

Хома Ю.В.

Національний університет «Львівська політехніка»

Микитин І.П.

Національний університет «Львівська політехніка»

Артемук С.І.

Національний університет «Львівська політехніка»

Бридінський В.А.

Національний університет «Львівська політехніка»

НЕЙРОКОМП'ЮТЕРНА СИСТЕМА КЕРУВАННЯ НА ОСНОВІ ПЛАТФОРМИ OPEN VCI ТА ГЛИБОКИХ НЕЙРОННИХ МЕРЕЖ

Інтерфейс «мозок-комп'ютер» є потужним інструментом комунікації між людиною та технічними системами. Потенційні застосування нейрокомп'ютерних інтерфейсів доволі широкі: від сфери ігор та розваг до нейроергономічного керування технічними об'єктами. Особливо важливим є розвиток мобільних роботів, керованих сигналами мозку. Такі системи можуть допомагати людям із нервово-м'язовими розладами рухатися і тим самим покращувати якість свого життя. Завдяки технологічним досягненням на цей час стали доступними прості і зручні способи відбору і реєстрації сигналів ЕЕГ. Тому ключовими завданнями створення нейрокомп'ютерної системи керування роботом є ефективно кондиціонування зареєстрованих сигналів та їх розпізнавання. У роботі описано сутність функціонування нейрокомп'ютерного інтерфейсу, а також наведено прототип власної нейрокомп'ютерної системи керування, який включає шолом із платформою Open VCI Cyton, VCI-сервер на основі персонального комп'ютера і, власне, колісний робот із бортовим комп'ютером Raspberry Pi. Передавання зареєстрованих засобами Open VCI Cyton 16-канальних ЕЕГ-записів на VCI-сервер здійснюється через протокол Bluetooth, а для комунікації між роботом та VCI-сервером застосовано стандарт WiFi. Основним завданням було створення і дослідження змоги застосувати технології глибокого навчання для класифікації відфільтрованих сигналів, що відповідають частотній смузі Alpha-хвиль енцефалограм. Представлено програмну архітектуру й алгоритм функціонування системи, а також досліджено в ролі нейрокласифікатора згорткову нейронну мережу і багатошаровий перцептрон. Фільтрування ЕЕГ-сигналів та їх класифікація виконуються на VCI-сервері. Нейрокласифікатор на основі згорткової мережі показав вищу точність, але вимагає для своєї реалізації більших обчислювальних ресурсів.

Ключові слова: ЕЕГ-сигнали, інтерфейс «мозок-комп'ютер», глибоке навчання, згорткова нейронна мережа, багатошаровий перцептрон.

Постановка проблеми. Системи взаємодії людини і машини мають мати різну структуру і призначення. Протягом останніх років увагу дослідників привертають системи, що базуються на використанні інтерфейсу «мозок-комп'ютер» (англ. Brain-Computer Interface - BCI). Основна ідея роботи таких систем полягає у відборі та опрацюванні сигналів електроенцефалограми з метою інтерпретації образів (емоцій, думок, команд тощо). Інтерфейс «мозок-комп'ютер» (інша назва – нейрокомп'ютерний інтерфейс (НКІ)) є унікальним комунікаційним каналом між людським мозком і зовнішнім світом, який, на відміну від традиційних технологій обміну

повідомленнями, має низку особливостей, переваг і обмежень [1; 2].

Системи управління на основі інтерфейсу «мозок-комп'ютер» можуть знайти і вже знаходять широке застосування від сфери ігор та розваг до нейрональної реабілітації і нейроергономічного керування технічними об'єктами [3; 4]. Ключовим аспектом у роботі НКІ є інтелектуальний аналіз енцефалограм. Для цього використовують різні алгоритми машинного навчання [5].

Аналіз останніх досліджень і публікацій. Активність головного мозку, в тому числі і розумова діяльність людини, супроводжується розкладом на поверхні голови електричних біопотенціалів.

Зйом за допомогою електродів цих біопотенціалів, їх підсилення і запис за використанням відповідного обладнання і становить сутність методу електроенцефалографії [6]. Упродовж тривалого часу цей метод застосовувався в медичній діагностиці, де лікар-діагност «розшифровував» багатоканальні ЕЕГ-записи на предмет встановлення відповідності чи відхилень енцефалограми від норми.

З розвитком інформаційних технологій ситуація докорінно змінилася. На базі алгоритмів машинного навчання створюються не лише системи підтримки прийняття рішень у медичній діагностиці, але постійно розширюється коло завдань, пов'язаних з інтелектуальним аналізом енцефалограм. Значна частина таких завдань базується на використанні інтерфейсу «мозок-комп'ютер» [1,3,7]. Створення комунікаційного інтерфейсу за допомогою сигналів мозку зіткнулося з багатьма проблемами як технічного характеру, так і спричинених зручністю використання в реальних застосуваннях (англ. usability).

Складність опрацювання ЕЕГ-сигналів зумовлена їх нестационарною природою, слабкою інтенсивністю, податливістю до дії сторонніх дестабілізуючих чинників, таких як зміни в розміщенні електродів, інтерференція інших електричних сигналів, спричинених електричною активністю серця (електрокардіограма) і скелетних м'язів (електроміограма), а також внаслідок руху очей (електроокулограма). Для зменшення впливу артефактів застосовується низка методів цифрового кондиціонування сигналів, що засновані на формальних методах частотної і просторової фільтрації, часо-частотних перетворень, статистичного і кореляційного аналізу тощо [3; 8; 9]. Деякі фірми, наприклад, Texas Instruments, випускають спеціальні апаратні модулі (Front-End) для реєстрації і кондиціонування ЕЕГ-сигналів [10; 11]. Є проблема у застосуванні формальних методів для придушення впливу артефактів, частотна смуга яких перекривається з корисними компонентами сигналів ЕЕГ. У зв'язку з цим виглядає перспективним застосування неформальних моделей машинного навчання для виявлення й усунення аномалій із біосигналів [12].

Іншим серйозним бар'єром, що стоїть перед технологією НКІ, є природна мінливість електрофізіологічних сигналів мозку [6; 13]. Психічний та емоційний стан, рівень втоми і концентрації є факторами, що породжують непередбачувані зміни і відхилення сигналів ЕЕГ, одержаних у різ-

них сесіях запису. Ці чинники маскують основну структуру ЕЕГ-сигналів, утруднюючи розрізнення і виокремлення слабких корисних компонент. Звідси потреба використання неформальних моделей опрацювання ЕЕГ-сигналів, які засновані на алгоритмах машинного навчання.

Незважаючи на те, що сама галузь машинного навчання є порівняно молодою, в останні роки в цій царині з'явився та бурхливо розвивається новітній напрям – глибинне навчання (Deep Learning). Завдяки саме технології глибинного навчання відбувся революційний прорив у питаннях комп'ютерного розпізнавання зображень, опрацювання живої мови, розшифруванні геному людини [14; 15]. Для реалізації глибинного навчання застосовують різні архітектури нейронних мереж, зокрема згорткові мережі [14; 16].

Сфера застосування технологій глибинного навчання постійно розширюється. Глибинне навчання доцільно застосовувати для розв'язання складних задач. До таких, безперечно, належить й інтелектуальний аналіз ЕЕГ-сигналів в інтерфейсі «мозок-комп'ютер».

Постановка завдання. Метою роботи є порівняльний аналіз двох варіантів реалізації інтерфейсу «мозок-комп'ютер» для керування колісним роботом на базі технологій глибинного навчання, а саме згорткової нейронної мережі і багатопарового перцептрона.

Виклад основного матеріалу дослідження.

Структура і функціонування нейрокомп'ютерного інтерфейсу. Типова структура інтерфейсу «мозок-комп'ютер» складається з п'яти структурних компонентів (рис. 1).

Блок відбору ЕЕГ-сигналів відповідає за багатоканальний зйом за допомогою електродів розкладу біопотенціалів із поверхні голови та формування «сирих» цифрових ЕЕГ-сигналів. Наступний блок виконує функцію кондиціонування сирих ЕЕГ-сигналів шляхом їх підсилення та фільтрації шуму. Блок витягування характерних ознак формує дискримінаційні характеристики (дескриптори) з релевантних ЕЕГ-сигналів, зменшуючи розмір даних, що надходять до класифікатора. Блок класифікатор, що збудований за одним із методів машинного навчання, аналізуючи вектор дескрипторів, зараховує ЕЕГ-сигнали до одного з класів. Блок трансляції формує вихідні дані, формат яких залежить від цільового призначення інтерфейсу «мозок-комп'ютер». Наприклад, це можуть бути команди управління технічним об'єктом, рух курсором чи написання букв на моніторі.

Для зйому сигналів EEG використовують спеціальні шоломи. На цей час на ринку є шоломи різних фірм, найпопулярнішими з яких є Emotiv, OpenEEG, OpenBCI, Muse, MindWave [9]. Системи відбору різняться типом і числом електродів (каналів зйому) їх розташуванням, якістю зареєстрованих EEG-сигналів. У табл. 1 подано основні технічні характеристики двох шоломів, які використовувалися в дослідженнях.

Інтенсивність EEG-сигналів більше ніж на два порядки нижча за сигнали електрокардіограми і не перевищує 100 мкВ. Це означає надзвичайно високу вразливість EEG-сигналів до дії різних дестабілізуючих факторів, які мають внутрішню біологічну природу, як рухи очей, м'язів, робота серця, а також технічне походження, насамперед, наведення силової мережі живлення, артефакти зумовлені змінами імпедансу «шкіра-електрод». Для придушення мережевої завади застосовують загороджувальні фільтри (Power-Line Notch Filter). Щоб покращити відношення сигналу до шуму, традиційно використовують різного роду смугові фільтри (Band-pass Filter), які розраховані на частотний інтервал інформативних складників EEG-сигналів. З-поміж різних хвиль мозкової активності найбільш придатними є Alpha-хвилі, зосереджені в смузі між 7 Hz та 13 Hz.

Традиційні підходи інтелектуального аналізу електрокардіограм передбачають етап витягування характеристичних ознак, за якими класифікатор може однозначно диференціювати EEG-сигнали, щоб забезпечити наступну фазу – класифікацію. Для витягування таких ознак застосовуються різні методи перетворення і трансформацій як у часовій, так і у частотній областях, наприклад авто-регресійний аналіз, канонічно-кореляційний

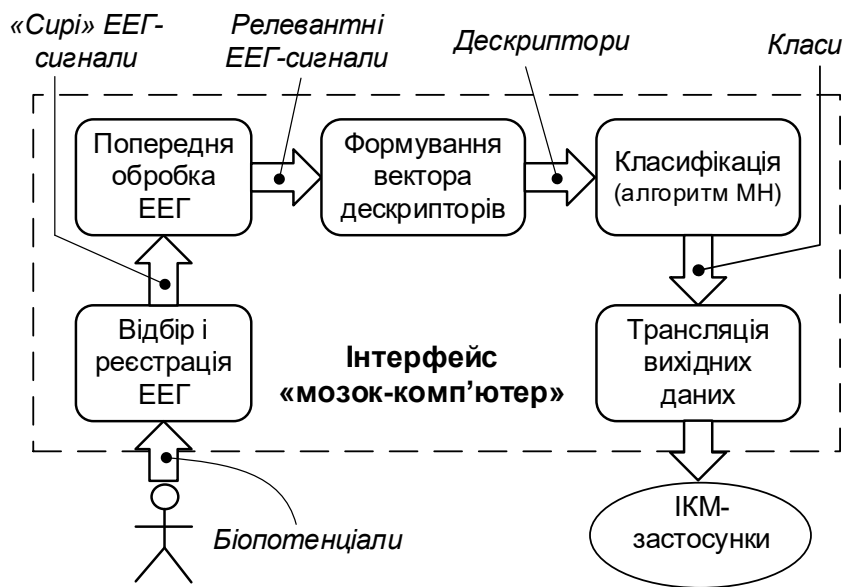


Рис. 1. Типова структура інтерфейсу «мозок-комп'ютер»

аналіз (Canonical Correlation Analysis – CCA), короткочасове перетворення Фур'є (Short-Time Fourier Transform – STFT), хвилькове перетворення, згладжувальне фільтрування (Smoothing Filter) [3; 9; 17]. Видобуті ознаки формують вектор дескрипторів, який становить вхідні дані для класифікатора, який реалізує один з алгоритмів машинного навчання.

Реалізація системи управління роботом на основі інтелектуального аналізу EEG-сигналів глибокими нейромережами. Для проведення натурального експерименту автори збудували систему, що складається з трьох окремих фізичних компонент (рис. 2):

- шолом з платформою Open BCI Cyton [18];
- персональний комп'ютер, що виконує функцію BCI-сервера;
- колісний робот, на якому встановлено плату Raspberry Pi.

Шолом зі встановленою апаратно-програмною платформою Open BCI Cyton забезпечує 16-каналний відбір енцефалограм та їх передавання Bluetooth-протоколом до персонального комп'ютера. На ПК відбувається програмне кондиціонування EEG-сигналів.

Таблиця 1

Основні технічні характеристики двох шоломів для зйому EEG-сигналів

Тип шолома	Число каналів	Розміщення електродів	Вихідні інтерфейси	Доступність програмного забезпечення
Emotiv Insight	5	Фіксоване	Bluetooth	Закрите
Open BCI Cyton	16	Еластичне	Bluetooth, Wi-Fi, UART	Відкрите

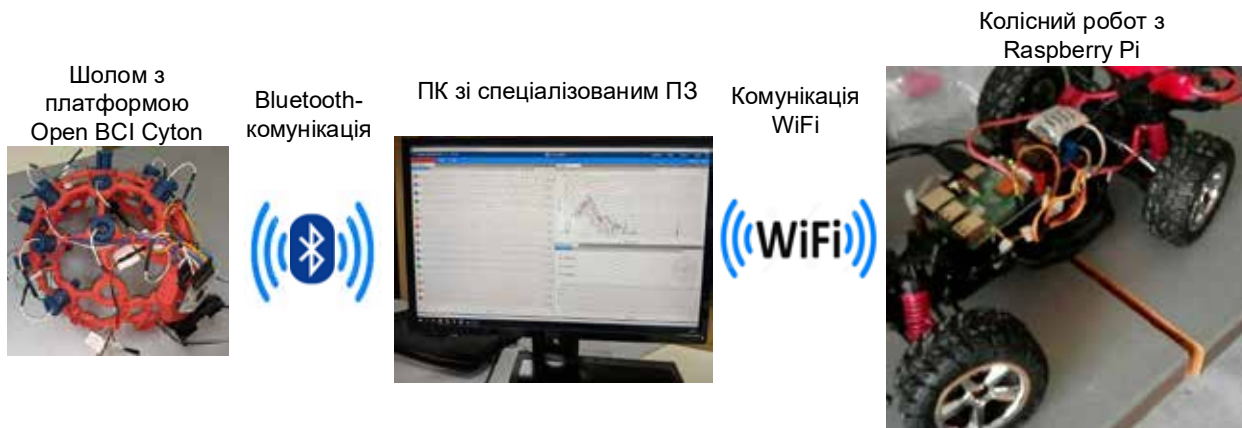


Рис. 2. Узагальнена структура системи управління колісним роботом

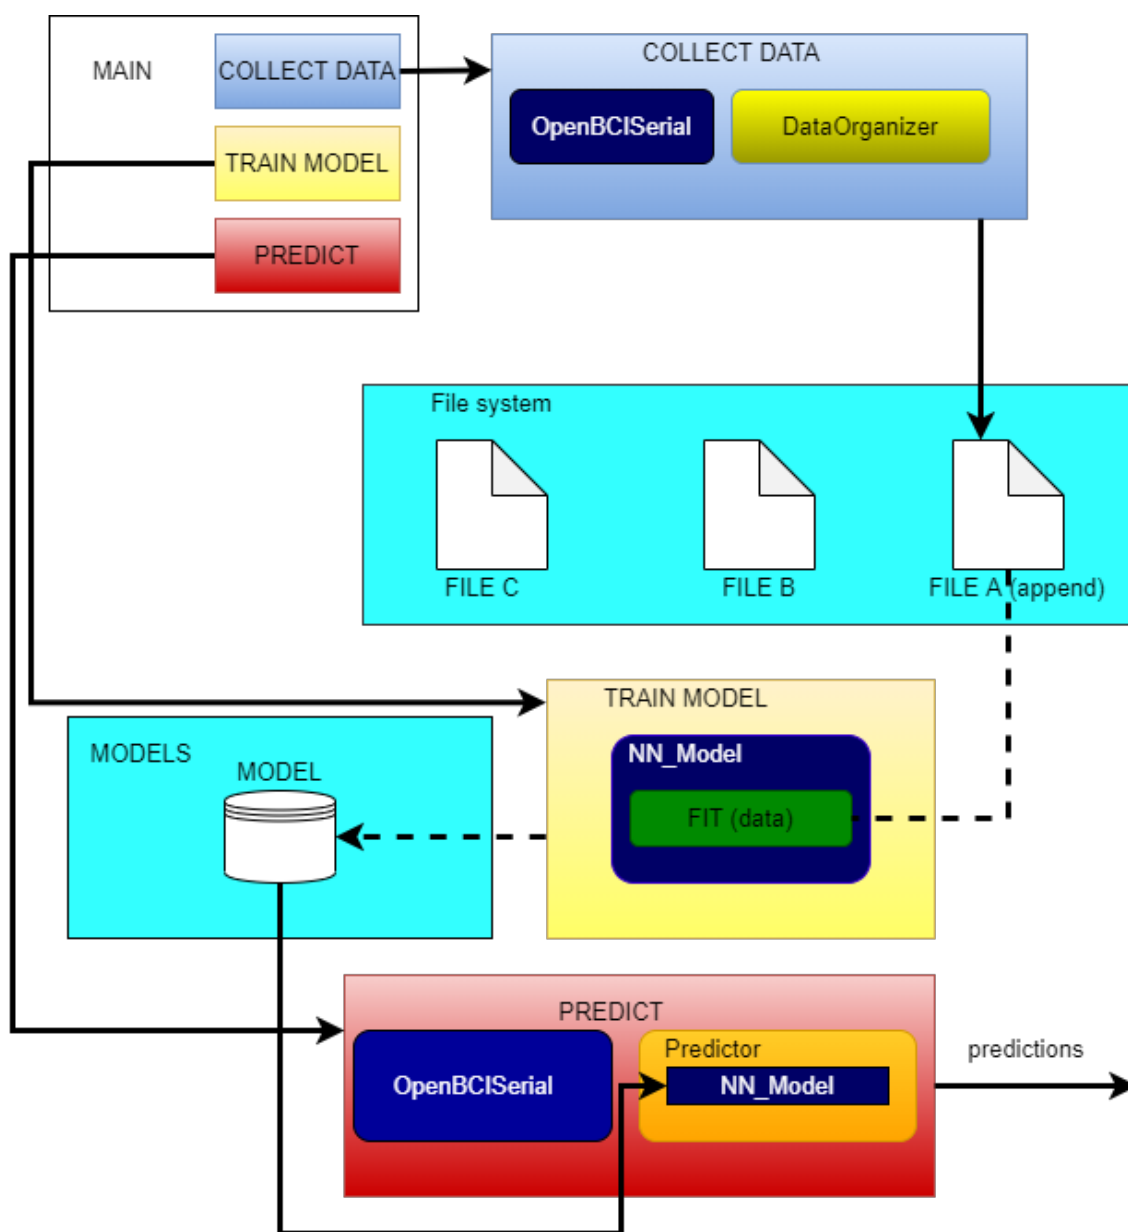


Рис. 3. Архітектура інтелектуальної системи опрацювання ЕЕГ-сигналів

Для інтелектуального аналізу ЕЕГ-сигналів автори застосували парадигму глибинного навчання, за якою на вхід класифікатора подаються не дескриптори, а відфільтровані ЕЕГ-сигнали. Для виконання досліджень нами розроблено два варіанти класифікаторів – на основі згорткової нейронної мережі і багатошарового перцептрона.

Результати класифікації із VCI-сервера за стандартом WiFi передаються на одноплатний комп'ютер Raspberry Pi, який встановлено на колісному роботі. До основних переваг Raspberry Pi варто зарахувати компактні габарити (85 × 56 × 17 mm), наявність спеціалізованої операційної системи Raspbian (написаної на базі ядра Linux), підтримка безпроводних протоколів обміну даними Wi-Fi та Bluetooth. Okремо варто зазначити наявність цифрових виводів типу GPIO, які уможливають формування сигналів управління для керування моторами, через спеціальну плату-драйвер. Таким чином, Raspberry Pi забезпечує управління колісною платформою та комунікацію з VCI-сервером.

Програмна архітектура та алгоритм функціонування системи. Авторами розроблено власний варіант інтелектуальної системи опрацювання ЕЕГ-сигналів (рис. 3), до складу якої входять три основні блоки:

- блок збору даних (COLLECT DATA);
- блок тренування моделі (TRAIN MODEL);
- блок передбачення (PREDICT).

Кожен із цих блоків відповідає за окремий режим роботи системи, який задається встановленням відповідного параметра в конфігураційному файлі перед запуском основної програми (MAIN).

У режимі *COLLECT DATA* за допомогою модулів *OpenBCISerial* та *DataOrganizer* відбувається відбір та запис на файлову систему зареєстрованих ЕЕГ-сигналів. При цьому об'єкт *OpenBCISerial* зчитує дані з шолому через протокол Bluetooth. З початком відбору даних із плати Open VCI Cyton створюється окремий потік, дані з якого записуються в буфер VCI-сервера паралельно з роботою програми. У разі заповнення буфера дані з нього переносяться в модуль *DataOrganizer*, а буфер очищається. Модуль *DataOrganizer* відповідає за зберігання отриманих із буфера пакетів даних у файли .csv та організацію файлів на диску за заданою структурою.

У режимі *TRAIN MODEL* відбувається навчання нейронних мереж за допомогою модуля *NNModel*. У цьому блоці створюється модель нейронної мережі шляхом навчання на даних, зібраних

у режимі *COLLECT DATA*. Вичитані з файлів дані агрегуються у вхідну матрицю або тензор і так подаються на вхід обчислювального графу, де відбувається ітераційний процес підбору оптимальних вагових коефіцієнтів у шарах нейронної мережі. Після завершення навчання модель нейронної мережі зберігається у два окремі файли – .json із структурою обчислювального графу і .h5 з отриманими ваговими коефіцієнтами.

У режимі *PREDICT* за допомогою модулів *OpenBCISerial*, *Predictor* та *NNModel* відбувається розпізнавання зареєстрованих ЕЕГ-сигналів за допомогою нейронної мережі, навченої в режимі *TRAIN MODEL*. Модуль *OpenBCISerial* надсилає пакетами нові оброблені ЕЕГ-дані для інтелектуального аналізу на модуль *Predictor*, де сигнали нарізаються на сегменти відповідної довжини та подаються на модуль *NNModel*, в якому, власне, і відбувається процедура класифікації. Результати класифікації з модуля *Predictor* передаються на бортовий комп'ютер колісної платформи, де на їх основі формуються відповідні команди керування.

Методика та результати експерименту. У проекті розроблено та випробувано в ролі класифікатора ЕЕГ-сигналів два типи глибоких нейронних мереж – багатошаровий перцептрон (далі – MLP) і згорткова нейронна мережа (далі – CNN). Програмну імплементацію алгоритму виконано мовою програмування Python3 із використанням спеціалізованих фреймворків для побудови глибоких нейронних мереж: *Tensorflow v1*, *Keras*, *NumPy*, *cuDNN*.

Нейронна мережа на основі багатошарового перцептрона складається з 4 блоків на основі *dense*-шарів (рис. 4а). Загальне число шарів у мережі MLP – 9, із них 4 – шари з ваговими коефіцієнтами, за рахунок яких, власне, і відбувається навчання нейромережі. Розміри зазначених шарів такі: *Dense1* – 32, *Dense2* – 64, *Dense3* – 32, *Dense4* – 5. Дані, що подаються на вхідний шар *Input* мережі MLP, мають вигляд вектора розміром 4096x1. В усіх активаційних шарах, окрім вихідного, використовувалася функція *ReLU*, а у вихідному шарі функція – *softmax*.

Навчання мережі MLP здійснювалося за таких гіперпараметрів:

- функція втрат (loss): *categorical_crossentropy*;
- алгоритм навчання (optimizer): *Adadelta*;
- число епох навчання (num_epoch): 100;
- швидкість навчання (learning_rate): 0,001;
- коефіцієнт кросс-валідації (співвідношення навчального і тестового наборів даних): 70/30.

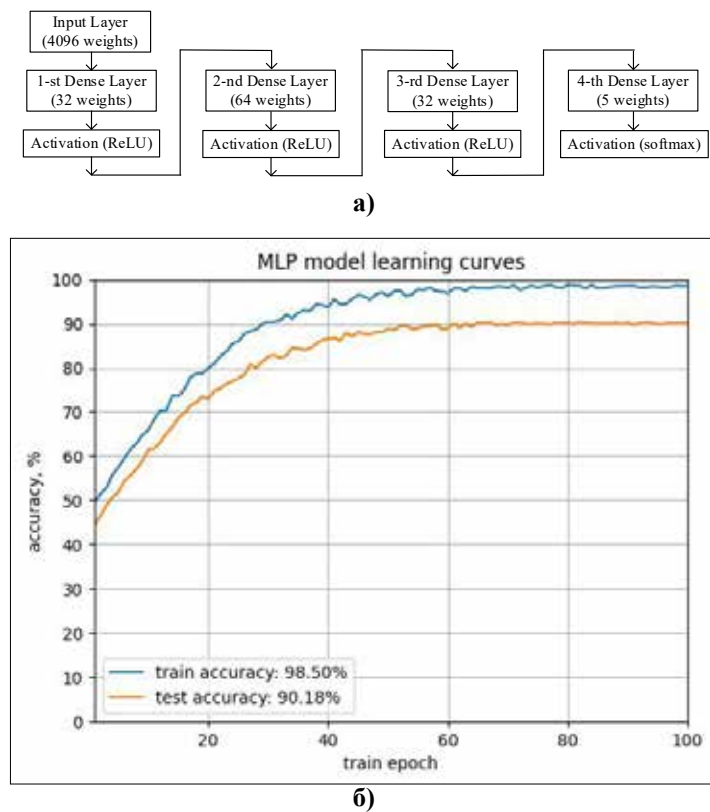


Рис. 4. Архітектура мережі MLP (а) та криві навчання (б)

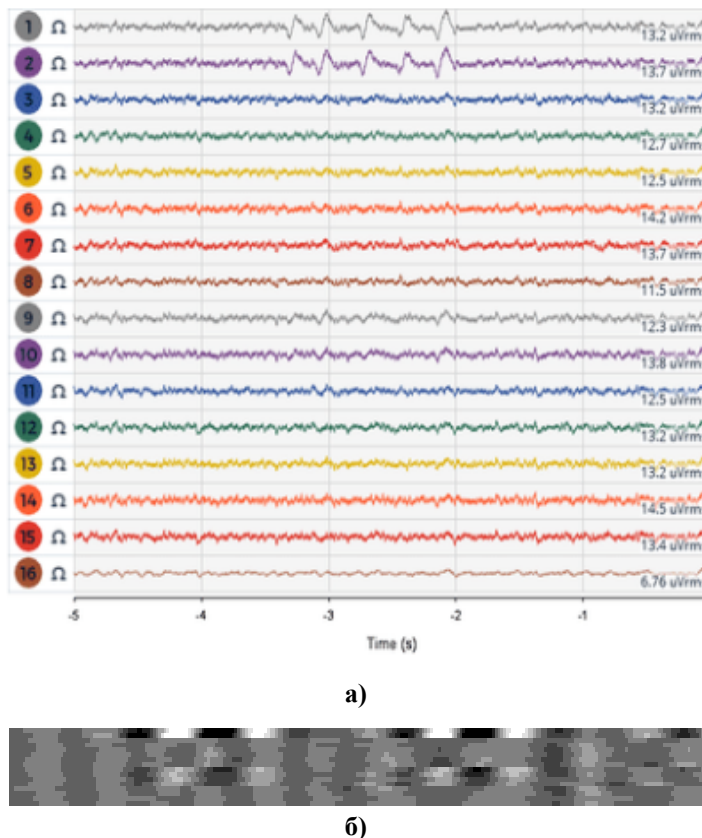


Рис. 5. Відфільтровані EEG-сигнали із 16 каналів (а) та візуалізація матриці вхідних даних (б)

Значення таких параметрів, як тип і коефіцієнт регуляризації, алгоритм ініціалізації вагових коефіцієнтів взято за замовчуванням.

Етап навчання зайняв 30 хвилин на процесорі Intel Core i7-5500 (операційна система Ubuntu 18.04 LTS, 8 ГБ оперативної пам'яті). Візуалізацію кривих навчання (learning curves) наведено на рис. 4б.

Мережа CNN складається із 3 блоків на основі згорткових шарів. У другому та третьому блоці додатково використано шари типу *dropout* та *max pooling*. Після згорткових шарів у CNN-архітектурі імплементовано два *dense*-шари. Загальне число шарів у мережі – 18, з них 5 – шари з ваговими коефіцієнтами, за рахунок яких власне і відбувається навчання CNN. В усіх активаційних шарах, крім вихідного, використовувалася функція *ReLU*, а у вихідному шарі функція – *softmax*. Зазначені шари мають такі розміри: *Conv1* – $16 \times 254 \times 32$, *Conv2* – $16 \times 252 \times 32$, *Conv3* – $16 \times 124 \times 32$, *Dense1* – 128, *Dense2* – 5.

Особливістю даних, що подаються на вхідний шар *Input* мережі CNN, є їх матричне, а не векторне представлення, у форматі $16 \times 256 \times 1$. На рис. 5а показано вигляд релевантних сигналів ЕЕГ із 16 каналів. Матрицю вхідних даних одержано шляхом нормалізації 256 вибірок зазначених 16 ЕЕГ-сигналів. На рис. 5б виконано візуалізацію матриці вхідних даних мережі CNN (як зображення у градаціях сірого).

Навчання мережі CNN здійснювалося за таких гіперпараметрів, що й мережі MLP, однак із використанням додаткового гіперпараметра – коефіцієнта *dropout*, значення якого встановлено на рівні 0,2. Навчання тривало 80 хвилин на процесорі Intel Core i7-5500 (операційна система Ubuntu 18.04 LTS, 8 Гб оперативної пам'яті). Архітектуру мережі і візуалізацію кривих навчання (learning curves) наведено на рис. 6.

Після завершення навчання оцінено точність класифікації нейромережею сигналів ЕЕГ на тестовій вибірці. Крім оцінювання точності мережі на тестовій вибірці, проведено додаткове тестування вже на реально працюючій системі – в режимі експлуатації (production). З цією метою оператор у шоломі подумки виконував команди

«вперед» (forward), «стоп» (stop), «вправо» (right), «вліво» (left), а ЕЕГ-сигнали, які відповідають цим командам, подавалися на ВСІ-сервер для розпізнавання нейронною мережею (спочатку MLP, а потім CNN). Загальне число команд, які подав оператор у режимі production, становило по 50 для кожної категорії (вперед, стоп, вправо, вліво). Підраховувалося число правильно і хибно визначених команд оператора. Результати експериментів наведено в таблиці 2.

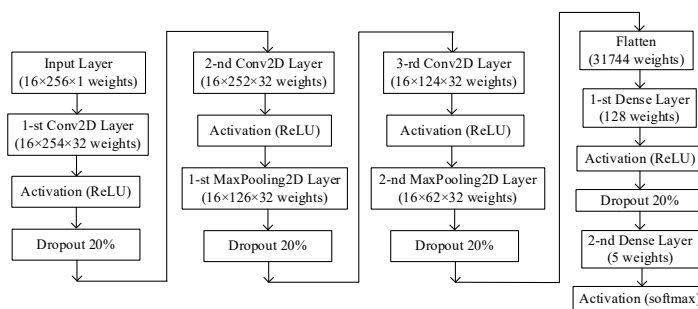
Таблиця 2

Результати тренування нейронних мереж

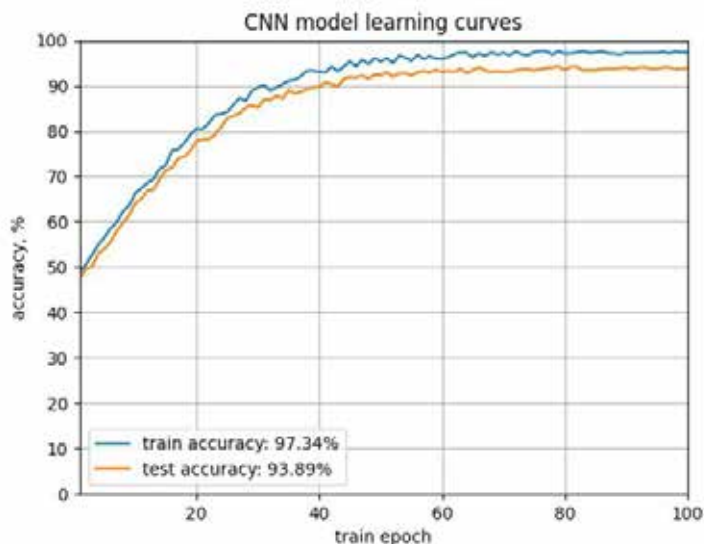
	MLP Model	CNN Model
Accuracy (Train set)	98,50 %	97,34 %
Accuracy (Test set)	90,18 %	93,89 %
Accuracy (Production)	78,5 %	86,07 %

Для глибшого аналізу поведінки нейрокомп'ютерної системи керування в режимі експлуатації (production), результати експериментів додатково відображено на рис. 7.

Результати роботи системи представлено у вигляді таблиці помилок (confusion matrix), рядки якої – це команда, яку подумки подавала людина-оператор, а стовпці – команда, яку розпізнала система. Таким чином, цифри на діагональних елементах відтворюють число коректних спрацювань, а числа поза межами діагоналі матриці, відповідно, – число хибних спрацювань. За результатами досліджень встанов-




а)



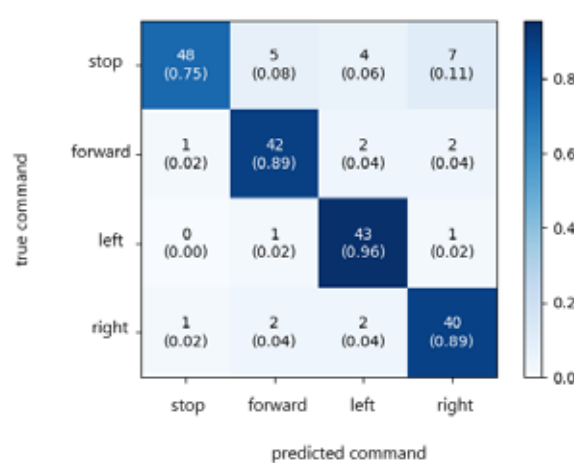
б)

Рис. 6. Архітектура мережі CNN (а) та криві навчання (б)

лено, що класифікатор ЕЕГ-сигналів на основі згорткової мережі показав кращі результати порівняно з класифікатором на багатошаровому перцептроні (точність на моделі CNN 86,07%, проти 78,5% на моделі MLP). Проте обчислювальна складність глибокої нейронної мережі



а)



б)

Рис. 7. Таблиця помилок MLP-моделі (а) та CNN-моделі (б)

CNN є істотно вищою як у режимі навчання, так і в режимі розпізнавання. Оскільки на практиці CNN-модель показала кращий результат, її використано для керування колісною платформою.

Як видно з результатів експерименту, нейрокомп'ютерна система управління демонструє доволі високу точність, враховуючи клас складності задачі. З метою подальшого підвищення точності автори вважають за доцільне застосувати технологію автоенкодерів для виявлення та коригування аномалій у відфільтрованих EEG-сигналах. Такий підхід показав свою ефективність у системах біометричної ідентифікації, що базуються на аналізі іншого виду біосигналів – електрокардіограм [XXX].

Висновки. Застосовано парадигму глибокого навчання до створення інтерфейсу «мозок-комп'ютер». Представлено прототип власної нейрокомп'ютерної системи керування, який включає такі три компоненти: шолом із платформою Open BCI Cyton, BCI-сервер на основі персо-

нального комп'ютера і колісний робот із бортовим комп'ютером Raspberry Pi. Передавання зареєстрованих засобами Open BCI Cyton 16-каналних EEG-записів на BCI-сервер здійснюється протоколом Bluetooth, а для комунікації між роботом та BCI-сервером застосовано стандарт WiFi.

Основним доробком є створення та дослідження двох варіантів реалізації нейрокласифікаторів – на основі багат шарового перцептрона та згорткової нейронної мережі. Обидва експерименти показали досить високі результати: точність декодування команд з EEG-сигналів із тестової вибірки становила 90,18% для багат шарового перцептрона і 93,89% – для згорткової мережі. Точність виконання команд керування в режимі експлуатації дещо знизилася (майже на 12% на моделі MLP і на 8% на моделі CNN). Хоча нейрокласифікатор на згортковій мережі забезпечує вищу точність, в аспекті обчислень є складнішим, а також час його навчання майже втричі триваліший.

Список літератури:

1. Hippe Z.S., Kulikowski J.L., Mroczek T., Wtorek J. Human-Computer Systems Interaction: Backgrounds and Applications. *Kacprzyk J. (eds) Advances in Intelligent Systems and Computing Vol. 300*, Springer, Switzerland, 2014.
2. Wolpaw, J.R.; Birbaumer, N.; McFarland, D.J.; Pfurtscheller, G.; Vaughan, T.M. Brain-computer interfaces for communication and control. *Clin. Neurophysiol.* 2002, 113, 767–791.
3. Abdulkader S.N., Atia A., Mostafa M-S.M. Brain computer interfacing: Applications and challenges. *Egypt. Informatics J.* Vol. 16 (2), 2015, 213–230.
4. Padmavathi, R., Ranganathan, V. A review on EEG based brain computer interface systems. *Int. J. Emerg. Technol. Adv. Eng.* 2014, 4, 683–696.
5. Kalshetti U., Goel A., Srivastava P., Ingole M., Bhide D. Human Authentication from Brain EEG Signals using Machine Learning. *Int. J. Pure and App. Math.*, 2018, Vol. 118 (24), 1–7.
6. Subha D.P., Joseph P.K., Acharya R., Lim C.M. EEG signal analysis: A survey. *J. Med. Syst.* 2010, 34, 195–212.
7. Nguyen P.T. On EEG-based Person Recognition and Human Characteristics Classification. Dr Ph. Thesis, University of Canberra, 2015, 188 p.
8. Georgieva P., Silva F., Milanova M., Kasabov N. (2014) EEG Signal Processing for Brain-Computer Interfaces. *Kasabov N. (eds) Springer Handbook of Bio-Neuroinformatics*. Springer, Berlin, Heidelberg.
9. Minguillona J., M. Lopez-Gordoc A., Pelayo F. Trends in EEG-BCI for daily-life: Requirements for artifact removal. *Biomed. Sign. Proces. & Contr.*, 2017, 31, 407–418.
10. EEG Front-End Performance Demonstration Kit. Texas Instruments. *User's Guide*. SLAU443B–May 2012–Revised January 2016.
11. Uktveris, T., Jusas, V. Development of a Modular Board for EEG Signal Acquisition. *Sensors*, 2018, 18, 2140.
12. Хома В.В., Хома Ю.В., Сабодашко Д.В., Хома П.П. Автоенкодери для опрацювання промахів сигналів ЕКГ у системі біометричної автентифікації. *Штучний інтелект*. 2019. № 1-2. С. 101–110.
13. American Electroencephalographic Society Guidelines for Standard Electrode Position Nomenclature. *Journal of Clinical Neurophysiology*. 1991. 8 (2): 200–202.
14. Seonwoo, M., Byunghan, L., Sungroh, Y. Deep learning in bioinformatics. *Briefings in Bioinformatics*, Vol. 18(5), 2017, p. 851–869.
15. Belo, B., Rodrigues, J., Vaz, J.R., Pezarat-Correia P., Gamboa, H. Biosignals learning and synthesis using deep neural networks. *BioMed Eng OnLine*, 2017, 1–17.
16. Ковальчук А.М., Марчук Г.В., Марчук Д.К. Застосування згорткової нейронної мережі для розпізнавання рукописних символів. *Вчені записки ТНУ ім. В.І. Вернадського*. 2019. Том 30 (69), ч. 1. № 4. С. 68–73.
17. Kawala-Sterniuk, A., Podpora, M., Pelc, M., Blaszczyzyn, M., Gorzelanczyk, E.J., Martinek, R., Ozana, S. Comparison of Smoothing Filters in Analysis of EEG Data for the Medical Diagnostics Purposes. *Sensors*. 2020, 20, 807.
18. Open BCI Documentation. Cyton Board. URL: <https://docs.openbci.com/docs/02Cyton/CytonLanding>.

Khoma Yu.V., Mykytyn I.P., Artemuk S.I., Brydinskyi V.A. NEUROCOMPUTER CONTROL SYSTEM BASED ON OPEN BCI PLATFORM AND DEEP NEURAL NETWORKS

The brain-computer interface is a powerful communication tool between humans and technical systems. The potential applications of neurocomputer interfaces are quite wide: from games and entertainment to neuroergonomic control of technical objects. Especially important is the development of mobile robots controlled by brain signals. Such systems can help people with neuromuscular disorders to move and thus improve their quality of life. Thanks to technological advances, simple and convenient ways of EEG signals acquisition have become available at this time. Therefore, the key task of creating a neurocomputer robot control system is the effective conditioning of the recorded signals followed by pattern recognition. The paper describes the essence of the neurocomputer interface operating process, as well as presents a prototype of the custom neurocomputer control system, which includes a helmet based Open BCI Cyton platform, BCI-server based on a personal computer and, in fact, a wheeled robot with a single-board computer Raspberry Pi. The transmission of 16-channel EEG recordings registered by Open BCI Cyton to BCI-server is carried out via Bluetooth protocol, and the WiFi standard is used for communication between the robot and BCI-server. The main task was to create and investigate the possibility of using deep learning techniques for the classification of filtered signals that represent the frequency band of Alpha waves of encephalograms. The software architecture, data flow, and operating details of system functioning are presented in the paper. Also, two alternative implementations of neuroclassifier based on a convolutional neural network and a multilayer perceptron are investigated. EEG signal filtering and their classification are performed on BCI-server. The neuroclassifier based on the convolutional network has shown higher accuracy but requires more computing resources for its implementation.

Key words: EEG signals, brain-computer interface, deep learning, convolutional neural network, multilayer perceptron.