу, бет тану және басқа да көптеген салаларда кең қолданыс тапты. CNN құрылымы биологиялық жүйелерге, әсіресе адам мен жануарлардың көру қыртысындағы (visual cortex) нейрондық ұйымдасу принциптеріне негізделген. Модель мысықтың көру жүйесіндегі нейрондар тізбегінің жұмысын белгілі бір деңгейде имитациялайды. Суреттерді жіктеуге арналған CNN архитектурасының мысалы 1.14 – суретте көрсетілген [28].



1.14 - сурет – CNN архитектурасының мысалы

Терең нейрондық желілердің негізгі үйренетін параметрлері - weights, яғни кіріс сигналдарын шығысқа түрлендіретін коэффициенттер. Деректердегі бейсызық байланыстарды үйрену үшін әр қабаттың шығысына арнайы бейсызық активация функциялары қолданылады. Ең кең тарағандарына Sigmoid, ReLU және Tanh функциялары жатады. Қолданылатын функция түрі деректердің сипатына және шешілетін есептің табиғатына байланысты таңдалады [6].

Бұл жұмыста қадағаланатын оқыту тәсілі қолданылып, DAS өлшемдеріндегі сейсмикалық сигналдарды анықтай алатын терең нейрондық желі моделі құрастырылды. Модельдің мақсаты - берілген DAS сигнал үзіндісінің сейсмикалық толқын болуы ықтималдығын есептеу. Жүйені оқыту үшін дәстүрлі кеңжолақты сейсмометрлермен жазылған сейсмикалық сигналдар мен шу деректерінен құралған үлкен көлемді белгіленген деректер базасы пайдаланылды. Оқыту барысында сигналдар топтамалар (batch) түрінде модельге жіберіліп, әр кіріс үшін сейсмикалық оқиға ықтималдығы есептеледі. Модельдің болжауы ground truth белгілерімен салыстырылып, қате шамасы Binary Cross-Entropy (BCE) шығын функциясы арқылы бағаланады

[6]. BCE ықтималдықтарды бағалайтын екі классты классификация үшін стандартты өлшем болып табылады:

$$L(\hat{y}, y) = -\frac{1}{N} \sum_{n=1}^N [y_n \log(\hat{y}_n) + (1 - y_n) \log(1 - \hat{y}_n)]; \quad (1.8)$$

мұндағы $\hat{y}$ - модельдің шығысы (яғни, кіріс өлшемдерінің сейсмикалық толқындар болу ықтималдығы), y - кіріс толқын пішінінің жиыны үшін шынайы белгілердің векторы, ал N - әрбір партиядағы мысалдар саны.

Желінің параметрлерін жаңарту үшін градиенттер есептеледі. Толық деректер жиыны бойынша градиенттерді есептеу есептеу жағынан өте ауыр болғандықтан, градиенттер batch негізінде жуықталады. Градиенттерді есептеу backpropagation алгоритмі арқылы жүзеге асады. Параметрлер градиент бағытымен жаңартылып, олардың өзгеру шамасы learning rate гиперпараметрімен басқарылады [6].

Модельдің соңғы өнімділігін бағалау үшін оқу және валидация деректерінен бөлек test set қолданылады. Әр сынаманың сейсмикалық толқын болуы ықтималдығы есептеліп, нақты белгілермен салыстырылады. Классификация нәтижелері белгілі бір threshold мәніне байланысты интерпретацияланады. Модельді бағалау үшін төрт негізгі метрика қолданылды: Accuracy, Precision, Recall, F-score. Бұл метрикалар True Positive (TP), True Negative (TN), False Positive (FP) және False Negative (FN) мәндеріне сүйеніп есептеледі. Accuracy - дұрыс классификацияланған барлық мысалдардың жалпы үлгілер санына қатынасы ретінде анықталады [6].

$$Accuracy(th) = \frac{TP(th) + TN(th)}{TP(th) + TN(th) + FP(th) + FN(th)}; \quad (1.9)$$

мұндағы th тиісті жіктеу үшін анықталған шекті мәнге сәйкес келеді.

Recall (толық қамту) - дұрыс анықталған оң нәтижелердің жалпы оң мысалдар санына қатынасы. Бұл метрика модельдің барлық нақты позитивті жағдайларды қаншалықты толық таба алғанын көрсетеді [6]:

$$Recall(th) = \frac{TP(th)}{TP(th) + FN(th)}; \quad (1.10)$$

Precision (нақтылық) - дұрыс анықталған оң нәтижелердің, модель позитив деп жіктеген барлық жағдайлар санына (true positives + false positives) қатынасы. Precision жоғары болса, модель жасаған позитивті анықтамалардың көпшілігі шын мәнінде дұрыс дегенді білдіреді, яғни триггерлерге сенім жоғары болады [6]:

$$Precision(th) = \frac{TP(th)}{TP(th) + FP(th)}; \quad (1.11)$$

F-score - Recall мен Precision көрсеткіштерінің гармониялық орташа мәні. Бұл метрика екеуінің арасындағы теңгерімді бағалау үшін қолданылады [6]:

$$F - score(th) = 2 \frac{Precision(th) \cdot Recall(th)}{Precision(th) + Recall(th)}, \quad (1.12)$$

F-score метрикасы Precision мен Recall көрсеткіштерін бір уақытта бағалайтындықтан, олардың кез келгені төмендеген жағдайда F-score мәні де айтарлықтай төмендейді. Бұл метрика әсіресе жалған оң (false positives) және жалған теріс (false negatives) нәтижелердің санын бағалауда тиімді, себебі ол дәл осы қателіктерге ерекше сезімтал. Assurance көрсеткіші көбінесе деректердегі класстар теңгерімсіз болғанда (imbalanced dataset) жаңылыстыруы мүмкін: басым классты дұрыс анықтау жалпы дәлдікті жоғары көрсетіп, сирек кездесетін класстағы қателерді жасырып қалуы ықтимал. Ал F-score, керісінше, екі классты да дұрыс классификациялауды талап ететіндіктен, мұндай жағдайда модельдің шынайы сапасын нақтырақ көрсетеді. Модельдің әртүрлі шекті мәндердегі (threshold) жұмысын бағалау үшін Precision–Recall (PR) қисығы кеңінен қолданылады. Бұл графикте Precision әдетте тік осьте, ал Recall көлденең осьте орналасады, және ол модельдің жалпы өнімділігін толық әрі дәл бақылауға мүмкіндік береді [6].

1.5 Сейсмикалық сигналдарды машиналық оқыту арқылы өндеудің заманауи тәсілдері (әдеби шолу)

Бұл бөлімде әртүрлі уақыттық және кеңістіктік масштабтағы жер сілкіністерін болжау үшін машиналық оқыту әдістерін қолдануды зерттейтін ғылыми зерттеулерге шолу берілген. Жер сілкінісінің пайда болу процестері стохастикалық сипатқа ие болғандықтан және сызықтық емес мінез-құлықты көрсететіндіктен, соңғы зерттеулер, ең алдымен, осы мәселені шешу үшін нейрондық желілерге негізделген модельдерді қолдануға бағытталған. Нейрондық желілерден басқа, машиналық оқытудың басқа тәсілдері, соның ішінде регрессия мен жіктеудің әртүрлі әдістері де зерттелді және осы шолуда талқыланады.

Жер сілкінісін болжау үшін жасанды нейрондық желілерді қолдануды зерттеген алғашқы зерттеулердің бірін 2006 жылы Э.И. Альвес ұсынған [29]. Автор сейсмикалық белсенділік пен қаржы нарықтары арасында параллельдер жүргізіп, екі жүйеге де ортақ хаотикалық және күрделі табиғатты атап өтті. Осы ұқсастыққа сүйене отырып, қаржылық болжауда дәстүрлі түрде қолданылатын көрсеткіштер - мысалы, жылжымалы орташа мәндер (MA), жылжымалы орташа конвергенция–дивергенция (MACD) және салыстырмалы беріктік индексі (RSI) - нейрондық желі моделінің кіріс мүмкіндіктері ретінде пайдаланылды. Ұсынылған тәсіл жер сілкінісінің пайда болу уақыты мен

географиялық орнын алдын ала белгіленген уақытша және кеңістіктік интервалдар шегінде болжауға, сондай-ақ оның қарқындылығын Модификацияланған Меркалли Қарқындылығы (ММІ) шкаласы бойынша бағалауға бағытталған [30]. Әдістеме Португалияның Азор аймағындағы сейсмикалық деректерді пайдалана отырып бағаланды. Автордың айтуынша, модель 1998 жылдың шілдесінде ММІ=8 қарқындылығымен және 2004 жылдың қантарында ММІ=5 қарқындылығымен жер сілкінісі оқиғаларын сәтті болжаған.

Дегенмен, зерттеу нәтижелердің сандық көрсеткіштері туралы есеп бермеді, бұл модельдің дәлдігі мен сенімділігін объективті бағалауды қиындатады. Сонымен қатар, болжамды уақытша терезелер салыстырмалы түрде кең болды, олардың пайда болу уақыты ± 5 айлық диапозонда бағаланды. Осы шектеулерге қарамастан, хабарланған нәтижелер перспективалы деп сипатталды және нейрондық желілерге негізделген тәсілдердің жер сілкінісін болжау үшін әлеуетті қолданылуын көрсетті [31].

Х.Адели мен А. Панаккат [32, 33] жүргізген зерттеулерде жер сілкінісін болжау мәселесі жіктеу тапсырмасы ретінде тұжырымдалған, онда шығыс кластары алдын ала белгіленген уақыт терезесінде күтілетін ең күшті сейсмикалық оқиғаның магнитудалық интервалдарына сәйкес келеді, мысалы, бір ай.. Ұсынылған негіздеме келесі айда белгілі бір географиялық аймақта болған ең үлкен жер сілкінісінің магнитудасын шамамен $\pm 0,5$ бірлік дәлдікпен болжауға бағытталған. Атап айтқанда, 2007 жылы International Journal of Neural Systems журналында жарияланған [32] еңбегінде аймақтың сейсмикалық әлеуетін бағалау үшін математикалық түрде алынған белгілер ретінде қызмет ететін сегіз сейсмикалық көрсеткіш енгізілген. Бұл көрсеткіштер жер сілкінісі шамаларының уақытша таралуын сипаттайтын екі белгіленген модель негізінде құрылады. Бірінші модель-жер сілкінісінің шамасы мен жиілігі арасындағы статистикалық байланысты сипаттайтын гутенберг-Рихтердің кері қуат заңы. Екіншісі-жер сілкінісінің сипаттамалық моделі, ол белгілі бір тектоникалық аймақтарда үлкен магнитудалық құбылыстар кезінде байқалатын сейсмикалық энергияның бөлінуінің мерзімді заңдылықтарын ескереді.

Кейінгі және логикалық тұрғыдан байланысты үлес 2009 жылы Neural Networks журналында жарияланған [33] мақаласында ұсынылды, онда авторлар [32] - да анықталған жер сілкінісін болжау мәселесін шешу үшін ықтималдық нейрондық желі (PNN) архитектурасын ұсына отырып, бұрынғы жұмыстарын кеңейтті.. Бұл зерттеуде Адели мен Панаккат ұсынылған желіні оқыту үшін кіріс мүмкіндіктері сияқты сейсмикалық көрсеткіштер жиынтығын пайдаланды. PNN моделінің өнімділігі $33,8^{\circ}$ - $35,4^{\circ}$ N ендіктермен және $114,75^{\circ}$ - $119,25^{\circ}$ W бойлықтармен шектелген Оңтүстік Калифорния аймағының сейсмикалық деректерін пайдалана отырып бағаланды. Нәтижелер корреляция коэффициентінің (R) мәндері 0,62-ден 0,78-ге дейінгі магнитудасы 4,5-тен 6,0-ге дейінгі жер сілкіністерін болжаудың қанағаттанарлық дәлдігін көрсетті. Дегенмен, модель магнитудасы 6,0-ден асатын күшті сейсмикалық

оқиғаларды болжауда шектеулі тиімділікті көрсетті, олар үшін R мәндері 0,0-0,5 диапазонына дейін төмендеді.

Бірге алғанда, [32] және [33] - де хабарланған нәтижелерді қосымша ретінде қарастыруға болады. Қайталанатын нейрондық желілер жоғары магнитудалы жер сілкіністерін болжау үшін қолайлырақ болғанымен, ықтимал нейрондық желілер шағын және орташа сейсмикалық оқиғалар үшін жақсы өнімділікті көрсетті. Адели мен Панаккаттың зерттеулері сейсмикалық қауіпті бағалаудың жүйелі, машиналық оқытуға негізделген тәсілдерін әзірлеудегі маңызды кезең болып табылады. Атап айтқанда, авторлар енгізген сейсмикалықтың сегіз индикаторының жиынтығы кеңінен қабылданды және бүкіл әлем бойынша ғалымдар жүргізген кейінгі зерттеулерде одан әрі зерттелді [31].

2018 жылы Computers & Geosciences журналында жарияланған [34] журналында жарияланған зерттеу жеті күндік уақыт көкжиегінде күтілетін ең күшті сейсмикалық оқиғаның шамасын болжау мәселесін зерттеді. Классификацияға негізделген тұжырымдамалардан айырмашылығы, жер сілкінісін болжау регрессия мәселесі ретінде қарастырылды. Осы мақсатта регрессияның төрт моделі—жалпыланған сызықтық модельдер, градиентті күшейту машиналары, тереңдетіп оқыту тәсілдері және кездейсоқ орман алгоритмдері-олардың ансамбльдік комбинацияларымен бірге бағаланды. Кіріс ерекшеліктері ретінде авторлар бұрын Панаккат пен Адели енгізген сейсмикалық көрсеткіштерді қолданды [32]. Бұл жұмыстың айрықша аспектісі оның үлкен деректерді талдауға бағытталуы болып табылады: шамамен 1 ГБ сейсмикалық деректер модельдерді оқыту және бағалау үшін бұлттық есептеу инфрақұрылымы арқылы өңделді.

Модельдің өнімділігі орташа абсолютті қателік (MAE) және салыстырмалы қателік (RE) көрсеткіштері арқылы бағаланды. Сонымен қатар, есептеу тиімділігі әр тәсілге қажетті жаттығу уақытын өлшеу арқылы қарастырылды. Бағаланған регрессорлардың ішінде кездейсоқ орман моделі ең жақсы жалпы өнімділікті көрсетті, орташа есеппен 0,74 MAE көрсеткішіне қол жеткізді, сонымен қатар жоғары есептеу тиімділігін көрсетті, бұл толық деректер жинағында жаттығуға небәрі 18 минутты алды. Бір қызығы, кездейсоқ орман орташа магнитудалы ($4 \leq m < 7$) жер сілкіністері туралы ең дәл болжамдарды берді, MAE мәндері 0,26-дан аспады. Керісінше, ансамбльге негізделген регрессиялық модельдер экстремалды магнитудалық диапазондарда, атап айтқанда шағын ($0 \leq M < 3$) және үлкен ($7 \leq m < 8$) жер сілкіністерінде жоғары өнімділікті көрсетті [31].

[35] – жұмыста 2017 Жылы Natural Hazards журналында жарияланған, Асим және т.б. жер сілкінісін болжау $\geq 5,5$ баллдық оқиғалардың ай сайынғы болжамдарына назар аудара отырып, екілік жіктеу мәселесі ретінде қарастырылды. Зерттеуге Адели мен Панаккат енгізген сегіз сейсмикалық көрсеткіштер қолданылды [32] қайталанатын нейрондық желілерді, үлгіні танудың нейрондық желілерін, кездейсоқ орманды және шешім ағаштарының LPBoost ансамблін қоса алғанда, машиналық оқытудың бірнеше үлгілеріне

кіріс ретінде. Модельдер дәлдік, сезімталдық, ерекшелік және болжамды мәндер сияқты бірнеше өнімділік көрсеткіштерін пайдалана отырып бағаланды. Индукуш аймағының сейсмикалық деректері бойынша жүргізілген эксперименттер LPBoost ансамблінің ең жоғары дәлдікке (65%) және сезімталдыққа (91%) қол жеткізгенін көрсетті, ал PRNN моделі 71% оң болжамды мәнмен көрсетілген ең аз жалған дабылдарды шығарды. Тұтастай алғанда, авторлар барлық бағаланған тәсілдер қолайлы болжамды көрсеткіштерді көрсетті деген қорытындыға келді.

2018 жылы PLOS ONE журналында жарияланған Асим және т.б. жер сілкінісін қысқа мерзімді болжау үшін көп сатылы машиналық оқыту жүйесін ұсына отырып, олардың бұрынғы зерттеулерін кеңейтті. Зерттеу 15 күндік көкжиекте $\geq 5,0$ баллдық сейсмикалық құбылыстарды болжауға бағытталған және әртүрлі аналитикалық тәсілдер арқылы алынған 60 сейсмологиялық параметрлердің кеңейтілген жиынтығын пайдаланды. Мүмкіндіктердің ақпараттық көрінісін қамтамасыз ету үшін мүмкіндіктерді алудың бірнеше стратегиялары қолданылды [36].

Ұсынылған жүйе иерархиялық оқыту стратегиясын қолдану арқылы бұрын хабарланған тәсілдерден ерекшеленеді, онда машиналық оқытудың бірнеше модельдері дәйекті түрде біріктіріледі. Бастапқыда ең маңызды параметрлерді анықтау үшін минималды резервтеу-максималды өзектілік (mRMR) критерийіне негізделген мүмкіндіктерді таңдаудың екі сатылы процесі қолданылды. Содан кейін таңдалған мүмкіндіктер гибридіт нейрондық желіге қосымша кіріс ретінде шығыс тенденциясы енгізілген тірек векторлық регрессорды оқыту үшін пайдаланылды. Бұл гибридіт модель үш жасанды нейрондық желіні біріктіреді және салмақты оңтайландыру үшін бөлшектер тобын оңтайландырудың эволюциялық алгоритмін пайдаланады [36].

Алынған SVR-HNN құрылымы Индукуш, Чили және Оңтүстік Калифорния аймақтарынан алынған сейсмикалық деректерді пайдалана отырып бағаланды. Модельдің өнімділігі дәлдік, сезімталдық, ерекшелік, Мэттьюс корреляция коэффициенті және корреляция коэффициенті (R) сияқты бірнеше статистикалық көрсеткіштерді пайдалана отырып бағаланды. Алдыңғы зерттеулермен салыстырмалы талдау барлық аймақтардағы болжамды көрсеткіштердің айтарлықтай жақсарғанын көрсетті, бұл ұсынылған көп сатылы әдістеме машиналық оқытудың жеке үлгілерінен асып түсетінін көрсетеді [36].

Қарастырылған барлық ғылыми еңбектердің негізгі сипаттамалары 1.2 - кестеде жинақталған. Осы жұмыстарға жүргізілген салыстырмалы талдау жер сілкінісін болжау мәселесін зерттеуде бірқатар ортақ заңдылықтар мен әдістемелік үрдістердің бар екенін көрсетті [31].

Кесте 1.2 – Барлық қаралған зерттеулердің қысқаша мазмұны [31]

№ (әдеб)	Сейсмикалық аймақ	Деректер көзі	Қолданылған ML әдістері	Қолданылған белгілер (features)	Бағалау көрсеткіштері
[29]	Азор аралдары (Португалия)	–	ANN	Қаржылық осцилляторлар	–
[32]	Оңтүстік Калифорния, Сан-Франциско шығанағы (АҚШ)	SCEC каталогы	LMBP, RNN, RBFN	Гутенберг– Рихтер заңы мен сипаттамалық үлестірімге негізделген сейсмикалық индикаторлар	S_n , FAR, FB, R
[33]	Оңтүстік Калифорния (АҚШ)	SCEC каталогы	PNN	[16]-дағы индикаторлар	S_n , FAR, R
[34]	Калифорния (АҚШ)	ANSS құрама жер сілкінісі каталогы, CEDS	GLM, GBM, DL	[16], [18] индикаторлары	MAE, RE
[37]	Грекия	Сейсмолог ия институты, Афины ұлттық обсерватор иясы (SINOA), VAN тобы	ANN	Барлық сейсмикалық деректер үшін SES моделдеудің екі тәсілі	MAE негізіндегі дәлдік
[35]	Хиндукуш (Пәкістан)	Жер сілкіністері н зерттеу орталығы (Пәкістан), USGS	LMBP-RNN, PRNN, RF, LPBoost	[16]-дағы индикаторлар	P_0 , P_1 , S_n , S_p , Accuracy
[38]	Хиндукуш (Пәкістан), Чили, Оңтүстік Калифорния (АҚШ)	USGS каталогы	GP, AdaBoost	Бір уақытта қолданылған 50 сейсмикалық индикатор	P_0 , P_1 , S_n , S_p , Accuracy, MCC, R
[36]	Хиндукуш (Пәкістан), Чили, Оңтүстік Калифорния (АҚШ)	USGS каталогы	mRMR, SVR, HNN, EPSO	Бір уақытта қолданылған 60 сейсмикалық индикатор	P_0 , P_1 , S_n , S_p , Accuracy, MCC, R

Талшықты-оптикалық сенсорлар нақты уақыт режимінде кеңістіктік тығыздығы жоғары, көлемі үлкен әрі күрделі құрылымды деректерді өндіруге қабілетті. Мұндай деректерде сейсмикалық тербелістер, механикалық деформация, температуралық өзгерістер, акустикалық діріл, тіпті құрылымдық ақау белгілері сияқты әртүрлі физикалық құбылыстар қатар көрінеді. Дегенмен, бұл сигналдар көбіне жоғары дәрежеде шуылдаған, көпөлшемді, уақытша және кеңістіктік тұрғыдан тәуелді болғандықтан, оларды дәстүрлі әдістермен талдау көп жағдайда тиімсіз немесе толық емес нәтиже береді.

Осыған байланысты, талшықты-оптикалық сенсорлардан алынған сигналдарды өңдеуде машиналық оқыту (Machine Learning) және әсіресе оның терең оқыту (Deep Learning) бағыттары кеңінен қолданылуда. Машиналық оқыту әдістері үлкен көлемдегі деректер ішінен жасырын заңдылықтарды автоматты түрде табуға, көпөлшемді белгілерді (features) өздігінен бөлуге және сигналдарды классификациялау, детекциялау немесе болжау сияқты тапсырмаларды жоғары дәлдікпен орындауға мүмкіндік береді.

Машиналық оқытуды (ML) сейсмикалық сигналдарды анықтау мен талдауға біріктіру сейсмологияда трансформациялық жетістіктерге қол жеткізді, бұл жер сілкінісін бақылау жүйелерінің дәлдігі мен тиімділігін арттырды. Маңызды жетістіктердің бірі сейсмикалық оқиғаларды жіктеу және сейсмикалық деректер ішіндегі шуды басу үшін терең оқыту әдістерін қолдануды қамтиды. Конволюциялық нейрондық желілер (CNN), атап айтқанда, микросейсмикалық құбылыстарды тануда және жіктеуде маңызды рөл атқарды, осылайша әртүрлі бақылау сценарийлерінде дәстүрлі әдістерден асып түсті [39, 40]. Бұл модельдердің дәлдігі шулы сейсмикалық деректер жиынтығында минуттық үлгілерді алуға мүмкіндік береді, бұл сигналдарды сәйкестендіруді жақсартуға әкеледі [40, 41]. Сонымен қатар, нақты уақыттағы Denoiser (RTDenoiser) сияқты нақты уақыттағы қолданбаларға бейімделген жетілдірілген алгоритмдер кең сейсмикалық желілерден алынған жер сілкінісі деректерінің үздіксіз тікелей эфирінде шуды тиімді басу үшін терең оқытуды пайдаланады. Бұл әдіс әсіресе жер сілкінісі емес сигналдар мен қоршаған ортаның шуы деректер сапасына жиі нұқсан келтіретін нақты уақыттағы операцияларда сигналдың тұтастығын сақтау үшін пайдалы [42]. Ұзақ мерзімді қысқа мерзімді жад (LSTM) желілерін басқа терең оқыту парадигмаларымен біріктіретін гибриді модельдер сейсмикалық оқиғаларды фондық шудан ажыратудың жақсартылған мүмкіндіктерін көрсетті [43].

1 бөлім бойынша қорытынды

Жүргізілген теориялық талдау таралған акустикалық сезгіштік (DAS) технологиясының дәстүрлі сейсмикалық датчиктермен салыстырғанда оптикалық талшықтың бүкіл ұзындығы бойымен деформацияны үздіксіз өлшеу мүмкіндігіне ие екенін көрсетті. Бұл қасиет DAS жүйелерін әлсіз және

локалды сейсмикалық оқиғаларды тіркеуде аса перспективалы етеді. DAS сигналының физикалық табиғаты орын ауыстыру немесе жылдамдықтың кеңістіктік градиентімен анықталады, ал жүйенің Р және S толқындарға сезімталдығы толқынның түсу бұрышы мен жиілігіне тәуелді екені анықталды, бұл деректерді интерпретациялау кезінде маңызды рөл атқарады.

Сонымен қатар, дәстүрлі сигнал өңдеу әдістерінің DAS деректерінің жоғары өлшемділігі мен шуылдылығы жағдайында шектеулі екені көрсетілді. Осыған байланысты машиналық оқыту әдістері, әсіресе терең оқыту архитектуралары, сейсмикалық және DAS сигналдарындағы кеңістіктік-уақыттық заңдылықтарды автоматты түрде анықтауға мүмкіндік береді. CNN, RNN және LSTM модельдері жоғары дәлдік көрсететін тиімді құралдар ретінде қарастырылды. Модельдердің сапасын бағалауда Precision, Recall және F-score көрсеткіштерін қолданудың маңыздылығы, сондай-ақ Precision–Recall қисықтары арқылы талдаудың тиімділігі негізделді. Жалпы алғанда терең оқыту әдістерін одан әрі дамыту және нейрондық желілер архитектурасын оңтайландыру DAS деректері бойынша сейсмикалық оқиғаларды автоматты анықтаудың дәлдігін арттыруға мүмкіндік береді.

2 DAS деректерін алдын ала өңдеу және сигналдарды тану әдістемесі

2.1 Таратылған акустикалық талшықты-оптикалық сенсордың (DAS) деректер жиынтығы


Бұл зерттеу жұмысында қолданылған деректер жиынтығы Distributed Optical Fibre Sensors (DOFS) технологиясына негізделген. DOFS жүйесі талшықты-оптикалық кабель бойымен таралған жарықтың кері шашырауын талдау арқылы механикалық деформациялар мен тербелістерді үздіксіз және кеңістіктік тұрғыдан жоғары дәлдікпен тіркеуге мүмкіндік береді. Атап айтқанда, бұл жұмыста пайдаланылған деректер Distributed Acoustic Sensing (DAS) әдісі арқылы алынған, мұнда талшық бойындағы әрбір нүкте виртуалды сезгіш ретінде қарастырылады. Мұндай тәсіл мыңдаған өлшеу арналарын бір мезетте қамтып, сейсмикалық сигналдарды жоғары уақыттық және кеңістіктік рұқсаттылықпен бақылауға жағдай жасайды. DOFS-қа негізделген деректер классикалық нүктелік сейсмикалық сенсорлармен салыстырғанда кең аумақты мониторингтеудің тиімді құралын ұсынып, жер қыртысындағы динамикалық процестерді тереңірек зерттеуге мүмкіндік береді.

Imperial Valley Dark Fiber Project Continuous DAS Data - Imperial Valley (Оңтүстік Калифорния, АҚШ) аймағында алынған Distributed Acoustic Sensing (DAS) технологиясы арқылы тіркелген сейсмикалық деректер жиынтығы. Бұл датасет 28 км-ге жуық телеком кабель сегментіндегі DAS сигналдарын қамтиды, ол Calipatria және Imperial қалалары арасындағы «dark fiber» желісінде орналастырылған. «Dark fiber» - телекоммуникация жүйелерінде қазір қолданылмай тұрған талшықты-оптикалық сымдар, олар осы жобада DAS жүйесіне арнап қайта пайдаланылған [47].

Зерттеуде қолданылған DAS деректері жер астына көмілген оптикалық кабельден алынған. Кабельдің орналасу сұлбасы 2.1 - суретте көрсетілген. Оптикалық кабель:

- жер бетінен шамамен 1-2 м тереңдікте орналасқан;
- үстіңгі қабатта әртүрлі материалдармен (топырақ, бетон, асфальт) жабылған;
- кабельдің өзі ПВХ немесе соған ұқсас қорғаныш қабықшамен қапталған.

Талшықты-оптикалық кабельдің үстінде және айналасында орналасқан бұл қабаттар жер бетіндегі және жер қойнауындағы деформациялардың кабельге тиімді берілуін қамтамасыз етеді.



2.1 - сурет – Оптикалық кабельдің орналасу сұлбасы

Imperial Valley - Салтон шұңқыр жүйесінің оңтүстік шетіндегі сейсмикалық белсенді алаң, геотермиялық көздерге бай аймақ. Жоба осы талшықты-оптикалық кабельді пайдаланып жерүсті және жер асты сейсмикалық сигналдарды жоғары кеңістіктегі тығыздықпен ұзақ қашықтықтарға дейін тіркеуді мақсат етеді. Бұл датасет Lawrence Berkeley National Laboratory және Rice University ғылыми ұйымдарының зерттеуі нәтижесінде жарияланды. Жоба АҚШ Энергетика департаментінің Geothermal Technologies Office қаржыландыруымен жүзеге асырылды.


Зерттеу мақсаты:

- Dark fiber кабелі мен DAS технологиясын пайдалана отырып, геотермиялық жүйелер мен сейсмикалық белсенділікті жоғары бөлшектікпен зерттеу;
- Бассейн масштабындағы жер асты құрылымдарды сипаттау және геотермиялық ресурстарды мониторингтеу әдістерін дамыту;
- Өрістегі DAS өлшеулерінің сенімділігін, шу сипаттамаларын және деректер сапасын бағалау.

Деректердің техникалық сипаттамасына сәйкес, қолданылған DAS деректер жиынтығы үздіксіз режимде тіркелген жер сілкінісінің 100 оқиғасын қамтиды. Деректер HDF5 (.h5) форматында сақталған, бұл оларды MATLAB және Python сияқты ғылыми есептеу орталарында тиімді өндеуге мүмкіндік береді. Құрылымдық тұрғыдан алғанда, деректер шамамен 2 880 файлдан тұрады, олардың әрқайсысы бір минуттық DAS strain rate өлшемдерін қамтиды. 1 жазба бойында (файлда) 6 912 өлшеу арнасы пайдаланылған, арналар арасындағы кеңістіктік қадам 4 метрді құрайды, ал өлшеу ұзындығы 10 метрге тең. Уақыттық рұқсаттылығы жоғары болып, үлгілеу жиілігі 500 Гц

деңгейінде жүзеге асырылған, бұл сейсмикалық тербелістердің уақыт бойынша егжей-тегжейлі құрылымын талдауға мүмкіндік береді. Бұл параметрлер DAS-тың жоғары кеңістіктік және уақыттық рұқсаттылығын қамтамасыз етеді, яғни жердегі тербелістер мен сейсмикалық сигналдарды өте жоғары шеберлікпен жазуға мүмкіндік береді.

2.2 – суретте DAS деректер жиынын машиналық оқыту негізінде өңдеу, валидациялау және тестілеу кезеңдерінің жалпы сұлбасы көрсетілген. Алдымен бастапқы DAS деректері алдын ала өңдеуден өткізіледі, оның ішінде шумды азайту және сигналды қалыпқа келтіру операциялары орындалады. Кейін деректер жиыны оқыту, тексеру және тестілеу жиындарына бөлінеді. Оқыту кезеңінде модель параметрлері анықталып, тексеру жиыны арқылы модельдің жалпылау қабілеті бақыланады. Соңғы кезеңде тест деректер жиыны негізінде модельдің тиімділігі бағаланып, DAS сигналдары бойынша алынған нәтижелер талданады.



2.2 - сурет – DAS деректер жинағын оқыту, валидация және тестілеу сұлбасы

2.2 Деректерді алдын ала өңдеу – сүзгілеу

Distributed Acoustic Sensing (DAS) технологиясы арқылы алынған деректер жоғары кеңістіктік және уақыттық ажыратымдылығымен ерекшеленеді. Алайда DAS жүйесімен тіркелетін бастапқы сигналдар (raw data) тек сейсмикалық толқындарды ғана емес, сонымен қатар әртүрлі табиғи және антропогендік шуды, сондай-ақ талшықтың жермен байланысуына (coupling) байланысты әсерлерді қамтиды. Сондықтан DAS деректерін тікелей талдау сенімді нәтижелерге әкелмейді және алдын ала өңдеу кезеңін міндетті түрде талап етеді.

Алдын ала өңдеудің негізгі мақсаты – пайдалы сейсмикалық ақпаратты (P және S толқындар) күшейтіп, шудың әсерін азайту, сигнал-шу қатынасын (SNR) арттыру және деректерді әрі қарайғы талдауға жарамды күйге келтіру.


2.3 - суретте DAS массиві арқылы алынған типтік жазба бірнеше минуттық үздіксіз бақылауды көрсетеді. Бұл жазбада бір мезгілде әртүрлі физикалық процестерден туындайтын сигналдар тіркеледі: жер сілкінісі, көлік қозғалысы, өндірістік жабдықтардың жұмысы және фондық шу. Сондықтан DAS деректері табиғаты бойынша көп компонентті және күрделі құрылымға ие. Берілген жазбада уақыт осі бойымен (шамамен 0–300 с аралығында) және виртуалды сенсорлар нөмірі бойынша сигналдардың таралуы көрсетілген. Жазбаның орталық бөлігінде Imperial Valley аймағында тіркелген магнитудасы шамамен $M \approx 3.5$ болатын жер сілкінісінің сигналы айқын байқалады. Бұл сигнал көптеген арналарда бір уақытта көрініп, кеңістіктік корреляцияға ие, яғни ол сейсмикалық толқындардың таралуына тән сипаттамаларды көрсетеді.

Сонымен қатар жазбада бірнеше түрлі шу көздері анық байқалады:

- Интерферометриялық фондық шу - DAS жүйесінің үздіксіз лазерлік импульстар жіберуіне байланысты пайда болатын әлсіз, бірақ тұрақты сигналдар;

- Көлік шуы (автокөліктер, автобустар) – уақыт бойынша еңкіш (диагональ) іздер түрінде көрінеді, бұл қозғалмалы көздерден тарайтын толқындарға тән белгі;

- Механикалық немесе өндірістік шу (мысалы, сорғылар) – белгілі бір арналарда және тұрақты жиілік диапазонында байқалады.




2.3 - сурет – 5 минут ішіндегі DAS сенсорының жазбасы

Бұл шу компоненттері сейсмикалық сигналдармен қабаттасып, пайдалы ақпаратты ажыратуды қиындатады. Атап айтқанда, кейбір арналарда жергілікті coupling жағдайына байланысты сигнал амплитудасы әлсіреген немесе күшейген түрде көрінуі мүмкін.

Осы құбылыстың физикалық себептері 2.4 - суретте егжей-тегжейлі көрсетілген. Мұнда бір сейсмикалық оқиға үшін талшық бойымен тіркелген сигналдардың кеңістіктік өзгергіштігі кабель–жер ортасының байланысымен (fiber–soil–rock coupling) және жергілікті шу көздерімен түсіндіріледі. Кабельдің төселу жағдайы, жер бетіне жақын қабаттардың қасиеттері және кабель бағытының өзгеруі бірдей сейсмикалық толқындардың әр арнада әртүрлі амплитудада және формада тіркелуіне әкеледі.


DAS жүйесі талшық бойындағы осьтік деформацияларды тіркеп, уақыт–кеңістік (time–distance) форматында үздіксіз сейсмикалық жазба береді. Суретте жер сілкінісінің P-толқыны мен S-толқынының келу фронттары айқын байқалады. Сонымен қатар жазбада жергілікті шу көздерінің (көлік, өндірістік белсенділік) және fiber–soil coupling әсерлерінің сигналға ықпалы көрінеді. Кабель бағытының өзгеруі мен жермен байланыс сапасының әркелкілігі сигнал амплитудасының кеңістікте өзгеруіне әкеледі.



2.4 - сурет – DAS сенсоры арқылы тіркелген нақты жер сілкінісінің сигналдарын тану

Осы жұмыста DAS деректері талшық бойымен әр 10 м сайын орналастырылған виртуалды датчиктер арқылы алынған. Мұндай кеңістіктік дискретизация сейсмикалық толқындардың таралу динамикасын жоғары ажыратымдылықпен бақылауға мүмкіндік береді. 2.5 - суретте 10 м арақашықтықтағы виртуалды DAS датчиктерінде тіркелген сигналдардың уақыт бойынша өзгерісі және жеке трассалардағы тербелістер көрсетілген.

Суреттің сол жақ бөлігінде уақыт–кеңістік жазбасында (time–offset domain) тіркелген толқын өрісі берілген, мұнда сейсмикалық толқындардың талшық бойымен таралуы анық байқалады. Ал оң жақ бөлігінде бір виртуалды датчик үшін алынған амплитудалық сигнал көрсетіліп, онда Р толқынының ертерек келуі және S толқынының кейінгі, бірақ амплитудасы жоғарырақ бөлімі айқын ажыратылады. Бұл Р және S толқындарының физикалық табиғатына сәйкес келеді, яғни Р толқындары жоғары жылдамдықпен таралып, ал S толқындары салыстырмалы түрде баяу таралады.



2.5 - сурет – 10 м арақашықтықтағы виртуалды DAS датчиктерінде тіркелген Р және S толқындары

Бұл зерттеуде сейсмикалық сигналдарды шудан тазарту үшін әртүрлі принциптерге негізделген сүзгілеу әдістері қолданылды. Сүзгілердің тиімділігін жан-жақты бағалау мақсатында уақыт–жиілік аймағында жұмыс істейтін адаптивті әдіс және жиілік аймағында қолданылатын классикалық сүзгі қарастырылды. Осыған байланысты төменде Винер және Баттерворт сүзгілерінің теориялық негіздері мен қолданылу ерекшеліктері сипатталады.

2.2.1 Винер сүзгісі

Бұл зерттеуде сейсмикалық сигналдарды шудан тазарту үшін уақыт - жиілік аймағында жұмыс істейтін Винер сүзгісі қолданылды. Винер сүзгісі сейсмикалық сигнал мен шудың спектралдық сипаттамаларына негізделе отырып, пайдалы сигналды қалпына келтіруге мүмкіндік беретін тиімді әдіс болып табылады. Аталған тәсіл болашақтағы шу деңгейін ағымдағы сигнал ақпараты арқылы бағалауға мүмкіндік береді және сейсмикалық деректерді өңдеуде кеңінен қолданылады.

Винер сүзгісін іске асырудың алғашқы кезеңінде бастапқы уақыт аймағындағы сейсмикалық сигнал қысқа уақыттық Фурье түрлендіру (STFT) арқылы уақыт - жиілік аймағына ауыстырылады. STFT үдерісі сигналды бір-бірімен қабаттасатын қысқа уақыт сегменттеріне бөліп, әр сегмент үшін жиілік аймағындағы спектралдық амплитуданы есептейді. Осылайша, сигналдың уақыт бойынша өзгертін жиілік құрамы анықталады.

k -ші жиілік индексі мен n -ші уақыт сегментіндегі бастапқы сигнал спектрі $Y(k, n)$ қажетті сигнал спектрі $X(k, n)$ мен шу спектрі $S(k, n)$ қосындысынан тұрады деп болжанады, бұл төмендегі теңдеуде көрсетілген:

$$Y(k, n) = X(k, n) + S(k, n) \quad (2.1)$$

Қажетті сигнал спектрін бағалау үшін бастапқы сигнал спектрі күшейту функциясымен $G(k, n)$ немесе Винер сүзгісінің беріліс функциясымен көбейтіледі. Мұндағы $\hat{X}(k, n)$ — $X(k, n)$ бағаланған мәнін білдіреді. $X(k, n)$ алынғаннан кейін, ол кері STFT көмегімен уақыт аймағындағы сигналға қайта қалпына келтіріледі. Қажетті спектрді бағалау келесі формуламен өрнектеледі:

$$\hat{X}(k, n) = G(k, n) \cdot Y(k, n) \quad (2.2)$$

Жиілік аймағында бақыланған сигнал қажетті сигнал мен шудың қосындысы ретінде қарастырылады. Қажетті сигнал спектрін бағалау үшін Винер сүзгісінің беріліс функциясы қолданылады, ол сигналдың қуат спектрінің шу қуат спектріне қатынасына тәуелді. Бұл беріліс функциясы сигнал - шу қатынасы (SNR) негізінде анықталып, жиілікке және уақытқа тәуелді түрде өзгеріп отырады.

Сейсмикалық шу деңгейі алдын ала белгілі болмағандықтан, ол шешімге бағытталған әдіс арқылы бағаланады. Бұл әдіс алдыңғы уақыт сегментіндегі сүзгілеу нәтижелерін пайдалана отырып, ағымдағы уақыт сегменті үшін априорлық SNR мәнін есептейді. Мұндай тәсіл сигнал мен шудың стационар емес сипатын ескеруге мүмкіндік береді. Шуға қатысты эталон дисперсиясы жер сілкінісі сигналы байқалмайтын уақыт аралықтарынан анықталады және шудың уақыт бойынша өзгеруіне байланысты үздіксіз жаңартылып отырады. Шу эталонының жаңартылуы спектралдық айырма және шу сегментінің ұзақтығы сияқты алдын ала анықталған критерийлерге негізделеді. Бұл механизм Винер сүзгісінің әртүрлі шу жағдайларына бейімделуін қамтамасыз етеді. Нәтижесінде, Винер сүзгісі төмен жиілікті және стационар емес шуды тиімді түрде басып, жер сілкінісі сигналының толқын пішіні мен негізгі динамикалық ерекшеліктерін мүмкіндігінше сақтай отырып қалпына келтіруге мүмкіндік береді [44].

2.2.2 Баттерворт сүзгісі

Винер сүзгісі сейсмикалық сигналды шудың статистикалық сипаттамаларына сүйене отырып бейімделгіш түрде өндесе, Баттерворт сүзгісі сигналды алдын ала анықталған жиілік диапазоны бойынша сүзуге негізделген классикалық әдіс болып табылады. Сондықтан бұл зерттеуде Баттерворт сүзгісі Винер сүзгісіне балама әрі салыстырмалы тәсіл ретінде қарастырылды.

Баттерворт сүзгісі биомедициналық, аудио және сейсмикалық сигналдар сияқты әртүрлі цифрлық сигналдарды өңдеуде кеңінен қолданылатын танымал сүзгі болып табылады. Ол берілген жиілік диапазонына (кесу жиілігіне) негізделе отырып сигнал спектрін жақсартатын жиілікке негізделген сүзгілер түріне жатады. Өткізу жолағындағы жиілік құрамына байланысты Баттерворт сүзгілерінің төрт түрі бар.

Төмен жиілікті өткізгіш (low-pass) сүзгі - кесу жиілігінен төмен орналасқан сигналдың жиілік құрамын өткізетін сүзгі. Жоғары жиілікті өткізгіш (high-pass) сүзгі - кесу жиілігінен жоғары орналасқан сигналдың жиілік құрамын өткізетін сүзгі. Жолақтық өткізгіш (band-pass) сүзгі - екі кесу жиілігінің арасындағы сигналдың жиілік құрамын өткізетін сүзгі. Ал ойық (notch) немесе жолақты тоқтатушы (band-stop) сүзгі - екі кесу жиілігінің арасындағы сигналды бөгейтін немесе әлсірететін сүзгі болып табылады [44].


Жиілік аймағындағы Баттерворт сүзгісінің амплитудалық сипаттамасы (2.3) теңдеуімен анықталады:

$$|H(j\omega)| = \frac{1}{\sqrt{1 + \left(\frac{\omega}{\omega_c}\right)^{2N}}} \quad (2.3)$$

мұнда $H(j\omega)$ - жауап амплитудасы, j - жорамал бірлік, ω - кіріс жиілігі, ω_c - берілген кесу жиілігі, ал N - сүзгінің реттілігі.

Осы зерттеуде Баттерворт сүзгісінің параметрлері жер сілкіністерін автоматты анықтау жүйелерінде кеңінен қолданылатын стандартты баптауларға сүйене отырып анықталды. Нақтырақ айтқанда, үшінші ретті жолақтық өткізгіш Баттерворт сүзгісі қолданылып, оның кесу жиіліктері 0.7–2 Гц аралығында белгіленді. 2.6 - суретте осы зерттеуде пайдаланылған Баттерворт сүзгісінің амплитудалық сипаттамасының графигі көрсетілген. Бұл жиілік диапазоны жер сілкінісі сигналдарының негізгі энергиясы жинақталатын аймақты қамтиды және төмен жиілікті фондық шуды, сондай-ақ жоғары жиілікті кездейсоқ кедергілерді әлсіретуге мүмкіндік береді.

Жалпы алғанда, Баттерворт сүзгісі белгілі бір жиілік диапазонында басым болатын шуды тиімді түрде азайта алады, алайда ол Винер сүзгісіне қарағанда бейімделгіш емес және уақыт аймағындағы толқын пішінін толық сақтауды қамтамасыз етпейді. Осы себепті Баттерворт сүзгісінің тиімділігі Винер сүзгісімен салыстырмалы түрде бағаланып, олардың артықшылықтары мен шектеулері келесі бөлімде талданады.



2.6 - сурет – 0.7–2 Гц жиілік диапазонында үшінші ретті Баттерворт жолақтық өткізгіш сүзгісінің амплитудалық сипаттамасы

2.3 Сүзгілеу әдістерінің тиімділігін бағалау

Қолданылған сүзгілеу әдістерінің тиімділігін бағалау үшін олардың сейсмикалық сигнал сапасына әсері сандық көрсеткіштер арқылы талданды. Бұл зерттеуде Винер және Баттерворт сүзгілерінің өнімділігі сигнал - шу қатынасының (SNR) өзгерісі және толқын пішінінің сақталу деңгейі негізінде салыстырылды. Аталған көрсеткіштер жер сілкінісі сигналдарын анықтау мен интерпретациялаудың сапасын бағалауда кеңінен қолданылады.

SNR көрсеткіші сүзгілеу нәтижесінде пайдалы сигналдың қаншалықты күшейгенін немесе шудың қаншалықты азайғанын сипаттайды. SNR мәні сейсмикалық сигнал амплитудасының орташа квадраттық түбірінің (A_s) шу амплитудасының орташа квадраттық түбіріне (A_n) қатынасы арқылы анықталады және децибелмен өрнектеледі:

$$\text{SNR} = 20\log_{10} \left(\frac{A_s}{A_n} \right) \quad (2.4)$$

мұнда A_s жер сілкінісі сигналы басым болатын уақыт аралығынан, ал A_n жер сілкінісі басталғанға дейінгі шу басым болатын уақыт аралығынан есептеледі. Бұл уақыт терезелері Р-толқынының келу уақытына қатысты анықталып, сигнал және шу сегменттерінің ұзақтығы бірдей етіп таңдалады.

Сүзгінің толқын пішінін сақтау қабілетін бағалау үшін бастапқы және сүзгіден өткен сигналдардың өзара ұқсастығы есептелді. Бұл мақсатта екі сигналдың нормаланған өзара корреляция коэффициенті қолданылды, ол толқын пішіндерінің фазалық сәйкестігін және амплитудалық ұқсастығын сипаттайды. Нормаланған өзара корреляция коэффициенті келесі түрде анықталады:

$$CC = \frac{\sum_{i=1}^N x(i) y(i)}{\sqrt{\sum_{i=1}^N x^2(i)} \sqrt{\sum_{i=1}^N y^2(i)}} \quad (2.5)$$

мұнда $x(i)$ — бастапқы сейсмикалық сигнал, $y(i)$ — сүзгіден өткен сигнал, ал N — салыстыру үшін алынған уақыт үлгілерінің саны. Корреляция коэффициентінің мәні -1 мен 1 аралығында болады, ал мәннің 1 -ге жақындауы екі толқын пішінінің жоғары ұқсастығын білдіреді.

Өзара корреляцияны есептеу үшін жер сілкінісі сигналының алғашқы бірнеше секундтық бөлігі пайдаланылды, себебі бұл аралықта сигнал энергиясы басым және фазалық ақпарат айқын көрінеді. Бұл тәсіл сүзгілеу нәтижесінде толқын пішінінің бұрмалану деңгейін нақты бағалауға мүмкіндік береді. Осылайша, SNR өзгерісі сүзгілердің шуды азайту қабілетін сипаттаса, өзара корреляция коэффициенті олардың сейсмикалық толқын пішінін сақтау мүмкіндігін көрсетеді. Аталған екі көрсеткішті бірлесе қолдану Винер және Баттерворт сүзгілерінің артықшылықтары мен шектеулерін жан-жақты салыстыруға мүмкіндік береді.

Жоғарыда қарастырылған сүзгілеу әдістері сейсмикалық сигналдардың сапасын жақсартуға және шудың әсерін азайтуға мүмкіндік береді. Алайда, тек классикалық сигнал өңдеу тәсілдерін қолдану жер сілкінісі сигналдарын автоматты түрде анықтау мен жіктеу міндеттерінде әрдайым жеткілікті нәтиже бере бермейді. Әсіресе, төмен амплитудалы және шу деңгейі жоғары сигналдар жағдайында қосымша интеллектуалды әдістерді қолдану қажеттілігі туындайды[44].

Осыған байланысты, алдын ала сүзгіден өткен сейсмикалық сигналдарды әрі қарай талдау үшін машиналық оқыту әдістерін қолдану орынды болып табылады. Машиналық оқыту архитектуралары күрделі, сызықтық емес заңдылықтарды анықтауға және сигналдың жасырын ерекшеліктерін автоматты түрде үйренуге қабілетті. Сондықтан келесі бөлімде жер сілкінісі сигналдарын анықтау және сипаттау үшін қолданылған машиналық оқыту архитектураларының құрылымы мен жұмыс принциптері сипатталады.

2.4 Сигналдарды тану және өңдеу үшін Машиналық оқыту моделінің архитектурасы

Бұл зерттеу жұмысында Distributed Acoustic Sensing (DAS) жүйесі арқылы алынған сейсмикалық сигналдарды тану және талдау үшін терең оқытуға негізделген нейрондық желі архитектуралары қарастырылды. Жалпы алғанда, терең оқыту әдістері толық байланысқан жасанды нейрондық желілерді, конволюциялық нейрондық желілерді және рекуррентті нейрондық желілерді қамтиды. Аталған архитектуралар уақыттық деректердегі күрделі және бейсызық заңдылықтарды модельдеуге мүмкіндік береді, сондықтан олар сейсмикалық сигналдарды автоматты түрде тану міндеттері үшін кеңінен қолданылады [6].

Толық байланысқан нейрондық желілер (feedforward немесе multilayer perceptron) кіріс және шығыс деректер арасындағы тәуелділікті үйренуге негізделген базалық модельдер болып табылады. Мұндай желілерде әрбір нейрон келесі қабаттағы барлық нейрондармен байланысқан, ал бейсызықтықты енгізу үшін активация функциялары қолданылады. Дегенмен, уақыттық сигналдардың өлшемі үлкен болған жағдайда мұндай модельдер параметрлер санының шамадан тыс өсуіне әкелуі мүмкін.


Осыған байланысты, бұл жұмыста негізгі назар уақыттық сигналдарды тиімді өңдеуге бейімделген Convolutional Neural Network (CNN) архитектурасына аударылды. CNN модельдері сигналдың локальды пішіндік ерекшеліктерін автоматты түрде анықтауға мүмкіндік береді.

Convolutional Neural Network (CNN) архитектурасы DAS технологиясы арқылы алынған уақыттық сейсмикалық сигналдарды өңдеу үшін қолданылды. CNN модельдерінің негізгі артықшылығы – уақыттық сигналдардағы локальды пішіндік ерекшеліктерді автоматты түрде анықтау қабілеті. DAS деректері үздіксіз уақыттық қатарлар түрінде ұсынылатындықтан, бұл жұмыста екіөлшемді емес, бірөлшемді (1D) конволюциялық қабаттар пайдаланылды. CNN моделінің кірісіне алдын ала өңдеуден өткен, сегменттелген және қалыпқа келтірілген уақыттық сигналдар берілді. Әрбір кіріс үлгісі бір арналы уақыттық вектор ретінде ұсынылады. Архитектура бірнеше қайталанатын блоктардан тұрады, олардың әрқайсысы Conv1D – Batch Normalization – ReLU – MaxPooling қабаттарының тізбегінен құралған. Конволюциялық қабаттар уақыт осі бойынша жылжымалы филтрлерді қолдану арқылы сигналдағы маңызды локальды ерекшеліктерді бөліп алады.

Batch Normalization қабаттары оқыту процесін тұрақтандыру және конвергенция жылдамдығын арттыру мақсатында енгізілді. Ал ReLU активация функциясы желіге бейсызықтық қасиет беріп, терең архитектураларда жиі кездесетін градиенттің жоғалу мәселесін азайтады. MaxPooling қабаттары деректер өлшемін біртіндеп қысқартып, модельдің есептеу күрделілігін төмендету және шу әсерін азайту үшін қолданылды.

CNN архитектурасының соңғы бөлігінде Global Average Pooling қабаты пайдаланылды, бұл толық байланысқан қабаттарға өтпес бұрын уақыттық өлшемді ықшамдауға мүмкіндік береді және модельдің артық үйрену (overfitting) ықтималдығын төмендетеді. Одан кейін бір толық байланысқан қабат арқылы алынған сипаттамалар өңделіп, шығыс қабатта Sigmoid активация функциясы қолданылды. Sigmoid функциясы шығыс мәнін $[0,1]$ аралығында қалыптастырып, кіріс сигналдың сейсмикалық оқиғаға жату ықтималдығын бағалауға мүмкіндік береді.

Осылайша, ұсынылған CNN архитектурасы DAS деректерінің уақыттық құрылымын тиімді сипаттауға, сейсмикалық сигналдарды автоматты түрде анықтауға және бинарлы классификация міндетін шешуге бағытталған.



2.7 - сурет – Ұсынылған конволюциялық нейрондық желілердің архитектурасы

Ұсынылған конволюциялық нейрондық желілердің архитектурасы 2.7 – суретте көрсетілген. Бұл LeNet архитектурасының бейімделуі [45], алдымен кескінді жіктеу мәселелерін шешу үшін ұсынылған және үлгіні танудың бірнеше саласында, соның ішінде сейсмикалық мәліметтерді өңдеуде қолданылады. Сейсмикалық анықтау және фазалық іріктеу үшін қолданылатын конволюциялық модельдердің көпшілігі осы схеманың вариациялары болып табылады [46], [48].

2 бөлім бойынша қорытынды

2 - бөлімде таратылған талшықты-оптикалық сенсорлардан (DOFS/DAS) алынған деректер зерттеудің бастапқы материалы ретінде қарастырылып, олардың сейсмикалық және механикалық тербелістерді талдаудағы ерекшеліктері айқындалды. DAS технологиясының үздіксіз өлшеу мүмкіндігі мен жоғары кеңістіктік ажыратымдылығы оны дәстүрлі нүктелік сейсмикалық сенсорлармен салыстырғанда машиналық оқыту әдістерін қолдану үшін тиімді дереккөзге айналдыратыны көрсетілді.

Деректерді алдын ала өңдеу кезеңінде сигнал сапасын арттыру мақсатында Butterworth және Wiener сүзгілері қолданылды. Butterworth сүзгісі жиілік аймағында сигналды тегістеуге және төмен немесе жоғары жиілікті шуды басуға мүмкіндік беріп, сигналдың негізгі спектрлік құрамын сақтауды қамтамасыз етті. Ал Wiener сүзгісі статистикалық тәсілге негізделіп, сигнал мен шудың дисперсиялық сипаттамаларын ескеру арқылы шу әсерін бейімделген түрде азайтып, сигнал/шу қатынасын жақсартуда жоғары тиімділік көрсетті.


Сейсмикалық сигналдарды тану үшін қолданылған машиналық оқыту моделінің архитектурасы сипатталып, оның DAS деректеріне тән күрделі уақыттық-кеңістіктік ерекшеліктерді өңдеудегі артықшылықтары негізделді. Жалпы алғанда, осы тарауда қарастырылған деректерді өңдеу тәсілдері мен машиналық оқыту әдістері диссертациялық жұмыстың эксперименттік бөлімін орындау үшін қажетті әдістемелік негіз қалыптастырып, үшінші тарауда алынатын нәтижелердің ғылыми негізділігін қамтамасыз етті.

3 DAS сенсорынан алынған деректер жинағын алдын ала өңдеу және машиналық оқыту арқылы зерттеу нәтижелері

3.1 DAS деректерін алдын - ала өңдеу нәтижелері

Зерттеу барысында 2020 жылдың 1-30 маусым аралығында магнитудасы 2.2-5.3 диапазонында болатын жер сілкінісі оқиғалары таңдалып алынды. Тіркелген жер сілкінісі сигналдарының SNR мәндері -4.97 дБ-ден 64.68 дБ-ге дейінгі аралықта өзгерді. Ең жоғары SNR мәні 2020 жылғы 4 маусымда, 08:49 UTC уақытында тіркелген, магнитудасы 5,3 және эпицентрге дейінгі қашықтығы шамамен 206 км болатын жер сілкінісіне сәйкес келеді. Ал ең төмен SNR мәні 2020 жылғы 8 маусымда, 10:47 UTC уақытында тіркелген, магнитудасы 3.4 және эпицентрге дейінгі қашықтығы шамамен 260 км болатын оқиғада байқалды.


3.1a-суреттен SNR гистограммасының басым бөлігі 0-30 дБ аралығында орналасқанын көруге болады, алайда SNR мәні 0 дБ-ден төмен болатын 13 оқиға бар. Жалпы алғанда, Винер сүзгісі SNR мәнін орта есеппен 8.10 дБ-ге арттыра алады. Винер сүзгісінен кейінгі SNR мәндері негізінен 0 дБ-ден жоғары және көбіне 10–40 дБ аралығында орналасқан (3.1c-сурет). 3.1b-суреттен Баттерворт сүзгісін қолданғаннан кейін SNR гистограммасында сүзгілеуге дейінгі жағдаймен салыстырғанда айтарлықтай өзгеріс байқалмайтыны көрінеді. Баттерворт сүзгісін қолдану нәтижесінде SNR өзгерісі негізінен -10 бен 10 дБ аралығында болып, орташа мәні 0.13 дБ-ді құрады.



3.1 a - сурет – Сүзгіленбеген сигналдың, b - Баттерворт сүзгісімен және c - Винер сүзгісімен өңделген сигналдардың SNR мәндерінің гистограммалары

3.2-сурет сүзгілеуге дейінгі және кейінгі SNR арасындағы күшті корреляцияны көрсетеді: сүзгілеуге дейінгі SNR неғұрлым жоғары болса, сүзгілеуден кейінгі SNR де соғұрлым жоғары болады. Алайда Баттерворт сүзгісі мен Винер сүзгісінен кейінгі SNR нәтижелері арасында айтарлықтай


айырмашылық бар. Винер сүзгісінің нәтижелері, әсіресе бастапқы SNR төмен болған жағдайда, Баттерворт сүзгісіне қарағанда анағұрлым жоғары SNR көрсетеді. Винер сүзгісі SNR мәні 0 дБ-ден төмен болатын 13 сейсмикалық сигналды тиімді түрде жақсартта алды. SNR-дың 0 дБ-ден төмен болуы жер сілкінісі сигналын анықтаудың қиын екенін білдіреді, себебі сигнал амплитудасы сейсмикалық шудың амплитудасынан әлсіз болады. Мұндай жағдайлар көбінесе жоғары жиілікті құрамдас бөлігі бар, амплитудасы төмен, шағын магнитудалы жер сілкіністеріне тән. Төмен жиілікті фондық шу спектрлік амплитудасы жоғары болғандықтан, жоғары жиілікті жер сілкінісі сигналын бүркемелейді.



3.2 - сурет – Butterworth сүзгісінен кейінгі SNR мен Wiener сүзгісінен кейінгі SNR мен сүзу алдындағы SNR арасындағы салыстыру

3.3-суретте SNR мәні -2.99 дБ болатын жер сілкінісі сигналының мысалы көрсетілген, ол Винер сүзгісі арқылы өңделгеннен кейін 22.06 дБ-ге дейін жақсарған. Шамамен 1.1 Гц жиіліктегі фондық шу басым спектрлік амплитудаға ие болып, 4-10 Гц диапазонында басым жиілікке ие жер сілкінісі сигналын жауып тұрған. Сүзгілеуден кейін төмен жиілікті шу тиімді түрде басылып, жер сілкінісі сигналы айқын көрінетін күйге жеткен. Ал Баттерворт сүзгісі жер сілкінісі сигналының басым жиілігі сүзгінің қиылысу жиілік


диапазонына сәйкес келмеген жағдайда спектрді айтарлықтай күшейте алмайтыны байқалды.



3.3 - сурет – Төмен жиілікті шу басым болатын сейсмикалық сигналды Баттерворт және Винер сүзгілері арқылы сүзу

Көрсетілген толқын пішіні 2020 жылғы 1 маусымда, 21:41:37 UTC уақытында MGA1 станциясында тіркелген, магнитудасы 3.1 болатын жер сілкінісі оқиғасына сәйкес келеді.

Винер сүзгісінің сейсмикалық шудың уақыт бойынша өзгеретін жағдайларына бейімделу қабілеті 3.4-суреттегі басылған шу арқылы анық көрінеді. Төмен жиілікті шуды басумен қатар, Винер сүзгісі жоғары жиілікті шуды да азайтып, төмен жиілікті жер сілкінісі сигналдарының SNR мәнін арттыра алады. Мысалы, 2020 жылғы 3 маусымда тіркелген магнитудасы 5.0 жер сілкінісінде Винер сүзгісі SNR мәнін 1.50 дБ-ден 22.82 дБ-ге дейін көтерген.




3.4 - сурет – Баттерворт пен Винер сүзгісін қолдана отырып, жоғары жиілікті-
шұыл басым сейсмикалық сигналды сүзу

Жалпы алғанда, фондық сейсмикалық шудың сипаттамалары сүзгінің өнімділігіне елеулі әсер етеді. Егер фондық шудың спектрі Баттерворт сүзгісінің өткізу жолағына сәйкес келсе, бұл Р-толқынының келу уақытын анықтауда қиындық тудыруы мүмкін.

3.2 1D-CNN моделін оқыту және нәтижелері


Келесі кезеңде сейсмикалық сигналдарды өңдеу үшін бірөлшемді конволюциялық нейрондық желі (1D-CNN) қолданылды. Бұл модель сигналдың локальды пішіндік ерекшеліктерін автоматты түрде анықтауға бағытталған.

CNN моделін оқыту үшін деректер уақыттық терезелерге бөлінді. Нәтижесінде 565 терезе қалыптастырылды, олардың ішінде 452 — шу сигналдары, ал 113 - сейсмикалық оқиғаларға сәйкес келетін терезелер. CNN моделін оқыту барысы 3.5 - суретте берілген.




3.5 - сурет – CNN моделін оқыту барысы

CNN моделінің классификация нәтижелері қателік матрицасы арқылы бағаланды (3.6– сурет). Сонымен қатар, threshold мәнінің accuracy, precision, recall және F1-score көрсеткіштеріне әсері 3.7-суретте көрсетілген.



3.6 - сурет – CNN моделінің қателік матрицасы



3.7 - сурет – CNN моделінің Threshold / Accuracy , Threshold/F1 score , Threshold/Recall , Threshold / Precision графиктері

CNN моделінің негізгі метрикалары:

- Accuracy = 0.988
- Precision = 0.967
- Recall = 0.967
- F1-score = 0.967

Бұл нәтижелер CNN моделінің DAS деректеріндегі сейсмикалық сигналдарды анықтауда жоғары тиімділік көрсеткенін дәлелдейді.

3 бөлім бойынша қорытынды

Бұл бөлімде DAS сенсорынан алынған деректер жиынтығы алдын ала өңделіп, машиналық оқыту әдістері арқылы сейсмикалық сигналдарды тану нәтижелері зерттелді. 2020 жылғы маусым айында тіркелген әртүрлі магнитудадағы жер сілкінісі оқиғалары негізінде бастапқы сигналдардың шуыл деңгейі кең диапазонда өзгертіні анықталды, бұл алдын ала өңдеу кезеңінің маңыздылығын көрсетті.

Сүзгілеу нәтижелерін талдау Wiener сүзгісінің Butterworth сүзгісімен салыстырғанда айтарлықтай жоғары тиімділікке ие екенін дәлелдеді. Wiener сүзгісі SNR мәнін орта есеппен 8.10 дБ-ге арттырып, бастапқы SNR мәні 0 дБ-ден төмен болған әлсіз сейсмикалық сигналдарды анық күйге келтіруге мүмкіндік берді. Ал Butterworth сүзгісі жиілік аймағында пайдалы болғанымен, шу басу тұрғысынан шектеулі әсер көрсететіні байқалды. Алынған нәтижелер фондық шудың спектрлік сипаттамалары сүзгінің өнімділігіне тікелей әсер ететінін көрсетті.

Алдын ала өңделген деректер негізінде бірөлшемді конволюциялық нейрондық желі (1D-CNN) моделі оқытылды. Уақыттық терезелерге бөлінген деректермен жүргізілген оқыту нәтижелері CNN моделінің DAS деректеріндегі сейсмикалық сигналдарды жоғары дәлдікпен жіктей алатынын көрсетті. Модельдің Accuracy, Precision, Recall және F1-score көрсеткіштерінің 0.96–0.99 аралығында болуы ұсынылған тәсілдің тиімділігін дәлелдейді.

Жалпы алғанда, үшінші бөлімде алынған нәтижелер Wiener сүзгісі мен 1D-CNN моделін бірлесе қолдану DAS деректеріндегі әлсіз және шуыл басым сейсмикалық сигналдарды сенімді түрде анықтауға мүмкіндік беретінін көрсетті. Бұл тәсіл таратылған талшықты-оптикалық сенсорлар негізіндегі сейсмикалық мониторинг және ерте анықтау жүйелерінде практикалық тұрғыдан қолдануға жарамды.

ҚОРЫТЫНДЫ

Бұл диссертациялық жұмыста таратылған талшықты-оптикалық сенсорлардан (DOFS, соның ішінде DAS технологиясы) алынатын сигналдарды машиналық оқыту әдістері негізінде тану және өңдеу мәселелері жан-жақты зерттелді. Зерттеудің негізгі мақсаты – дәстүрлі сигнал өңдеу тәсілдерінің шектеулерін ескере отырып, сейсмикалық және механикалық тербеліс сигналдарын автоматты түрде анықтауға және жіктеуге қабілетті тиімді интеллектуалды әдістерді әзірлеу болды.

Жұмыстың алғашқы бөлімінде талшықты-оптикалық сенсорлардың физикалық жұмыс принциптері, DOFS және DAS технологияларының ерекшеліктері, олардың классикалық сейсмологиялық өлшеу жүйелерімен салыстырмалы артықшылықтары талданды. Сонымен қатар, уақыттық сигналдарды өңдеудің дәстүрлі әдістерінің кемшіліктері мен күрделі, шуылға толы деректер жағдайында олардың шектеулі мүмкіндіктері көрсетілді. Осы негізде машиналық оқыту әдістерін қолданудың өзектілігі ғылыми тұрғыда дәлелденді.

Екінші бөлімде зерттеу барысында қолданылған деректер жиынтығы сипатталып, талшықты-оптикалық сенсор сигналдарын алдын ала өңдеу кезеңдері ұсынылды. Атап айтқанда, сигналдарды сүзу, нормализациялау, сегментациялау және ерекшелікке бай терезелерге бөлу әдістері жүзеге асырылды. Сонымен қатар, машиналық оқытудың CNN, LSTM және гибридік CNN+LSTM модельдерінің архитектуралары қарастырылып, олардың уақыттық және кеңістіктік ерекшеліктерді үйренудегі мүмкіндіктері негізделді.

Үшінші бөлімде жүргізілген тәжірибелік зерттеулердің нәтижелері ұсынылды. Әзірленген модельдер сейсмикалық сигналдарды анықтау және жіктеу тапсырмаларында салыстырмалы түрде бағаланып, дәлдік (Accuracy), нақтылық (Precision), толықтық (Recall) және F1-score сияқты метрикалар бойынша талданды. Алынған нәтижелер гибридік CNN+LSTM моделінің жеке CNN немесе LSTM модельдеріне қарағанда жоғары тиімділік көрсететінін дәлелдеді. Бұл модель кеңістіктік сипаттамаларды терең үйренумен қатар, уақыт бойынша тәуелділіктерді тиімді түрде ескеруге мүмкіндік береді.

Жалпы алғанда, диссертациялық жұмыста қойылған мақсаттар мен міндеттер толық орындалды. Алынған ғылыми нәтижелер таратылған талшықты-оптикалық сенсорлардан алынатын үлкен көлемді деректерді интеллектуалды өңдеу саласын дамытуға үлес қосады. Зерттеу нәтижелерін жер сілкіністерін ерте анықтау жүйелерінде, инфрақұрылым нысандарының құрылымдық күйін мониторингілеуде және өнеркәсіптік қауіпсіздік салаларында қолдануға болады. Болашақта ұсынылған әдістерді кеңейтілген деректер жиынтығында сынақтан өткізу, нақты уақыт режимінде жұмыс істейтін жүйелерге енгізу және көпмодальды сенсор деректерін біріктіру бағыттарында дамыту мүмкіндігі бар.

Жұмыс нәтижелерінің ғылыми, әлеуметтік және танымдық құндылығы.

Ғылыми құндылығы диссертациялық жұмыста таратылған талшықты-оптикалық сенсорлардан (DOFS, соның ішінде DAS технологиясы) алынатын сигналдарды интеллектуалды өңдеу әдістерін дамытуымен анықталады. Зерттеу барысында шуыл деңгейі жоғары және үлкен көлемді уақыттық деректерді талдауда машиналық оқыту мен терең нейрондық желілерді қолданудың тиімділігі ғылыми тұрғыда негізделді. CNN, LSTM және гибридік CNN+LSTM модельдерін пайдалану арқылы кеңістіктік және уақыттық ерекшеліктерді бірлесе есепке алу мүмкіндігі көрсетілді. Алынған нәтижелер талшықты-оптикалық сенсорика, сейсмология және жасанды интеллект тоғысындағы пәнаралық зерттеулердің дамуына үлес қосады.

Әлеуметтік құндылығы ұсынылған әдістердің табиғи және техногендік процестерді мониторингілеу жүйелерінде практикалық қолдану мүмкіндігімен айқындалады. Машиналық оқыту алгоритмдерімен біріктірілген таратылған талшықты-оптикалық сенсорлар жер сілкіністерін, механикалық тербелістерді және инженерлік нысандардың қауіпті күйін ерте анықтауға мүмкіндік береді. Бұл төтенше жағдайлар тәуекелін төмендетуге, халықтың қауіпсіздігін арттыруға және маңызды инфрақұрылым объектілерін қорғауға ықпал етеді.

Танымдық құндылығы зерттеу барысында DOFS/DAS сигналдарын өңдеудің заманауи тәсілдерін жүйелеу және жалпылаумен сипатталады. Диссертациялық жұмыста машиналық оқытудың уақыттық деректерді талдаудағы мүмкіндіктері туралы тұтас ғылыми түсінік қалыптастырылған. Алынған материалдар телекоммуникация, ақпараттық технологиялар, талшықты-оптикалық сенсорлар және сейсмикалық мониторинг салалары бойынша мамандарды даярлау үдерісінде, сондай-ақ одан әрі ғылыми зерттеулер жүргізу үшін оқу-әдістемелік және танымдық негіз ретінде пайдаланылуы мүмкін.

ПАЙДАЛАНЫЛҒАН ӘДЕБИЕТТЕР ТІЗІМІ

- 1 Wu, Huan, et al. "Vibration detection in distributed acoustic sensor with threshold-based technique: A statistical view and analysis." *Journal of Lightwave Technology* 39.12 (2021): 4082-4093.
- 2 Shatalin, Sergey, Tom Parker, and Mahmoud Farhadiroushan. "High definition seismic and microseismic data acquisition using distributed and engineered fiber optic acoustic sensors." *Distributed acoustic sensing in geophysics: Methods and applications* (2021): 1-32.
- 3 D. Wamriew, R. Pevzner, E. Maltsev, & D. Pissarenko, "Deep neural networks for detection and location of microseismic events and velocity model inversion from microseismic data acquired by distributed acoustic sensing array", *Sensors*, vol. 21, no. 19, p. 6627, 2021. <https://doi.org/10.3390/s21196627>
- 4 D. Wamriew, D. Dorhjie, D. Bogodov, R. Pevzner, E. Maltsev, M. Chararaet al., "Microseismic monitoring and analysis using cutting-edge technology: a key enabler for reservoir characterization", *Remote Sensing*, vol. 14, no. 14, p. 3417, 2022. <https://doi.org/10.3390/rs14143417>
- 5 Meier, M., Ross, Z., Ramachandran, A., Balakrishna, A., Nair, S., Kundzicz, P., ... & Yue, Y. (2019). Reliable real-time seismic signal/noise discrimination with machine learning. *Journal of Geophysical Research Solid Earth*, 124(1), 788-800. <https://doi.org/10.1029/2018jb016661>
- 6 P. Hernández, J. Ramírez, & M. Soto, "Deep-learning-based earthquake detection for fiber-optic distributed acoustic sensing", *Journal of Lightwave Technology*, vol. 40, no. 8, p. 2639-2650, 2022. <https://doi.org/10.1109/jlt.2021.3138724>
- 7 F. Liu, M. Wang, M. Zhang, X. Dong, G. Zhu, & X. Zhou, "Intelligent microseismic events recognition in fiber-optic microseismic monitoring system compared with electronic one", *Ieee Photonics Journal*, vol. 14, no. 2, p. 1-5, 2022. <https://doi.org/10.1109/jphot.2022.3148315>
- 8 M. Malfante, M. Mura, J. Métaixian, J. Mars, O. Macedo, & A. Inza, "Machine learning for volcano-seismic signals: challenges and perspectives", *Ieee Signal Processing Magazine*, vol. 35, no. 2, p. 20-30, 2018. <https://doi.org/10.1109/msp.2017.2779166>
- 9 Yamashita, Y., Tanoue, E. Production of bio-refractory fluorescent dissolved organic matter in the ocean interior. *Nature Geosci* 1, 579–582 (2008). <https://doi.org/10.1038/ngeo279>
- 10 <https://news.cgtn.com/news/2022-03-17/M7-4-earthquake-hits-NE-Japan-killing-at-least-four-18tnP2lai76/index.html>
- 11 Djurhuus, Martin Søren Engmann. "Machine learning-based methods for temperature estimation of fiber Bragg grating sensors." (2020).

- 12 T. Reinsch, P. Jousset, & C. Krawczyk, "Fiber optic distributed strain sensing for seismic applications", p. 1-5, 2020. https://doi.org/10.1007/978-3-030-10475-7_284-1.
- 13 X. Bao, Z. Zhou, & Y. Wang, "Review: distributed time-domain sensors based on brillouin scattering and fwm enhanced sbs for temperature, strain and acoustic wave detection", *Photonix*, vol. 2, no. 1, 2021. <https://doi.org/10.1186/s43074-021-00038-w>.
- 14 <https://www.earthscope.org/what-is/das/>.
- 15 K. Wang, X. Lu, M. Schukar, & K. Hicke, "Water absorption effects on distributed temperature sensing using polyimide-coated optical fiber", p. 427, 2025. <https://doi.org/10.1117/12.3062748>.
- 16 I. Ashry, Y. Mao, B. Wang, F. Hveding, A. Bukhamsin, T. Nget al., "A review of distributed fiber-optic sensing in the oil and gas industry", *Journal of Lightwave Technology*, vol. 40, no. 5, p. 1407-1431, 2022. <https://doi.org/10.1109/jlt.2021.3135653>
- 17 Hatley, R., Shehata, M., Sayde, C., & Castro-Bolinaga, C. (2023). High-resolution monitoring of scour using a novel fiber-optic distributed temperature sensing device: a proof-of-concept laboratory study. *Sensors*, 23(7), 3758. <https://doi.org/10.3390/s23073758>
- 18 Shearer, Peter M. *Introduction to seismology*. Cambridge university press, 2019.
- 19 Lindsey, Nathaniel J., and Eileen R. Martin. "Fiber-optic seismology." *Annual Review of Earth and Planetary Sciences* 49.1 (2021): 309-336.
- 20 Zhan, Zhongwen. "Distributed acoustic sensing turns fiber-optic cables into sensitive seismic antennas." *Seismological Research Letters* 91.1 (2020): 1-15.
- 21 <https://www.sciencelearn.org.nz/resources/340-seismic-waves>
- 22 Moczo, P., Rutšeková, E., Kristek, J., Galis, M., Kristeková, M. *Earthquakes: A Short Introduction for Almost Everyone*. Springer Praxis Books, 2024.
- 23 Chambers, Kit. "What Is DAS And What Is It Measuring?" Motion Signal Technologies, 16 May 2019, motionsignaltechnologies.com/what-is-das-and-what-is-it-measuring/.
- 24 <https://www.youtube.com/watch?v=gs3SQoe5w8Q> – A 15 minute YouTube video from EAGE featuring Mark Willis discussing comparisons of DAS sensors with other measurements.
- 25 Bansal, Malti, Apoorva Goyal, and Apoorva Choudhary. "A comparative analysis of K-nearest neighbor, genetic, support vector machine, decision tree, and long short term memory algorithms in machine learning." *Decision analytics journal* 3 (2022): 100071.
- 26 Pandey, Darpan, Kamal Niwaria, and Bharti Chourasia. "Machine learning algorithms: a review." *Mach. Learn* 6.2 (2019).
- 27 SPRH LABS. (2019, March 21). *Understanding deep learning: DNN, RNN, LSTM, CNN and R-CNN*. Medium.

<https://medium.com/@sprhlab/understanding-deep-learning-dnn-rnn-lstm-cnn-and-r-cnn-6602ed94dbff>

28 Taye, M.M. Understanding of Machine Learning with Deep Learning: Architectures, Workflow, Applications and Future Directions. Computers 2023, 12, 91. <https://doi.org/10.3390/computers12050091>

29 E. I. Alves, "Earthquake forecasting using neural networks: results and future work," Nonlinear Dynamics, vol. 44(1-4), pp. 341-349, 2006.

30 C. F. Richter, Elementary Seismology. W. H. Freeman, 1958.

31 Galkina, Alyona, and Natalia Grafeeva. "Machine learning methods for earthquake prediction: A survey." *Proceedings of the fourth conference on software engineering and information management (SEIM-2019), Saint Petersburg, Russia*. Vol. 13. 2019.

32 A. Panakkat, and H. Adeli, "Neural network models for earthquake magnitude prediction using multiple seismicity indicators," International Journal of Neural Systems, vol. 17(1), pp. 13–33, 2007.

33 H. Adeli, and A. Panakkat, "A probabilistic neural network for earthquake magnitude prediction," Neural Networks, vol. 22(7), pp. 1018–1024, 2009.

34 G. Cortés, A. Morales-Esteban, X. Shang, and F. Martínez-Álvarez, "Earthquake Prediction in California Using Regression Algorithms and Cloud-based Big Data Infrastructure," Computers & Geosciences, vol. 115, pp. 198-210, 2018.

35 K. Asim, F. Martínez-Álvarez, A. Basit, and T. Iqbal, "Earthquake magnitude prediction in Hindukush region using machine learning techniques," Natural Hazards, vol. 85, pp. 471-486, 2017.

36 K. Asim, A. Idris, T. Iqbal, and F. Martínez-Álvarez, "Earthquake prediction model using support vector regressor and hybrid neural networks," PLOS ONE, vol. 13, 2018.

37 M. Moustra, M. Avraamides, C. Christodoulou, "Artificial neural networks for earthquake prediction using time series magnitude data or Seismic Electric Signals," Expert Systems & Applications, vol. 38, pp. 15032-15039, 2011.

38 K. Asim, A. Idris, T. Iqbal, and F. Martínez-Álvarez, "Seismic indicators based earthquake predictor system using Genetic Programming and AdaBoost classification," Soil Dynamics and Earthquake Engineering, vol. 111, pp. 1–7, 2018.

39 H. Shu and A. Dawod, "Microseismic monitoring signal waveform recognition and classification: review of contemporary techniques", Applied Sciences, vol. 13, no. 23, p. 12739, 2023. <https://doi.org/10.3390/app132312739>

40 H. Shu, A. Dawod, W. Tepsan, L. Mou, & Z. Tang, "Multi-channel microseismic signals classification with convolutional neural networks", Iaes International Journal of Artificial Intelligence (Ij-Ai), vol. 13, no. 1, p. 1038, 2024. <https://doi.org/10.11591/ijai.v13.i1.pp1038-1049>

41 C. Ma, X. Ran, W. Xu, W. Yan, T. Li, K. Dai et al., "Fine classification method for massive microseismic signals based on short-time fourier transform and deep learning", Remote Sensing, vol. 15, no. 2, p. 502, 2023. <https://doi.org/10.3390/rs15020502>

42 H. Wang and J. Zhang, "A deep learning approach for suppressing noise in livestream earthquake data from a large seismic network", *Geophysical Journal International*, vol. 233, no. 3, p. 1546-1559, 2023. <https://doi.org/10.1093/gji/ggad009>

43 S. Kulkarni, M. Phadke, A. Sawant, N. Patel, & O. Patil, "Advancements in seismic data collection and analysis through machine learning", *Indonesian Journal of Electrical Engineering and Computer Science*, vol. 37, no. 3, p. 2058, 2025. <https://doi.org/10.11591/ijeecs.v37.i3.pp2058-2068>

44 Sriyanto, Sesar Prabu Dwi, Aan Rahardji Puhi, and Christofel Haposan Great Sibuea. "The performance of Butterworth and Wiener filter for earthquake signal enhancement: a comparative study." *Journal of Seismology* 27.1 (2023): 219-232.

45 Y. LeCun, L. Bottou, Y. Bengio, and P. Haffner, "Gradient-based learning applied to document recognition," *Proc. of IEEE*, vol. 86, no. 11, pp. 2278–2324, Nov. 1998.

46 A. Lomax, A. Michelini, and D. Jozinovic', "An investigation of rapid earthquake characterization using single-station waveforms and a convolutional neural network," *Seismol. Res. Lett.*, vol. 90, no. 2A, pp. 517–529, 2019.

47 <https://catalog.data.gov/dataset/imperial-valley-dark-fiber-project-continuous-das-data-a0338>

48 M. Meier *et al.*, "Reliable real-time seismic signal/noise discrimination with machine learning," *J. Geophys. Res. Solid Earth*, vol. 124, no. 1, pp. 788–800, 2019.

ҚОСЫМША А

Диссертациялық зерттеу тақырыбы бойынша ғылыми жарияланымдар

International Journal of Innovative Research and Scientific Studies, 8(5) 2025, pages: 1295-1304



Monitoring of emergency situations using fiber-optic acoustic sensors and signal processing algorithms

 Nurzhigit Smailov¹,  Amina Barysova¹,  Sauletbek Koshkinbayev^{1,2},  Yersaiyn Mailybayev³,  Askhat Batyrgaliyev^{1*}

¹Department of Radio Engineering, Electronics and Space Technologies, Satbayev University, Satpaev str., 22a, Almaty, Republic of Kazakhstan, 050013.

²Department of IT and Telecommunications, Miras University, Sapak Datka str., 2, Shymkent, Republic of Kazakhstan, 160012.

³Department of Computer Technology and Telecommunications, International University of Transport and Humanities, microdistrict Zhetisu-1, 32a, Almaty, Republic of Kazakhstan, 050063.

Corresponding author: Askhat Batyrgaliyev (Email: a.batyrgaliyev@satbayev.university)

Abstract

This article presents a detailed analytical review of distributed acoustic sensing (DAS) systems for seismic monitoring, with emphasis on their optical infrastructure, signal processing methodologies, and integration with machine learning (ML) approaches. DAS leverages existing fiber-optic cables by utilizing Rayleigh backscattering to convert them into high-resolution seismic sensing networks. These networks offer spatial resolution down to one meter and can operate effectively over distances up to 250 kilometers in real time. The system's responsiveness to pressure and environmental fluctuations has been captured through mathematical modeling. To enhance signal quality, seismic data is subjected to advanced processing techniques, including Fourier analysis, wavelet transformation, and adaptive noise filtering, yielding signal-to-noise improvements of up to 15 dB. In terms of data interpretation, machine learning models such as support vector machines (SVM), long short-term memory networks (LSTM), and gradient boosting classifiers have achieved high performance, often surpassing 90% accuracy in seismic event detection. Furthermore, scalable insights are supported through unsupervised and semi-supervised learning strategies. To address challenges related to model transparency, explainability tools like SHAP and LIME are applied to aid in the interpretation of predictive outputs. Field deployments of DAS systems, combined with intelligent analytics, demonstrate significant promise for large-scale seismic detection across both terrestrial and marine environments.

Keywords: Das classification, Distributed acoustic sensing, Fiber optic seismic monitoring, Fourier transform, Lstm, Machine learning, Pressure modeling, Seismic event detection, Signal processing, Wavelet analysis.

Proceedings of the 2025 Conference of Young Researchers in Electrical and Electronic Engineering (2025 ElCon)



**January 28 – 29, 2025
St. Petersburg, Russia**

Fiber Optic Sensing and Machine Learning for Enhanced Earthquake Prediction in Seismology

Smailov Nurzhigit
*Electronics, Telecommunications and
Space technologies Department
Satbayev University
Almaty, Kazakhstan
n.smailov@satbayev.university*

Tolemanova Akmaral
*Electronics, Telecommunications and
Space technologies Department
Satbayev University
Almaty, Kazakhstan
tolemanova@gmail.com*

Barysova Amina
*Electronics, Telecommunications and
Space technologies Department
Satbayev University
Almaty, Kazakhstan
barysova.a@gmail.com*

Bazarbay Aidana
*Electronics, Telecommunications and
Space technologies Department
Satbayev University
Almaty, Kazakhstan
a.bazarbay@satbayev.university*

Dosbayev Zhandos
*Electronics, Telecommunications and
Space technologies Department
Satbayev University
Almaty, Kazakhstan
Zh.dosbayev@satbayev.university*

Akezhan Sabibolda
*Electronics, Telecommunications and
Space technologies Department
Satbayev University
Almaty, Kazakhstan
sabibolda98@gmail.com*

Abstract— This study examines the integration of fiber optic sensing technology and machine learning to improve earthquake prediction in seismology. Traditional methods often struggle to capture subtle geophysical signals indicating potential seismic events. Fiber optic sensing enables continuous, high-resolution monitoring of stress, strain, and other geological parameters across large areas, making it well-suited for detecting small shifts in geological structures. By applying machine learning algorithms, vast fiber optic data can be processed to identify patterns and anomalies signaling early seismic activity. Trained machine learning models recognize complex patterns, enhancing prediction precision and reducing false alarms. This approach advances earthquake prediction accuracy and contributes to developing a reliable early warning system, potentially reducing earthquake impacts by offering additional response time for at-risk areas. The study demonstrates the potential of fiber optic sensing and advanced data analytics as a robust tool in earthquake prediction, supporting greater safety and resilience to natural disasters.

Keywords— earthquake prediction, seismology, fiber optic sensing, machine learning, early warning system, geophysical monitoring, anomaly detection

I. INTRODUCTION

The growing demand for accurate and timely earthquake prediction has driven advancements in fiber-optic sensing technologies and machine learning methods. Distributed Acoustic Sensing (DAS) has emerged as a key approach, leveraging the ability of fiber-optic cables to detect seismic activity with high spatial resolution [1]. The integration of machine learning, particularly deep learning models, enhances the ability to recognize and classify seismic signals in real time [2]. Recent studies have demonstrated that convolutional neural networks (CNNs) and recurrent neural networks (RNNs) can significantly improve the detection of impulsive events, enabling more precise earthquake prediction [3]. Machine learning models are also employed to distinguish artificial seismic sources from natural ones, ensuring the reliability of predictions [4]. Advances in optical fiber networks, combined with Internet of Things (IoT) technologies, have facilitated the development of early warning systems that provide timely alerts for seismic hazards [5]. The use of submarine optical cables for seismic monitoring has further expanded the scope of earthquake detection, offering coverage in previously inaccessible underwater regions [6]. Research into intelligent data

analysis using neural networks has highlighted the potential of hybrid models to process large datasets from fiber-optic sensors [7]. By employing distributed sensor networks, earthquake monitoring can achieve greater coverage, allowing for a more comprehensive early warning infrastructure [8]. This paper aims to explore the application of fiber-optic sensing and machine learning techniques for enhanced earthquake prediction, with a focus on distributed sensor systems and advanced classification models.

II. MATERIALS AND METHODS

A. Fundamentals of Fiber-Optic Sensing

Fiber-optic sensing technology leverages the unique properties of optical fibers to detect and measure various physical parameters, such as strain, temperature, and acoustic signals. This technology has become an essential tool for seismic monitoring due to its ability to provide continuous, distributed measurements over long distances with high sensitivity. The principle of operation is based on the interaction of light with the fiber medium, where disturbances along the fiber alter light propagation characteristics such as intensity, phase, and wavelength. Different configurations, including Fiber Bragg Gratings (FBG) and Distributed Acoustic Sensing (DAS), are employed for seismic applications [9].

Recent advancements have introduced submarine optical cable-based seismic monitoring, where existing undersea communication cables are repurposed for earthquake detection. This approach offers a cost-effective way to expand seismic networks, especially in oceanic regions where traditional seismic stations are limited [10]. Such systems rely on variations in backscattered light caused by seismic events, enabling real-time monitoring and early warning capabilities.

Moreover, DAS technology allows for the continuous monitoring of large geographical areas, with each segment of the optical fiber acting as a virtual seismic sensor. Compared to traditional point-based sensors, DAS systems provide higher spatial resolution and reduce deployment costs [2]. Advances in optical fiber materials and manufacturing have further enhanced the sensitivity and robustness of these systems, making them a critical component in modern seismic monitoring networks [11].

«7М06201 – Телекоммуникация» білім беру бағдарламасының магистранты

Барысова Әмина Ниетқызы

Магистрлік диссертациясына

ҒЫЛЫМИ ЖЕТЕКШІНІҢ ПІКІРІ

Тақырыбы: Машиналық оқыту негізінде талшықты – оптикалық сенсорлардағы сигналдарды тану және өңдеу.

Барысова Әмина Ниетқызының магистрлік диссертациялық жұмысы таратылған талшықты-оптикалық сенсорлардан алынатын сейсмикалық сигналдарды машиналық оқыту әдістері негізінде тану және өңдеу бойынша зерттеу жүргізуге арналған. Диссертация тақырыбының өзектілігі жер сілкіністерін ерте анықтау және нысандардың вибрациялық күйін бақылау жүйелерін жетілдіру қажеттілігімен айқындалады. Жұмыста талшықты-оптикалық сенсорлар саласындағы заманауи ғылыми зерттеулерге әдебиеттік шолу жасалып, FBG, DAS және DTS технологияларының жұмыс принциптері мен қолдану ерекшеліктері жан-жақты талданған. DAS технологиясының дәстүрлі сейсмикалық датчиктермен салыстырғандағы артықшылықтары мен шектеулері ғылыми тұрғыдан негізделген.

Диссертацияның маңызды бөлігінде DAS деректерін алдын ала өңдеу кезеңдері жүзеге асырылып, сүзгілердің тиімділігі салыстырмалы түрде бағаланған. Зерттеу нәтижелері Wiener сүзгісінің сейсмикалық сигналдарды шуылдан тазартуда және сигнал/шу қатынасын жақсартуда жоғары тиімділікке ие екенін көрсетті. Сигналдарды өңдеу және машиналық оқыту модельдерінің жұмыс қабілетін тексеру мақсатында MATLAB бағдарламалық ортасында имитациялық модельдеу жүргізілген.

Сейсмикалық сигналдарды тану және классификациялау үшін бірөлшемді конволюциялық нейрондық желіге негізделген машиналық оқыту моделі қолданылып жұмыс өнімділігі метрикалық көрсеткіштері арқылы бағаланып, жоғары нәтижелер көрсеткен. Жалпы алғанда, магистрлік диссертациялық жұмыс логикалық тұрғыдан жүйелі, ғылыми-әдістемелік деңгейі жоғары және қойылған мақсаттар мен міндеттер толық орындалған.

Магистрлік диссертация **«өте жақсы»** (А, 95%) деп бағаланады және магистрант Барысова Әмина Ниетқызы 7М06201 - «Телекоммуникация» білім беру бағдарламасы бойынша «Техника ғылымдарының магистрі» академиялық дәрежесін алуға ұсынылады.

Ғылыми жетекші

Электроника, телекоммуникациялар және
ғарыштық технологиялар кафедрасының
профессоры, PhD докторы

Смайлов Н.К.

2026 ж.



**«7M06201 – Телекоммуникация» білім беру бағдарламасының
магистранты
Барысова Әмина Ниетқызы
магистрлік диссертациясына
СЫН ПІКІР**

Тақырыбы: Машиналық оқыту негізінде талшықты – оптикалық сенсорлардағы сигналдарды тану және өңдеу.


Барысова Әмина Ниетқызының магистрлік диссертациясында таратылған талшықты-оптикалық сенсорлардан алынатын сейсмикалық сигналдарды машиналық оқыту әдістері негізінде тану және өңдеу мәселелері қарастырылған. Жұмыста талшықты-оптикалық сенсорлар саласындағы заманауи зерттеулерге әдебиеттік шолу жасалып, олардың жұмыс принциптері мен қолдану ерекшеліктері талданған.

Жұмыстың маңызды бөлігі ретінде DAS деректерін алдын ала өңдеу кезеңдері қарастырылып, сүзгілеу әдістерінің тиімділігі салыстырмалы түрде бағаланған. Магистрант сейсмикалық сигналдарды тану және классификациялау үшін машиналық оқыту әдісін қолданып, өнімділігін көрсеткіштері арқылы бағалаған.

Зерттеудің ғылыми жаңашылдығы талшықты-оптикалық сенсорлардан алынатын сейсмикалық сигналдарды алдын ала өңдеуде Wiener сүзгісінің тиімділігін негіздеумен сипатталған. Сигналдарды өңдеу және машиналық оқыту модельдерінің жұмысын тексеру мақсатында MATLAB бағдарламалық ортасында имитациялық модельдеу жүргізілген. Алынған нәтижелердің қолданбалы маңызы жоғары және оларды жер сілкіністерін ерте анықтау және инженерлік нысандардың вибрациялық күйін бақылау жүйелерінде қолдануға болады.

Жалпы алғанда, диссертация жоғары ғылыми деңгейде орындалған, зерттеу нәтижелері нақты және дәйекті түрде баяндалған. Сондықтан бұл жұмысты жоғары бағалап, магистрлік диссертацияны **«өте жақсы» (А, 95%)** деген бағаға лайық деп санаймын және қорғауға ұсынамын.

Пікір беруші,
Energo university,
«Телекоммуникациялық
инженерия» кафедрасының
профессоры, PhD

 Ермекбаев М.М.
«21» 01 2026 ж.



Протокол

о проверке на наличие неавторизованных заимствований (плагиата)

Автор: Барысова Эмина Нияткызы

Соавтор (если имеется):

Тип работы: Магистерская диссертация

Название работы: Машиналық оқыту негізінде талшықты - оптикалық сенсорлардағы сигналдарды тану және өңдеу

Научный руководитель: Нуржигит Смайлов

Коэффициент Подобия 1: 2

Коэффициент Подобия 2: 0.2

Микропробелы: 27

Знаки из других алфавитов: 4

Интервалы: 5

Белые Знаки: 0

После проверки Отчета Подобия было сделано следующее заключение:

☒ Заимствования, выявленные в работе, является законным и не является плагиатом. Уровень подобия не превышает допустимого предела. Таким образом работа независима и принимается.

☐ Заимствование не является плагиатом, но превышено пороговое значение уровня подобия. Таким образом работа возвращается на доработку.

☐ Выявлены заимствования и плагиат или преднамеренные текстовые искажения (манипуляции), как предполагаемые попытки укрытия плагиата, которые делают работу противоречащей требованиям приложения 5 приказа 595 МОН РК, закону об авторских и смежных правах РК, а также кодексу этики и процедурам. Таким образом работа не принимается.

☐ Обоснование:

2026-01-20

Дата:



Заведующий кафедрой



Протокол

о проверке на наличие неавторизованных заимствований (плагиата)

Автор: Барысова Әмина Ниятқызы

Соавтор (если имеется):

Тип работы: Магистерская диссертация

Название работы: Машиналық оқыту негізінде талшықты - оптикалық сенсорлардағы сигналдарды тану және өңдеу

Научный руководитель: Нуржигит Смайлов

Коэффициент Подобия 1: 2

Коэффициент Подобия 2: 0.2

Микропробелы: 27

Знаки из других алфавитов: 4

Интервалы: 5

Белые Знаки: 0

После проверки Отчета Подобия было сделано следующее заключение:

☒ Заимствования, выявленные в работе, является законным и не является плагиатом. Уровень подобия не превышает допустимого предела. Таким образом работа независима и принимается.

☐ Заимствование не является плагиатом, но превышено пороговое значение уровня подобия. Таким образом работа возвращается на доработку.

☐ Выявлены заимствования и плагиат или преднамеренные текстовые искажения (манипуляции), как предполагаемые попытки укрытия плагиата, которые делают работу противоречащей требованиям приложения 5 приказа 595 МОН РК, закону об авторских и смежных правах РК, а также кодексу этики и процедурам. Таким образом работа не принимается.

☐ Обоснование:

2026-01-20

Дата



Сұңғат Марқсұлы

проверяющий эксперт

**Университеттің жүйе администраторы мен Академиялық мәселелер департаменті
директорының ұқсастық есебіне талдау хаттамасы**

Жүйе администраторы мен Академиялық мәселелер департаментінің директоры көрсетілген еңбекке қатысты дайындалған Плагиаттың алдын алу және анықтау жүйесінің толық ұқсастық есебімен танысқанын мәлімдейді:

Автор: Барысова Әмина Ниетқызы

Тақырыбы: Машиналық оқыту негізінде талшықты - оптикалық сенсорлардағы сигналдарды тану және өңдеу

Жетекшісі: Нуржигит Смайлов

1-ұқсастық коэффициенті (30): 2

2-ұқсастық коэффициенті (5): 0.2

Дәйексөз (35): 1.2

Әріптерді ауыстыру: 4

Аралықтар: 5

Шағын кеңістіктер: 27

Ақ белгілер: 0

Ұқсастық есебін талдай отырып, Жүйе администраторы мен Академиялық мәселелер департаментінің директоры келесі шешімдерді мәлімдейді :

☒ Ғылыми еңбекте табылған ұқсастықтар плагиат болып есептелмейді. Осыған байланысты жұмыс өз бетінше жазылған болып санала отырып, қорғауға жіберіледі.

☐ Осы жұмыстағы ұқсастықтар плагиат болып есептелмейді, бірақ олардың шамадан тыс көптігі еңбектің құндылығына және автордың ғылыми жұмысты өзі жазғанына қатысты күмән тудырады. Осыған байланысты ұқсастықтарды шектеу мақсатында жұмыс қайта өңдеуге жіберілсін.

☐ Еңбекте анықталған ұқсастықтар жосықсыз және плагиаттың белгілері болып саналады немесе мәтіндері қасақана бұрмаланып плагиат белгілері жасырылған. Осыған байланысты жұмыс қорғауға жіберілмейді.

Негіздеме:

2026-01-20

Күні



Кафедра меңгерушісі

