

## ІНТЕГРОВАНЕ НЕЙРОМЕРЕЖЕВЕ МОДЕЛЮВАННЯ ЕЕГ ДЛЯ ДІАГНОСТИКИ ПОРУШЕНЬ МОЗКОВОЇ ДІЯЛЬНОСТІ

*Анотація.* У статті розглядається структуроване багатоступеневе моделювання ЕЕГ засобами прикладної математики з налаштування простору вхідних параметрів для нейромережевого прогнозування. Також, проводиться аналіз підходів та моделей на їх точність у визначенні відповідних ознак сигналу та пристосованості до реальних даних.

*Ключові слова:* нейромережа, електроенцефалографія, часовий ряд, прогнозування, функція активації, хаотична динаміка.

**Постановка проблеми.** Прогрес розвитку інтелектуальних здібностей, формування мозку, як складної структури взаємозалежних нейронів стає стрімкішим з кожним століттям, що межує із поліпшенням всіх аспектів життєдіяльності. Припускаючи еволюцію геному людини як безпосередній фактор формування мозкової структури, виникає необхідність у створенні категоричного та гнучкого інструменту аналізу взаємозалежної поведінки нейронів. Наразі, існує велика бібліотека досліджень, які частково або повністю описують та пропонують алгоритми подібного аналізу [1,2,3], однак не мають достатньої пристосованості до реальних подій або обмежують розмах точності до необґрунтовано значних меж. Тому, в даній роботі пропонується до огляду більш гнучкий метод аналізу та прогнозування відповідних даних електроенцефалограми (ЕЕГ).

**Мета дослідження.** Розробити ряд методів та підходів для гнучкого аналізу ЕЕГ з використанням математичного моделювання, як для попереднього відтворення зв'язків та ідентифікації глобальних параметрів, так і для налаштування параметрів нейромережі, для більш точного прогнозування.

**Огляд проблеми.** Електроенцефалографія дозволяє неінвазивно реєструвати електричну активність мозку, надаючи цінну інформацію про його стан і функції. Цей метод широко застосовується для діагностики та аналізу неврологічних розладів, таких як епілепсія, шизофренія та аутизм.

Важливим етапом в обробці ЕЕГ є виділення релевантних ознак або маркерів для конкретного застосування. Для цього було розроблено безліч методів, від класичного спектрального аналізу до нелінійних підходів і сучасних алгоритмів глибокого навчання. Оскільки мозок функціонує як складна мережа нейронів, що взаємодіють і синхронізуються, то використання метрик функціональної зв'язності як ознаки для аналізу

ЕЕГ-сигналів, пошук параметрів поведінки моделі та використання адаптивних, гнучких підходів з використанням нейромережевого моделювання залишається актуальним.

**Опис наданих даних ЕЕГ.** В роботі були використані дані пацієнта з ознаками порушення мозкової активності, однак без епілептичних нападів та в порівнянні використано базу даних з дитячої лікарні в Бостоні, пацієнтів з важко виловковими судомами. А саме:

Пацієнт 1. 8 років, хлопчик, тимчасові аномалії – 20.06.2024

Пацієнт 2. 11 років, дівчина, часті судомні напади – 08.06.2010

**Алгоритм попередньої обробки ЕЕГ сигналів.** Попередня обробка ЕЕГ є відповідальним етапом у підготовці її до подальшого аналізу. Це включає в себе ряд методів, спрямованих на зниження шуму і видалення артефактів, щоб забезпечити готовність чистого сигналу до подальших кроків. Початковим етапом цього процесу є видалення шумів, що походять від зовнішніх електромагнітних полів. Далі необхідно усунути артефакти руху, оскільки вони можуть мати негативний вплив на сигнал ЕЕГ. Одним з найбільш популярних інструментів для видалення артефактів і шумів з нелінійних сигналів ЕЕГ є метод незалежних компонент (Independent Component Analysis, ICA) [4]. Завдяки ICA вдається ефективно розкласти сигнал на незалежні компоненти і ідентифікувати ті з них, що пов'язані з артефактами відповідної ознаки. При роботі з багатоканальними сигналами ICA розділяє багатоконпонентний сигнал ЕЕГ на незалежні частини, тим самим видаляючи шум і перешкоди, викликані морганням, рухами очей, серцевими скороченнями і м'язовою активністю.

Наступним кроком було застосовано ряд фільтрів різного типу, що включає застосування смугового фільтра для виділення частотного діапазону, який містить релевантну інформацію, та режекторного фільтра для зниження впливу електромагнітних перешкод від мережі живлення [5]. Параметри фільтрів можуть бути гнучко налаштовані відповідно до вимог конкретного дослідження та змінені відповідно спостережуваним висновкам про вихідний сигнал. В даній роботі смуговий фільтр було встановлено в діапазоні 0,5-30 Гц, режекторний 50 Гц з вікном розмаху 5 Гц. Отримані результати візуалізовано порівнянням оригінальних даних з обробленими (рис. 1-2).

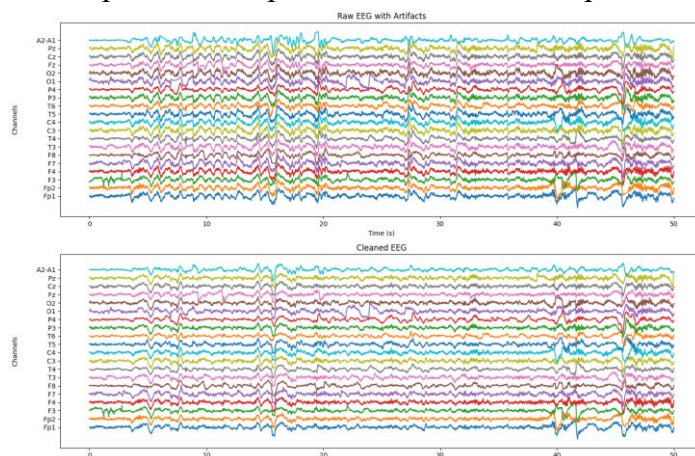


Рисунок 1 – Порівняння вхідних даних з очищеними від артефактів для першого пацієнта

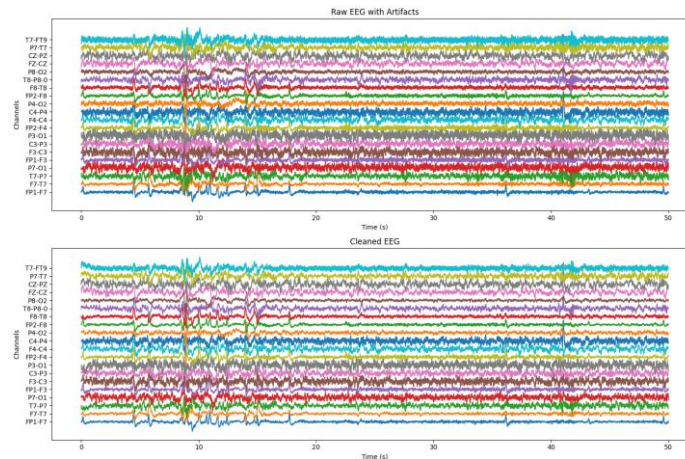


Рисунок 2 – Порівняння вхідних даних з очищеними від артефактів для другого пацієнта

Для виявлення інших типів артефактів застосовується метод на основі амплітудного порогу. Хоча цей підхід є відносно простим, він дозволяє виявляти значні відхилення у сигналі, проте його можливості можуть бути розширені шляхом застосування більш складних алгоритмів, таких як класифікація артефактів з використанням машинного навчання.

Для подальшої обробки даних, сигнал було розділено на сегменти однакової довжини та проаналізовано частотний вміст сигналу.

Спектральний аналіз є широко використовуваним методом вилучення цінної інформації з сигналів ЕЕГ [6]. Аналізуючи спектральну щільність потужності (спектр потужності) сигналу, спектральний аналіз може дати уявлення про частотний склад або розподіл потужності сигналу по частоті. Ця інформація допомагає зрозуміти основні нейронні процеси, відповідальні за генерацію сигналу, і виявити закономірності, які можуть бути пов'язані з конкретними когнітивними станами або поведінкою

З порівняння показників спектру було визначено, що пацієнт з активним та прогресуючим захворюванням мозку має більш виражені піки активності в частоті 15-20 Гц та близько 30 Гц, на відміну від іншого пацієнта з більш гладкою поведінкою частоти, яка демонструє найбільшу потужність сигналу в низькочастотному діапазоні та різкий спад після 40 Гц. Для візуалізації даних та оцінки якості їх обробки було використано інструменти з бібліотеки Matplotlib (рис. 3-4).




Рисунок 3 – Візуалізація спектральної потужності першого пацієнта

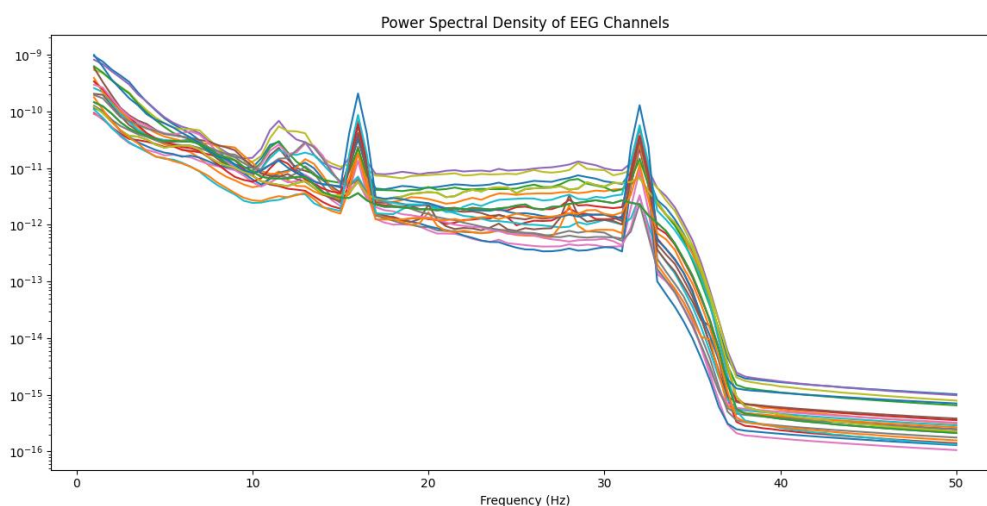


Рисунок 4 – Візуалізація спектральної потужності другого пацієнта

Варто зазначити, що алгоритм обробки може бути вдосконалений шляхом впровадження адаптивної фільтрації для більш ефективного видалення артефактів, а також за рахунок застосування методів машинного навчання для автоматичної класифікації артефактів. Крім того, перспективним є додавання аналізу зв'язності між каналами ЕЕГ і автоматичний вибір параметрів фільтрації на основі характеристик сигналу.

Незважаючи на відсутність консенсусу щодо оптимального алгоритму попередньої фільтрації та методів видалення артефактів, поточні дослідження продовжують підвищувати якість даних ЕЕГ та підвищувати точність аналізу. Використання різних методів, може ефективно пом'якшити артефакти в сигналах ЕЕГ, забезпечуючи всебічне використання даних в широкому діапазоні.

**Використання адаптивних алгоритмів глибокого навчання.** В даному розділі розглянемо наступний етап роботи з даними, ціллю якого є інтеграція математичних моделей хаотичної динаміки для пошуку нелінійних зв'язків між сигналами. Для огляду та порівняння були використані різноманітні моделі з їх специфікою пристосова-

ності та визначені показники функції втрат та точності моделювання для висновку щодо їх подальшого застосування.

Слід зазначити, що пошук стабільних станів здорової людини стає задачею менш актуальною та вже отримав певний рівень автоматизації, однак розуміння прояву аномальної активності нейронів, що призводить до так званого нейрозапалення є більш складним процесом.

Складність досліджуваних процесів, що взаємодіють у різних часових масштабах, робить розуміння епілептогенезу великим викликом. У такій системі з декількома нелінійними взаємодіючими процесами математичне моделювання є корисним інструментом для кращого розуміння динаміки системи [7]. Крім того, моделювання допомагає систематизувати та пояснити велику кількість спостережень, отриманих у клінічних дослідженнях

Сигнал ЕЕГ несе цінну інформацію в певних частотних діапазонах: альфа (8-13 Гц), бета (14-40 Гц), тета (4-8 Гц), дельта (0,5-3 Гц), гамма (вище 40 Гц). Кожна з цих частот має свої унікальні характеристики і області застосування. Оскільки частотні діапазони і їх характеристики були широко вивчені, то множину цих значень можна використовувати в якості вхідного вектору для певних моделей.

Представлені математичні моделі були пристосовані для глибокого аналізу динаміки ЕЕГ сигналів, де кожна модель намагається забезпечити унікальний погляд на природу досліджуваних процесів. Авторегресійна модель (AR) дозволяє виявити лінійні залежності в часових рядах ЕЕГ та прогнозувати їх поведінку на основі попередніх значень, що особливо корисно для виявлення повторюваних патернів активності мозку. Прихована марковська модель (НММ) ефективно ідентифікує дискретні стани мозкової активності та переходи між ними, що важливо для розуміння зміни режимів функціонування мозку.

Модель Лоренца демонструє високу ефективність у моделюванні хаотичної динаміки ЕЕГ сигналів, дозволяючи виявити детерміновані хаотичні процеси в мозковій активності. Модель Рьослера, що має простішу структуру порівняно з моделлю Лоренца, але також здатна генерувати хаотичну поведінку, допомагає виявити більш тонкі особливості нелінійної динаміки ЕЕГ. Модель Ван дер Поля, що описує автоколивання, особливо корисна для аналізу ритмічної активності мозку та її автоматичних коливань. Модель ФітцХью-Нагумо, спочатку розроблена для опису нейронної активності, відмінно підходить для моделювання збудження та релаксації нейронних популяцій, що відображаються в ЕЕГ сигналах. Модель Кермака-МакКендріка дозволяє аналізувати поширення активності між різними ділянками мозку за аналогією з епідеміологічними процесами. Модель ФітцХью-Нагумо-Даффінга поєднує властивості нейронної динаміки з нелінійними коливаннями, що робить її особливо цінною для аналізу складних патернів ЕЕГ.

Нижче продемонстроване візуальне порівняння моделей для очищених даних та окремо виділені їх фазові портрети (рис. 5 – 8).




Рисунок 5 – Порівняння результатів моделювання на основі даних першого пацієнта

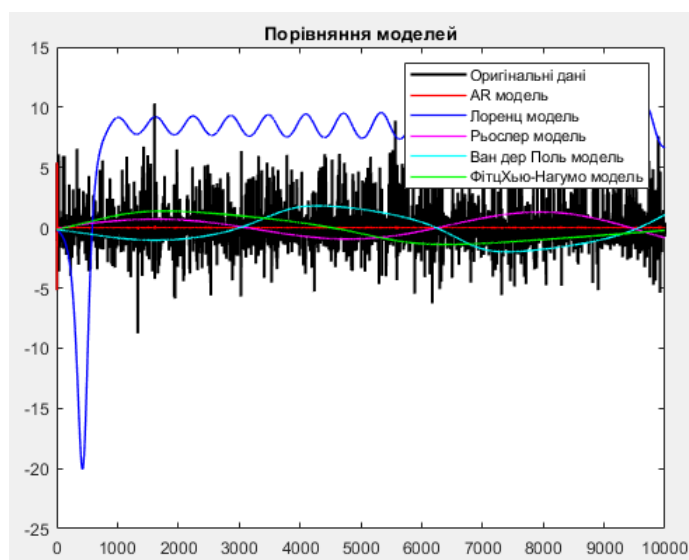


Рисунок 6 - Порівняння результатів моделювання на основі даних другого пацієнта

Аналіз результатів моделювання з використанням певних метрик дозволяє виявити найбільш адекватну модель для конкретного типу ЕЕГ сигналу та краще зрозуміти механізми, що лежать в основі спостережуваної мозкової активності. До таких можемо віднести обчислення показника Ляпунова, які дозволяють оцінити ступінь хаотичності досліджуваних процесів, кореляційна розмірність характеризує складність атрактора та може вказувати на кількість незалежних змінних, необхідних для опису динаміки системи, середньоквадратична помилка (MSE) слугує об'єктивним критерієм для порівняння точності відтворення експериментальних даних [8]. Для прикладу нижче було розраховано середньоквадратичну помилку пацієнтів, яка демонструє перевагу AR моделювання, що було підтверджено візуальною інтерпретацією раніше.




Рисунок 7 – Фазові портрети моделей на основі даних першого пацієнта

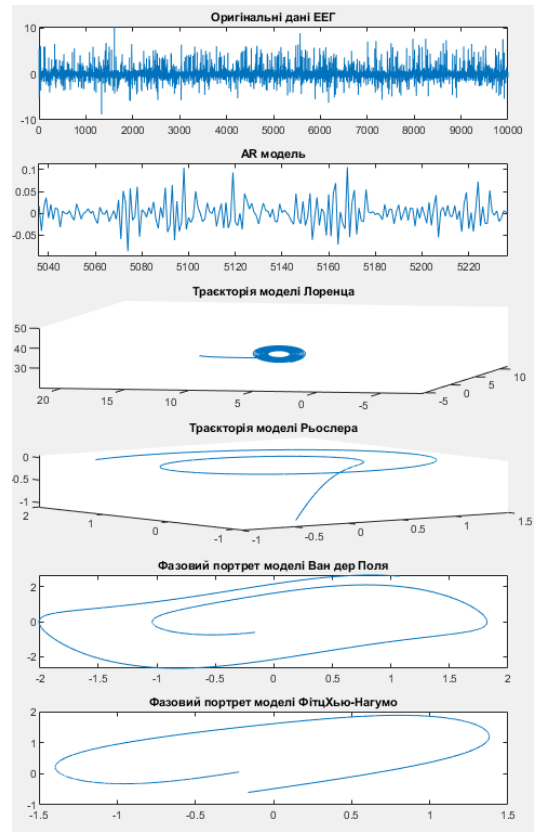


Рисунок 8 – Фазові портрети моделей на основі даних другого пацієнта

Для 1го пацієнта:

AR MSE: 0.974036

Lorenz MSE: 73.473649

Rosler MSE: 3.729282

Van der Pol MSE: 2.779805

FitzHugh-Nagumo MSE: 1.585269

Kermack-McKendrick MSE: 0.998940

FitzHugh-Nagumo-Duffing MSE: 2.511791

Для 2го пацієнта:

AR MSE: 0.990802

Lorenz MSE: 73.568802

Rosler MSE: 1.518555

Van der Pol MSE: 2.368941

FitzHugh-Nagumo MSE: 1.929700

Kermack-McKendrick MSE: 1.036738

FitzHugh-Nagumo-Duffing MSE: 2.212152

**Оптимізація прогнозу EEG даних через попереднє налаштування LSTM архітектури.** У цьому розділі дослідження запропоновано підхід до аналізу та прогнозування часових рядів електроенцефалограм на основі модифікованої архітектури Long Short-Term Memory (LSTM) [9]. Модель LSTM – це рекурентна нейронна мережа, вдос-

конталена моделлю RNN. LSTM може ефективно передавати та виражати інформацію в більш тривалих часових рядах. Це успішно вирішує проблему градієнтного зникнення RNN, спричинену додаванням мережевих шарів і плином часу, роблячи її більш прийнятною. Унікальний стан нейронних клітин топології нейронної мережі LSTM, яка записує та передає дані за допомогою комірок пам'яті, відрізняє її від інших методів глибокого навчання. Стандартна LSTM архітектура включає вхідний шар, один або декілька прихованих LSTM-шарів, а також вихідний шар. Кожен LSTM-шар містить три типи воріт: вхідні, які контролюють потік нової інформації; ворота забування, що визначають, яку інформацію зберігати або відкидати; та вихідні ворота, що вирішують, яку інформацію передавати далі по мережі. Така структура дозволяє ефективно працювати з довгими послідовностями, зберігаючи релевантну інформацію і ігноруючи непотрібні дані.

В більшості подібних досліджень модифікація будови шарів та комбіноване застосування комплексного аналізу не призводило до втішних результатів прогнозування, яке зводилось до стаціонарного стану. Тому, були застосовані попередні процедури визначення параметрів LSTM моделі для досягнення прогнозованими значеннями хаотичної та природньо відповідної поведінки.

По-перше, для ініціалізації вхідних ваг мережі проведено ряд математичних операцій над вхідними даними [10, 11], що надає мережі початкове розуміння структури вхідних даних, прискорюючи збіжність і покращуючи точність прогнозування на ранніх етапах навчання. По-друге, впроваджується нестандартна активаційна функція, що поєднує синусоїдальну компоненту та гаусівський шум, яка надає моделі стохастичності та нерегулярності. Ця функція відрізняється від традиційних активаційних функцій (сигмоїди чи гіперболічного тангенса) тим, що створює більш хаотичну і нелінійну динаміку, що є важливим для моделювання складних біологічних систем, таких як мозкова активність (рис. 9-10).

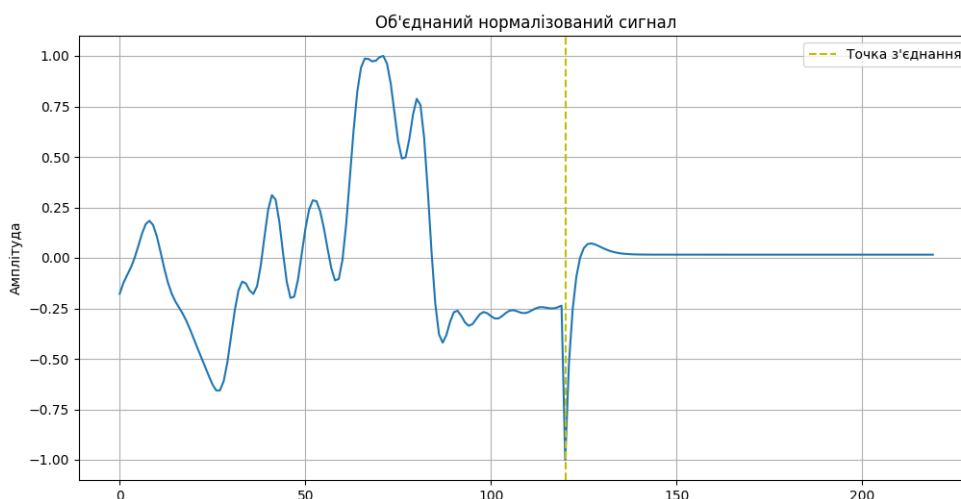


Рисунок 9 – Використання гіперболічного тангенса для прогнозування даних






Рисунок 10 – Використання гаусівського шуму з синусоїдним доданком для прогнозування даних

З отриманих результатів можемо зробити висновок, що запропонований підхід дозволив моделі краще відображати складні нелінійні залежності в ЕЕГ-сигналах та підвищило її здатність моделювати хаотичні процеси, що відкриває поле пошуку та потенціал для можливості виявлення аномалій мозку, таких як епілептичні напади або ознаки нейродегенеративних захворювань.

Подальші дослідження можуть включати оптимізацію гіперпараметрів моделі для різних типів ЕЕГ-даних, порівняння з іншими методами виявлення аномалій, інтеграцію з методами попередньої обробки сигналів, а також розширення моделі для аналізу багатоканальних ЕЕГ.

**Висновки.** 1. Було розглянуто алгоритм попередньої обробки ЕЕГ сигналів з фільтрацією, видалення артефактів, сегментацією та введенням спектрального аналізу. Використання спеціалізованих бібліотек, методу незалежних компонент (ІСА) для видалення артефактів очей, амплітудного порогу для виявлення інших артефактів, та методу Велча для обчислення спектральної щільності потужності забезпечує ефективну та надійну обробку даних для подальшої автоматизації клінічної практики. Алгоритм демонструє здатність виявляти відмінності між пацієнтами з різним станом здоров'я мозку, що підтверджується візуалізацією результатів, і має потенціал для подальшого вдосконалення шляхом впровадження методів машинного навчання.

2. Також, було описано застосування математичного моделювання, зосереджуючись на пошуку нелінійних зв'язків між сигналами за допомогою хаотичної динаміки. Представлений підхід використовує комплекс взаємодоповнюючих моделей, включаючи авторегресійну модель, приховану марковську модель, моделі Лоренца, Рьослера, Ван дер Поля, ФітцХью-Нагумо та інші. Кожна модель надає можливість синтезувати параметри динаміки ЕЕГ сигналів, дозволяючи виявляти різні аспекти мозкової активності. Результати моделювання візуалізуються та порівнюються для двох пацієнтів, включаючи часові ряди та фазові портрети. Оцінка ефективності моделей здійснюється за допомогою середньоквадратичної помилки (MSE). Представлені значення MSE для

різних моделей дозволяють порівняти їх точність у відтворенні експериментальних даних для обох пацієнтів, що має важливе значення для діагностики та лікування неврологічних розладів. Для описаних даних найнижчі показники похибки має авторегресійна модель, яка найточніше передбачає поведінку даних, що стверджує відповідна візуалізація.

3. В останньому розділі було представлено підхід для прогнозування ЕЕГ даних, використовуючи модифіковану архітектуру LSTM. Ключовими особливостями є застосування попередніх процедур для визначення параметрів моделі, ініціалізація вхідних ваг на основі попереднього моделювання сигналу та впровадження нестандартної активаційної функції, що поєднує синусоїдальну компоненту з гаусівським шумом. Ця модифікована архітектура демонструє підвищену здатність моделювати складні нелінійні залежності в ЕЕГ-сигналах, відкриваючи нові можливості для виявлення аномалій мозкової активності. Подальші перспективи включають оптимізацію гіперпараметрів, порівняння з іншими методами та розширення моделі для аналізу багатоканальних ЕЕГ, що потенційно може значно вплинути на діагностику та дослідження неврологічних розладів.

#### ЛІТЕРАТУРА

1. Rupak Kumar Das., Dale Dowling., Arshia Khan. (2023). A Survey on EEG Data Analysis Software. *Sci*, 5(2):23-23. doi: 10.3390/sci5020023
2. Vicchietti ML, Ramos FM, Betting LE, Campanharo ASLO. Computational methods of EEG signals analysis for Alzheimer's disease classification. *Sci Rep*. 2023 May 20;13(1):8184. doi: 10.1038/s41598-023-32664-8
3. Giovanni Chiarion., Laura Sparacino., Yuri Antonacci., Luca Faes., Luca Mesin. (2023). Connectivity Analysis in EEG Data: A Tutorial Review of the State of the Art and Emerging Trends. *Bioengineering*, doi: 10.3390/bioengineering10030372
4. Seonjoo Lee, Haipeng Shen, Young K. Truong. Nonparametric Independent Component Analysis for the Sources with Mixed Spectra. doi: 10.48550/arxiv.2212.06327
5. Zhong-Ke Gao., Yanli Li., Yu-Xuan Yang., Na Dong., Xiong Yang., Celso Grebogi. (2020). A Coincidence-Filtering-Based Approach for CNNs in EEG-Based Recognition. *IEEE Transactions on Industrial Informatics*, doi: 10.1109/TII.2019.2955447
6. Maliheh Miri., Vahid Abootalebi., Hamid Saeedi-Sourck., Dimitri, Van De Ville., Hamid Behjat. (2023). Spectral Representation of EEG Data using Learned Graphs with Application to Motor Imagery Decoding. *bioRxiv*, doi: 10.1101/2022.08.13.503836
7. Marius Georgescu., Laura Haidar., Alina-Florina Serb., Daniela Puscasiu., D. Georgescu. (2021). Mathematical Modeling of Brain Activity under Specific Auditory Stimulation.. *Computational and Mathematical Methods in Medicine*, doi: 10.1155/2021/6676681
8. Martine, Canada., Ness. Einevoll., Fellin. Panzeri. (2020). Computation of the electroencephalogram (EEG) from network models of point neurons. *bioRxiv*, doi: 10.1101/2020.11.02.364802

9. Raden Aurelius, Andhika. Viadinugroho., Rosadi. Dedi. (2021). Long Short-Term Memory Neural Network Model for Time Series Forecasting: Case Study of Forecasting IHSG during Covid-19 Outbreak. doi: 10.1088/1742-6596/1863/1/012016
10. О.А. Інкін, О.В. Погорєлов. (2024). Моделювання ЕЕГ за допомогою глибоких нейронних мереж. doi:10.34185/1562-9945-3-152-2024-06
11. Belozyorov V. Y., Inkin O. A. (2023). Systems of singular differential equations as the basis for neural network modeling of chaotic processes. Journal of Optimization, Differential Equations and Their Applications, 31(2), 24. <https://doi.org/10.15421/142309>

#### REFERENCES

1. Rupak Kumar Das., Dale Dowling., Arshia Khan. (2023). A Survey on EEG Data Analysis Software. Sci, 5(2):23-23. doi: 10.3390/sci5020023
2. Vicchiatti ML, Ramos FM, Betting LE, Campanharo ASLO. Computational methods of EEG signals analysis for Alzheimer's disease classification. Sci Rep. 2023 May 20;13(1):8184. doi: 10.1038/s41598-023-32664-8
3. Giovanni Chiarion., Laura Sparacino., Yuri Antonacci., Luca Faes., Luca Mesin. (2023). Connectivity Analysis in EEG Data: A Tutorial Review of the State of the Art and Emerging Trends. Bioengineering, doi: 10.3390/bioengineering10030372
4. Seonjoo Lee, Haipeng Shen, Young K. Truong. Nonparametric Independent Component Analysis for the Sources with Mixed Spectra. doi: 10.48550/arxiv.2212.06327
5. Zhong-Ke Gao., Yanli Li., Yu-Xuan Yang., Na Dong., Xiong Yang., Celso Grebogi. (2020). A Coincidence-Filtering-Based Approach for CNNs in EEG-Based Recognition. IEEE Transactions on Industrial Informatics, doi: 10.1109/TII.2019.2955447
6. Maliheh Miri., Vahid Abootalebi., Hamid Saeedi-Sourck., Dimitri, Van De Ville., Hamid Behjat. (2023). Spectral Representation of EEG Data using Learned Graphs with Application to Motor Imagery Decoding. bioRxiv, doi: 10.1101/2022.08.13.503836
7. Marius Georgescu., Laura Haidar., Alina-Florina Serb., Daniela Puscasiu., D. Georgescu. (2021). Mathematical Modeling of Brain Activity under Specific Auditory Stimulation.. Computational and Mathematical Methods in Medicine, doi: 10.1155/2021/6676681
8. Martine, Canada., Ness. Einevoll., Fellin. Panzeri. (2020). Computation of the electroencephalogram (EEG) from network models of point neurons. bioRxiv, doi: 10.1101/2020.11.02.364802
9. Raden Aurelius, Andhika. Viadinugroho., Rosadi. Dedi. (2021). Long Short-Term Memory Neural Network Model for Time Series Forecasting: Case Study of Forecasting IHSG during Covid-19 Outbreak. doi: 10.1088/1742-6596/1863/1/012016
10. Inkin O.A., Pogorelov O.V. (2024). EEG modeling using deep neural networks. doi:10.34185/1562-9945-3-152-2024-06
11. Belozyorov V. Y., Inkin O. A. (2023). Systems of singular differential equations as the basis for neural network modeling of chaotic processes. Journal of Optimization, Differential Equations and Their Applications, 31(2), 24. <https://doi.org/10.15421/142309>

Received 17.09.2024.  
Accepted 21.09.2024.

***Integrated neuronetwork modeling of EEG for diagnostic disorders of brain activity***

*The article discusses the structured multistage modeling of EEG by means of applied mathematics to customize the input parameter space for neural network prediction. Also, the approaches and models are analyzed for their accuracy in determining the relevant signal features and adaptability to real data.*

*The activity of potentials during brain activity is a biological process that depends on many factors and hides a space of parameters, the search for which and their definition can open us up to a new perspective on the nature and activity of the human brain. A rational way of obtaining data on brain activity is a non-invasive electroencephalogram, which registers the potential difference on the electrodes relative to the base. For further processing of the received data, it is necessary to remove noise and artifacts from them. In this work, a standard algorithm of frequency filtering and filtering from noise caused by the power grid is used. After processing the data, an overview of mathematical models is offered, which with a certain degree of accuracy try to simulate the behavior of the signal or the peak moments of certain features. Added to this is the use of the LSTM model to predict the further behavior of the signal with the preliminary introduction of chaos into the model due to the modified activation function (Gaussian noise) and the input modeling of the weights.*

*Keywords: neural network, electroencephalography, time series, prediction, activation function, chaotic dynamics.*

**Білозьоров Василь Євгенович** - доктор фізико-математичних наук, професор кафедри комп'ютерних технологій Дніпровського національного університету імені Олеся Гончара.

**Інкін Олександр Андрійович** – аспірант, кафедри комп'ютерних технологій Дніпровського національного університету імені Олеся Гончара.

**Belozyorov Vasily** - Doctor of Physical and Mathematical Sciences, Professor, Department of computer Technologies, Oles Honchar Dnipro National University.

**Inkin Oleksandr** – postgraduate student, department of computer technologies, Oles Honchar Dnipro National University.