


МІНІСТЕРСТВО ОСВІТИ І НАУКИ УКРАЇНИ
ДЕРЖАВНИЙ УНІВЕРСИТЕТ «ЖИТОМИРСЬКА ПОЛІТЕХНІКА»
ФАКУЛЬТЕТ ІНФОРМАЦІЙНО-КОМП'ЮТЕРНИХ ТЕХНОЛОГІЙ
КАФЕДРА КОМП'ЮТЕРНИХ ТЕХНОЛОГІЙ У МЕДИЦИНІ ТА ТЕЛЕКОМУНІКАЦІЯХ

УДК 616-073.7

«Допущено до захисту»

Завідувач кафедри
комп'ютерних технологій у
медицині та телекомунікаціях
к.т.н., доц. Чухов В.В.



« 19 » 12 2023 р.

КВАЛІФІКАЦІЙНА РОБОТА


на тему _____ прогнозування епілептичних нападів на основі аналізу
електричної активності мозку _____

за спеціальністю 163 «Біомедична інженерія»
освітній ступінь «магістр»

Виконавець роботи
студент 2 курсу, гр.БІм-22-1

19.12.2023  Хоменко Д.С.
(дата, підпис)

Керівник роботи
к.т.н., доц.

19.12.2023  Коломієць Р.О.
(дата, підпис)

Житомир
2023

МІНІСТЕРСТВО ОСВІТИ І НАУКИ УКРАЇНИ
ДЕРЖАВНИЙ УНІВЕРСИТЕТ «ЖИТОМИРСЬКА ПОЛІТЕХНІКА»
ФАКУЛЬТЕТ ІНФОРМАЦІЙНО-КОМП'ЮТЕРНИХ ТЕХНОЛОГІЙ
КАФЕДРА КОМП'ЮТЕРНИХ ТЕХНОЛОГІЙ У МЕДИЦИНІ ТА ТЕЛЕКОМУНІКАЦІЯХ

Пояснювальна записка
до кваліфікаційної магістерської роботи

на тему прогнозування епілептичних нападів на основі аналізу
електричної активності мозку

Виконав: студент 2 курсу,
групи БІм-22-1 спеціальності
163 «Біомедична інженерія»


Керівник Коломієць Р.О.

Рецензент Нікітчук Т.М.

Житомир
2023

«Затверджено»

Завідувач кафедри комп'ютерних
технологій у медицині та
телекомунікаціях

 Владислав ЧУХОВ
«27» 10 2022 р.

Завдання на кваліфікаційну магістерську роботу

Хоменко Дмитро Сергійович
(прізвище, ім'я, по батькові)

1. Тема роботи прогнозування епілептичних нападів на основі аналізу
електричної активності мозку

затверджено наказом по університету від «22» листопада 2023 р. № 680

2. Мета дослідження розробка автоматизованої системи для прогнозування
ймовірного розвитку епілептичних схилень людини з огляду на результати
ЕЕГ.

3. Вихідні дані (характеристики об'єкта, умов дослідження та ін.


4. Основні задачі дослідження створення програми для зчитування даних
ЕЕГ, створення моделі глибокого навчання.

5. Термін подання роботи до захисту _____

6. Дата видачі завдання «____» _____ 202_ р.

Науковий керівник

Завдання прийняв
до виконання


(підпис)

Коломієць Р.О.
(прізвище, ініціали)
Хоменко Д.С.
(прізвище, ініціали)

Анотація

Дана кваліфікаційна робота присвячена дослідженню, розробці та моделюванню алгоритму для прогнозування схильності людини до епілепсії. Основним матеріалом для аналізу були результати ЕЕК пацієнтів.

В роботі було проведено: аналітичний огляд літературних джерел; вибір каналів; створення метаданих; опис зчитування даних ЕКГ; оцінювання системи сумістності та моделі виявлення судом .

Результатом цього проектування є модель глибокого навчання яка спроможна з точністю 96,87% та чутливістю 96,85%.

Abstract

Epilepsy to external neurological damage, like pouring on 1.5% of people in all sorts of light. Twenty hundreds of patients stiff up to doctor's abilities. To that an early forecast of epileptical attacks is of great importance for a change in the burden of ill health. Epilepsy does not only lead to stigmatization (social alleviation), but it is linked to comorbid camps in patients with depression, bipolar disabilities, hyperactivity syndrome and lack of respect, sleep disorders, headaches. She is also tied to the promotion of the raptor death. According to statistics, close to 30% of the patients who were sick with epilepsy died from the syndrome of raptor death before the attack. Try to prove that you can tell about those symptoms that develop in a few years to a classy ear. This change will base on a some pre-construction EEG monitoring of patients who are ill on epilepsy. Previously, it was shown that the analysis of the activity of the autonomic nervous system (ANS) can help to detect epileptic attacks. Information about the activity of the ANS can be recognized by additional analysis of the variability of the heart rhythm (HRV). This means that the analysis of HRV can be used for rejection of indirect clues about the range of the nervous system.

The development of effective methods of forecasting by the court can lead to the development of new diagnostics and therapeutic methods for early diagnostics to attack anyway for additional indicative modulation of brain activity.

The present study compares EEG analysis with ECG analysis and, similarly to HRV analysis, identifies the following parametric indicators: mean RR interval, standard deviation from the normal RR interval, maximum RR interval, mean square of the sum of square deviations from the normal RR interval values, mode, coefficient of variation of the RR interval. Spectral analysis of HRV reveals frequency ranges that are the essence of diagnostic information. At the same frequencies, the lead parameters increase, namely, intensity and normal intensity for spectral ranges, centralization index, and vagosympathetic balance index.

The function estimates are classified according to the ensemble of decision trees and the support vector method.

Реферат

Дана кваліфікаційна робота присвячена дослідженню, розробці автоматизованої системи для прогнозування ймовірного розвитку епілептичних схилень людини з огляду на результати ЕЕГ.

Робота складається з вступу, трьох розділів з висновками, загальних висновків, переліку використаних джерел (33 джерел), та двох додатків. Робота містить 5 таблиці, 10 рисунків, основний матеріал викладений на 60 сторінці. Повний обсяг роботи становить 64 сторінки.

У вступі обґрунтовано задачу, мета цієї кваліфікаційної роботи.

У першому розділі був проведений огляд літературних джерел.

У другому розділі була описана розроблена в ході виконання роботи система для прогнозування епілептичних нападів.

У третьому розділі відображені експериментальні дослідження та їхні результати.

У висновках коротко наведені всі характеристики розробленого алгоритму.

У додатку представлена Таблиця з Алгоритмом 1.

Зміст

Перелік умовних скорочень	9
Перелік умовних позначень	10
Вступ	11
РОЗДІЛ 1 Аналітичний огляд літературних джерел	13
1.1 Загальна характеристика епілепсії	13
1.2 Гострі зміни серця та епілепсія	14
1.2.1 Тахікардія при епілепсії	16
1.2.2 Брадикардія та асистолія при епілепсії	17
1.2.3 Порушення провідності серця при епілепсії	18
1.2.4 Раптова смерть хворих на епілепсію	18
1.2.5 Непритомність при епілепсії	21
1.2.6 Ішемія серця при епілепсії	22
1.3 Схожі роботи	22
РОЗДІЛ 2 Система для прогнозування епілептичних нападів	30
2.1 Набори даних	30
2.2. Платформа сумісності для інтеграції даних	30
2.3 Вибір каналів	32
2.4 Монтаж каналів	34
2.5 Створення метаданих	34
2.6 Зчитування даних ЕЕГ	36
2.7 Вейвлет-розклад	38
2.8 Масштабування	42
2.9 Модель виявлення судом	44
2.10 Згортоква нейронна мережа	44
2.11 Максимальне об'єднання	45
2.12 Пакетна нормалізація	45
2.13 Двонаправлена довгострокова пам'ять	46
2.14 Увага	46
2.15 Повність підключений рівень	47
РОЗДІЛ 3 Експериментальні дослідження	48
3.1 Оцінка системи сумісності	48
3.2 Оцінка моделі виявлення судом	53
Висновки	58

Перелік використаних джерел

60

Додаток А

66

Перелік умовних скорочень

ЕКГ	- Електрокардіограма
ЕЕГ	- Електроенцефалограма
BNP	- Brain natriuretic peptide(Мозковий натрійуретичний пептид)
СК-МВ	- Creatine kinase-myocardial band(Креатинкіназна міокардіальна смуга)
MIMO	- Multiple-input multiple-output
NLD	- Necrobiosis lipoidica diabetorum(ліпоїдний атрофічний дерматит)
DNN	- Differential Neural Network(Диференціальна нейронна мережа)
LDA	- Line Drain Airway(Лінійний дренаж дихальних шляхів)
ШИМ	- Широтно-імпульсна модуляція
ІІНМ	- Штучна нейронна мережа
LSTM	- Long Short-Term Memory(Довга короткочасна пам'ять)
DWT	- Discrete wavelet transform(Дискретне вейвлет-перетворення)
CSV	- Comma-separated values(Значення через кому)
SWLU	- Swish Relu

Перелік умовних позначень

β	- константа
FN	- кількість сигналів
TN	- кількість сигналів без судом
PN	- кількість сигналів, не пов'язаних із судомами, які виявляються як напади

Вступ

Епілепсія - це захворювання нервової системи. Енцефалографія (ЕЕГ) — це загальноновживаний клінічний підхід для реєстрації електричної активності в мозку. Хоча існує низка доступних наборів даних, більшість із них є не збалансованими через наявність меншої кількості епілептичних ЕЕГ-сигналів порівняно з не епілептичними ЕЕГ-сигналами. Це дослідження спрямоване на вивчення можливості інтеграції локальних сигналів ЕЕГ із центру епілепсії в лікарні університету короля Абдулазіза в набір даних CHB-MIT шляхом застосування нової системи сумісності для інтеграції даних. Фреймворк включає в себе кілька функцій, які включають вибір домінантного каналу з наступною реалізацією нового алгоритму для зчитування даних ЕЕГ XLTek. Отримані інтегровані набори даних, які містять вибірккові канали, перевіряються та оцінюються за допомогою моделі глибокого навчання 1D-CNN, Bi-LSTM та уваги. Результати досягли 96,87% точності, 96,98% точності та 96,85% чутливості, перевершуючи інші новітні системи, які мають більшу кількість каналів ЕЕГ.

Метою даної роботи буде розробка автоматизованої системи для прогнозування ймовірного розвитку епілептичних схилень людини з огляду на результати ЕЕГ.

Об'єктом даного дослідження є результати електроенцефалограми, а **предметом** – її параметри та і характеристики.

В роботі вирішувалися наступні завдання:

- 1) Створення програми для зчитування даних ЕЕГ
- 2) Створення моделі глибокого навчання
- 3) Проведено моделювання просторової діаграми направленості такої антени

Результатом даного проектування є автоматизованої системи для прогнозування схильності людини до епілептичних нападів у майбутньому з огляду на результати ЕЕГ.

РОЗДІЛ 1

Аналітичний огляд літературних джерел

1.1 Загальна характеристика епілепсії

Епілѐпсія (від давньогр. ἐπιλαμβάνειν — «захоплювати, володіти, вражати»)

— це група довготривалих неврологічних розладів, що характеризуються виникненням судомних нападів [7]. Епілептичний напад є тимчасовим явищем ознак та / або симптомів через ненормальну, надмірну та синхронну нейронну активність у мозку [8]. Напади мають певний характер: від швидкоплинних і майже непомітних проявів, до появи тривалих судом. Для епілепсії характерне раптове виникнення нападів із рецидивами впродовж життя хворого, тоді як напади, викликані певною відомою причиною вважаються епілептичними реакціями, які слід відрізняти від епілепсії як хвороби [7]. Двадцять відсотків епілепсії є стійкими до лікарських засобів. Тому раннє виявлення прогнозу епілептичних нападів має першочергове значення для зменшення тягара захворювання [9].

У багатьох випадках причина хвороби невідома, але епілепсія може виникати внаслідок ЧМТ, інсульту, пухлин головного мозку, зловживання наркотичними речовинами й алкоголем, та з інших причин. Епілептичні напади спричиняються надмірною й аномальною активністю нервових клітин кори головного мозку [7]. Призначення та симптоми нападу бувають такими: тимчасова плутанина, неконтрольовані ритмічні рухи рук і ніг, втрата свідомості або усвідомлення, психічні симптоми, наприклад, страх, тривога або Дежавю, симптоми можуть змінюватись в залежності від типу нападу. У більшості випадків, хворий на епілепсію, як правило, має один і той же тип нападу кожного разу, тому симптоми будуть подібними під час нападів. Лікарі класифікують судоми як фокальні або узагальнені, виходячи з того, як починається аномальна

активність мозку [10]. Для уточнення діагнозу слід виключити інші стани, за яких можливий розвиток подібних симптомів. Підтвердження діагнозу здійснюється за допомогою методу електроенцефалографії [7]. Серед безлічі методів діагностики та візуалізації, електроенцефалограма (ЕЕГ) є найпоширенішою методикою при щоденному

1.2 Гострі зміни серця та епілепсія

Зміни серцевої функції при епілепсії означають активізацію центральної вегетативної системи. Вважається, що у пацієнтів із судомами епілептичні напади поширюються до центральної вегетативної системи (ВНС) і змінюють або порушують нормальний вегетативний контроль життєво-важливих серцевих функцій. Вважається, що ця активація центральної ВНС відповідальна за преіктальні вегетативні серцеві симптоми, що спостерігаються у хворих на епілепсію. Значення цих вегетативних особливостей у патофізіології епілепсії та її ускладнень стало більш зрозумілим в останні роки. Через специфічну для півкулі організацію центральної вегетативної нервової системи, вегетативні симптоми при епілептичних нападах можуть забезпечити латералізацію та локалізацію інформації. Натомість краще розпізнавання клінічних вегетативних ознак при епілепсії може надати більше інформації про організацію центральної вегетативної нервової системи [14]

клінічному лікуванні. Враховуючи, що метод неінвазійний, відносно точний і має низьку вартість, він був створений як необхідний інструмент для лікарів і людей, які мають справу з епілепсією.

До недавнього часу напади були виявлені лише візуально експертом-неврологом. Однак ця процедура є трудомісткою, особливо у випадку довгострокових записів ЕЕГ. Таким чином, були розроблені автоматичні комп'ютерні алгоритми, для скорочення та автоматизування процедури, і велика кількість методів виявлення нападів наводиться в

міжнародній літературі [11, 12].

Епілепсія зазвичай діагностується після того, як у людини було принаймні два напади, які не були викликані іншими захворюваннями, відмовою від алкоголю або надзвичайно низьким рівнем цукру в крові.

Якщо напади виникають з певної ділянки головного мозку, то початкові симптоми нападу часто відображають функції цієї області. Права половина мозку контролює ліву частину тіла, а ліва половина мозку контролює праву частину тіла. Наприклад, якщо приступ починається з правого боку головного мозку в області, що контролює рух у великому пальці, то приступ може починатися з ривками великого пальця лівої руки [13].

На даний момент вилікуватися від такої хвороби як епілепсії неможливо, але за умови відповідного лікування напади можна стримати у 70% випадках [7]. Лікування медикаментами або іноді хірургічним втручанням може контролювати напади в більшості хворих на епілепсію. Деякі пацієнти потребують довічного лікування, щоб контролювати напади, а в інших – судоми зрештою зникають. Бувають випадки, що діти з епілепсією з віком можуть перерости цей стан [10]. Близько 1% людей по всьому світі хворі на епілепсію, майже 80% випадків хвороби реєструється у країнах, що розвиваються. Частота епілептичних нападів має тісний зв'язок із віком пацієнта, в осіб похилого віку напади спостерігаються частіше. В індустріально розвинених країнах хвороба найчастіше спостерігається у немовлят та осіб похилого віку; у країнах, що розвиваються, — у дітей молодшого шкільного віку та підлітків, що пояснюється відмінностями у частоті реєстрації причинних факторів. Спонтанний епілептичний напад виникає у 5—10% людей віком до 80 років, вірогідність виникнення другого нападу коливається від 40 до 50%. У багатьох країнах світу хворі на епілепсію не можуть керувати транспортними засобами, але більшість з них можуть отримати водійські права за умови тривалої ремісії [7].

1.2.1 Тахікардія при епілепсії

Тахікардія (дав.-гр. *ταχύς* швидкий та *καρδία* серце)— прискорене серцебиття. Слід розрізняти тахікардію як патологічне явище, тобто збільшення ЧСС в спокої, та тахікардію як нормальне фізіологічне явище (збільшення ЧСС унаслідок фізичного навантаження, унаслідок хвилювання або страху).

Патологічна тахікардія шкідлива з деяких причин. По-перше, при частому серцебитті знижується ефективність роботи серця, оскільки шлуночки не встигають наповнитися кров'ю, унаслідок чого знижується артеріальний тиск і зменшується притік крові до органів. По-друге, погіршуються умови кровопостачання самого серця, оскільки воно здійснює велику роботу в одиницю часу та потребує більше кисню, а погані умови кровопостачання серця збільшують ризик ішемічної хвороби та інфаркту [7].

Іктальна тахікардія була зареєстрована приблизно при 100% нападів. Тахікардія може передувати, збігатися або слідувати за іктальним станом. Часова затримка між тахікардією та початком судом варіюється від 0,7 до 49,3 с. Можливим механізмом є поширення епілептичних розрядів в праву островцеву кору. Можна очікувати переважання тахікардії при правосторонніх скроневих нападах, і це підтверджується в деяких дослідженнях. Існують і інші фактори, що пояснюють тахікардію. Тахікардія, що розпочалася з боку ікталу, здається більш помітною при скроневій епілепсії (TLE - temporal lobe epilepsy) порівняно з позачеревними нападами (XTLE), що підтверджує гіпотезу про те, що ураження островцевої кори є ключовою частиною іктальної тахікардії. Тривалість тахікардії також більша у пацієнтів з епілепсією мезіально-скроневої частки порівняно з позачеревною. Можливо, що епілептичні розряди поширюються до островцевої кори легше і довше при скроневій епілепсії порівняно з позачеревною.

Тахікардія та розвиток тахіаритмії під час судом є однією з можливих причин раптової смерті хворих на епілепсію [14].

1.2.2 Брадикардія та асистолія при епілепсії

Брадикардія (дав.-гр. βραδύς повільний та καρді́α серце) — уповільнене серцебиття, іноді симптом деяких захворювань.

Під синусовою брадикардією розуміють таку зміну серцевого ритму, при якій відбувається зменшення частоти серцевих скорочень до 45-50 ударів в хвилину, обумовлене пониженням автоматизму синоатриального вузла (водій ритму). Цей водій ритму розташовується в гирлі верхньої і нижньої порожнистих вен, тобто в місці впадання їх в праве передсердя.

Асистолія (від грец. ἄ- - «не», «ні» і «систола») – припинення діяльності серця зі зникненням біоелектричної активності.

Асистолія шлуночків (близько 5% всіх випадків зупинки серця) може виникнути при будь-якому важкому захворюванні серця, частіше в гострій фазі інфаркту міокарда, при тромбоемболії легеневої артерії, при передозуванні серцевих глікозидів, протиаритмічних засобів, електротравми, наркозі, внутрішньосерцевих маніпуляціях і важких загальних метаболічних порушеннях [7].

Брадикардія та брадиаритмія спостерігаються при епілепсії набагато рідше тахікардії, і спостерігаються при судамах різного походження. Сильне уповільнення частоти серцевих скорочень, що призводить до асистолії та непритомності, називають синдромом іктальної брадикардії.

Фактори, що призводять до іктальної брадиаритмії в пацієнтів, залишається важко визначити. Патофізіологія брадиаритмії, ймовірно, опосередковується через складну кортикальну систему. Відзначається, що стимуляція кори лівого островного мозку та мигдалин викликає брадикардію. Ліва півкуля, як визначається, є найбільш поширеним

місцем виникнення нападів, що знову підтверджує гіпотезу про специфічну для півкулі організацію серцевого контролю кори. Атріовентрикулярна блокада була відзначена у одного пацієнта під час кортикальної стимуляції лівої скроневої базальної області. Ці результати вказують на більш високий ризик брадиаритмії при епілептичних нападах із поширенням судом на ліву острівцеву кору та мигдалеподібне тіло. Зона початку епілептичних нападів у пацієнтів з іктальною брадикардією є найбільш частою тимчасовою і менш лобовою, що підтверджує гіпотезу про острівцевий вплив.

Повідомлялося про іктальну брадикардію аж до іктальної асистолії у пацієнтів з рефрактерними частковими нападами, і це може бути ще однією важливою причиною раптової смерті хворих на епілепсію [14].

1.2.3 Порушення провідності серця при епілепсії

Порушення провідності, здається, є загальним явищем під час судом при епілепсії. Nei та співавт. [15] можуть продемонструвати наявність аритмій або порушень провідності при нападах, особливо якщо вони тривалі або генералізовані. Такі аритмії включають фібриляцію передсердь, суправентрикулярну тахікардію та передчасну деполяризацію передсердь та шлуночків.

Зміни ЕКГ, включаючи інверсію зубця Т та депресію ST, були частішими та потенційно небезпечнішими у пацієнтів із генералізованими нападами [16].

1.2.4 Раптова смерть хворих на епілепсію

Загальновідомо, що люди з епілепсією мають підвищений ризик раптової смерті. Раптова смерть визначається як несподівана нетравматична смерть пацієнтів з епілепсією з нападами або без них, за винятком задокументованого епілептичного статусу, і у яких

патологоанатомічне дослідження не виявляє структурної або токсикологічної причини смерті. Було розглянуто демографічні показники та фактори ризику серед хворих на епілепсію. Їх профіль пацієнтів із ризиком раптової смерті – це молоді люди з епілепсією. Вони найчастіше помирають під час сну та судом.

Обструктивне апное може бути одним із пояснень смерті, пов'язаної зі сном, але це не підтверджується висновками коронарив. Позиція пацієнта, а також відсутність нагляду за відновленням після нападу є більш вірогідною. Також попередні дослідження показали, що у пацієнтів з раптовою смертю спостерігається більш ранній початок, більша тривалість епілепсії та частіші напади. Є дані про збільшення серцевої вегетативної стимуляції у пацієнтів із зареєстрованою несподіваною смертю, більш виражене при епілептичних нападах під час сну, сумісне з демографічними даними.

Точний механізм раптової смерті залишається відкритим питанням, але, ймовірно, є багатофакторним. Передбачається взаємодія між центральною та периферичною вегетативною нервовою системою та серцево-легеневою системою. Існує три добре розпізнані основні патофізіологічні механізми, які викликають раптову смерть у пацієнтів:

1. серцево-судинні: іквальна аритмія, включаючи іквальну асистолю та явище блокування;
2. нейрогенні: нейрогенний набряк легенів;
3. дихальні: іквальне зниження дихання, центральне або обструктивне апное.

Першим можливим механізмом, що лежить в основі раптової смерті пацієнтів, є серцеві аритмії, пов'язані із судомами, тахіаритміями, брадикардією та іквальною асистолю, як пояснювалося вище. Тахіаритмії можуть еволюціонувати до шлуночкової тахікардії та, зрештою, фібриляції шлуночків. При брадиаритміях спостерігається перехід до іквальної асистолю у пацієнтів з вогнищевою епілепсією. Як раптове

підвищення вагусного тону, так і вплив післягангліозних епілептичних розрядів на серце, як описано нижче, можна розглядати як пояснення порушеного серцевого ритму при епілептичних нападах. Втрати свідомості спостерігалася під час відеоелектроенцефалографічного спостереження і відбулася пізно під час клінічного випадку. Втраті постурального тону передували 8 с асистолії. У таких пацієнтів активація, що призводить до іктальної асистолії найімовірніше опосередковується через підвищений тонус блукаючого нерва. Схема іктальної асистолії та уповільнення ЕЕГ-картини церебральної гіперперфузії дуже нагадували картину, виявлену при вазовагальній асистолії. Основний механізм, швидше за все, подібний в обох станах і передбачає втручання медулярних рефлексорних центрів під час епілептичних розрядів, відповідальних за підвищення вагусного тону. У деяких пацієнтів асистолія може бути спричинена гіпоксією через тривале тонічне скорочення м'язів та зупинку дихання, а не через поширення судом у медулярні рефлексорні центри [17, 18].

Інше важливе нейрофізіологічне явище – активація центральної вегетативної нервової системи, спричинена судом, може спричинити прямий вплив на постгангліонарні розряди в серці. Це призводить до синхронізації серцевих вегетативних розрядів з епілептогенною активністю, що називається явищем блокування та індукує летальну брадиаритмію або асистолію. Електрична стимуляція кори острівця призводить до часової реакції на серцевий ритм і може спричинити різні типи аритмії. На моделях на тваринах електрична мікростимуляція, синхронізована з зубцем Т ЕКГ, призводила до збільшення ступеня серцевої блокади та призводила до ритму втечі і, в кінцевому рахунку, до асистолії та загибелі. Вторинний нейрогенний набряк легенів відомий як рідкісне ускладнення, що загрожує життю – травми центральної нервової системи та епілепсія. Експериментальні дослідження постулювали сильні симпатичні напади як основу нейрогенного набряку легенів. Церебральні ділянки, що розглядаються як пускові зони симпатичного розряду,

знаходяться в задній частині гіпоталамуса, а також в черевному і дорсальному відділах мозку, включаючи медіальне сітчасте ядро, дорсальне ядро блукаючого мозку та одиночний тракт. Симпатичний розряд викликає системні та легеневі звуження судин, що призводить до підвищення гідростатичного тиску в легневих капілярах та переміщення рідини в альвеоли та інтерстиції.

Третім можливим механізмом при раптовій смерті пацієнта є зупинка дихання. Пригнічення центрального дихання може бути наслідком епілептичних нападів. Апноє є рідкісною клінічною особливістю нападів, але спазм гортані та апноє повідомляються як про окремі епілептичні ознаки або при складних часткових нападах. Фокальні напади, пов'язані з апноє, походять, в основному, від скроневої частини. Це спостереження разом із результатами інвазивного моніторингу ЕЕГ у дорослих вказує на залучення лімбічної системи до судом, ускладнених пригніченим диханням. Обструктивне апноє та зупинка дихання вже спостерігались через тонічне скорочення м'язів під час судом. Це може призвести до сильної гіпоксії та спровокувати асистолію [14].

1.2.5 Непритомність при епілепсії

Різниця між непритомністю через серцеву аритмію та судомами у пацієнтів із встановленою епілепсією залишається клінічно складною. У пацієнтів з епілепсією слід розрізняти серцево-судинну або епілептичну причину втрати свідомості та синкопи (непритомність, короткочасна втрата свідомості, обумовлена тимчасовим порушенням мозкового кровотоку) [7]. Серцево-судинний вегетативний баланс визначається медулярними рефлексамі, що викликаються активацією барорецепторів, серцевих рецепторів та хеморецепторів та впливами з боку кори головного мозку, гіпоталамуса, мигдалин та пери-аквадуктальної (біляводопровідної сірої речовини) сірої речовини. Як ми вже згадували раніше, у пацієнтів з

епілептичними нападами можуть розвиватися різні серцево-судинні проблеми, аритмії, іквальна брадикардія та тривала асистолія, спричинені епілептичними нападами у вищих центрах вегетативного контролю. Ці серцево-судинні проблеми можуть призвести до іквальної синкопи в результаті церебральної гіперперфузії. З іншого боку, раптова втрата тону у пацієнтів з іквальною асистолією може бути результатом іквальної активації певних ділянок мозку, що призводить до втрати свідомості. Швидке розповсюдження іквальних епілептичних розрядів із залученням понтієвої ретикулярної формації може призвести до втрати свідомості та клінічної непритомності [14].

1.2.6 Ішемія серця при епілепсії

Як вже зазначалося, надмірна вегетативна стимуляція може призвести до серцевих аритмій. Але повторювана вегетативна стимуляція може також призвести до структурних пошкоджень серця. Це підвищує сприйнятливості до серцевих аритмій або ішемії. У пацієнтів із раптовою смертю вже виявлено фіброз міокарда. У пацієнтів з неускладненими судомами, схоже, не спостерігається підвищення рівня тропоніну в постікталі, але ознаки ішемії на ЕКГ та підвищення рівня серцевих ферментів у хворих на епілепсію вказують на вторинне ураження серця. Деякі дослідження показують наявність підвищеного рівня BNP і СК-МВ у пацієнтів із судомами, що є першим свідченням тонкої серцевої дисфункції у хворих на епілепсію [14].

1.3 Схожі роботи

Багато досліджень зосереджені на внутрішньочерепних сигналах мозку, у яких електроди розміщуються всередині черепа безпосередньо на мозку. Антоніадес та ін. [12] використовували згорточні нейронні мережі

(CNN), застосовані з двома згортковими шарами на внутрішньочерепних даних ЕЕГ, щоб виділити особливості міжнападкових епілептичних розрядів (IED). Система розділила дані на кілька сегментів по 80 мс з перекриттям 40 мс і досягла рівня виявлення 87,51%.

Birjandtalab та ін. [9] використовував перетворення Фур'є з глибокими нейронними мережами (DNN) для класифікації сигналів шляхом застосування перетворення спочатку до отриманих альфа, бета, гамма, дельта та тета, а також до окремих вікон, щоб обчислити щільність спектра потужності, яка вимірює потужність сигналу як функція частоти. Потім для класифікації сигналів було використано DNN на основі багатошарових перцептронів лише з двома прихованими шарами. Щоб уникнути проблеми з переобладнанням, було застосовано кілька прихованих шарів. Система досягла точності 95%.

Системи виявлення нападів залежать від типу даних ЕЕГ. Деякі з цих систем виявляють епілептичні випадки лише з одного каналу, а інші можуть виявляти епілептичні випадки з кількох каналів. ChannelAtt [13] — це нова структура уваги з урахуванням каналів, яка застосовує повне пов'язане навчання кількох ракурсів для м'якого вибору критичних ракурсів із багатоваріантних біосигналів. Ця модель реалізує нову техніку, яка покладається на глобальну увагу в області перегляду, а не в часовій області. Система досягла рівня точності 96,61%.

Деякі дослідження виконували вивчення функцій шляхом навчання моделі глибокого навчання безпосередньо на сигналах ЕЕГ. Іхсан Уллах та ін. [14] використав пірамідальну структуру 1D-CNN для зменшення обсягу пам'яті та часу виявлення. Остаточний результат використовував підхід голосування для постобробки. Щоб подолати вузьке місце, пов'язане з вимогою навчання величезної кількості даних, вони виконали розширення даних за допомогою вікон, що перекриваються. Система досягла 99% точності.

Забіхі та ін. [15] розробив систему, яка поєднує нелінійну динаміку

(NLD) і лінійний дискримінантний аналіз (LDA) для вилучення ознак, і ввів концепцію нуль-клінів для вилучення дискримінантних ознак. Для класифікації система використовує штучну нейронну мережу (ШНМ). Отримана точність моделі склала 95,11%. Щоб імітувати реальну клінічну ситуацію, лише 25% набору даних було використано для навчання. Результати показали, що хибнонегативні результати були відносно високими в результаті використання обмеженого набору даних для навчання. Показники чутливості вважаються занадто низькими для практичного клінічного використання.

Подібним чином Avsu et al. [16] використовував глибокий алгоритм CNN на сигналах ЕЕГ 29 педіатричних пацієнтів з жіночої та дитячої лікарні КК, Сінгапур. Дослідники намагалися мінімізувати кількість каналів у записаних даних ЕЕГ до двох каналів, Fp1 і Fp2. Ці дані складаються з 1037 хвилин, з яких лише 25 хвилин містять епілептичні сигнали, розподілені на 120 нападів. Як видно, дані не збалансовані. Щоб подолати цю проблему, дослідники спробували використати різні методи порівняння пропорцій відповідно до наявності або відсутності нападів, застосовуючи два процеси зсуву. Перший займає 5 с, щоб створити міжнаступний клас (без перекриття). Другий займає 0,075 с для створення іктального класу. Ці процеси зміщення були застосовані, щоб збалансувати вхідні дані для CNN. Система досягла точності 93,3%. Однак у цьому дослідженні не було згадано результат техніки збільшення даних.

Ху та ін. [17] використовував довгострокову пам'ять (LSTM), оскільки вона ефективна як для довгострокових, так і для короткочасних залежностей у даних часових рядів. Автори розробили модель за допомогою Bi-LSTM. Автори витягли та подали в мережу сім лінійних ознак. Систему було навчено та випробувано на базі даних Боннського університету, і вона мала точність 98,56%. Однак це відображає точність результатів тестування, тоді як результати оцінки не згадувалися в цьому дослідженні.

Чандел та ін. [18] запропонував специфічний для пацієнта алгоритм, який базується на функціях на основі вейвлетів, щоб виявити затримку початку-зміщення. Модель працює шляхом обчислення статистичних характеристик, таких як середнє значення, ентропія та енергія в піддіапазонах вейвлетів, а потім класифікації сигналів ЕЕГ за допомогою лінійного класифікатора. Розроблений алгоритм досягав середньої точності 98,60%. Алгоритм був перевірений на 14 із 23 пацієнтів у наборі даних. Незважаючи на те, що алгоритм є індивідуальним для кожного пацієнта, його продуктивність значно погіршилася для пацієнта 7, який мав дуже коротку тривалість нападу порівняно з іншими пацієнтами; кількість нападів у цього пацієнта становила 10, загальною тривалістю 94 с. Це означає, що алгоритм працює добре, якщо тривалість нападу велика, але значно зменшується, якщо напад короткий.

Казиха та ін. [19] запропонував використовувати модель, запропоновану в попередньому дослідженні, застосовану до набору даних СНВ-МІТ і налаштовану для підвищення продуктивності. Модель ґрунтується на п'яти рівнях CNN, за кожним із яких слідує пакетна нормалізація та середній рівень об'єднання відповідно. Нарешті, модель має три щільні шари для визначення класу сигналу. Однак діаграма ефективності навчання та точності тестування є очевидним показником переобладнання мережі, що можна побачити з показника чутливості. Це пов'язано з незбалансованістю набору даних, оскільки кількість епілептичних сигналів значно менша, ніж кількість неепілептичних сигналів, і тому вимагає використання схеми доповнення даних.

Хуан та ін. [20] запропонував гібридну структуру з трьох частин. Перша частина виділяє створені вручну ознаки та перетворює їх на розріджені категоріальні ознаки, тоді як друга частина базується на архітектурі нейронної мережі з вихідними сигналами як вхідними даними для вилучення глибоких ознак. Обидва типи виділених ознак об'єднані в третій і останній частині моделі для класифікації сигналів ЕЕГ на напади

та без них. Модель досягла показника чутливості 90,97%. Слід зазначити, що ідея гібридної структури може досягти вищих результатів, якщо вона покращить вихід першої частини моделі, яка є ознаками, витягнутими вручну із сигналів. Це досягається за допомогою одного з методів важливості функції. Деревоподібна модель реалізована для визначення оцінки важливості кожної функції на основі правил прийняття рішень (або ансамблів дерев, таких як випадковий ліс) моделі.

Jeong та ін. [21] реалізував глибоку нейронну мережу на основі уваги для виявлення нападів. Модель розділена на три модулі; перший модуль виділяє просторові характеристики, тоді як другий модуль виділяє просторово-часові характеристики. Третій модуль — це механізм уваги для захоплення уявлень, які враховують взаємодію між декількома змінними в кожен момент часу. Точність моделі 89%, чутливість 94%. Однак, виходячи з показників продуктивності моделі, відсоток хибно негативних результатів (FN), тобто кількість сигналів нападу, які були виявлені як неприступні, був низьким, що відображено у високій оцінці чутливості. Навпаки, загальна точність моделі була значно нижчою порівняно з показником чутливості, що означає, що кількість помилкових спрацьовувань (FP) була високою. FP підраховує кількість неприпадкових сигналів, які були виявлені як напади. Отже, модель була зосереджена на виділенні ознак, які чітко відрізняють клас захоплення, не беручи до уваги також виділення дискримінаційних ознак для класу без захоплення. Це вплинуло на загальну продуктивність моделі. Таблиця 1 узагальнює всі вищезазначені дослідження в цьому розділі.

Таблиця 1. Системи виявлення епілептичних нападів на основі ЕЕГ із використанням підходів глибокого навчання.

Посилання	Рік видання	Підхід	Шари	Набір даних	Канали	Точність	Розмір вікна
[12]	2016 рік	CNN	2	Набір даних лондонської лікарні Королівського коледжу	12 каналів	87,51 %	80 мс
[9]	2017 рік	Глибинні нейронні мережі	4	23 хворих на епілепсію з Бостонського дитячого відділення Лікарня	Діапазон від 18 до 23 каналів	95%	10 с
[13]	2018 рік	Структура уваги з урахуванням каналів	23	Набір даних CHB-MIT	23 канали (у деяких випадках 24 або 26)	96,61%	ТО
[14]	2018 рік	Пірамідальні одновимірні моделі CNN	3	Набір даних Боннського університету	1 канал	99%	10 с
[15]	2019 рік	Нелінійна динаміка (NLD) з лінійним дискримінантним аналізом (LDA) і штучною нейронною мережею (ANN)	5	Набір даних CHB-MIT	23	95,11%	1 с

[16]	2019 рік	Глибокий CNN	4	29 пацієнтів дитячого віку з КК Жіночий та Дитячий Лікарня, Сінгапур	2 канали	93,3%	5 с
[17]	2019 рік	Глибока мережа Bi-LSTM	5	Набір даних Боннського університету	1 канал	98,56%	ТО
[18]	2019 рік	Дискретне вейвлет-перетворення (DWT) + лінійний класифікатор	ТО	Набір даних CHB-MIT	23 канали (у деяких випадках 24 або 26)	98,60%	1 с
[19]	2020 рік	CNN	18	Набір даних CHB-MIT	23 канали (у деяких випадках 24 або 26)	96,74%	100 с
[20]	2021 рік	Gradient-Boosted Decision Trees (GBDT) з глибокою нейронною мережею (DNN)	ТО	Набір даних CHB-MIT	23 канали (у деяких випадках 24 або 26)	ТО	20 с
[21]	2021 рік	CNN	20	Набір даних CHB-MIT	23 канали (у деяких випадках 24)	89%	ТО

Більшість згаданих досліджень використовують аргументацію для вирішення проблеми незбалансованого набору даних. Це дослідження об'єднує два набори даних за допомогою домінуючих каналів перетину між

цими наборами даних, а потім модель глибокого навчання для перевірки ефективності методу.

РОЗДІЛ 2

Система для прогнозування епілептичних нападів

2.1 Набори даних

У цьому розділі пояснюється обидва набори даних, які використовувалися в дослідженні. Перший – це набір даних СНВ-МІТ [11], який був зібраний у 22 суб'єктів: 5 чоловіків віком 3–22 роки та 17 жінок віком 1,5–19 років. Набір даних містить 969 годин записів ЕЕГ, а кількість нападів становить 198. Кількість сигналів про відсутність нападів перевищує кількість сигналів про напади.

Другий набір даних — це набір даних КАУ, який було зібрано від 2 суб'єктів чоловічої статі віком 28 із записами ЕЕГ шкіри голови, де частота вибірки така ж, як і набір даних СНВ-МІТ, 256 Гц. Враховувався віковий фактор піддослідних. Вік цих двох пацієнтів приблизно відповідає віку суб'єктів у наборі даних СНВ-МІТ.

Отже, діапазон, вибраний з обох наборів даних, був від 1 до 28. Це має вирішальне значення, оскільки клінічні та електроенцефалографічні характеристики судом значною мірою залежать від віку [22]. Обидва суб'єкти мають записи ЕЕГ з 38 каналів. В одного з них було два напади загальною тривалістю 495 с, а в іншого — чотири напади загальною тривалістю 417 с.

2.2. Платформа сумісності для інтеграції даних

Запропонована система має кілька етапів, включаючи анотування набору даних КАУ, вибір каналів і налаштування монтажу каналів, після чого йде етап підготовки даних, який включає створення метаданих і зчитування даних ЕЕГ.

Третій етап попередньої обробки даних включає видалення відсутніх значень, розкладання сигналу за допомогою дискретного

вейвлет-перетворення (DWT) і масштабування. І, нарешті, фаза вивчення ознак і класифікації, яка виконується за допомогою моделі глибокого навчання (DL), яка класифікує сигнали ЕЕГ на класи нападів і без них. Рисунок 1 ілюструє структурну схему запропонованої системи. Система запрограмована Colab, середовищем розробки Python, що працює в Google Cloud із використанням фреймворків TensorFlow і Keras.




Рисунок 1. Запропонована архітектура рамки сумісності.

Анотація даних набору даних KAU: Дані були анотовані у співпраці з нейрофізіологами та розділені на категорії: нормальні з відкритими очима, нормальні із закритими очима, передіктальні, іктальні, постіктальні, міжіктальні та артефакти. Таблиця 2 описує ці категорії.

Таблиця 2. Опис категорій ЕЕГ для анотованого локального набору даних.

Категорія	Опис
Відкриті очі	Запис ЕЕГ для розслабленого пацієнта в стані неспання з відкритими очима
Заплющені очі	Запис ЕЕГ розслабленого або сплячого пацієнта із закритими очима
Преіктальний	Запис ЕЕГ пацієнта в стані перед епілептичним нападом
Ictal	Запис ЕЕГ пацієнта під час епілептичних нападів
Постіктальний	Запис ЕЕГ пацієнта в стані після епілептичного нападу
Інтеріктальний	Запис ЕЕГ пацієнта в безнападний інтервал між нападами
Артефакти	Сигнали, записані ЕЕГ, які можуть імітувати судоми, але генеруються ззовні мозку

2.3 Вибір каналів

У наборі даних СНВ-МІТ вибрано вісімнадцять каналів із двадцяти трьох, оскільки ці вісімнадцять каналів є загальними серед усіх записів. Відповідно до розподілу положень електродів, показаного на Рисунку 2, прийняті вісімнадцять каналів: ('C3-P3', 'C4-P4', 'CZ-PZ', 'F3-C3', 'F4-C4',

'F7-T7', 'F8-T8', 'FP1-F3', 'FP1-F7', 'FP2-F4', 'FP2-F8', 'FZ-CZ', 'P3-O1', 'P4-O2', 'P7-O1', 'P8-O2', 'T7-P7', 'T8-P8'). Порівнюючи набір даних КАУ з набором даних СНВ-МІТ щодо позицій електродів, як показано на Рисунок 2, зрозуміло, що розташування електродів у двох наборах даних різне. Більшість електродів у наборі даних СНВ-МІТ відсутні в наборі даних КАУ. У зв'язку з цим було проведено роботу по заміні електрода, якого не було, на найближчий встановлений електрод як альтернативу. Два набори даних узгоджуються в таких електродах: ('C3-P3', 'C4-P4', 'Cz-Pz', 'F3-C3', 'F4-C4', 'FP1-F3', 'FP1-F7', 'FP2-F4', 'FP2-F8', 'Fz-Cz', 'P3-O1', 'P4-O2'). Вони відрізняються рештою електродів. Для демонстрації запропонована система замінює наступні електроди: ('F7-T7' на 'F7-T3', 'F8-T8' на 'F8-T4', 'P7-O1' на 'T5-O1', 'P8-O2' на 'T6-O2', 'T7-P7' на 'T3-T5', 'T8-P8' на 'T4-T6').




Рисунок 2. Схематичне зображення позицій електродів ЕЕГ для: (а) Позиції електродів СНВ-МІТ, де прийняті електроди виділені синім кольором; (б) Позиції електродів КАУ.

2.4 Монтаж каналів

Монтаж відноситься до розташування каналів, де канал є парою електродів. Канали набору даних KAU впорядковані у загальний еталонний монтаж, тоді як набір даних СНВ-МІТ є біполярним. Різниця між цими двома типами монтажу полягає в тому, що загальний еталонний монтаж порівнює сигнал у кожному положенні електрода на голові з одним загальним еталонним електродом, тоді як у біполярному монтажі сигнал складається з різниці між двома сусідніми електродами [23]. Щоб інтегрувати обидва набори даних, запропонована система змінює монтаж набору даних KAU на біполярний монтаж.

2.5 Створення метаданих

Файли CSV, які містять метадані, створюються для кожного пацієнта. Метадані містять назву файлу, час початку запису та мітку, присвоєну запису, де мітка 1 вказує на захоплення, а мітка 0 означає відсутність захоплення. Сигнал ЕЕГ розділяється для кожного сигналу нападу у кожного пацієнта за допомогою техніки ковзного вікна. Ця методика є стандартною технікою, яка була прийнята в інших дослідженнях [24,25]. Техніка ковзного вікна з фіксованим розміром була обрана, щоб уникнути зміщення параметрів мережі, яке може виникнути, якщо вхідні сигнали в мережу мають різну довжину. Розмір вікна становить $n = 10$ с з перекриттям $k = 1$ с. Цю техніку використовували при виникненні ЕЕГ-сигналу про напад. У випадку ЕЕГ-сигналу без судом не було необхідності в накладенні. Набір даних СНВ-МІТ містить приблизно 24 000 вікон нормальних записів ЕЕГ (клас без випадків) і приблизно 434 вікна записів ЕЕГ при епілепсії (клас випадків) для тренувальних даних перед накладанням. Він також містить близько 6000 вікон звичайних записів ЕЕГ (клас без нападів) і близько 108 вікон записів ЕЕГ (клас

нападів) для перевірки даних до накладення. Після перекриття навчальні дані складали приблизно 24 000 вікон для класу без судом і 4344 вікна для класу нападів, тоді як дані перевірки стали 6000 вікон для класу без нападів і приблизно 1086 вікон для класу нападів. Розмір вікна було спеціально обрано 10 с на основі кількох факторів. Перший, Таблиця 4 показує середню тривалість одного нападу для деяких суб'єктів у наборі даних. Це показує, що суб'єкт 7 має коротку середню тривалість нападу порівняно з іншими суб'єктами в наборі даних, оскільки мінімальний час впливу для нападів становить у середньому 10 с залежно від набору даних. По-друге, архітектура моделі заснована на використанні шару LSTM, з яким чим більше довжина вікна, тим складніше стає навчання. Щоб уникнути витоку даних, необхідно враховувати два моменти: (1) набір даних необхідно розділити на набори для навчання, перевірки та тестування перед застосуванням техніки накладання; і (2) техніку накладання слід застосовувати лише до даних, які використовуються для навчання.

Таблиця 3. Тривалість нападу для вибірки суб'єктів у наборі даних CNV-MIT.

Тема №	Загальна кількість вилучень	Загальна тривалість нападів (секунди)	Середня тривалість нападу (секунди)
1	7	449	64.14
3	7	409	58.43
5	4	280	70

7	10	94	9.4
9	6	323	53,83

2.6 Зчитування даних ЕЕГ

Необроблені дані та метадані в наборі даних CHB-MIT поєднуються та аналізуються за допомогою бібліотеки `wonambi`. Зібраний набір даних KAU містить дані ЕЕГ `XLtek`, записані за допомогою `Natus Neuroworks`. Цей тип даних ЕЕГ складається з набору файлів у різних форматах, до складу яких входять: `eeg`, `ent`, `epo`, `erd` тощо, `snc`, `stc`, `vt2` і `vtc`. Модуль `wonambi.ioeeg.ktlx` використовується для забезпечення правильного зчитування сигналів ЕЕГ. Таблиця 4. Алгоритм 1. ілюструє, як читати дані ЕЕГ `XLtek`. Зазначимо, що тривалість кожної епохи в запропонованій системі становить 10 с, що включає 46 080 вибірок.

Таблиця 4. Алгоритм 1.

Algorithm 1. READING XLTEK EEG DATA ALGORITHM.	
	Input: An EEG signal and the size of window in seconds
	Output: Array of EEG data samples that constitute the epochs
1	FUNCTION <code>get_epoch(s, min_secs = 10)</code>

2		// Extracting signal start time, sample rate, channel names, and number of samples
3		start_time, s_rate, ch_names, n_samples ← s.return_hdr()
4		s_rate ← int(round(s_rate))
5		// Extracting the creation time for the erd file that holds the raw data
6		erd_time ← s.return_hdr() [-1]['creation_time']
7		// Excluding samples between the start time of recording and the actual acquisition
8		stc_erd_diff ← (erd_time–start_time). total_seconds()
9		// Computing the number of samples required from each channel
10		stride ← min_secs * s_rate
11		start_index ← int(stc_erd_diff) * s_rate
12		end_index ← start_index + stride

13		findings $\leftarrow$ []			
14		WHILE end_index $\leq$ n_samples DO			
15			t $\leftarrow$ s.return_dat ([1], start_index, end_index)		
16			// Excluding the epochs that may contain NaN values		
17			IF ! np.any(np.isnan(t), axis = 1) THEN		
18				data $\leftarrow$ s.return_dat(range(len(ch_names)), start_index, end_index)	
19				IF s_rate > 256 THEN	
20					data $\leftarrow$ decimate(data, q = 2)
21				ENDIF	

Видалення відсутніх значень: Значення Not-a-Number або NaN були знайдені та відкинуті в запропонованій системі, оскільки вони траплялися рідко.

2.7 Вейвлет-розклад

Запропонована система використовує дискретне вейвлет-перетворення (DWT) для розкладання сигналів. Сигнали пропускаються через фільтри високих і низьких частот. Фільтр високих частот генеруватиме всі високочастотні компоненти, які відомі як детальні коефіцієнти. Подібним чином фільтр низьких частот генерує вейвлет-коефіцієнти, які мають низьку частоту і відомі як коефіцієнти апроксимації.

Запропонована система має багаторівневу декомпозицію db4, яка розділяє вейвлет на чотири рівні. Кожен рівень представляє певний діапазон частот для сигналів ЕЕГ, які раніше згадувалися в Таблиці 1, за винятком перших двох діапазонів частот, де перший рівень DWT у запропонованій системі представляє обидва діапазони. Рисунок 3 показує процес розкладання вихідного сигналу на дві частини на першому рівні, де A1 відноситься до коефіцієнтів апроксимації першого рівня, тоді як D1 відноситься до детальних коефіцієнтів першого рівня. Процес декомпозиції триває після першого рівня до четвертого рівня так само, як і коефіцієнти апроксимації. Прийняті коефіцієнти в запропонованій системі з дерева DWT на Рисунку 3 це A4, D4, D3 і D2. A4 представляє діапазони частот дельта і тета, D4 представляє діапазон частот альфа, D3 представляє діапазон частот бета, а D2 представляє діапазон частот гамма. Ці прийнятні коефіцієнти включають сигнали, які знаходяться в діапазоні частот від 0,5 до 60 Гц, оскільки напади більш помітні в цьому діапазоні [26]. Крім того, це гарантує видалення багатьох шумів, у тому числі шуму лінії електропередач, що виділяється хронічною синусоїдальною складовою на 60 Гц, яку можна побачити в необроблених записах біомедичних даних. Синусоїдальний елемент зазвичай виникає в результаті використання пристроїв, які залежать від змінного струму як джерела живлення [27].




Рисунок 3. Запропоноване дерево вейвлет-декомпозиції (db4).

Рисунок 4. показує графічне представлення сигналу EEG для кожного коефіцієнта в дереві DWT, показаному на Рисунку 3. Як видно після чотирьох рівнів розкладання, ширина шумового сигналу (сигналу апроксимації на першому рівні) майже фільтрується порівняно з останнім сигналом апроксимації на останньому рівні, оскільки всі високочастотні компоненти на кожному рівні видаляються. Таким чином, сигнал апроксимації, що залишився на останньому рівні, є синусоїдою у відфільтрованій формі.




Рисунок 4. Апроксимація та деталізація коефіцієнтів ЕЕГ-сигналів.

2.8 Масштабування

Щоб прискорити процес навчання моделі, запропонована модель використовує скаляр, який є z-показником (стандартний показник). Z-показник – це статистичне вимірювання, яке обчислює відстань між точкою даних і середнім [28]. У запропонованій системі z-показник виконується для партій. У цьому випадку всі ознаки будуть перетворені таким чином, що вони матимуть властивості стандартного нормального розподілу. У цьому сценарії функції, як правило, мають форму дзвона. Його було використано, оскільки модель заснована на архітектурі глибокого навчання, де вона в основному включає градієнтний спуск, який, у свою чергу, допомагає бібліотекам TensorFlow і Keras, які використовуються під час роботи з нейронними мережами, швидше вивчати вагові коефіцієнти.

Модель глибокого навчання: була використана модель глибокого навчання (модель DL), яка складається з кількох рівнів. На додаток до цих шарів використовувалися допоміжні шари, такі як шари активації та максимального об'єднання 1D. Перший допомагає визначити нелінійність даних, тоді як другий сприяє зниженню дискретизації результату згорткового шару (зменшення розмірів) шляхом вибору максимального значення на фільтрі.

Модель DL приймає сигнали ЕЕГ як вхідні дані. Ці сигнали зберігаються в одному з вбудованих типів даних у Python, який є кортежем. Розміри кортежу такі ($\text{None} * 18$), що вказує на послідовності 18-вимірних векторів змінної довжини. Слід зазначити, що розмір «Жодного» означає, що мережа зможе приймати вхідні дані з будь-якого виміру. Зверніть увагу, що довжина вікна становить 10 с, частота дискретизації – 256, а кількість каналів – 18. Отже, кількість цифрових вибірок у кожному каналі становить 2560 вибірок, тому розміри будь-якого сигналу дорівнюють (2560×18), і після аналізу сигналу за

допомогою DWT, його розміри стануть $(x * 18)$, де x є конкатенацією компонентів сигналу після процедури декомпозиції. Таким чином, розміри сигналу стають $(A4 + D4 + D3 + D2, 18)$. Навпаки, модель класифікує ці вхідні сигнали ЕЕГ на два класи: напади або без нападів як вихідні. Рисунок 5 показує порядок і конфігурації шарів у моделі.




Рисунок 5. Архітектура моделі глибокого навчання.

Функція втрат, яка використовується в запропонованій моделі, є категоричною крос-ентропією. Прийнятим алгоритмом оптимізації для моделі є алгоритм Адама [29]. Одним із гіперпараметрів алгоритму є швидкість навчання. Автори Adam рекомендують по-різному встановлювати швидкість навчання залежно від системи. Краще використовувати зменшувану швидкість навчання, ніж фіксовану, яка є

швидкістю навчання, значення якої зменшується зі збільшенням номера епохи. Це означає, що це дозволяє почати з відносно високого рівня навчання, водночас отримувати переваги від нижчих показників навчання на завершальних етапах навчання. Це корисно, коли необхідна відносно висока швидкість навчання для встановлення величезних кроків, тоді як дедалі менші кроки необхідні для наближення до мінімальних втрат. Запропонована модель використовує швидкість навчання з початковим значенням 0,00001, беручи до уваги використання загальної схеми розпаду, яка дозволяє експоненціально знижувати швидкість навчання меншими кроками кожні кілька епох.

2.9 Модель виявлення судом

Запропонована система навчена, перевірена та перевірена на наборі даних ЕЕГ шкіри голови СНВ-МІТ. Це залежить від вісімнадцяти загальних каналів, які були згадані раніше. Модель, запропонована на Рисунку 5 використовується, за винятком того, що кожен шар вилучення замінюється шаром пакетної нормалізації. Сигнали ЕЕГ вводяться в систему та проходять через три рівні CNN, кожен з яких має різні конфігурації, як показано на Рисунку 5. Далі йдуть Bi-LSTM і рівні уваги відповідно. Нарешті, сигнали проходять через два щільні шари, які класифікують сигнал як захоплення або без нападів.

2.10 Згорткова нейронна мережа

Сигнали ЕЕГ є одновимірними даними часового ряду; отже, для його аналізу пропонується одновимірна CNN (1D-CNN). 1-D CNN автоматично вивчає дискримінаційні ознаки, які представляють структуру сигналів ЕЕГ [30].

Функцією активації для запропонованої моделі є Swish Rectified

Linear Unit (Swish Relu) [31]. Метою функції активації є класифікація та визначення нелінійності даних. Формула Swish Relu така:

$$f(x) = x * \text{sigmoid}(\beta x)$$

(1)

де:

$$\text{sigmoid}(\beta x) = 1/(1 + e(-\beta x))$$

(2)

де β – константа; якщо β близьке до 0, функція працюватиме лінійно. Якщо β є великим значенням, більшим або рівним 10, функція працює подібно до Relu. Після виконання деяких експериментальних робіт, у цьому дослідженні вважається $\beta = 1$.

2.11 Максимальне об'єднання

Максимальне об'єднання 1D [32] — це операція, яка зазвичай додається до CNN після окремих згорткових шарів для зменшення дискретизації виходу. Максимальне об'єднання використовується для зменшення роздільної здатності виходу згорткового шару, що зменшує параметри мережі та відповідно зменшує обчислювальне навантаження, а також переобладнання. Це також корисно при виборі частот з вищим значенням як найбільш активованих частот. У запропонованій системі застосовано фільтр (вікно) розміру 3.

2.12 Пакетна нормалізація

Протягом навчання розподіл вхідних даних змінюється через оновлення параметрів. Це сповільнить навчання, тому навчання стає важчим із нелінійністю. Це явище називається внутрішнім зсувом коваріат [33]. Щоб вирішити цю проблему, використовується пакетна

нормалізація. Це робить оптимізацію значно плавнішою, прискорює процес навчання та дещо нормалізує модель.

2.13 Двонаправлена довгострокова пам'ять

Двонаправлений LSTM (Bi-LSTM) [34] розділяє шар прихованих нейронів стандартного LSTM на два напрямки поширення: вперед і назад. Таким чином, ця структура Bi-LSTM зробить його здатним обробляти вхідні дані двома способами: моделюванням спереду назад і ззаду наперед. Bi-LSTM має здатність виявляти контекстну інформацію в довгих послідовностях даних і вивчати важливість різних подій. Для цього запропонована система використовує Bi-LSTM. Насправді Bi-LSTM у запропонованій моделі повністю використовуватиме інформацію до та після епілептичного нападу, дозволяючи правильно виявляти напади. Кількість одиниць Bi-LSTM представляє розмірність вихідного простору.

2.14 Увага

Увага [35] — це здатність динамічно виділяти та використовувати важливі частини інформації подібно до людського мозку. Цей тип механізму працює через ітераційне перезважування, щоб дозволити моделі гнучко використовувати найбільш релевантні компоненти вхідної послідовності, якою є сигнал ЕЕГ, щоб надати цим релевантним компонентам найвищі ваги. Цей тип механізму був спочатку запропонований і зазвичай використовується для обробки послідовностей, таких як сигнали ЕЕГ. З цієї причини він був використаний у запропонованій моделі. Bi-LSTM з увагою - це спосіб значно підвищити продуктивність моделі.

2.15 Повність підключений рівень

Повністю підключений шар [36] працює як класифікатор і передбачає клас вхідного сигналу. Пропонована система має два щільних шари. Перший шар складається з тридцяти двох одиниць (нейронів), які представляють розмірність вихідного простору. Другий щільний шар у моделі має дві одиниці, оскільки запропонована модель класифікує сигнали ЕЕГ на два класи: напади та без нападів. Причина використання двох щільних шарів замість одного полягає в тому, що шари згортки в поєднанні з Bi-LSTM і шарами уваги витягують характеристики з сигналів ЕЕГ. Залежно від цих ознак шари глибокої нейронної мережі класифікують сигнали. Перший щільний шар діє як селектор ознак, щоб вирішити, чи є функція релевантною для класу, тоді як другий щільний шар діє як класифікатор. Таким чином, наявність двох щільних шарів покращує здатність мережі краще класифікувати витягнуті ознаки.

РОЗДІЛ 3

Експериментальний результат

Цей розділ буде поділено на дві частини. Перший – це оцінити структуру сумісності для інтеграції локальних даних ЕЕГ із набором даних СНВ-МІТ. Другий – оцінити модель виявлення нападів.

3.1 Оцінка системи сумісності

Щоб оцінити можливість інтеграції даних, модель DL використовує набір добре відомих показників продуктивності для вимірювання продуктивності моделі: чутливість, точність і точність. Формули для цих показників наведено нижче:

$$\text{Чутливість (Recall або Sen.)} = TP / (FN + TP)$$

(3)

$$\text{Точність (PRC)} = TP / (TP + FP)$$

(4)

$$\text{Точність (ACC)} = (TP + TN) / (\text{Загальна кількість зразків})$$

(5)

де *Місто* (Справжній позитивний) – це кількість сигналів нападу, які виявляються як напад, *FN* (Хибно-негативний) – це кількість сигналів нападу, які виявлені як несудомні, *TN* (Істинно негативний) – це кількість сигналів без судом, які виявлені як такі, що не є судомами, і *FP* (Хибно позитивний) – це кількість сигналів, не пов'язаних із судомами, які виявляються як напади.

Було проведено серію експериментів, щоб продемонструвати здійсненність і корисність моделі глибокого навчання для підтвердження концепції інтеграції даних і ефективності структури сумісності зі

стандартами набору даних СНВ-МІТ.

Спочатку для кожного експерименту з набору даних СНВ-МІТ брали випадкову вибірку сигналів ЕЕГ. Враховуючи, що кількість випадкових сигналів ЕЕГ у вибірці пропорційна кількості сигналів ЕЕГ, витягнутих із набору даних КАУ, вплив сигналів КАУ ЕЕГ можна вивчити шляхом їх інтегрування з випадковою вибіркою. Щоб уточнити, кількість сигналів ЕЕГ, вилучених із набору даних КАУ, становила 185 сигналів для обох класів, а кількість випадкових сигналів ЕЕГ у кожній вибірці становила 750 сигналів. Таким чином, кількість сигналів ЕЕГ з набору даних КАУ склала приблизно 25% від розміру випадкової вибірки, що дозволяє виміряти ефективність інтеграції даних. Для ілюстрації, кількість сигналів ЕЕГ у кожній випадковій вибірці з набору даних СНВ-МІТ була пропорційна кількості сигналів ЕЕГ, вилучених із набору даних КАУ, щоб переконатися, що вплив інтеграції даних із набору даних КАУ у СНВ-МІТ набір даних було вивчено. Відбір сигналів у вибірці був випадковим, щоб переконатися, що ефект інтеграції був належним чином вивчений. Тому було проведено кілька експериментів з кількома випадковими вибірками.

Було проведено шість різних експериментів, як показано в Таблиці 4. Кожен експеримент має на меті виміряти ефективність моделі DL на зразку, витягнутому з набору даних СНВ-МІТ, і об'єднати сигнали ЕЕГ КАУ із випадковою вибіркою також із набору даних СНВ-МІТ, щоб вивчити вплив даних, які додаються до Набір даних СНВ-МІТ.

Таблиця 4. Продуктивність моделі DL з інтеграцією даних і без неї.

EXP №	БД	Середня Епоха АСС	Сере. Epoch Sen. для конфіскації	Середнє Epoch Sen. для No-Seizure	Середнє Епоха КНР для конфіскації	Середнє Епоха КНР для беззахоплення

1	ЧБ-3	79,25	64.16	93.14	89.2	75,29
2	ЧБ-3	81,93	68,43	94,41	91,54	78.03
3	ЧБ-3	75,38	54,95	94.02	89,26	70,53
Серед нє	ЧБ-3	78,85	62,51	93,86	90	74,62
4	СНВ -МІТ + ВІ	77,81	66,76	88.01	84.01	76,99
5	СНВ -МІТ + ВІ	80,90	75,34	84,66	78.09	86.03
6	СНВ -МІТ + ВІ	81,73	62.29	94.8	87,71	79,78

Серед не	СНВ -МІТ + ВІ	80.15	68.13	89.16	83,27	80,93
-------------	---------------------	-------	-------	-------	-------	-------


Для додаткової ілюстрації кожна випадкова вибірка, взята з набору даних СНВ-МІТ, містила 750 випадкових сигналів, які потім були розділені на навчання, перевірку та тестування на 50%, 20% і 30% відповідно, так що кількість тренувальних сигналів було 375, а кількість тестових сигналів становила 225. Слід зазначити, що кількість сигналів про напади дорівнювала кількості сигналів без нападів у перших трьох експериментах, проведених лише на наборі даних СНВ-МІТ. Потім набори даних KAU EEG були випадковим чином поділені на групи навчання, перевірки та тестування. Після цього ці зразки з даних KAU EEG були об'єднані з трьома випадковими зразками з набору даних СНВ-МІТ.

Як зазначив в Таблиці 4, значення показників ефективності для кожного експерименту до та після об'єднання випадкової вибірки з даними EEG KAU підвищуються або знаходяться в тому самому діапазоні, доводячи, що інтеграція даних із набором даних KAU за допомогою запропонованої системи є ефективною для боротьби з проблемою дисбалансу даних.

Як видно, запропонована структура сумісності для створення великого та збалансованого набору даних шляхом інтеграції сигналів EEG з набору даних KAU з набором даних СНВ-МІТ продемонструвала покращення здатності моделі ідентифікувати сигнали нападів з вищою точністю. Система запропонувала збільшити кількість сигналів епілепсії та виміряти вплив інтеграції на продуктивність моделі з точки зору загальної точності виявлення епілептичних випадків до і після процесу

інтеграції. Загальна точність з 78,85% зросла до 80,15%. Зокрема, продуктивність покращилася через рівень чутливості до епілептичних випадків конкретно; спочатку він становив 62,51%, а потім став 68,13%, що означає, що кількість сигналів нападів, які були виявлені як неприємкові, була низькою, що відображено у високому рівні чутливості.

Модель було навчено в Google Colab за допомогою графічного процесора Nvidia Tesla K80. Рисунок 6 показує середні значення за епохою метрик, які були згадані раніше в Таблиці 5 для обох класів випадків і без випадків. Завдяки цьому ми відзначаємо високий рівень чутливості після інтеграції даних, яка вимірює відсоток сигналів нападу, які були класифіковані як напад. Однак ми також бачимо на діаграмі, що рівень точності дещо знизився після інтеграції даних, яка вимірює частку сигналів без судом, які були класифіковані як відсутність нападів. Причиною цього є наявність сигналів артефактів у наборі даних KAU, які, у свою чергу, були класифіковані як сигнали захоплення. Цю проблему можна вирішити в майбутній роботі, включивши в модель інструмент, який має справу з сигналами артефактів. Нарешті, ми помічаємо підвищення загальної точності після процесу інтеграції даних, незважаючи на зниження точності, і причиною цього є висока чутливість.



Риснок 6. Середні значення експериментів до і після інтеграції даних для показників ефективності.

3.2 Оцінка моделі виявлення судом

Для оцінки та тестування було використано 20% і 30% набору даних СНВ-МІТ відповідно. Дані тестування становлять близько 12 000 вікон нормальних записів ЕЕГ (клас без нападів) і близько 3004 вікон записів ЕЕГ при епілепсії (клас нападів). Ефективність оцінювалася за допомогою тих самих показників продуктивності, які використовуються для оцінки системи сумісності, а саме чутливості, точності та точності.

Порівняння запропонованої моделі з сучасними методами, навченими та перевіреними на СНВ-МІТ, наведено в 5. Як видно, запропонована система перевершує попередні системи, за винятком однієї [18] вивчення. Однак, порівнюючи запропоновану систему з цим дослідженням, ми виявили, що дослідження було протестовано лише на 14 із 23 пацієнтів у наборі даних, але запропоновану систему оцінювали на всіх 23 пацієнтах. Крім того, ми виявили, що хоча алгоритм цього дослідження є індивідуальним для пацієнта, його ефективність значно

погіршилася для пацієнта 7, де рівень чутливості досяг 50%, оскільки тривалість епілептичних випадків у цього пацієнта була дуже короткою. Це означає, що алгоритм працює добре, якщо тривалість нападу велика. Однак, якщо випадок короткий, точність різко падає. Запропонована система забезпечує хорошу продуктивність в обох випадках, незалежно від того, чи є тривалість нападу довгою чи короткою, як видно через коефіцієнт чутливості запропонованої системи, яка була протестована на всіх пацієнтах і перевершила чутливість попередньої моделі..

Таблиця 5. Порівняння продуктивності запропонованої системи в порівнянні з іншими системами на базі даних CHB-MIT dataset.

Посилання	Кількість каналів	Кількість предметів	Його.	КНР	ACC	Швидкість конвергенції
[13]	23 канали (у деяких випадках 24 або 26)	23	-	96,51	96,61	ТО
[15]	23	25% набору даних	91.15	-	95.11	ТО
[18]	23	14 конкретних пацієнтів	96,43	-	98,60	ТО

[19]	23 канали (у деяких випадка х 24 або 26)	23	82,35	-	96,74	Близько 60 epoch
[21]	23 канали (у деяких випадка х 24 або 26)	23	90,97	-	-	ТО
[20]	23 канали (у деяких випадка х 24 або 26)	23	94	-	89	ТО
Пропонов ана модель	18 канал	23	96,85	96,98	96,87	Близько 130 epoch

Унікальність запропонованої моделі глибокого навчання полягає в її топології дизайну, яка пропонує конкретні типи рівнів із певними параметрами конфігурації, як на Рисунку 5, де конфігурація цієї моделі робить її здатною перевершити найсучасніші моделі завдяки поєднанню кількох переваг у дизайні мережі. По-перше, він візуально виділяє аномалії сигналу з 1D-EEG через Conv1D, яка є візуальною нейронною мережею. По-друге, він вивчає нелінійність сигналів EEG через свист Relu. По-третє, він визначає деякі відмінні характеристики від частот з вищим значенням як найбільш активовані частоти через максимальне об'єднання. По-четверте, він вивчає події нападу та відсутності нападу з

контекстної інформації до та після станів епілептичних або неепілептичних сигналів у прямому та зворотному напрямках поширення через Bi-LSTM. По-п'яте, це значно покращує продуктивність моделі, поєднуючи увагу з Bi-LSTM, щоб надати відповідним компонентам найвищу вагу під час повторного процесу повторного зважування.

Оскільки патерни EEG сильно залежать від суб'єкта, головний внесок запропонованої моделі полягає у вирішенні проблем подвійного виявлення (припадок чи відсутність) на основі використання невеликої кількості каналів, які є загальними для всіх пацієнтів, а не для кожного пацієнта окремо, щоб досягти кращої продуктивності, ніж у систем з повними каналами.

Обмеженням запропонованої моделі може бути нездатність виявити напад або його відсутність за сигналами EEG із частотою дискретизації 512 Гц. Для подальшого вдосконалення модель можна навчити за допомогою методу `decimate()` для зменшення дискретизації сигналу з частотою дискретизації 512 Гц, що дозволить моделі виявляти епілептичні припадки за сигналами з частотою дискретизації 256 або 512 Гц. .

Модель було навчено в Google Colab за допомогою графічного процесора Nvidia Tesla K80. Рисунок 7. показує продуктивність моделі за епохами для тестування за метриками, які раніше використовувалися в Таблиці 6 для кожного класу, судомі або без судом. Спостерігаємо, що збіжність моделі відбулася на 130-й епосі. Порівнюючи Kaziha et al. [19] з нашою моделлю наш метод показує кращу чутливість 96,85%, тоді як їхній метод становив 82,35%. Однією з головних причин є те, що їхній розмір вікна становив 100 с, тоді як розмір нашого вікна становив 10 с, що, у свою чергу, враховує лише точні інтервали нападів.




Рисунок 7. Метричні діаграми продуктивності тестування за епохами.

Висновки

У цьому дослідженні запропоновано структуру сумісності для інтеграції локальних сигналів ЕЕГ у набір даних СНВ-МІТ. Запропонований підхід має багато переваг. По-перше, він долає проблему дисбалансу даних, з якою стикається більшість наборів даних у цій галузі через низьку частоту епілептичних сигналів порівняно з неепілептичними сигналами. По-друге, це дозволяє створювати великі набори даних шляхом інтеграції локальних сигналів ЕЕГ з доступними наборами даних, необхідних для моделей глибокого навчання, які використовуються для розробки систем виявлення та прогнозування нападів. Підхід, представлений у цьому документі, також можна використовувати як допоміжний інструмент для дослідників у цій галузі для обробки та зчитування локальних сигналів ЕЕГ типу XLtek, для яких не було функцій зчитування, доступних у пакетах програмного забезпечення аналізу для таких типів ЕЕГ. Зрештою, низка експериментів, проведених для перевірки інтеграції даних із використанням запропонованої системи, довела її здійсненність і корисність.

Крім того, була запропонована автоматизована система виявлення епілепсії, яка базується на деяких каналах. Ця система має справу з проблемами подвійного виявлення (захоплення чи відсутність захвату). Запропонована система використовує техніку вейвлет-декомпозиції та просту одновимірну згорткову нейронну мережу разом із двонаправленною довготривалою пам'яттю та увагою для отримання сигналів ЕЕГ як вхідних даних, передачі їх на різні рівні та, нарешті, прийняття рішення через щільним шаром. Ця модель може допомогти нейрофізіолога виявити напади та значно зменшити навантаження, а також підвищити ефективність.

Є кілька майбутніх пропозицій щодо запропонованої моделі. Одна з таких пропозицій полягає в тому, що його можна включити в пристрій,

який можна носити пацієнтам, враховуючи вимоги до пам'яті та пам'яті. Іншою пропозицією є можливість розгортання системи в центральному хмарному середовищі для швидкого доступу через мобільні пристрої без використання спеціальних пристроїв, що зношуються. Сигнал ЕЕГ, який розглядається як вхідні дані, має невеликий розмір, а запропонована модель є портативною, що робить її придатною для хмарного розгортання. Сигнали ЕЕГ легко передаються в хмару для обробки в режимі реального часу, оскільки вона може видати попереджувальний сигнал, щоб сповістити лікарів/пацієнтів, якщо це необхідно. Запропонована система може бути використана для реалізації експертних систем для аналогічних розладів, які включають ЕЕГ сигнали мозку.

Перелік використаних джерел

1. Panayiotopoulos C. A *Clinical Guide to Epileptic Syndromes and Their Treatment*. Springer; Berlin/Heidelberg, Germany: 2010. Online: https://scholar.google.com/scholar_lookup?title=A+Clinical+Guide+to+Epileptic+Syndromes+and+Their+Treatment&author=C.+Panayiotopoulos&publication_year=2010&
2. World Health Organization Epilepsy. 2018. Available online: <http://www.who.int/en/news-room/fact-sheets/detail/epilepsy>
3. Background to Seizures. Epilepsy Research UK. 2018. Available online: <https://www.epilepsyresearch.org.uk/about-epilepsy/background-to-seizures/>
4. Bell G., Sinha S., Tisi J., Stephani C., Scott C., Harkness W., McEvoy A., Peacock J., Walker M., Smith S., et al. Premature mortality in refractory partial epilepsy: Does surgical treatment make a difference? *J. Neurol. Neurosurg. Psychiatry*. 2010;**81**:716–718. online: <https://pubmed.ncbi.nlm.nih.gov/20478848/>
5. Ulate-Campos A., Coughlin F., Gaínza-Lein M., Fernández I., Pearl P., Loddenkemper T. Automated seizure detection systems and their effectiveness for each type of seizure. *Seizure*. 2016;**40**:88–101. online: <https://pubmed.ncbi.nlm.nih.gov/27376911/>
6. EEG (Electroencephalogram)—Mayo Clinic. 2022.. Available online: <https://www.mayoclinic.org/tests-procedures/eeg/about/pac-20393875>
7. Nacy S., Kbah S., Jafer H., Al-Shaalan I. Controlling a Servo Motor Using EEG Signals from the Primary Motor Cortex. *Am. J. Biomed. Eng.* 2016;**6**:139–146. Online: https://scholar.google.com/scholar_lookup?journal=Am.+J.+Biomed.+Eng.&title=Controlling+a+Servo+Motor+Using+EEG+Signals+from+the+Primary+Motor+Cortex&author=S.+Nacy&author=S.+Kbah&author=H.+Jafer&author=I.+Al-Shaalan&volume=6&publication_year=2016&pages=139-146&
8. Tatum W.O. Ellen R. grass lecture: Extraordinary EEG. *Neurodiagnostic J.* 2014;**54**:3–21. Online: <https://pubmed.ncbi.nlm.nih.gov/24783746/>
9. Birjandtalab J., Heydarzadeh M., Nourani M. Automated EEGbased epileptic seizure detection using deep neural networks; Proceedings of the 2017 IEEE International Conference on Healthcare Informatics (ICHI); Park City, UT, USA.

23–26 August 2017; pp. 552–555. Online: [https://scholar.google.com/scholar_lookup?journal=Proceedings+of+the+2017+IEEE+International+Conference+on+Healthcare+Informatics+\(ICHI\)&title=Automated+EEGbased+epileptic+seizure+detection+using+deep+neural+networks&author=J.+Birjandtalab&author=M.+Heydarzadeh&author=M.+Nourani&pages=552-555&](https://scholar.google.com/scholar_lookup?journal=Proceedings+of+the+2017+IEEE+International+Conference+on+Healthcare+Informatics+(ICHI)&title=Automated+EEGbased+epileptic+seizure+detection+using+deep+neural+networks&author=J.+Birjandtalab&author=M.+Heydarzadeh&author=M.+Nourani&pages=552-555&)

10. Buda M., Maki A., Mazurowski M.A. A systematic study of the class imbalance problem in convolutional neural networks. *Neural Netw.* 2018;**106**:249–259. doi: 10.1016/j.neunet.2018.07.011. Online: <https://pubmed.ncbi.nlm.nih.gov/30092410/>

11. Shoeb A. *Ph.D. Thesis*. Massa-Chusetts Institute of Technology; Cambridge, MA, USA: 2009. Application of Machine Learning to Epileptic Seizure Onset Detection and Treatment. Online: https://scholar.google.com/scholar_lookup?title=Ph.D.+Thesis&author=A.+Shoeb&publication_year=2009&

12. Antoniadou A., Spyrou L., Took C.C., Sanei S. Deep learning for epileptic intracranial EEG data; Proceedings of the 2016 IEEE 26th International Workshop on Machine Learning for Signal Processing (MLSP); Vietri sul Mare, Italy. 13–16 September 2016; pp. 1–6. Online: https://scholar.google.com/scholar_lookup?title=Ph.D.+Thesis&author=A.+Shoeb&publication_year=2009&

13. Yuan Y., Xun G., Ma F., Suo Q., Xue H., Jia K., Zhang A. A novel channel-aware attention framework for multi-channel EEG seizure detection via multi-viewdeep learning; Proceedings of the 2018 IEEE EMBS International Conference on Biomedical & Health Informatics (BHI); Las Vegas, NV, USA. 4–7 March 2018; pp. 206–209. Online: [https://scholar.google.com/scholar_lookup?journal=Proceedings+of+the+2018+IEEE+EMBS+International+Conference+on+Biomedical+&+Health+Informatics+\(BHI\)&title=A+novel+channel-aware+attention+framework+for+multi-channel+EEG+seizure+detection+via+multi-viewdeep+learning&author=Y.+Yuan&author=G.+Xun&author=F.+Ma&author=Q.+Suo&author=H.+Xue&pages=206-209&](https://scholar.google.com/scholar_lookup?journal=Proceedings+of+the+2018+IEEE+EMBS+International+Conference+on+Biomedical+&+Health+Informatics+(BHI)&title=A+novel+channel-aware+attention+framework+for+multi-channel+EEG+seizure+detection+via+multi-viewdeep+learning&author=Y.+Yuan&author=G.+Xun&author=F.+Ma&author=Q.+Suo&author=H.+Xue&pages=206-209&)

14. Ullah I., Hussain M., Qazi E.-U.-H., Aboalsamh H. An automated system for epilepsy detection using EEG brain signals based on deep learning approach. *Expert Syst. Appl.* 2018;**107**:61–71. doi: 10.1016/j.eswa.2018.04.021. Online: <https://linkinghub.elsevier.com/retrieve/pii/S0957417418302513>

15. Zabihi M., Kiranyaz S., Jantti V., Lipping T., Gabbouj M. Patient-Specific Seizure Detection Using Nonlinear Dynamics and Nullclines. *IEEE J. Biomed. Health Inform.* 2019;24:543–555. doi: 10.1109/JBHI.2019.2906400. Online: <https://pubmed.ncbi.nlm.nih.gov/30932854/>
16. Avcu M.T., Zhang Z., Chan D.W.S. Seizure detection using least EEG channels by deep convolutional neural network; Proceedings of the ICASSP 2019 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP); Brighton, UK. 12–17 May 2019; pp. 1120–1124. Online: [https://scholar.google.com/scholar_lookup?journal=Proceedings+of+the+ICASSP+2019+IEEE+International+Conference+on+Acoustics,+Speech+and+Signal+Processing+\(ICASSP\)&title=Seizure+detection+using+least+EEG+channels+by+deep+convolutional+neural+network&author=M.T.+Avcu&author=Z.+Zhang&author=D.W.S.+Chan&pages=1120-1124&](https://scholar.google.com/scholar_lookup?journal=Proceedings+of+the+ICASSP+2019+IEEE+International+Conference+on+Acoustics,+Speech+and+Signal+Processing+(ICASSP)&title=Seizure+detection+using+least+EEG+channels+by+deep+convolutional+neural+network&author=M.T.+Avcu&author=Z.+Zhang&author=D.W.S.+Chan&pages=1120-1124&)
17. Hu X., Yuan Q. Epileptic EEG Identification Based on Deep Bi-LSTM Network; Proceedings of the 2019 IEEE 11th International Conference on Advanced Infocomm Technology (ICAIT); Jinan, China. 18–20 October 2019; pp. 63–66. Online: <https://ieeexplore.ieee.org/document/8935899>
18. Chandel G., Farooq O., Khan Y., Varshney Y. Patient Specific Seizure Onset-Offset Latency Detection using Long- term EEG Signals. In Proceedings of the 2019 International Conference on Electrical, Electronics and Computer Engineering (UPCON); Aligarh, India. 8–10 November 2019. Online: [https://scholar.google.com/scholar_lookup?journal=Patient+Specific+Seizure+Onset-Offset+Latency+Detection+using+Long-term+EEG+Signals.+In+Proceedings+of+the+2019+International+Conference+on+Electrical,+Electronics+and+Computer+Engineering+\(UPCON\)&author=G.+Chandel&author=O.+Farooq&author=Y.+Khan&author=Y.+Varshney&](https://scholar.google.com/scholar_lookup?journal=Patient+Specific+Seizure+Onset-Offset+Latency+Detection+using+Long-term+EEG+Signals.+In+Proceedings+of+the+2019+International+Conference+on+Electrical,+Electronics+and+Computer+Engineering+(UPCON)&author=G.+Chandel&author=O.+Farooq&author=Y.+Khan&author=Y.+Varshney&)
19. Kaziha O., Bonny T. A Convolutional Neural Network for Seizure Detection; Proceedings of the 2020 Advances in Science and Engineering Technology International Conferences (ASET); Dubai, United Arab Emirates. 4 February–9 April 2020. Online: [https://scholar.google.com/scholar_lookup?journal=Proceedings+of+the+2020+Advances+in+Science+and+Engineering+Technology+International+Conferences+\(ASET\)&title=A+Convolutional+Neural+Network+for+Seizure+Detection&author=O.+Kaziha&author=T.+Bonny&](https://scholar.google.com/scholar_lookup?journal=Proceedings+of+the+2020+Advances+in+Science+and+Engineering+Technology+International+Conferences+(ASET)&title=A+Convolutional+Neural+Network+for+Seizure+Detection&author=O.+Kaziha&author=T.+Bonny&)
20. Huang C., Chen W., Chen M., Yuan B. A Feature Fusion Framework and Its Application to Automatic Seizure Detection. *IEEE Signal Process.*

Lett. 2021;**28**:753–757. doi: 10.1109/LSP.2021.3069344. Online: <https://ieeexplore.ieee.org/document/9388850>

21. Jeong S., Jeon E., Ko W., Suk H. Fine-grained Temporal Attention Network for EEG-based Seizure Detection. In Proceedings of the 2021 9th International Winter Conference on Brain-Computer Interface (BCI); Gangwon, Korea. 22–24 February 2021. Online: [https://scholar.google.com/scholar_lookup?journal=Fine-grained+Temporal+Attention+Network+for+EEG-based+Seizure+Detection.+In+Proceedings+of+the+2021+9th+International+Winter+Conference+on+Brain-Computer+Interface+\(BCI\)&author=S.+Jeong&author=E.+Jeon&author=W.+Ko&author=H.+Suk&](https://scholar.google.com/scholar_lookup?journal=Fine-grained+Temporal+Attention+Network+for+EEG-based+Seizure+Detection.+In+Proceedings+of+the+2021+9th+International+Winter+Conference+on+Brain-Computer+Interface+(BCI)&author=S.+Jeong&author=E.+Jeon&author=W.+Ko&author=H.+Suk&)

22. Holmes G. Consequences of Epilepsy through the Ages: When is the Die Cast? *Epilepsy Curr.* 2012;**12**:4–6. doi: 10.5698/1535-7511-12.4s.4. Online: https://scholar.google.com/scholar_lookup?journal=Epilepsy+Curr.&title=Consequences+of+Epilepsy+through+the+Ages:+When+is+the+Die+Cast?&author=G.+Holmes&volume=12&publication_year=2012&pages=4-6&doi=10.5698/1535-7511-12.4s.4&

23. Jadeja N.M. *How to Read an EEG*. Cambridge University Press; Cambridge, MA, USA: 2021. Montages; pp. 17–22. Online: https://scholar.google.com/scholar_lookup?title=How+to+Read+an+EEG&author=N.M.+Jadeja&publication_year=2021&

24. Sharmila A., Geethanjali P. DWT Based Detection of Epileptic Seizure From EEG Signals Using Naive Bayes and k-NN Classifiers; Proceedings of the 2017 International Conference on Trends in Electronics and Informatics (ICEI); Tirunelveli, India. 11–12 May 2017; pp. 7716–7727. Online: [https://scholar.google.com/scholar_lookup?journal=Proceedings+of+the+2017+International+Conference+on+Trends+in+Electronics+and+Informatics+\(ICEI\)&title=DWT+Based+Detection+of+Epileptic+Seizure+From+EEG+Signals+Using+Naive+Bayes+and+k-NN+Classifiers&author=A.+Sharmila&author=P.+Geethanjali&volume=Volume+4&pages=7716-7727&doi=10.1109/ACCESS.2016.2585661&](https://scholar.google.com/scholar_lookup?journal=Proceedings+of+the+2017+International+Conference+on+Trends+in+Electronics+and+Informatics+(ICEI)&title=DWT+Based+Detection+of+Epileptic+Seizure+From+EEG+Signals+Using+Naive+Bayes+and+k-NN+Classifiers&author=A.+Sharmila&author=P.+Geethanjali&volume=Volume+4&pages=7716-7727&doi=10.1109/ACCESS.2016.2585661&)

25. Zhang T., Chen W., Li M. AR based quadratic feature extraction in the VMD domain for the automated seizure detection of EEG using random forest classifier. *Biomed. Signal Process. Control.* 2017;**31**:550–559. doi: 10.1016/j.bspc.2016.10.001. Online: https://scholar.google.com/scholar_lookup?journal=Biomed.+Signal+Process.+Co

[ntrol&title=AR+based+quadratic+feature+extraction+in+the+VMD+domain+for+t
he+automated+seizure+detection+of+EEG+using+random+forest+classifier&auth
or=T.+Zhang&author=W.+Chen&author=M.+Li&volume=31&publication_year=
2017&pages=550-559&doi=10.1016/j.bspc.2016.10.001&](#)

26. Khan Y.U., Farooq O., Sharma P. Automatic detection of seizure onset in pediatric EEG. *Int. J. Embed. Syst. Appl.* 2012;2:81–89. doi: 10.5121/ijesa.2012.2309. Online:

https://scholar.google.com/scholar_lookup?journal=Int.+J.+Embed.+Syst.+Appl.&title=Automatic+detection+of+seizure+onset+in+pediatric+EEG&author=Y.U.+Khan&author=O.+Farooq&author=P.+Sharma&volume=2&publication_year=2012&pages=81-89&doi=10.5121/ijesa.2012.2309&

27. Akwei-Sekyere S. Powerline noise elimination in biomedical signals via blind source separation and wavelet analysis. *PeerJ*. 2015;3:e1086. doi: 10.7717/peerj.1086. Online:

https://scholar.google.com/scholar_lookup?journal=PeerJ&title=Powerline+noise+elimination+in+biomedical+signals+via+blind+source+separation+and+wavelet+analysis&author=S.+Akwei-Sekyere&volume=3&publication_year=2015&pages=e1086&pmid=26157639&doi=10.7717/peerj.1086&

28. Frost J. Z-score: Definition, Formula, and Uses. Statistics by Jim. 2022. Available online: <https://statisticsbyjim.com/basics/z-score/>

29. Kingma P.D., Ba J.L. Adam: A method for stochastic optimization. *arXiv*. 2017 doi: 10.48550/arXiv.1412.6980.1412.6980v9 Online:

https://scholar.google.com/scholar_lookup?journal=arXiv&title=Adam:+A+method+for+stochastic+optimization&author=P.D.+Kingma&author=J.L.+Ba&publication_year=2017&doi=10.48550/arXiv.1412.6980&

30. Albawi S., Mohammed T.A., Al-Zawi S. Understanding of a convolutional neural network; Proceedings of the 2017 International Conference on Engineering and Technology (ICET); Antalya, Turkey. 21–23 August 2017; pp. 1–6. Online:

[https://scholar.google.com/scholar_lookup?journal=Proceedings+of+the+2017+International+Conference+on+Engineering+and+Technology+\(ICET\)&title=Understanding+of+a+convolutional+neural+network&author=S.+Albawi&author=T.A.+Mohammed&author=S.+Al-Zawi&pages=1-6&doi=10.1109/ICEngTechnol.2017.8308186&](https://scholar.google.com/scholar_lookup?journal=Proceedings+of+the+2017+International+Conference+on+Engineering+and+Technology+(ICET)&title=Understanding+of+a+convolutional+neural+network&author=S.+Albawi&author=T.A.+Mohammed&author=S.+Al-Zawi&pages=1-6&doi=10.1109/ICEngTechnol.2017.8308186&)

31. Ramachandran P., Zoph B., Le Q.V. Searching for activation functions. *arXiv*. 20171710.05941 Online: https://scholar.google.com/scholar_lookup?journal=arXiv&title=Searching+for+activation+functions&author=P.+Ramachandran&author=B.+Zoph&author=Q.V.+Le&publication_year=2017&
32. Murray N., Perronnin F. Generalized Max Pooling; Proceedings of the 2014 IEEE Conference on Computer Vision and Pattern Recognition; Columbus, OH, USA. 23–28 June 2014; Online: https://scholar.google.com/scholar_lookup?journal=Proceedings+of+the+2014+IEEE+Conference+on+Computer+Vision+and+Pattern+Recognition&title=Generalized+Max+Pooling&author=N.+Murray&author=F.+Perronnin&doi=10.1109/cvpr.2014.317&
33. Ioffe S., Szegedy C. Batch normalization: Accelerating deep network training by reducing internal covariate shift. *arXiv*. 20151502.03167 Online: https://scholar.google.com/scholar_lookup?journal=arXiv&title=Batch+normalization:+Accelerating+deep+network+training+by+reducing+internal+covariate+shift&author=S.+Ioffe&author=C.+Szegedy&publication_year=2015&
34. Aggarwal R. Bi-LSTM. *Medium*. 2019 Available online: <https://medium.com/@raghavaggarwal0089/bi-lstm-bc3d68da8bd0>
35. Verma Y. A Beginner's Guide to Using Attention Layer in Neural Networks. *Analytics India Magazine*. 2022. Available online: <https://analyticsindiamag.com/a-beginners-guide-to-using-attention-layer-in-neural-networks/>
36. Unzueta D. Convolutional Layers vs. Fully Connected Layers. Towards Data Science. 2021. Available online: <https://towardsdatascience.com/convolutional-layers-vs-fully-connected-layers-364f05ab460b>

Додаток А

Математична модель геометричного опису плоскої спіральної антени

Algorithm 1. READING XLTEK EEG DATA ALGORITHM.		
	Input: An EEG signal and the size of window in seconds	
	Output: Array of EEG data samples that constitute the epochs	
1	FUNCTION get_epoch(s, min_secs = 10)	
2		// Extracting signal start time, sample rate, channel names, and number of samples
3		start_time, s_rate, ch_names, n_samples $\leftarrow$ s.return_hdr()
4		s_rate $\leftarrow$ int(round(s_rate))
5		// Extracting the creation time for the erd file that holds the raw data
6		erd_time $\leftarrow$ s.return_hdr() [-1]['creation_time']

7		// Excluding samples between the start time of recording and the actual acquisition	
8		stc_erd_diff $\leftarrow$ (erd_time–start_time). total_seconds()	
9		// Computing the number of samples required from each channel	
10		stride $\leftarrow$ min_secs * s_rate	
11		start_index $\leftarrow$ int(stc_erd_diff) * s_rate	
12		end_index $\leftarrow$ start_index + stride	
13		findings $\leftarrow$ []	
14		WHILE end_index $\leq$ n_samples DO	
15			t $\leftarrow$ s.return_dat ([1], start_index, end_index)
16			// Excluding the epochs that may contain NaN values
17			IF ! np.any(np.isnan(t), axis = 1) THEN

18				data ← s.return_dat(range(len(ch_names)), start_index, end_index)	
19				IF s_rate > 256 THEN	
20					data ← decimate(data, q = 2)
21				ENDIF	
22				// Converting numpy array to a pandas data frame	
23				df ← pd.DataFrame(data = data.T, columns = ch_names)	
24				findings.append(montage(df, model_modified_channels))	
25			ENDIF		
26			start_index ← start_index + stride		
27			end_index ← end_index + stride		
28		ENDWHILE			

29	return findings
30	ENDFUNCTION