

МОДЕЛЮВАННЯ ЕЕГ ЗА ДОПОМОГОЮ ГЛИБОКИХ НЕЙРОННИХ МЕРЕЖ

Анотація. У статті розглядається питання використання деяких моделей нейромереж для моделювання електроенцефалографічного сигналу. Для отримання та обробки чи сельних значень ЕЕГ пропонується використовувати мову Julia та розроблений на основі неї пакет Flux. Наведені обраховані показники втрат дозволили визначити найбільш оптимальний підхід для моделювання як епілептичних, так і неепілептичних типів ЕЕГ.

Ключові слова: нейромережа, електроенцефалографія, часовий ряд, рекурентний слой, функція втрат, LSTM, DARNN, LSTnet, TPA, Julia, EDF, Flux.

Постановка проблеми. З плином часу населення старіє, що вимагає більшої уваги до медичного догляду, вдосконалення та автоматизації рутинних методів ведення медичних справ. Одночасно з цим спостерігається постійне удосконалення технологій, зокрема в галузі медичної інтенсивної терапії та нейрокритичної допомоги. Застосування методів моніторингу ЕЕГ (електроенцефалографії) стає все більш важливим у лікуванні важких захворювань. Лікарям-неврологам та реаніматологам необхідно використовувати об'єктивний моніторинг мозкової активності, щоб швидко та ефективно робити висновки щодо стану пацієнта і планувати подальше лікування.

Проте, цей процес часто вимагає значних зусиль та може бути вирішальним для пацієнта. Відсутність або недостатня інформація про зміни в мозковій активності може призвести до серйозних наслідків. У зв'язку з цим виникає необхідність в розвитку нових методів аналізу даних, які дозволяють виявляти складні взаємозв'язки у великих обсягах інформації.

В цьому контексті виникає ідея використання нейромереж для аналізу електроенцефалографічних сигналів. Вони можуть ефективно обробляти великі обсяги даних і покращити точність та швидкість аналізу мозкової активності, що є критичним у неврологічних та реанімаційних відділеннях. На основі цього дослідження було розроблено програмне забезпечення, яке дозволяє моделювати ЕЕГ та може слугувати частиною автоматизованого аналізу сигналів пацієнта та покращити швидкість прийняття рішень щодо лікування пацієнтів.

Мета дослідження. Визначити та запропонувати незалежний, оптимальний нейромережовий підхід, який дозволить проаналізувати часовий ряд отриманий в ході зняття показників ЕЕГ та звернути увагу на наявні проблеми в реалізації моделювання подібних процесів.

Огляд проблеми та її аналіз. Однією з основних проблем є необхідність швидкого та точного визначення стану пацієнта на основі ЕЕГ-сигналів у ситуаціях, коли кожна секунда має вирішальне значення. Традиційні методи аналізу ЕЕГ, які ґрунтуються на візуальному спостереженні та експертній оцінці, часто не забезпечують необхідного рівня швидкості та точності, особливо в умовах неврологічної екстреної допомоги. Ще однією проблемою є складність інтерпретації ЕЕГ-сигналів через їхню високу залежність від індивідуальних особливостей пацієнта та специфічних умов вимірювання. В зв'язку з цим, дану проблему можна інтерпретувати мовою динаміки, як проблема виникнення хаосу.

Хаос виникає через експоненціальну чутливість системи до початкових умов, при чому точне передбачення хаотичної просторово-часової поведінки є складним, в більшості випадках, неможливим процесом. Оскільки чисельні обчислення можуть бути обчислювально дорогими, а вимірювання датчиків часто обмежені, забезпечуючи лише часткове спостереження динамічної поведінки. Ці часткові спостереження можуть призвести до неправильного уявлення неспостережуваних (прихованих) змінних або інших довгострокових фізичних властивостей, що ще більше ускладнює моделювання та прогнозування систем.

Передбачуваність і стабільність хаотичної системи характеризуються її дотичним простором, який можна охарактеризувати за допомогою показників Ляпунова, які вимірюють експоненціальну швидкість поділу траєкторій. Геометрична характеристика забезпечується коваріантними векторами Ляпунова, які становлять коваріантний базис дотичного простору та вказують на напрямки асимптотичного розширення та звуження динамічної системи, що моделюється. Збереження цих властивостей стабільності має вирішальне значення при створенні сурогатних моделей від обмежених спостережень до більш повного набору даних.

Нейронні мережі — це виразні нелінійні представлення безперервних функцій, які можуть витягувати закономірності з даних і, після навчання, надавати обчислювально дешеві прогнози.

У зв'язку з цим, використання програмних засобів моделювання ЕЕГ з використанням нейронних мереж є актуальним напрямком досліджень. Це доз-

волиять автоматизувати процес аналізу ЕЕГ сигналів, знижуючи тим самим час, необхідний для отримання результатів, та забезпечуючи більш точні та об'єктивні висновки. Нейронні мережі мають потенціал для виявлення складних зв'язків у динаміці мозкової активності та прогнозування можливих патологічних станів. Їхнє використання може значно полегшити роботу клініцистів та покращити якість наданої медичної допомоги в галузі неврології та реанімації.

Для проведення досліджень та аналізу роботи програмного забезпечення було використано показники ЕЕГ з бази даних Національного центр штучного інтелекту в Ісламбаді [1].

У роботі використовувалося програмне забезпечення Visual Studio Code, розробка і реалізація виконувалась на мові математичних розрахунків Julia з використанням бібліотек Flux, ChaosTools, PyMNE під ОС Windows.

Опис наданих даних ЕЕГ. Для дослідження часових рядів ЕЕГ за допомогою нейромереж була використана унікальна база реальних даних. Вона включала інформацію 2 пацієнтів:

Пацієнт 1. 12 років, аномальний стан, ЕЕГ знято - 10.04.2021, 22:50:49.

Пацієнт 2. 23 роки, нормальний стан, ЕЕГ знято - 10.04.2021, 15:57:16.

Форматування та обробки даних. Електроенцефалографія (ЕЕГ) — це метод, який вимірює просторовий розподіл полів напруги на шкірі голови та їх зміну з часом. Вважається, що причиною цієї активності є флуктуаційна сума збуджувальних і гальмівних постсинаптичних потенціалів. Ці потенціали виникають в основному з апікальних дендритів пірамідних клітин у зовнішньому (поверхневому) шарі кори головного мозку та модифікуються вхідними даними від підкоркових структур, зокрема таламуса та висхідних проєкцій висхідної ретикулярної системи активації. Структури в таламусі служать «кардіостимулятором». Це забезпечує поширену синхронізацію та ритмічність коркової активності в півкулях головного мозку. Дендритні генератори орієнтовані вертикально і мають два полюси, один відносно негативний, а інший відносно позитивний, які називаються диполем. Диполі - це джерела електричного струму, що складаються з двох зарядів протилежної полярності, розділених відносно невеликими відстанями. Оскільки церебральні потенціали виробляються дендритними генераторами, радіально орієнтованими на поверхню, скальповий електрод зазвичай виявляє лише один кінець генератора в один момент часу. Загалом приблизно 10 см² кори має розряджатися синхронно, щоб сигнал цінювався на ЕЕГ шкіри голови.

Більшість апаратних засобів запису ЕЕГ дозволяють експортувати дані у European Data Format (EDF) для подальшого аналізу. Європейський формат даних — це простий і гнучкий формат для обміну та зберігання багатоканальних біологічних і фізичних сигналів [3].

Для подальшої роботи з отриманим форматом даних на програмному рівні було розроблено алгоритм читання необхідних даних з урахуванням фільтрів та класифікації даних по відповідним каналам. Дана задача вирішена з використанням комбінації Julia бібліотек EDF та OndaEDF. Перша бібліотека дозволяє отримати безпосередній доступ до даних та декодувати їх в обраному форматі. Друга бібліотека дозволяє створити структур з отриманих даних та виділити лише канали з певних електродів. Також, за допомогою бібліотеки РумNE було візуалізовано отримані дані з накладанням відповідних фільтрів (рис. 1).




Рисунок 1 - Канали FP1, FP2, F3, F4 обох пацієнтів;
зліва – аномальний стан; справа – нормальний стан

Ідентифікація та побудова нейромережевих моделей. Мережа довготривалої короткочасної пам'яті, або LSTM, є різновидом рекурентної нейронної мережі. Повторювані нейронні мережі, або скорочено RNN, є особливим типом нейронних мереж, призначених для вирішення проблем числових послідовностей. Враховуючи стандартну мережу прямого зв'язку, RNN відрізняється додаванням петель до архітектури. Наприклад, у певному шарі кожен нейрон може передавати свій сигнал пізніше (вбік) на додаток до наступного шару. Періодичні підключення додають стан або пам'ять мережі та

дозволяють їй навчатися та використовувати впорядкований характер спостережень у вхідних послідовностях. Додавання послідовності є новим виміром для апроксимованої функції. Замість того, щоб відображати входи лише на виходи, мережа здатна вивчати функцію відображення для входів. Внутрішня пам'ять може означати, що виходи залежать від останнього контексту в послідовності введення, а не від того, що щойно було представлено як вхідні дані для мережі. У певному сенсі ця можливість дає змогу нейронним мережам моделювати часові ряди.

Для різного роду задач використовують певним чином змінену структуру LSTM моделі. В цій роботі розглянуто та використано наступні три інтерпретації:

1. Dual-Stage Attention-Based Recurrent Neural Network (DARNN) – двоступенева мережа з блоком уваги. Починаючи зі структури кодера-декодера, ця модель складається з двох блоків, один називається механізмом уваги введення, інший - механізмом тимчасової уваги [4]. Механізм введення уваги передає вхідні дані в мережу LSTM. У подальших обчисленнях використовується лише його прихований стан, де додаткові мережеві рівні намагаються оцінити важливість різних прихованих змінних. Механізм тимчасової уваги приймає прихований стан мережі кодера та поєднує його з прихованим станом іншого декодера LSTM. Додаткові мережеві рівні знову намагаються оцінити важливість прихованих змінних кодера та декодера разом. Лінійні шари об'єднують результати різних шарів у кінцевий прогноз часового ряду (рис. 2-3).




Рисунок 2 – Механізм уваги

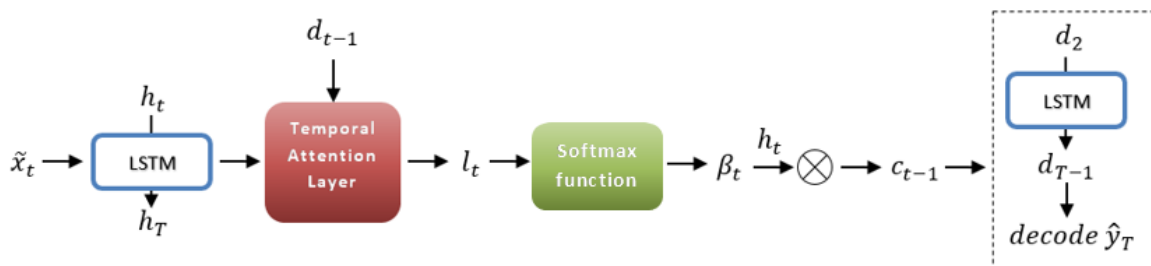


Рисунок 3 – Тимчасовий механізм уваги

2. Long- and Short-term Time-series network (LSTnet) [5]. LSTNet використовує нейронну згорткову мережу (CNN) і рекуррентну нейронну мережу (RNN) для вилучення короткострокових локальних функцій залежності між змінними та виявлення довгострокових функцій для тенденції часового ряду (рис. 4).

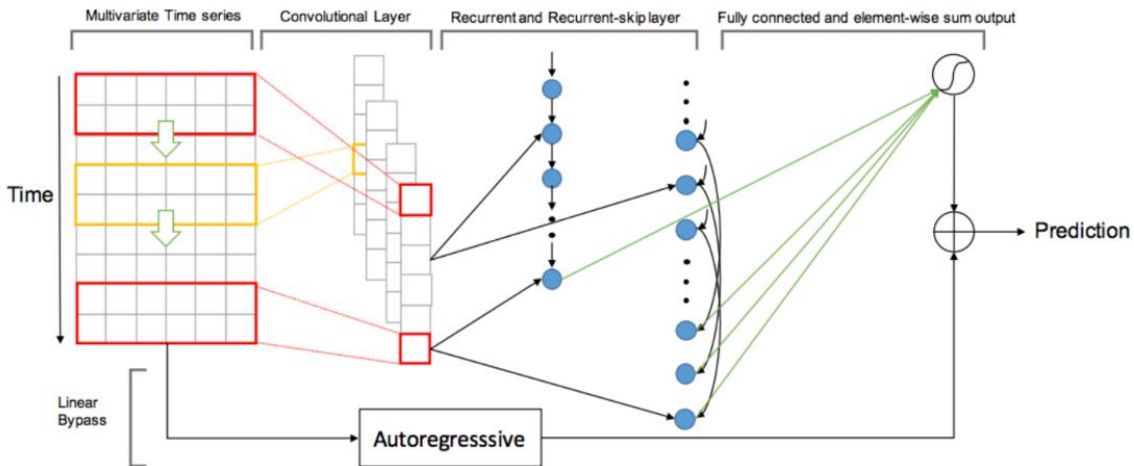


Рисунок 4 – Структура LSTnet моделі

3. Temporal Pattern Attention LSTM (TPA-LSTM) [6]. Має кращу продуктивність, ніж LSTnet, з додатковою перевагою в тому, що механізм уваги автоматично намагається визначити важливі частини часового ряду, замість того, щоб вводити параметри, які повинні бути оптимізовані користувачем (рис. 5).

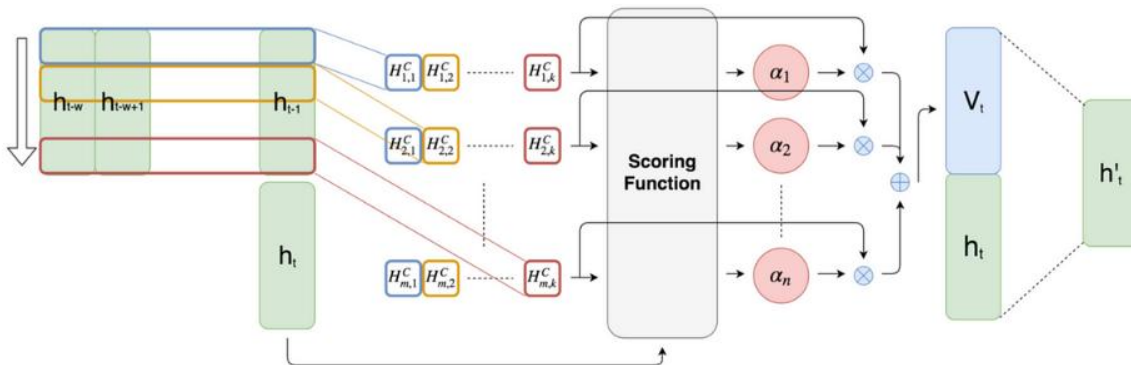


Рисунок 5 – Структура TPA-LSTM

Реалізація нейромереж та їх прогнозування. Кожна ітерація навчання нейромереж передбачає додавання вузла прихованого рівня j із вхідним вектором ваги $W(j)$, рівним вхідному вектору - екземпляру навчання, що

мінімізує помилку. Навчання припиняється, коли виконується будь-яка з двох умов:

1) стохастичне стаціонарне вбудовування знижується до граничного значення конвергенції, визначеного чисельним експериментом, щоб збалансувати помилку навчання та тестування та уникнути перетренованості;

2) кількість вузлів стає рівною кількості екземплярів навчання. Для даних ЕЕГ, використаних у цьому дослідженні, було отримано граничне значення конвергенції 0,001.

Продемонструємо роботу кожної із запропонованих у цій роботі моделі на даних обох пацієнтів з однаковими початковими параметрами та наведемо порівняльну характеристику.

Для DARNN моделі використовується мініпакетний стохастичний градієнтний спуск разом з оптимізатором Adam для навчання моделі. Розмір міні-пакета становить 128 (рис. 6-7). Швидкість навчання починається з 0,001 і зменшується на 10% після кожних 10 000 ітерацій. Дана модель є гладкою та диференційованою, тому параметри можна дізнатися за допомогою стандартного зворотного розповсюдження із середньоквадратичною помилкою як цільовою функцією. У DARNN є три параметри, кількість часових кроків у вікні (poollength), розмір прихованих станів для кодера (encodersize) і розмір прихованих станів для декодера (decodersize). Для найкращої продуктивності poollength = 10, encodersize = decodersize = 16.

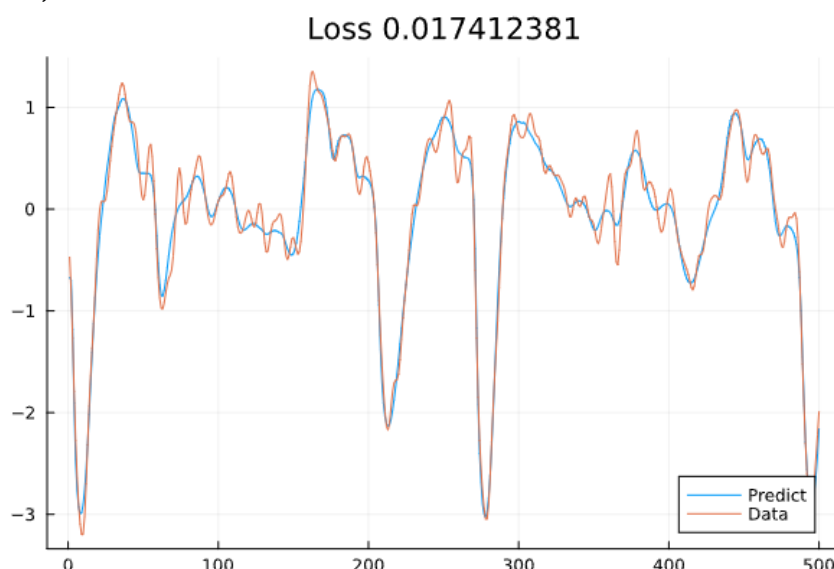


Рисунок 6 - DARNN модель для аномального ЕЕГ

Loss 0.021080276




Рисунок 7 - DARNN модель для нормального ЕЕГ

Для LSTnet мережі необхідно обрати розмір прихованого згорткового шару (convlayer) та рекурентного (reclayer) для досягнення максимальної продуктивності моделі (рис. 8-9). З проведених досліджень було виведено найбільш ефективні значення даних параметрів convlayer = 50, reclayer = 100 для відповідного значення рівня рекурентного пропуску (recurrent-skip = 24).

Loss 0.5298965




Рисунок 8 - LSTnet модель для аномального ЕЕГ

Loss 0.25573552




Рисунок 9 - LSTnet модель для нормального ЕЕГ

Для ТРА моделі було проведено пошук по сітці оптимальних параметрів і обрано розмір вікна рівний 24, діапазон для кількості прихованих одиниць – 30, діапазон кроку експоненціального зниження швидкості навчання обрано за 500 (рис. 10-11).

Loss 0.018966436



Рисунок 10 - ТРА-LSTM модель для аномального ЕЕГ

Loss 0.037689354



Рисунок 11 - TPA-LSTM модель для нормального ЕЕГ

Порівняльну характеристику результатів моделювання та навчання використаних нейромереж відносно їх показників функції можна побачити в підсумковій таблиці 1.

Таблиця 1

| Model | Loss function | | Time |
|----------|---------------|----------|--------------------------------|
| | normal | abnormal | |
| DARNN | 0,02108 | 0,01741 | $\approx 1,4 \frac{sec}{step}$ |
| LSTnet | 0,2557 | 0,5299 | $\approx 0,9 \frac{sec}{step}$ |
| TPA-LSTM | 0,03769 | 0,01897 | $\approx 18 \frac{sec}{step}$ |

Можно відмітити, що використання DARNN та TPA моделей мають найменше значення помилки та відхилення від заданого часового ряду даних та майже не залежить від стану пацієнта. Однак, якщо порівняти часовий простір, то TPA прогнозування набагато програє всім іншим представленим моделям. Тому, оптимально використовувати сам DARNN підхід для моделювання даних ЕЕГ та подальшого прогнозування.

Висновки. 1. У роботі наведено нейромережеві моделі, які було використано для моделювання ЕЕГ-сигналу з визначенням оптимальних параметрів та їх порівняльної характеристики.

2. Аналіз отриманої інформації дозволив визначити оптимальний підхід для подальшого моделювання та прогнозування складних хаотичних часових рядів.

3. Відмінність між типами ЕЕГ, нормальним станом та аномальним, не має особливого значення при моделюванні використовуючи DARNN підхід та потребує додаткового дослідження для виділення відповідних ознак.

ЛІТЕРАТУРА

1. National Center of Artificial Intelligence, NUST, Islamabad. [Online] Available: <https://dll.seecs.nust.edu.pk>.
2. Lawrence J. Hirsch, Richard P. Brenner, Atlas of EEG in Critical Care// Wiley–Blackwell, New York, 2010. ISBN: 978-0-470-98786-5
3. Kemp, B., Värri, A., Rosa, A. C., Nielsen, K. D., & Gade, J. (1992). A simple format for exchange of digitized polygraphic recordings. *Electroencephalography and Clinical Neurophysiology*, 82(5), 391–393. [https://doi.org/10.1016/0013-4694\(92\)90009-7](https://doi.org/10.1016/0013-4694(92)90009-7)
4. Yao Qin, Dongjin Song, Haifeng Chen, Wei Cheng, Guofei Jiang, and Garrison Cottrell. 2017. A dual-stage attention-based recurrent neural network for time series prediction. *arXiv preprint arXiv:1704.02971(2017)*.
5. Lai, G., Chang, W.-C., Yang, Y., & Liu, H. (2018). Modeling long- and short-term temporal patterns with deep neural networks. The 41st International ACM SIGIR Conference on Research & Development in Information Retrieval.
6. Shih, SY., Sun, FK. & Lee, Hy. Temporal pattern attention for multivariate time series forecasting. *Mach Learn* 108, 1421–1441 (2019). <https://doi.org/10.1007/s10994-019-05815-0>
7. 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. National Center of Artificial Intelligence, NUST, Islamabad. [Online] Available: <https://dll.seecs.nust.edu.pk>.
2. Lawrence J. Hirsch, Richard P. Brenner, Atlas of EEG in Critical Care// Wiley–Blackwell, New York, 2010. ISBN: 978-0-470-98786-5
3. Kemp, B., Värri, A., Rosa, A. C., Nielsen, K. D., & Gade, J. (1992). A simple format for exchange of digitized polygraphic recordings. *Electroencephalography and Clinical Neurophysiology*, 82(5), 391–393. [https://doi.org/10.1016/0013-4694\(92\)90009-7](https://doi.org/10.1016/0013-4694(92)90009-7)
4. Yao Qin, Dongjin Song, Haifeng Chen, Wei Cheng, Guofei Jiang, and Garrison Cottrell. 2017. A dual-stage attention-based recurrent neural network for time series prediction. *arXiv preprint arXiv:1704.02971(2017)*.

5. Lai, G., Chang, W.-C., Yang, Y., & Liu, H. (2018). Modeling long- and short-term temporal patterns with deep neural networks. The 41st International ACM SIGIR Conference on Research & Development in Information Retrieval.
6. Shih, SY., Sun, FK. & Lee, Hy. Temporal pattern attention for multivariate time series forecasting. Mach Learn 108, 1421–1441 (2019). <https://doi.org/10.1007/s10994-019-05815-0>
7. 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 09.04.2024.

Accepted 12.04.2024.

EEG simulation using deep neural networks

Electroencephalography (EEG) is a method that measures the spatial distribution of voltage fields on the skin heads and their change over time. It is believed that the reason for this activity is fluctuating sum of excitatory and inhibitory postsynaptic potentials. Application of EEG monitoring methods becomes everything more important in the treatment of serious diseases. However, this process often requires considerable effort and can be crucial for the patient. In this context, the idea of using neural networks for analysis of electroencephalographic signals. They can effectively process large amounts of data and improve accuracy and speed brain activity analysis. Based on this research was developed software that allows EEG simulation and can serve as part of automated patient signal analysis and improve the speed of decision-making regarding patient treatment. For this kind of task, the prediction of EEG behavior by some varieties of neural network LSTM model was evaluated and analyzed, namely, DARNN, LSTnet, TPA.

Keywords: neural network, electroencephalography, time series, recurrent layer, loss function, LSTM, DARNN, LSTnet, TPA, Julia, EDF, Flux.

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

Погорелов Олексій Вікторович - доктор медичних наук, професор кафедри неврології Дніпровського державного медичного університету.

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

Pohorielov Oleksiy - Doctor of Medical sciences, professor of the department of neurology, Dnipro State Medical University.