

Розпізнавання великого депресивного розладу на основі вейвлет-когерентності електроенцефалограм

Олександр Сухолейстер¹, Адріан Наконечний²

¹Аспірант, Національний Університет «Львівська Політехніка», 79013, Львів, вул. Степана Бандери, e-mail: oleksandr.o.sukholeister@lpnu.ua

²д.т.н., професор, Національний Університет «Львівська Політехніка», 79013, Львів, вул. Степана Бандери, e-mail: adrnakon@gmail.com

В даній статті досліджується, чи покращують ознаки, отримані з вейвлет-когерентності між каналами ЕЕГ, розпізнавання великого депресивного розладу (ВДР) порівняно з базовими ознаками, сформованими на основі вейвлет-перетворення окремих каналів. Розроблено цілісний алгоритм, що включає попередню обробку сигналів, обчислення когерентності з використанням аналітичної базової функції Морле та формування похідних мережесих і міжканальних ознак. Експериментальне оцінювання проведено на наборі даних TDBRAIN із поділом на незалежні тренувальну та тестову вибірки. Базові спектрально-енергетичні ознаки (відносна вейвлет-енергія та вейвлет-ентропія) забезпечили тестову точність 76,2%, що є найвищим результатом серед окремих наборів характеристик. Додавання міжканальної вейвлет-когерентності суттєво підвищило ефективність засобу класифікації, дозволивши досягти тестової точності 83,3%. Це підтверджує, що ознаки функціональної взаємодії між електродами є комплементарними до спектральних характеристик і покращують здатність системи виявляти патерни, пов'язані з депресивним розладом. Результати демонструють, що поєднання вейвлет-енергетичних характеристик із міжканальною когерентністю формує стабільний та відтворюваний підхід для автоматизованого розпізнавання ВДР за ЕЕГ-сигналами.

Ключові слова: Вейвлет-когерентність, зв'язність ЕЕГ, великий депресивний розлад, метод опорних векторів.

Вступ. Великий депресивний розлад (ВДР) є провідною причиною втрати років працездатного життя та зниження якості життя для людей у світі. Лабораторного тесту для цього розладу не існує, а діагностика зазвичай ґрунтується на поведінкових проявах, анкетуванні та суб'єктивному досвіді пацієнта. Об'єктивні, масштабовані біомаркери могли б доповнити клінічну оцінку, зменшити час затрачений на діагностику та покращити моніторинг реакції на лікування. Електроенцефалографія (ЕЕГ) розглядається як перспективна основа для таких біомаркерів завдяки неінвазивності, портативності та прямій чутливості до динаміки нейронних процесів.

Через виражену неперіодичність сигналів ЕЕГ, їхній зміст неможливо повністю описати лише у часовому або частотному доменах, тому в афективних обчисленнях широко застосовують часо-частотний аналіз, що дозволяє відстежувати динаміку нейронної активності в різних смугах частот упродовж часу. Вейвлет-когерентність зарекомендувала себе як один із ключових підходів аналізу фізіологічних сигналів в афективних обчисленнях [1]. У задачах розпізнавання емоцій вона дає змогу відобразити просторово-часові закономірності узгодженої нейронної активності, що відповідають поточному емоційному стану, забезпечуючи підвищену точність класифікації, зокрема для таких пар класів як «радість – смуток» або «стрес – спокій» [2]. У сфері дослідження депресивних розладів ознаки, отримані на основі вейвлет-когерентності (особливо між функціонально значущими ділянками мозку), демонструють потенціал щодо формування об'єктивних біомаркерів, оскільки дозволяють виокремити пацієнтів із ВДР за характерними просторово-часовими патернами синхронізації [2,3].

Методи часо-частотного аналізу доповнюють традиційні підходи до характеристики ЕЕГ, оскільки дозволяють оцінювати змінність енергетичних та фазових властивостей сигналу в реальному часі. Вейвлет-перетворення забезпечує компактне часо-частотне подання та широко застосовується для отримання смугово-обмежених показників потужності. Водночас, метрики функціональної зв'язності, побудовані на основі вейвлет-перетворення, відображають узгоджену активність між сенсорами, що може бути чутливим до мережевих змін у мозку, характерних для ВДР. Зокрема, вейвлет-когерентність кількісно оцінює частотно-специфічний і локалізований у часі рівень зв'язності між двома сигналами, забезпечуючи стійкість до нестационарності та зберігаючи часову структуру процесу. Таким чином, поєднання локальних (потужнісних) і зв'язнісних (когерентнісних) показників створює можливість багатовимірної оцінки нейронної динаміки при ВДР.

У даному дослідженні розроблено уніфікований алгоритм обробки ЕЕГ, орієнтований на використання вейвлет-когерентності між каналами для задачі бінарної класифікації (норма проти ВДР) на основі відкритого набору даних TDBRAIN [4]. Ознаки когерентності формуються у часових вікнах та агрегуються у формат, придатний для подальшого машинного навчання. Для побудови класифікатора застосовано метод опорних векторів (SVM), який є одним із найбільш стійких підходів для задач з високою розмірністю ознак та обмеженим обсягом даних. Навчання здійснюється на навчальній вибірці, а узагальнююча здатність оцінюється на окремій тестовій вибірці. Такий підхід дозволяє об'єктивно перевірити, наскільки ознаки на основі вейвлет-когерентності можуть виступати інформативними біомаркерами (об'єктивними вимірюваними показниками) депресивного розладу

1. Виклики та труднощі.

Попри зростаючий науковий інтерес, практичне використання вейвлет-когерентності для розпізнавання ВДР залишається обмеженим. Існуючі дослідження демонструють значну варіативність у методах попередньої обробки, параметризації когерентності та протоколах оцінювання, що ускладнює безпосереднє порівняння отриманих результатів. Вибір каналів часто здійснюється за випадковим принципом і не супроводжується аналізом стійкості до артефактів чи стабільності каналів у різних вибірках. Крім того, порівняння з базовими підходами, які використовують одно-канальні вейвлет-ознаки, нерідко подається без суб'єкт-незалежної валідації, що не дозволяє об'єктивно оцінити потенційний приріст, забезпечуваний ознаками на основі вейвлет-когерентності.

2. Постановка експерименту та методологія.

2.1. Дані та формування вибірок.

У дослідженні використано набір даних ЕЕГ TDBRAIN для бінарної класифікації великого депресивного розладу (ВДР) проти контрольної групи здорових осіб. Первинна вибірка містила 359 унікальних учасників (312 з ВДР та 47 здорових), які надали 367 придатних записів у стані «відкритих очей» (медіанна тривалість близько 2 хв). Після контролю якості була сформована підмножина із 93 учасників, яка на рівні суб'єктів була поділена на 65 осіб для навчання та 28 — для тестування, що відповідало 377 та 168 неперекривним 20-секундним вікнам відповідно. Сигнал було записано та проаналізовано із частотою дискретизації 500 Гц.

Аналіз виконано на рівні особи (суб'єктно незалежна класифікація) з метою запобігання витоку ідентичності. Когорту розподілено у пропорції 70/30 за суб'єктами: 70% учасників використано для навчання засобів класифікації, а 30% відкладено для фінального тестування.

2.2. Сегментація сигналу.

Оскільки тривалість запису ЕЕГ для кожного учасника становила близько двох хвилин, сигнал розбивався на 20-секундні часові вікна, що давало в результаті близько десяти вікон для кожного суб'єкта. Класифікація стану суб'єкта виконувалася на основі індивідуальних оцінок для кожного вікна: спочатку обчислювалась ймовірність належності кожного вікна до класу ВДР, після чого ці ймовірності агрегувалися до суб'єктного рішення шляхом медіанного усереднення. Такий підхід дає змогу згладити локальні коливання, зумовлені артефактами або короткочасними змінами активності, та отримати більш стабільну оцінку стану учасника. Для кількісної оцінки використовували точність (assurasy), прецизійність (precision), повноту (recall) та F1-міру з довірчими інтервалами на рівні суб'єкта. Загальну схему алгоритму наведено на рис. 1.




Рис 1. Алгоритм обробки даних.

2.3. Попередня обробка сигналів.

Безперервні сигнали ЕЕГ фільтрувалися у діапазоні 1–45 Гц з додатковою вузькосмуговою режекторною фільтрацією на частоті 50 Гц для придушення мережових завад. Вікна з вираженими артефактами видалялися на основі порога дисперсії у z-метриці, який обчислювався окремо для кожного суб’єкта та кожного каналу. Після цього проводилася покадрова багатоканальна z-агрегація, що дозволяло уникнути впливу канал-специфічних відхилень і забезпечувало

узгоджене масштабування між каналами. Статистики навчальної вибірки використовувалися для стандартизації (z-нормування) обчислених параметрів у всіх наборах даних. Приклад початкового та відфільтрованого сигналу разом із поданням вейвлет-когерентності наведено на рис. 2.




Рис. 2. Початковий та відфільтрований сигнал ЕЕГ та вейвлет-когерентність для пари каналів F3-F4

2.4. Обчислення вейвлет-когерентності та похідних наборів ознак.

Часово-частотний зв'язок між каналами кількісно визначається за допомогою аналітичної вейвлет-когерентності ($wcoh$). Для каналів $x(t)$ та $y(t)$ з безперервними вейвлет-перетвореннями $W_x(a,b)$ та $W_y(a,b)$ у масштабі a та часі b , згладжений перехресний спектр $W_x W_y^*$ дає когерентність за величиною (1)

$$R^2(a, b) = \frac{|\langle W_x(a, b) W_y^*(a, b) \rangle|^2}{\langle |W_x(a, b)|^2 \rangle \langle |W_y(a, b)|^2 \rangle} \quad (1)$$

Для обчислення вейвлет-когерентності в дослідженні застосовано комплексну базову функцію Морле («amor»). Ця базова функція є майже аналітичною, тобто її спектр зосереджений переважно в додатних частотах і містить мінімум енергії в ділянці від'ємних частот. Така властивість забезпечує точні та стабільні оцінки фази, що є критично важливим для обчислення когерентності. Крім того, базова функція Морле забезпечує збалансований компроміс між часовою та частотною роздільною здатністю і де-факто є стандартом у більшості сучасних реалізацій вейвлет-когерентності для біометричних сигналів, зокрема ЕЕГ [5]. Когерентність обчислюється в діапазоні 1–45 Гц із кількістю «голосів на октаву», підбраною для балансу між роздільною здатністю та обчислювальними витратами. Смугові підсумки отримано шляхом усереднення R^2 в межах канонічних частотних смуг (δ , θ , α , β , γ). Щоб зберегти інформацію, нечутливу до напрямку взаємодії, і водночас утримати часову структуру, смугові підсумки спочатку обчислено для кожного вікна окремо, а вже потім агреговано на рівні суб'єкта. Повний перелік обчислюваних наборів ознак наведено в табл. 1.

Таблиця 1. Зведений огляд груп ознак

#	Набір ознак	Опис
1	Міжканальна вейвлет-когерентність (смугове середнє на рівні пар каналів)	Для вибраних пар електродів (F3–F4, P3–P4, Fp1–Fp2) обчислюється часо-частотна вейвлет-когерентність і усереднюється в межах канонічних частотних смуг (δ , θ , α , β , γ) для кожного вікна. Використовуються смугові середні значення когерентності для кожної пари каналів.
2	Середня когерентність у мережі DMN	Серед доступних каналів визначаються ті, що відповідають вузлам мережі пасивного режиму роботи мозку (DMN). Внутрішньомережеві пари каналів формують ребра DMN, для яких обчислюється вейвлет-когерентність. У кожному вікні ваги ребер усереднюються в межах канонічних смуг, утворюючи мережевий показник внутрішньої зв'язності DMN.
3	Відносна вейвлет-енергія (RWE) + вейвлет-ентропія	До кожного каналу застосовується аналітичне безперервне вейвлет-перетворення Морле (CWT). Потужність інтегрується в межах канонічних частотних смуг і нормується на сумарну потужність у діапазоні 1–45 Гц для отримання RWE по смугах. Додатково обчислюється ентропія Шеннона розподілу смугових енергій. Обчислення проводяться окремо для кожного каналу та кожного вікна.
4	Графові метрики з фіксованим порогом	На основі когерентності будуються смуго-специфічні функціональні мережі, використовуючи фіксований поріг або пропорційну густину мережі. Для кожного вікна обчислюються глобальна ефективність, середній коефіцієнт кластеризації та характеристична довжина шляху в зваженому або бінарному представленні мережі.
5	Інтегровані графові метрики	Для кожної смуги обчислюються глобальна ефективність, кластеризація та довжина шляху на сітці густин мережі. Далі кожен метрику узагальнюють у межах смуги як площу під кривою (AUC), інтегровану методом трапецій. Такий підхід забезпечує густинно-інтегровані графові дескриптори та зменшує залежність від вибору одного порога.
6	Статистичні показники розподілу Phase-Locking Value (PLV)	Для кожної міжелектродної пари обчислюється PLV як модуль середнього комплексного фазового вектора за часо-частотними точками. У кожному вікні та смузі розподіл значень PLV підсумовується за допомогою середнього, дисперсії та ентропії гістограми, що відображає рівень і варіативність фазової синхронізації.
7	Індекс фазового зсуву (PLI) та спрямований індекс фазового зсуву (dPLI)	Миттєві різниці фаз між каналами використовуються для обчислення смугових значень PLI, що характеризує сталість фазового зсуву та є нечутливою до нульової затримки. Спрямований індекс dPLI оцінює дисбаланс між випередженнями та запізненнями фаз, тобто напрямок переважного фазового зсуву. Для кожного вікна у межах кожної смуги значення PLI та dPLI для всіх пар каналів узагальнюються за допомогою середнього та дисперсії, утворюючи показники фазової взаємодії та її варіабельності.

2.5. Структура експериментів.

Методологія експериментів складається з таких етапів:

Етап 1: Порівняння окремих наборів ознак. Для кожного з семи наборів ознак (табл. 1) будувалися окремі засоби класифікації. Це дозволило визначити ефективність кожного набору без впливу інших ознак.

Етап 2: Дослідження впливу комбінування ознак. З метою оцінки взаємного доповнення ознак було сформовано додаткові експериментальні конфігурації, в яких до базових ознак (wavelet-енергії та ентропії) додавалося кожне з інших шести інших сімейств ознак. Цей етап дозволив встановити, які групи ознак дають найбільший приріст точності при об'єднанні.

2.6. Засоби класифікації.

Як основний засіб класифікації застосовано лінійний метод опорних векторів (SVM), який є ефективним для високорозмірних ознак та обмежених навчальних вибірок. Методів на основі глибинних нейронних мереж не було застосовано, оскільки їх ефективне використання вимагає значно більшої кількості прикладів на суб'єкта та суттєвого розширення вибірки загалом, за наявних обсягів даних такі мережі схильні до перенавчання та не забезпечують узагальнення. Усі випадкові ініціалізації, схеми групування, параметри попередньої обробки та вибрані канали було задокументовано у файлах конфігурації експерименту, що забезпечує повну відтворюваність результатів.

2.7. Програмна реалізація.

Обчислювальні процедури реалізовано засобами MATLAB із застосуванням EEGLAB, Wavelet Toolbox, Signal Processing Toolbox та Statistics and Machine Learning Toolbox. Система включає модулі для завантаження даних, сегментації, попередньої обробки, обчислення вейвлет-когерентності, формування характеристик та оцінювання засобів класифікації.

3. Результати

3.1. Порівняння окремих наборів ознак.

Результати оцінювання семи наборів характеристик (табл. 1) наведено в табл.2. Найвищі показники узагальнення продемонстрували ознаки, отримані на основі вейвлет-енергії та ентропії, що забезпечили тестову точність 76,2%. Показники, сформовані на основі міжканальної вейвлет-когерентності, фазових індексів PLV/PLI/dPLI та графових метрик, демонстрували дещо нижчі результати, хоча й відображали корисні властивості функціональної взаємодії між каналами.

Таблиця 2. Результати порівняння окремих наборів ознак

#	Набір ознак	Кількість ознак	Точність тренування	Точність тестування
1	Міжканальна вейвлет-когерентність (смугове середнє на рівні пар каналів)	15	66,8%	67,1%
2	Середня когерентність у мережі DMN	5	64,9%	72,0%
3	Відносна вейвлет-енергія (RWE) + вейвлет-ентропія	48	80,9%	76,2%
4	Графові метрики з фіксованим порогом	15	60,5%	56,1%
5	Інтегровані графові метрики	15	63,8%	62,2%
6	Статистичні показники розподілу Phase-Locking Value (PLV)	15	67,2%	63,4%
7	Індекс фазового зсуву (PLI) та спрямований індекс фазового зсуву (dPLI)	20	63,4%	59,1%

3.2. Дослідження впливу додаткових наборів ознак.

Даний етап був спрямований на оцінювання того, наскільки кожен із шести додаткових наборів ознак може покращити базову конфігурацію, що містить вейвлет-енергію та ентропію. Додавання окремих характеристик до відносної вейвлет-енергії (RWE) + та вейвлет-ентропії здатне покращувати точність на 2–7% залежно від типу ознак (табл. 3).

Таблиця 3. Вплив додаткових наборів ознак

#	Набір ознак (додатково до відносної вейвлет-енергії (RWE) + та вейвлет-ентропії)	Кількість ознак	Точність тренування	Точність тестування
1	Відносна вейвлет-енергія (RWE) + вейвлет-ентропія (база)	48	80,9%	76,2%
2	Міжканальна вейвлет-когерентність (смугове середнє на рівні пар каналів)	63	89,5%	83,3%
3	Середня когерентність у мережі DMN	53	81,2%	78,5%
4	Графові метрики з фіксованим порогом	63	85,3%	81,5%
5	Інтегровані графові метрики	63	86,2%	81,9%
6	Статистичні показники розподілу Phase-Locking Value (PLV)	63	82,2%	78,0%
7	Індекс фазового зсуву (PLI) та спрямований індекс фазового зсуву (dPLI)	68	86,3%	82,0%

Таким чином, результати дослідження свідчать про потенціал комбінованого подання ЕЕГ як спектральної, так і мережевої інформації: характеристики функціональної взаємодії між каналами суттєво доповнюють енергетичні ознаки, покращуючи загальну здатність засобу класифікації узгоджувати патерни, пов'язані з депресивним розладом.

Висновки. Проведено порівняння семи груп ознак, отриманих на основі вейвлет-аналізу та показників функціональної зв'язності ЕЕГ, для розпізнавання великого депресивного розладу. Найвищу ефективність серед окремих наборів продемонстрували вейвлет-енергія та ентропія, які забезпечили тестову точність 76,2%. Дослідження впливу додаткових ознак показало, що поєднання енергетичних характеристик із міжканальною когерентністю, графовими метриками та фазовими індексами (PLI/dPLI) може підвищувати точність до 2–7%. Це свідчить про комплементарність спектральних і мережевих властивостей ЕЕГ та їхню спільну придатність для виявлення патернів, пов'язаних із депресивними станами.

Отримані результати демонструють, що найбільш практичним і ефективним базовим підходом є поєднання вейвлет-енергетичних ознак із міжканальною когерентністю, що дало тестову точність у максимальна точність 83.3%. Графові та фазові дескриптори можуть виступати релевантним доповненням у задачах, що вимагають підвищеної точності.

Серед обмежень дослідження — застосування лише одного набору даних та відсутність зовнішньої валідації. Подальша робота має бути спрямована на перевірку узагальнюваності методів на незалежних вибірках та розширення підходу шляхом мультимодальної інтеграції ЕЕГ з іншими фізіологічними сигналами.

Література

1. Fattouh, Anas. (2016). An Emotional Model based on Wavelet Coherence Analysis of EEG Recordings. *BVICAM's International Journal of Information Technology*. 8.
2. Deniz, S. M., Ademoglu, A., Duru, A. D., & Demiralp, T. (2025). Application of Graph-Theoretic Methods Using ERP Components and Wavelet Coherence on Emotional and Cognitive EEG Data. *Brain sciences*, 15(7), 714. <https://doi.org/10.3390/brainsci15070714>
3. Khan, Danish & Masroor, Komal & Jailani, Muhammad & Yahya, Norashikin & Yusoff, Mohd Zuki & Khan, Shariq. (2022). Development of Wavelet Coherence EEG as a Biomarker for Diagnosis of Major Depressive Disorder. *IEEE Sensors Journal*. PP. 1-1. 10.1109/JSEN.2022.3143176.
4. van Dijk, H., van Wingen, G., Denys, D., Olbrich, S., van Ruth, R., & Arns, M. (2022). The two decades brainclinics research archive for insights in neurophysiology (TDBRAIN) database. *Scientific data*, 9(1), 333. <https://doi.org/10.1038/s41597-022-01409-z>
5. Al-Qazzaz, N. K., Bin Mohd Ali, S. H., Ahmad, S. A., Islam, M. S., & Escudero, J. (2015). Selection of Mother Wavelet Functions for Multi-Channel EEG Signal Analysis during a Working Memory Task. *Sensors (Basel, Switzerland)*, 15(11), 29015–29035. <https://doi.org/10.3390/s151129015>

Recognition of Major Depressive Disorder Based on EEG Wavelet Coherence

Oleksandr Sukholeister, Adrian Nakonechnyi

This study investigates whether features derived from wavelet coherence between EEG channels improve the recognition of Major Depressive Disorder (MDD) compared with baseline features obtained from wavelet transforms of individual channels. A comprehensive algorithm was developed, incorporating signal preprocessing, coherence estimation using the analytic Morlet mother wavelet, and the construction of derived inter-channel and network-level features. Experimental evaluation was performed on the TDBRAIN dataset with a subject-wise split into independent training and test cohorts. Baseline spectral–energetic features (relative wavelet energy and wavelet entropy) achieved a test accuracy of 76.2%, representing the highest performance among individual feature sets. Adding pair wise wavelet-coherence features substantially improved classification performance up to 83.3%. These results indicate that features reflecting functional interactions between electrodes are complementary to spectral descriptors and enhance the system's ability to detect patterns associated with depressive disorders. Overall, the combination of wavelet-energy features with inter-channel coherence provides a stable and reproducible approach for automated MDD recognition from EEG signals.

Отримано 21.11.2025.