

# Виявлення епізодів апное та гіпопное сну за даними ЕКГ та ЕЕГ сигналів методами машинного навчання

Рихальська<sup>f</sup> А. К., ORCID [0000-0001-6286-4806](https://orcid.org/0000-0001-6286-4806)

Іванько К. О., к.т.н. доц., ORCID [0000-0002-3842-2423](https://orcid.org/0000-0002-3842-2423)

Іванушкіна Н. Г., к.т.н. доц., ORCID [0000-0001-8389-7906](https://orcid.org/0000-0001-8389-7906)

Кафедра електронної інженерії

Національний технічний університет України

"Київський політехнічний інститут імені Ігоря Сікорського" ROR [00syn5v21](https://ror.org/00syn5v21)

Київ, Україна

Іванько Д. О., к.т.н., ORCID [0000-0003-2442-8637](https://orcid.org/0000-0003-2442-8637)

Кафедра електроенергетики

Норвезький університет природничих та технічних наук ROR [05xg72x27](https://ror.org/05xg72x27)

Тронхейм, Норвегія

**Анотація**—Стаття присвячена застосуванню методів машинного навчання для комп'ютеризованого виявлення епізодів апное сну на основі аналізу одноканальних сигналів електрокардіограми (ЕКГ) та електроенцефалограми (ЕЕГ). Для дослідження можливостей машинного навчання для виявлення апное на основі аналізу ЕКГ та ЕЕГ було використано відкриті бази даних Apnea-ECG та MIT-BIH polysomnographic database з ресурсу PhysioNet, які містять анотації до кожної хвилини записів, що вказують на наявність або відсутність апное/гіпопное сну в поточний момент часу. Метою даної роботи є визначення та порівняння інформативних ознак виявлення епізодів апное сну за показниками варіабельності серцевого ритму та електричної активності мозку, а також вибір методів машинного навчання, що забезпечують найвищу точність класифікації. Розглянуто показники кардіоритмограм у часовій та частотній областях, спектрально-часові та вейвлет-характеристики, а також параметри ЕЕГ сигналів на основі відношення енергії ЕЕГ ритмів, показника Херста, фрактальної розмірності Хігучі та ентропії вибірки для ЕЕГ сигналів. Використовуючи різні набори ознак, було визначено точність класифікації для моделей на основі дерев рішень, дискримінантного аналізу, методу опорних векторів, методу k-найближчих сусідів та ансамблевого навчання. На основі цього запропоновані набори ознак та класифікатори, що забезпечують найвищу точність розпізнавання епізодів апное сну за даними ЕКГ та ЕЕГ сигналів.

**Ключові слова** — апное та гіпопное сну; електрична активність серця та мозку; варіабельність ритму серця; спектральний аналіз; спектрально-часовий аналіз; вейвлет-аналіз; фрактальний аналіз; ентропія; класифікація; машинне навчання.

## I. ВСТУП

Синдром апное сну — вид патології сну, який супроводжується дихальними паузами тривалістю більше 10 секунд та може провокувати багато проблем зі здоров'ям. Найчастіше дихальна пауза викликана синдромом апное під час сну триває 20-30 секунд, але у важких випадках може досягати 2-3 хвилин і забирати до 60% загального часу нічного сну. Апное сну характеризується епізодами часткового або повного закриття верхніх дихальних шляхів. Розрізняють апное та гіпопное сну. Перший стан (апное сну) являє собою зупинку дихання на 10 секунд і більше, під час яких потік повітря, що проходить крізь дихальні шляхи зменшується на 90%. Другий стан (гіпопное сну) — це епізод неповної зупинки дихання тривалістю мінімум 10 секунд, що

супроводжується зменшенням повітряного потоку не менше ніж на 30% та подальшою реакцією пробудження.

Епізод апное приводить до зменшення насичення крові киснем. Недостатня концентрація кисню може спричинити смерть, але через захисну функцію організму людина починає прокидатися під час сну і через деякий час настає момент вдиху. Етап пробудження під час сну порушує нормальний сон, що в свою чергу впливає на загальний стан здоров'я пацієнта. Так, різке зниження рівня кисню в крові сприяє підвищенню артеріального тиску та збудженню серцево-судинної системи [1]. У багатьох людей із синдромом обструктивного апное сну спостерігається гіпертонія під час сну, що збільшує ризик серцевих захворювань. Чим складніша стадія захворювання, тим вищий



ризик розвитку ішемічної хвороби серця, інфаркту, серцевої недостатності та інсульту. Також збільшується ризик серцевої аритмії. Хвороби серця та синдром обструктивного апное сну разом можуть призвести до раптової смерті від серцевого нападу [1].

Основним показником, що характеризує тяжкість апное сну, є апное-гіпноное індекс (АГІ), який відображає кількість випадків апное та гіпноное за годину. АГІ обчислюється як відношення кількості випадків апное сну до кількості годин сну [2]. Значення АГІ для дорослих:  $АГІ < 5$  – норма;  $5 \leq АГІ < 15$  – легкий стан апное сну;  $15 \leq АГІ < 30$  – середній стан апное сну;  $АГІ \geq 30$  – важкий стан апное сну. У пацієнтів із легким станом апное сну (від 5 до 14 зупинок дихання за годину), спостерігається сонливість протягом дня. Якщо відбувається від 15 до 29 зупинок дихання за годину сну, людина починає засинати при будь-якій можливості, їй дуже важко прокинутися вранці і немає сил виконувати щоденні завдання. Понад 30 зупинок дихання погіршують якість життя та можуть призвести до значних ускладнень зі здоров'ям.

Традиційним та загально визнаним методом виявлення апное уві сні є аналіз сигналів полісомнограм [3]. В останні роки багато досліджень було присвячено розробці комп'ютеризованих методів виявлення епізодів апное сну [4-7]. Такі підходи можуть базуватися на спектральних особливостях досліджуваних сигналів [8-10], вейвлет-аналізі [11], характеристиках, заснованих на статистичних моментах [8], аналізі головних компонент [12]. Аналіз полісомнограм передбачає реєстрацію великої кількості біомедичних сигналів під час сну, включаючи електричну активність мозку та серця, рівень кисню та вуглекислого газу в крові, реєстрацію рухів очей та кінцівок, скорочення м'язів, частоту серцевих скорочень, частоту дихання, виникнення хрипіння, потоки повітря крізь ніс і рот [3]. Очевидно, що ця процедура досить трудомістка; крім того, пацієнт може почувати себе некомфортно через велику кількість накладених електродів та необхідність сну з цим обладнанням.

У зв'язку з швидким розвитком портативних пристроїв для моніторингу стану здоров'я, виявлення епізодів апное сну на основі аналізу сигналу з одного відведення є актуальною задачею. При цьому реєстрація сигналу вимагає мінімальних незручностей пацієнта під час сну, суттєво зменшує витрати на обладнання і добре підходить для впровадження автоматизованого розпізнавання апное сну в умовах клінічного та віддаленого домашнього моніторингу з використанням стаціонарних або носимих пристроїв.

Дослідники застосовують різні методи виділення ознак у часовій та частотній області, а саме перетворення Фур'є, вейвлет аналіз, розпізнавання форми хвиль біомедичних сигналів [6, 8, 11]. Замість використання 12 фізіологічних сигналів полісомнограми з метою зменшення обчислювальних витрат для виявлення апное сну також використовується аналіз лише одного з сигналів. Дослідження довели можливість виявлення апное сну за допомогою ознак,

отриманих на основі ЕКГ сигналу, а саме показників варіабельності ритму серця (ВРС) [7-14]. Також ряд наукових робіт присвячено дослідженню можливості виявлення апное на основі аналізу ЕЕГ сигналів [15-18]. В дослідженні [16, 17] розраховується енергія ЕЕГ у кожній смузі частот ритмів ЕЕГ та їх відношення, в роботі [19] для виділення ритмів ЕЕГ використано пакетний вейвлет-розклад, а епізоди апное виявляються з використанням значень показників ентропії, обчислених для кожної смуги частот.

## II. МАТЕРІАЛИ І МЕТОДИ

Для нашого дослідження було використано 2 публічно відкриті бази даних електронного ресурсу Physionet [20]: “The Apnea-ECG Database” та “The MIT-BIH Polysomnographic Database”.

База даних “The Apnea-ECG Database” [21] складається з 35 довготривалих записів, що містять одне відведення ЕКГ з частотою дискретизації 100 Гц, роздільною здатністю 12 біт і тривалістю записів приблизно 8 годин. Записи супроводжується анотацією для кожної хвилини реєстрації сигналу, яка вказує на наявність або відсутність апное протягом цього часу. Дані розділено на наступні класи: клас А (апное) — записи, що містять не менше 100 хвилин з випадками апное; клас В (граничний з апное) — записи, що містять від 5 до 99 хвилин з випадками апное; клас С (контрольний) — записи, що містять менше 5 хвилин з апное і можуть вважатися нормою. “The Apnea-ECG Database” була використана нами в попередньому дослідженні [14], щоб оцінити ефективність методів машинного навчання для виявлення епізодів апное сну на основі показників варіабельності ритму серця (ВРС), розрахованих за сигналом ЕКГ. Було досліджено показники, розраховані у часовій і частотній областях, а також показники, отримані за допомогою спектрально-часового та вейвлет-аналізу. Проведене порівняння ефективності найпоширеніших методів машинного навчання для задачі класифікації сигналів у нормі та під час апное сну дозволило вибрати найкращі 9 параметрів для виявлення апное сну з розглянутих 24 параметрів варіабельності серцевого ритму. Найвища точність класифікації розпізнавання стану апное сну була отримана для моделі, побудованої за допомогою методу опорних векторів з квадратичним ядром. В даному дослідженні ми використовуємо методику розрахунку параметрів для розпізнавання апное сну на основі ЕКГ сигналу, розглянуту в нашій попередній роботі, та застосуємо її до бази даних “The MIT-BIH Polysomnographic Database”, в якій наявні одночасно зареєстровані ЕКГ та ЕЕГ сигнали. Метою даної роботи є дослідження можливості визначення апное сну за даними ЕЕГ, відбір параметрів одноканального сигналу електричної активності мозку для розпізнавання апное сну та порівняння результатів моделей машинного навчання, отриманих окремо для ЕКГ та ЕЕГ показників та у разі їх комбінації. Окрім цього, на відміну від нашого попереднього дослідження, анотовані сигнали бази “The MIT-BIH Polysomnographic Database” дозволяють провести класифікацію сигналів на 3 класи: норма, апное та гіпноное. Наявність класу “гіпноное” ускладнює задачу класифікації сигналів, тому що



в залежності від ступеню перекриття дихальних шляхів він може помилково визначатися і як норма, і як апное.

“The MIT-BIH Polysomnographic Database” [22, 23], являє собою набір записів полісомнографічних сигналів та є публічно відкритою базою електронного ресурсу Physionet. В роботі використано 16 полісомнографічних записів пацієнтів, середній вік яких складає 40 років (діапазон 32-56 років), середня вага 119 кг (діапазон від 89 до 152 кг). Більшість з пацієнтів страждають від важкого ступеню апное сну. Запис полісомнограм проводився в бостонській клініці порушень сну «Beth Israel Hospital Sleep Laboratory» для оцінки синдрому хронічного обструктивного апное сну і перевірки впливу постійного позитивного тиску в дихальних шляхах – терапевтичного втручання, яке зазвичай запобігає або істотно зменшує обструкцію дихальних шляхів.

Тривалість полісомнографічних сигналів у базі варіюється від 2 до 7 годин в залежності від тривалості сну конкретного пацієнта. Частота дискретизації ЕКГ та ЕЕГ сигналів складає 250 Гц, роздільна здатність 12 біт. Дані супроводжуються анотаціями розташування QRS комплексів, стадій сну, випадків центрального та обструктивного апное та гіпнопное. Біполярне відведення ЕЕГ залежить від реєстрації сигналу у конкретного пацієнта (у базі присутні сигнали з відведень C4-A1, O2-A1 або C3-O1: стандартні варіанти розташування електродів для дослідження стадій сну). З метою застосування методів машинного навчання до задачі автоматизованого виявлення епізодів апное сну наявні у базі довготривалі сигнали полісомнограм було сегментовано згідно анотацій на коротші ділянки тривалістю 30 секунд кожна. У дослідженні використано по 267 ділянок полісомнограм тривалістю 30 секунд для класу “норма”, 258 для класу “апное” та 273 для класу “гіпнопное”, загалом 798 одночасних записів ЕКГ та ЕЕГ.

Поверхнева ЕКГ — фізіологічний сигнал, що містить інформацію про центральну вегетативну регуляцію серцево-судинної функції, дихання та електричну активність серця. Аналіз варіабельності ритму серця є одним з основних підходів для визначення серцевих, дихальних та ендокринних порушень. ВРС пов'язана з взаємодією симпатичної та парасимпатичної гілок вегетативної нервової системи. У роботах [8-9] описується метод визначення апное сну за частотними показниками, визначеними в області дуже низьких частот (0,0033-0,04 Гц) за спектральною густиною потужності послідовності RR інтервалів, які відрізняються в стані апное від норми через сплеск симпатичної активності. Діапазон високих частот (0,15-0,4 Гц) відображає швидкі зміни частоти серцевих ударів, спричинені парасимпатичною стимуляцією, тоді як вважається, що діапазон дуже низьких частот відображає переважно симпатичну стимуляцію. Область низьких частот (0,04-0,15 Гц) відображає змішаний вплив як симпатичної, так і парасимпатичної стимуляції серця.

Попередня обробка зареєстрованого ЕКГ сигналу з метою усунення завад та шумів є важливим етапом, що передують детекції QRS комплексів та аналізу параметрів варіабельності серцевого ритму. Для усунення дрейфу ізолінії ЕКГ було використано метод вейвлет-аналізу. Декомпозицію сигналів ЕКГ було виконано до 12 рівня за допомогою симетричного вейвлету 5-го порядку. Низькочастотний періодичний зсув базової лінії ЕКГ видалено обробкою вейвлет-коефіцієнтів: коефіцієнти апроксимації  $a_{12}$  та коефіцієнти деталізації 9-12 рівнів вейвлет розкладу  $d_9-d_{12}$  були прирівняні до нульового значення, а корисний сигнал реконструйований без їх впливу. Для усунення високо-частотних завад спектр ЕКГ був обмежений до 40 Гц за допомогою фільтра низьких частот з кінцевою імпульсною характеристикою.

Детекцію QRS комплексів (рис.1, а) реалізовано з використанням встановленого порогу до опорного сигналу, обчисленого як нелінійне перетворення ЕКГ сигналу та його першої похідної. Підхід до визначення розташування R піків заснований на алгоритмі Пана Томпкінса та включає вдосконалення алгоритму для точнішого виявлення QRS комплексів у ЕКГ сигналах з наявністю шумових складових. R зубці розташовані у локальних максимумах ЕКГ сигналу, оскільки вони мають найкрутіші схили порівняно з іншими зубцями ЕКГ. Після ідентифікації R зубців послідовність RR-інтервалів було розраховано як часові інтервали між послідовними ударами серця. NN-інтервали, що використовуються для аналізу варіабельності серцевого ритму, — це інтервали між нормальними R-піками (від англ. *normal-to-normal*), тобто враховуються проміжки тільки між нормальними серцевими скороченнями і в аналізі не беруть участь інтервали, записані при порушенні серцевого ритму, а також такі, що виникли в результаті зовнішніх перешкод. Отже, всі показники VCP, визначені далі в роботі, були визначені з послідовності інтервалів між сусідніми QRS комплексами, які відповідають нормальним серцевим скороченням. З метою отримання рівновіддалених часових відліків кардіоритмограми ЕКГ сигнал було інтерпольовано за допомогою кубічної інтерполяції. Частота дискретизації для інтерпольованої послідовності RR-інтервалів обрана з урахуванням середнього та мінімального RR-інтервалу і дорівнює 5 Гц.

Зміна ритму серця при синдромі обструктивного апное сну має специфічний характер (рис.1, б, в). У момент зупинки дихання розвивається брадикардія (уповільнення ритму серця), а у вентиляційну фазу після апное відзначається тахікардія (прискорення ритму серця) (рис.2). Діапазон коливань частоти серцевого ритму становить 30-40 ударів за хвилину під час епізоду апное сну, а зменшення тривалості RR інтервалів у вентиляційну фазу після апное є відмінною рисою для розпізнавання апное уві сні за кардіоритмограмою.






Рис. 1. Виявлення апное за даними ЕКГ: а) детекція піків R зубців на ЕКГ; б) кардіоритмограма під час апное сну; в) кардіоритмограма в нормі

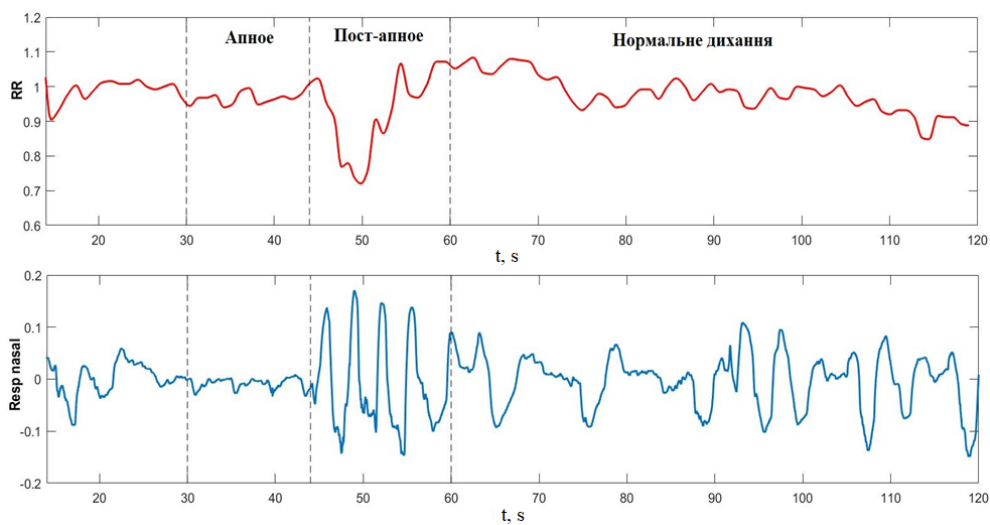


Рис. 2. Порівняння характерних інтервалів кардіоритмограми та назального потоку повітря під час апное сну





Кількісний аналіз кардіоритмограм зазвичай проводиться у часовій та частотній областях. В часовій області розраховуються наступні параметри [8, 9, 24]: середнє значення RR-інтервалів; стандартне відхилення RR-інтервалів; значення RR-інтервалу, що найбільш часто зустрічається в кардіоритмограмі; інтерквартильний діапазон RR-інтервалів; кількість пар сусідніх RR-інтервалів, які відрізняються більше ніж на 50 мс; стандартне відхилення послідовних різниць RR-інтервалів; частота серцевих скорочень; показник дихальної модуляції; індекс напруженості регуляторних систем, індекс вегетативної рівноваги; індекс вегетативного ритму; індекс адекватності регуляторних процесів; асиметрія та ексцентричність розподілу RR-інтервалів та інші.

Визначення діагностичних ознак у частотній області проведено шляхом розрахунку залежності густини спектра потужності від частоти для часових рядів RR-інтервалів з використанням непараметричного методу швидкого перетворення Фур'є. Для усунення ефекту розтікання спектра використано вікно Хемінга. В аналізі ВСР застосовано чотири основні частотні смуги: високих частот (HF) – від 0,15 до 0,4 Гц, низьких частот (LF) – від 0,04 до 0,15 Гц, дуже низьких частот (VLF) – від 0,0033 до 0,04 Гц і наднизьких частот (ULF) – від 0 до 0,0033 Гц. Найбільш суттєві відмінності між нормою та патологією проявляються в діапазоні низьких частот, що відповідає здебільшого симпатичній регуляції. Для виявлення апное окрім традиційних смуг частот, застосовано смугу, де середня спектральна щільність потужності для сигналів з апное перевищує цю криву для сигналів у нормі. Ми визначили цей діапазон як діапазон від 0,01 Гц до 0,075 Гц. Для інтерпольованих послідовностей RR-інтервалів було розраховано наступні параметри в частотній області [8, 9, 24]: нормована потужність у діапазоні низьких частот, нормована потужність у діапазоні високих частот, нормована потужність у діапазоні дуже низьких частот, індекс вегетативного балансу, нормована потужність в діапазоні 0,01-0,075 Гц.

Спектрально-часовий аналіз використовується для аналізу зміни частотного складу нестационарного сигналу з часом. Для виділення спектрально-часових особливостей ВСР у нормі та за наявності апное було розраховано спектрограми кардіоритмограм з використанням вікна Хемінга та 90% перекриття вікон. Також було розраховано спектральні параметри за допомогою вейвлет-аналізу. Кардіоритмограми розкладено за допомогою симетричної вейвлет-функції 5-го порядку до 4-го рівня вейвлет-перетворення. Апроксимаційна складова  $a_1$  передає особливості дуже низькочастотних та низькочастотних компонент кардіоритмограм, а деталізуючі складові  $d_1-d_4$  представляють собою високочастотні компоненти. Порівнюючи ці складові та їх частотні спектри, виявлено, що найбільша різниця між цими сигналами проявляється в апроксимаційній складовій  $a_4$ , а саме в її спектрі на частотах до 0,1 Гц. Отже, для розпізнавання апное було використано спектральну густину потужності апроксимаційної складової  $a_4$  у цьому діапазоні частот.

Таким чином, повний набір параметрів для розпізнавання апное за даними варіабельності ритму серця склав 25 параметрів, а зменшений — 9 параметрів, які найбільше відрізнялися за розподілом для норми, апное та гіпноное, а саме:

- 1) показник куртозису розподілу RR-інтервалів;
- 2) інтерквартильний діапазон RR-інтервалів (різниця між 75-м і 25-м процентилями у мс);
- 3) амплітуда моди (кількість кардіоінтервалів, які відповідають значенням моди, у % до всієї кількості кардіоінтервалів);
- 4) нормована спектральна густина потужності кардіоритмограми в діапазоні високих частот (від 0,15 до 0,4 Гц);
- 5) нормована спектральна густина потужності кардіоритмограми в діапазоні дуже низьких частот (від 0,0033 до 0,04 Гц);
- 6) нормована спектральна густина потужності кардіоритмограми в діапазоні частот, де найбільш відрізняється спектр для сигналів у нормі та при наявності апное сну (від 0,01 до 0,075 Гц);
- 7) натуральний логарифм суми абсолютних значень (L1-норми) середньої часової залежності спектральної густини потужності в діапазоні частот 0,01-0,075 Гц (розраховується за даними спектрально-часового аналізу);
- 8) натуральний логарифм Евклідової норми (L2-норми) середньої часової залежності спектральної густини потужності у діапазоні частот 0,01-0,075 Гц;
- 9) натуральний логарифм спектральної густини потужності, розрахованої для апроксимаційної складової 1-го рівня вейвлет-розкладу кардіоритмограми (розраховується за даними вейвлет-аналізу).

Аналіз сигналу електроенцефалограми також відіграє важливу роль для виявлення випадків апное сну. Хоча сон є станом загального зниження активності мозку, деякі групи нейронів активніші під час сну і служать для стабілізації цього стану або сприяння переходу від неспання до сну [25]. Рівні кисню та вуглекислого газу в крові відображають адекватність вентиляції легень та діють на хеморецептори, розташовані на периферії та в мозку. У разі апное, у крові накопичується вуглекислий газ через зупинку дихання і хеморецептори сигналізують про тривогу в мозок, що призводить до пробудження сплячого і вдиху повітря. В результаті відбувається перехід між стадіями сну, що, в свою чергу, викликає флуктуації ЕЕГ сигналу в різних діапазонах частот. Таким чином, аналіз ЕЕГ сигналу в частотній області та відношення енергій ритмів ЕЕГ між собою обґрунтовано можуть застосовуватися для виявлення епізодів апное сну.

В роботі проаналізовано шість діапазонів частот:  $\delta$  ритм (0,5–4 Гц),  $\theta$  ритм (4–8 Гц),  $\alpha$  ритм (8–12 Гц),



$\sigma$  ритм (12–15 Гц),  $\beta$  ритм (15–30 Гц) та  $\gamma$  ритм (30–50 Гц). Альфа-ритм – характерний хвильовий паттерн ЕЕГ дорослої людини, яка не спить, але розслаблена із заплющеними очима. Кожна область мозку має характерний альфа-ритм, але альфа-хвилі найбільшої амплітуди реєструються в потиличній і тім'яній областях кори головного мозку. Бета-ритм реєструється у людей, які пильні і уважні до зовнішніх подразників або докладають певних розумових зусиль, також бета-ритм виникає під час глибокого сну, швидкого сну, швидкого руху очей. Амплітуда бета-ритму зазвичай нижче, ніж альфа-ритму. Бета-хвилі відображають пробудження кори головного мозку до більш високого стану пильності або напруженості. Це також може бути пов'язано з "запам'ятовуванням" або відновленням спогадів. Хоча дельта-і тета-ритм зазвичай найбільш помітні під час сну, бувають випадки, коли дельта — і тета-ритми записуються у людей, які не сплять. Наприклад, тета-хвилі будуть виникати протягом коротких проміжків часу під час емоційних реакцій на хвилюючі події або ситуації. Дельта-хвилі можуть посилюватися під час складної розумової діяльності, що вимагає концентрації. Потужність гама-ритму збільшується під час респіраторних подій.

Для розпізнавання епізодів апное за даними ЕЕГ було виділено альфа, бета, дельта, тета і гама ритми. Відносну потужність для кожного діапазону частот, що відповідає певним ритмам ЕЕГ, було обчислено з нормалізацією на потужність у всій смугі частот ЕЕГ сигналу. За спектром потужності в частотній

області розраховано відношення потужностей різних ритмів між собою. Отримано наступні відношення потужностей ритмів: 'Alpha/Beta', 'Alpha/Gamma', 'Alpha/Delta', 'Alpha/Theta', 'Beta/Gamma', 'Beta/Delta', 'Beta/Theta', 'Gamma/Delta', 'Gamma/Theta', 'Delta/Theta'. Також розраховано показник Херста [26], фрактальну розмірність Хігучі [27] та ентропію вибірки [28] для досліджуваних ЕЕГ сигналів.

Для кожного параметру наведено діаграми розмаху значень (боксплоти), які компактно представляють одновимірний розподіл ймовірностей та демонструють медіану, нижній і верхній квартилі, мінімальне і максимальне значення вибірки і викиди (рис.3). Якщо побудовані блоки знаходяться на різних рівнях – це свідчить про відмінність між значеннями параметру для різних класів. Аналіз діаграм розмаху значень параметрів ЕЕГ сигналів з досліджуваної бази даних полісомнографічних сигналів [22] для норми, апное та гіпноное свідчить про те, що розподіли для норми та гіпноное значно накладаються для більшості параметрів, в той час як розподіл значень параметрів для стану апное значно відрізняється і не накладається у більшості випадків (окрім значень, визначених як викиди даних).

З метою визначення найкращих моделей класифікації для виявлення епізодів апное сну було застосовано машинне навчання на основі дерев рішень, дискримінантного аналізу, методу опорних векторів, методу k-найближчих сусідів та ансамблевого навчання (рис.4, 5).

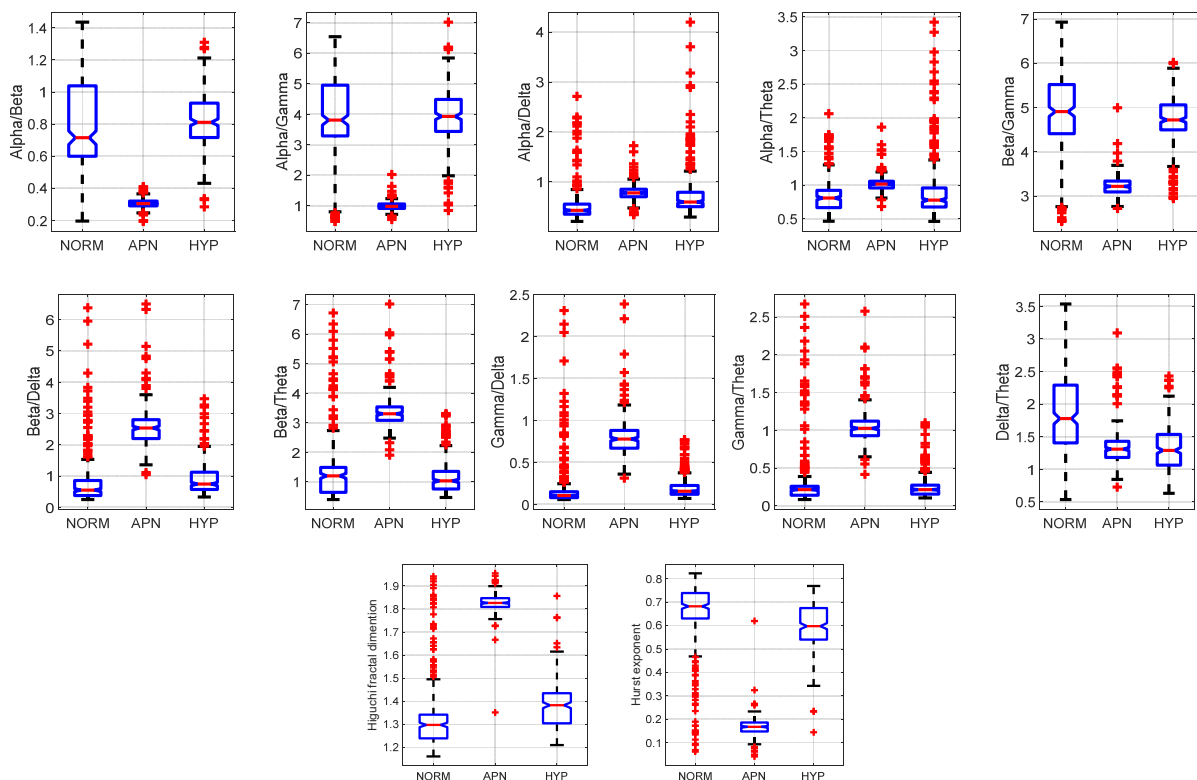


Рис. 3. Діаграми розмаху значень параметрів ЕЕГ сигналів з бази [22] для норми (NORM), апное (APN) та гіпноное (HYP)



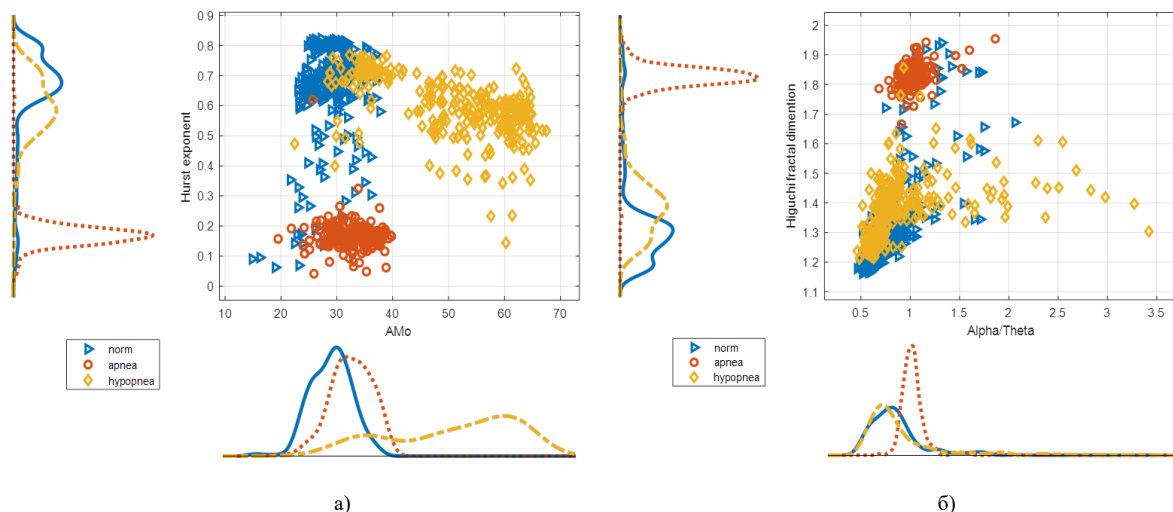


Рис. 4. Приклади розподілу ознак: а) амплітуда моди для послідовності RR інтервалів та експонента Херста для ЕЕГ сигналу; б) відношення потужностей ритмів альфа і тета та фрактальна розмірність Хігучі для ЕЕГ сигналу

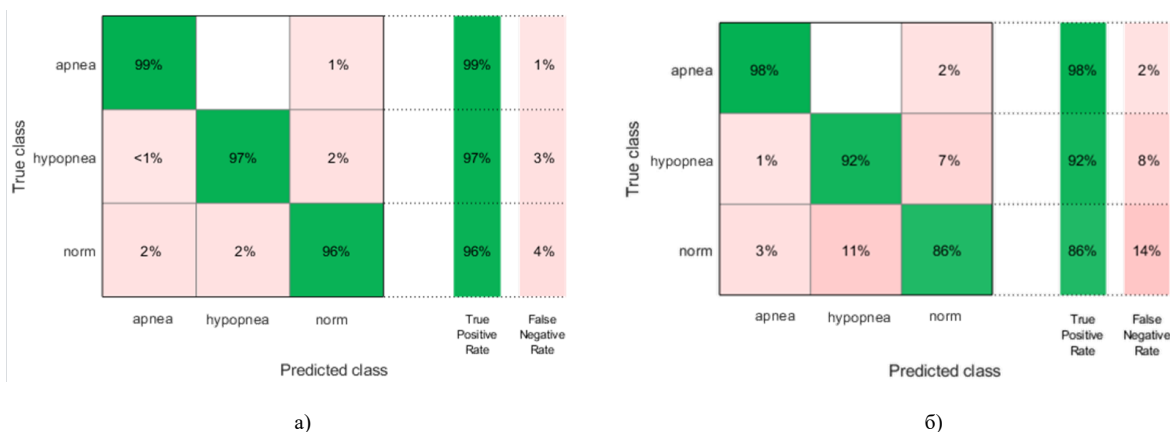


Рис. 5. Приклади матриць невідповідності: а) дерева рішень (ознаки на основі ЕКГ), б) метод опорних векторів (ознаки на основі ЕЕГ)

Дерево рішень — це метод побудови правил прийняття рішень в ієрархічній структурі, що складається з елементів двох типів — вузлів та листя. У вузлах знаходяться правила і проводиться перевірка відповідності ознак цим правилам за деяким атрибутом навчальної множини. Побудова дерев рішень полягає в послідовному рекурсивному розбитті навчальної множини на підмножини із застосуванням вирішальних правил у вузлах. Процес розбиття триває до того часу, поки всі вузли наприкінці всіх гілок будуть оголошені листям, тобто підмножиною об'єктів, що задовольняють усім правилам гілки, яка закінчується цим листом. Оголошення вузла листом може статися, коли він міститиме єдиний об'єкт або об'єкти лише одного класу, або ж після досягнення певної умови зупинки, наприклад, мінімально допустимої кількості прикладів у вузлі або максимальної глибини дерева, яка є мірою того, скільки розколів може зробити дерево, перш ніж дійти прогнозу. Для вибору найкращого підходу ми використовували три варіанти дерев рішень: з максимальною глибиною 4; 20 та 100.

Алгоритм k-найближчих сусідів є одним із найпростіших алгоритмів машинного навчання. Щоб

зробити прогноз для нової вибірки даних, алгоритм знаходить найближчий до нього навчальний набір даних, тобто знаходить його «найближчих сусідів». У найпростішому випадку алгоритм k-найближчих сусідів розглядає лише одного найближчого сусіда — точку навчальної множини, найближчу до точки, для якої ми хочемо отримати прогноз. Якщо враховується більше одного сусіда, для присвоєння мітки використовується найпоширеніший клас, тобто вибирається клас, який набрав більшість серед k-найближчих сусідів. У разі багатокласової класифікації, як у нашому випадку з 3 класами (норма, апное, гіпноное), підраховується кількість сусідів, що належать до кожного класу, і визначається найбільш поширений клас. Класифікатор k-найближчих сусідів враховує два важливі параметри: кількість сусідів і міру відстані між точками даних. Ми застосували та порівняли результати наступних налаштувань класифікатора k найближчих сусідів: кількість сусідів — 10 та 30, варіації міри відстані — евклідова відстань, квадрат оберненої евклідової відстані, косинусна відстань, відстань Мінковського.



Таблиця І — Порівняння ЕФЕКТИВНОСТІ ЗАСТОСУВАННЯ МЕТОДІВ МАШИННОГО НАВЧАННЯ ДО ЗАДАЧІ ВИЯВЛЕННЯ АПНОЕ СНУ: % ВІРНО ВИЗНАЧЕНИХ ВИПАДКІВ ПРИ КЛАСИФІКАЦІЇ НА 3 КЛАСИ (У ДУЖКАХ % ВІРНО ВИЗНАЧЕНИХ ВИПАДКІВ ДЛЯ КЛАСІВ “НОРМА”, “АПНОЕ” ТА “ГІПОПНОЕ”)

#	Метод машинного навчання	25 параметрів, ЕКГ	9 параметрів, ЕКГ	13 параметрів, ЕЕГ	22 параметри, 9 ЕКГ+13 ЕЕГ
1	Дерева рішень	98 (98, 99, 97)	97,5 (97, 99, 96)	87,6 (84, 94, 85)	97,5 (97, 99, 96)
2	Лінійний дискримінантний аналіз	99 (99, 100, 98)	98,0 (99, 100, 95)	86,2 (75, 93, 91)	95,4 (94, 94, 97)
3	Квадратичний дискримінантний аналіз	-	97,7 (96, 100, 97)	84,8 (70, 90, 94)	94,4 (91, 94, 98)
4	Метод опорних векторів (лінійна функція ядра)	99,1 (100, 100, 97)	98,6 (99, 99, 97)	87,5 (76, 94, 93)	96,2 (97, 94, 98)
5	Метод опорних векторів (квадратична функція ядра)	99 (100, 100, 99)	99 (99, 99, 98)	<b>91,9</b> <b>(87, 98, 91)</b>	97,5 (99, 94, 99)
6	Метод опорних векторів (кубічна функція ядра)	99,7 (99, 100, 99)	99,1 (99, 99, 99)	89,2 (86, 91, 90)	97,5 (99, 94, 99)
7	Метод опорних векторів (гаусівська функція ядра)	99 (99, 100, 99)	98,7 (98, 100, 99)	88,3 (81, 93, 92)	94,6 (99, 89, 96)
8	Метод k найближчий сусідів (кількість сусідів – 1, евклідова відстань)	99,6 (99, 100, 99)	98,9 (99, 100, 98)	87,2 (83, 91, 88)	96,6 (98, 94, 97)
9	Метод k найближчий сусідів (кількість сусідів – 10, евклідова відстань)	99,7 (100, 100, 99)	98,9 (99, 99, 98)	87,6 (82, 91, 87)	96,9 (98, 94, 98)
10	Метод k найближчий сусідів (кількість сусідів – 30, евклідова відстань)	94 (100, 86, 95)	97,6 (99, 98, 96)	84,1 (70, 94, 88)	89,8 (87, 94, 89)
11	Метод k найближчий сусідів (кількість сусідів – 10, косинусна відстань)	99,5 (100, 100, 99)	98,1 (99, 99, 96)	86,1 (81, 91, 86)	96,5 (99, 94, 96)
12	Метод k найближчий сусідів (кількість сусідів – 10, відстань Мінковського)	99,7 (100, 100, 99)	98,6 (99, 98, 98)	87,2 (82, 91, 88)	96,2 (97, 94, 98)
13	Зважений метод k найближчий сусідів (кількість сусідів – 10, квадрат оберненої евклідової відстані)	<b>99,9</b> <b>(100, 100, 99)</b>	99,1 (99, 99, 99)	88,5 (81, 93, 92)	96,9 (97, 94, 99)
14	Ансамблеве навчання (беггінг дерев рішень, кількість моделей — 30)	99,6 (99, 100, 99)	<b>99,4</b> <b>(99, 99, 99)</b>	91,5 (86, 98, 91)	98,6 (99, 98, 99)
15	Ансамблеве навчання з випадковою підмножиною ознак, дискримінантний аналіз (кількість моделей — 30)	98,9 (99, 100, 97)	96,0 (99, 100, 89)	87,2 (73, 99, 89)	97,0 (98, 100, 93)
16	Ансамблеве навчання з випадковою підмножиною ознак, метод k найближчий сусідів (кількість моделей — 30)	99,4 (99, 99, 99)	98,9 (99, 99, 97)	87,6 (81, 94, 88)	<b>99,1</b> <b>(99, 99, 98)</b>

Метод дискримінантного аналізу передбачає, що дані з різних класів мають різні багатовимірні гаусівські розподіли та використовує теорему Байєса для оцінки ймовірності приналежності до певного класу. Ми використовували лінійний та квадратичний дискримінантний аналіз.

Метод опорних векторів на основі набору навчальних даних знаходить гіперплощину, яка найкраще розділяє між собою два класи навчальних даних. Така гіперплощина є границею, що має максимальну відстань до різних класів навчальних даних. Границя знаходиться таким чином, щоб максимізувати відстань до найближчих точок даних усіх класів. Найближчі точки до роздільної поверхні називають опорними векторами. Ми застосували та порівняли результати наступних налаштувань класифікатора на основі методу опорних векторів: лінійна функція ядра; квадратична функція ядра; кубічна функція ядра; гаусівська функція ядра з різним масштабуванням.

Ансамблеві методи машинного навчання передбачають навчання кількох слабких моделей для вирішення одного завдання та їх об'єднання для отримання кращих результатів. Реалізовані методи ансамблевого навчання включали в себе алгоритми бустингу та беггінгу дерев рішень та ансамблеве навчання з випадковою підмножиною ознак для дискримінантного аналізу та методу k найближчих сусідів з кількістю моделей, що дорівнювала 30.

### III. РЕЗУЛЬТАТИ ТА ОБГОВОРЕННЯ

У Таблиці 1 наведено порівняння ефективності застосування методів машинного навчання до задачі виявлення епізодів апное/гіпопное сну. Наведені значення відповідають загальному відсотку правильно визначених випадків для трьох класів. Також окремо в дужках вказується чутливість — відсоток правильно визначених випадків для кожного класу «норма», «апное» та «гіпопное» (частка вірно визначених об'єктів класу до загальної кількості об'єктів класу, помножена на 100%). Досліджуваний набір даних містить невелику кількість сигналів для навчання (267 для класу “норма”, 258 для класу “апное” та 273 для класу “гіпопное”), тому доцільно застосувати підхід перехресної перевірки (кросвалідації) для оцінки точності класифікації, розділивши дані на 5 частин та використовуючи 80% даних для навчання і 20% даних для тестування. На кожній з п'яти ітерацій чотири частини даних використовувалися для навчання, а одна використовувалася для тестування. Оскільки для тестування на різних ітераціях використовується кожна з п'яти частин даних, як результат ми оцінюємо середню точність класифікації методу машинного навчання.

Перший вектор ознак, представлений у Таблиці 1, містить 25 параметрів варіабельності ритму серця, отриманих для послідовності RR інтервалів, визначеної за ЕКГ сигналом. У другому векторі ознак залишено 9 параметрів ВРС, розподіли яких найменше





перекривалися для класів «норма», «апное» та «гіпноное». Третій вектор ознак містить 13 параметрів, розрахованих за даними електричної активності мозку. Четвертий вектор ознак містить комбінацію 9 параметрів ВРС та 13 параметрів ЕЕГ.

Найкращі результати класифікації сигналів «норма», «апное» та «гіпноное» отримано для моделі, тренуваної з використанням 25 параметрів ВРС та зваженого методу  $k$  найближчих сусідів: загальний відсоток правильно визначених випадків для всіх трьох класів склав 99,9% (797 правильно визначених випадків з 798, 1 сигнал з класу «гіпноное» помилково віднесено до класу «апное»). Всі інші класифікатори, наведені у Табл.1, також показали дуже високу ефективність розпізнавання сигналів за 25 показниками ВРС, що свідчить про високу прогностичну цінність цього набору ознак до розпізнавання станів апное та гіпноное сну.

При зменшенні кількості параметрів ВРС до 9 найкращий результат машинного навчання досягнуто з використанням ансамблевого навчання, а саме беггінгу дерев рішень та 30 моделей у ансамблі: загальний відсоток правильно визначених випадків для всіх трьох класів склав 99,4% (793 правильно визначені випадки з 798, для класу «норма» правильно визначено 265 випадків з 267, для класу «апное» — 257 випадків з 258, для класу «гіпноное» — 271 випадок з 273).

Використання окремо взятих параметрів ЕЕГ у якості ознак для класифікації сигналів «норма», «апное» та «гіпноное» показало гірші результати порівняно з окремо взятими параметрами ВРС. У цьому випадку найкращий результат машинного навчання досягнуто з використанням методу опорних векторів з квадратичною функцією ядра: загальний відсоток правильно визначених випадків для всіх трьох класів склав 91,9% (733 правильно визначені випадки з 798, для класу «норма» правильно визначено 231 випадок з 267, для класу «апное» — 253 випадки з 258, для класу «гіпноное» — 249 випадків з 273). При цьому найгірше розпізнавалися сигнали, що відповідали

стану норми і у 27 випадках їх було віднесено до стану гіпноное, а у 9 випадках — до стану апное сну.

Комбінація параметрів ВРС та ЕЕГ дала найкращу точність 99.1%, але результати порівняні з використанням лише окремо взятих параметрів ВРС.

Отримані результати свідчать про те, що параметри ВРС дають змогу розпізнати апное та гіпноное сну з вищою точністю, ніж параметри ЕЕГ. Але проведені нами дослідження показали, що безсумнівно сигнал ЕЕГ відображає ознаки апное сну і параметри знайдені за відношенням потужностей ритмів ЕЕГ, показником Херста, фрактальною розмірністю Хігучі і ентропією вибірки для досліджуваних ЕЕГ сигналів можуть використовуватися для визначення апное сну окремо чи комбіновано з параметрами ВРС.

Напрямок наших подальших досліджень є дослідження зв'язку між стадіями сну та станами апное/гіпноное сну за даними ЕЕГ.

#### ВИСНОВКИ

Кількісний аналіз послідовності RR інтервалів у часовій та частотній областях, а також у спектрально-часовій області та з використанням вейвлет-аналізу, дозволив відібрати ознаки для розпізнавання епізодів апное сну за даними ЕКГ сигналу. Найкращий результат класифікації сигналів «норма», «апное» та «гіпноное» отримано для моделі, натренованої з використанням 25 параметрів ВРС — 797 правильно визначених випадків з 798. Зменшення кількості параметрів до 9, розподіли яких найменше перекривалися для розглянутих класів, також дозволило отримати гарний результат розпізнавання станів апное/гіпноное сну — 733 правильно визначені випадки з 798.

В роботі також проаналізовано ефективність використання параметрів ЕЕГ сигналу для розпізнавання апное. І хоча результати поступаються результатам, отриманим за допомогою параметрів ВРС, 91,9% сигналів було класифіковано вірно за даними ЕЕГ, що підтверджує реакцію мозку на тривалі дихальні паузи протягом сну.

#### ПЕРЕЛІК ПОСИЛАНЬ

- [1] S. F. Quan and B. J. Gersh, "Cardiovascular Consequences of Sleep-Disordered Breathing: Past, Present and Future: Report of a Workshop From the National Center on Sleep Disorders Research and the National Heart, Lung, and Blood Institute", *Circulation*, vol. 109, no. 8, pp. 951–957, Mar. 2004. DOI: [10.1161/01.CIR.0000118216.84358.22](https://doi.org/10.1161/01.CIR.0000118216.84358.22)
- [2] W. R. Ruehland, P. D. Rochford, F. J. O'Donoghue, R. J. Pierce, P. Singh, and A. T. Thornton, "The New AASM Criteria for Scoring Hypopneas: Impact on the Apnea Hypopnea Index", *Sleep*, vol. 32, no. 2, pp. 150–157, Feb. 2009. DOI: [10.1093/sleep/32.2.150](https://doi.org/10.1093/sleep/32.2.150)
- [3] X. Li, A. Al-Ani, and S. H. Ling, "Feature Selection for the Detection of Sleep Apnea using Multi-Bio Signals from Overnight Polysomnography", in *2018 40th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, Honolulu, HI, 2018, pp. 1444–1447. DOI: [10.1109/EMBC.2018.8512585](https://doi.org/10.1109/EMBC.2018.8512585)
- [4] T. Penzel, M. Glos, C. Schobel, M. Sebert, B. Diecker, and I. Fietze, "Revised recommendations for computer-based sleep recording and analysis", in *2009 Annual International Conference of the IEEE Engineering in Medicine and Biology Society, Minneapolis, MN, 2009*, pp. 7099–7101. DOI: [10.1109/IEMBS.2009.5332903](https://doi.org/10.1109/IEMBS.2009.5332903)
- [5] D. Álvarez-Estévez and V. Moret-Bonillo, "Identification of Electroencephalographic Arousals in Multichannel Sleep Recordings", *IEEE Transactions on Biomedical Engineering*, vol. 58, no. 1, pp. 54–63, Jan. 2011. DOI: [10.1109/TBME.2010.2075930](https://doi.org/10.1109/TBME.2010.2075930)
- [6] F. Liu, X. Zhou, Z. Wang, T. Wang, H. Ni, and J. Yang, "Identifying Obstructive Sleep Apnea by Exploiting Fine-Grained BCG Features Based on Event Phase Segmentation", in *2016 IEEE 16th International Conference on Bioinformatics and Bioengineering (BIBE)*, Taichung, Taiwan, 2016, pp. 293–300. DOI: [10.1109/BIBE.2016.45](https://doi.org/10.1109/BIBE.2016.45)
- [7] A. R. Hassan, "A comparative study of various classifiers for automated sleep apnea screening based on single-lead electrocardiogram", in *2015 International Conference on Electrical & Electronic Engineering (ICEEE)*, Rajshahi, Bangladesh, 2015, pp. 45–48. DOI: [10.1109/ICEEE.2015.7428288](https://doi.org/10.1109/ICEEE.2015.7428288)



- [8] K. Zhu, "Overnight heart rate variability in patients with obstructive sleep apnoea: A time and frequency domain study", *Clinical and Experimental Pharmacology and Physiology*, vol. 39, no. 11, pp. 901–908, Oct. 2012. DOI: [10.1111/1440-1681.12012](https://doi.org/10.1111/1440-1681.12012)
- [9] J. Foussier, P. Fonseca, X. Long, B. Misgeld, and S. Leonhardt, "Combining HRV features for automatic arousal detection", in *Computing in Cardiology*, pp. 1003–1006, 2013. URL: <https://ieeexplore.ieee.org/abstract/document/6713549>
- [10] M. J. Lado, X. A. Vila, L. Rodríguez-Liñares, A. J. Méndez, D. N. Olivieri, and P. Félix, "Detecting Sleep Apnea by Heart Rate Variability Analysis: Assessing the Validity of Databases and Algorithms", *Journal of Medical Systems*, vol. 35, no. 4, pp. 473–481, Oct. 2009. DOI: [10.1007/s10916-009-9383-5](https://doi.org/10.1007/s10916-009-9383-5)
- [11] J. Gubbi, A. Khandoker, and M. Palaniswami, "Classification of sleep apnea types using wavelet packet analysis of short-term ECG signals", *Journal of Clinical Monitoring and Computing*, vol. 26, no. 1, pp. 1–11, Dec. 2011. DOI: [10.1007/s10877-011-9323-z](https://doi.org/10.1007/s10877-011-9323-z)
- [12] N. Sadr and P. de Chazal, "A fast approximation method for principal component analysis applied to ECG derived respiration for OSA detection", in *2016 38th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, Orlando, FL, USA, 2016, pp. 6198–6201. DOI: [10.1109/EMBC.2016.7592144](https://doi.org/10.1109/EMBC.2016.7592144)
- [13] C. Varon, D. Testelmans, B. Buyse, J. A. K. Suykens, and S. Van Huffel, "Sleep apnea classification using least-squares support vector machines on single lead ECG", in *2013 35th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, Osaka, 2013, pp. 5029–5032. DOI: [10.1109/EMBC.2013.6610678](https://doi.org/10.1109/EMBC.2013.6610678)
- [14] K. Ivanko, N. Ivanushkina, and A. Rykhalska, "Identifying episodes of sleep apnea in ECG by machine learning methods", in *2020 IEEE 40th International Conference on Electronics and Nanotechnology (ELNANO)*, Kyiv, Ukraine, 2020, pp. 588–593. DOI: [10.1109/ELNANO50318.2020.9088749](https://doi.org/10.1109/ELNANO50318.2020.9088749)
- [15] G. Zhou, Y. Pan, J. Yang, X. Zhang, X. Guo, and Y. Luo, "Sleep Electroencephalographic Response to Respiratory Events in Patients With Moderate Sleep Apnea–Hypopnea Syndrome", *Frontiers in Neuroscience*, vol. 14, Apr. 2020. DOI: [10.3389/fnins.2020.00310](https://doi.org/10.3389/fnins.2020.00310)
- [16] S. Saha, A. Bhattacharjee, and S. A. Fattah, "Automatic detection of sleep apnea events based on inter-band energy ratio obtained from multi-band EEG signal", *Healthcare Technology Letters*, vol. 6, no. 3, pp. 82–86, Jun. 2019. DOI: [10.1049/htl.2018.5101](https://doi.org/10.1049/htl.2018.5101)
- [17] X. Zhao, "Classification of sleep apnea based on EEG sub-band signal characteristics", *Scientific Reports*, vol. 11, no. 1, Mar. 2021. DOI: [10.1038/s41598-021-85138-0](https://doi.org/10.1038/s41598-021-85138-0)
- [18] G. Zhou, Y. Pan, J. Yang, X. Zhang, X. Guo, and Y. Luo, "Sleep Electroencephalographic Response to Respiratory Events in Patients With Moderate Sleep Apnea–Hypopnea Syndrome", *Frontiers in Neuroscience*, vol. 14, Apr. 2020. DOI: [10.3389/fnins.2020.00310](https://doi.org/10.3389/fnins.2020.00310)
- [19] R. Jayaraj and J. Mohan, "Classification of Sleep Apnea Based on Sub-Band Decomposition of EEG Signals", *Diagnostics*, vol. 11, no. 9, p. 1571, Aug. 2021. DOI: [10.3390/diagnostics11091571](https://doi.org/10.3390/diagnostics11091571)
- [20] A. L. Goldberger, "PhysioBank, PhysioToolkit, and PhysioNet: Components of a New Research Resource for Complex Physiologic Signals", *Circulation*, vol. 101, no. 23, Jun. 2000. DOI: [10.1161/01.CIR.101.23.e215](https://doi.org/10.1161/01.CIR.101.23.e215)
- [21] T. Penzel, G. Moody, R. Mark, A. Goldberger, and J. Peter, "The apnea-ECG database", in *Computers in Cardiology 2000. Vol.27 (Cat. 00CH37163)*, Cambridge, MA, USA, 2000, pp. 255–258. DOI: [10.1109/CIC.2000.898505](https://doi.org/10.1109/CIC.2000.898505)
- [22] MIT-BIH Polysomnographic Database. URL: <https://physionet.org/content/slpdb/1.0.0/>
- [23] Y. Ichimaru and G. Moody, "Development of the polysomnographic database on CD-ROM", *Psychiatry and Clinical Neurosciences*, vol. 53, no. 2, pp. 175–177, Apr. 1999. DOI: [10.1046/j.1440-1819.1999.00527.x](https://doi.org/10.1046/j.1440-1819.1999.00527.x)
- [24] Task Force of the European Society of Cardiology the North American Society of Pacing Electrophysiology, "Heart Rate Variability: Standards of Measurement, Physiological Interpretation, and Clinical Use", *Circulation*, vol. 93, no. 5, pp. 1043–1065, Mar. 1996. DOI: [10.1161/01.CIR.93.5.1043](https://doi.org/10.1161/01.CIR.93.5.1043)
- [25] N. L. Chamberlin, "Brain circuitry mediating arousal from obstructive sleep apnea", *Current Opinion in Neurobiology*, vol. 23, no. 5, pp. 774–779, Oct. 2013. DOI: [10.1016/j.conb.2013.06.001](https://doi.org/10.1016/j.conb.2013.06.001)
- [26] S. Lahmiri, "Generalized Hurst exponent estimates differentiate EEG signals of healthy and epileptic patients", *Physica A: Statistical Mechanics and its Applications*, vol. 490, pp. 378–385, Jan. 2018. DOI: [10.1016/j.physa.2017.08.084](https://doi.org/10.1016/j.physa.2017.08.084)
- [27] S. Kesić and S. Z. Spasić, "Application of Higuchi's fractal dimension from basic to clinical neurophysiology: A review", *Computer Methods and Programs in Biomedicine*, vol. 133, pp. 55–70, Sep. 2016. DOI: [10.1016/j.cmpb.2016.05.014](https://doi.org/10.1016/j.cmpb.2016.05.014)
- [28] R. Bhavsar, N. Helian, Y. Sun, N. Davey, T. Steffert, and D. Mayor, "Efficient Methods for Calculating Sample Entropy in Time Series Data Analysis", *Procedia Computer Science*, vol. 145, pp. 97–104, Jan. 2018. DOI: [10.1016/j.procs.2018.11.016](https://doi.org/10.1016/j.procs.2018.11.016)

Надійшла до редакції 02 лютого 2022 р.

Прийнята до друку 18 квітня 2022 р.



# Detection of Episodes of Sleep Apnea and Hypopnea in ECG and EEG Signals by Machine Learning

A. K. Rykhalska<sup>f</sup>, ORCID [0000-0001-6286-4806](https://orcid.org/0000-0001-6286-4806)

K. O. Ivanko, PhD Assoc.Prof., ORCID [0000-0002-3842-2423](https://orcid.org/0000-0002-3842-2423)

N. H. Ivanushkina, PhD Assoc.Prof., ORCID [0000-0001-8389-7906](https://orcid.org/0000-0001-8389-7906)

Department of Electronic Engineering

National Technical University of Ukraine «Igor Sikorsky Kyiv Polytechnic Institute» ROR [00syn5v21](https://ror.org/00syn5v21)

Kyiv, Ukraine

D. O. Ivanko, PhD, ORCID [0000-0003-2442-8637](https://orcid.org/0000-0003-2442-8637)

Department of Electric Power Engineering

Norwegian University of Science and Technology ROR [05xg72x27](https://ror.org/05xg72x27)

Trondheim, Norway

**Abstract** — The article is devoted to the application of machine learning methods for computerized detection of sleep apnea episodes based on the analysis of single-channel signals of the electrocardiogram (ECG) and electroencephalogram (EEG). To study the possibilities of machine learning to detect apnea based on ECG and EEG analysis, we used Apnea-ECG database and MIT-BIH polysomnographic database from PhysioNet, which contain annotations to each minute of records indicating the presence or absence of apnea/hypopnea at the current time. In order to apply machine learning methods to the problem of automated detection of sleep apnea/hypopnea episodes in ECG and EEG signals, long-term polysomnograms available in MIT-BIH polysomnographic database were segmented according to annotations into shorter sections lasting 30 seconds each. The study used 267 segments lasting 30 seconds for the class "norm", 258 segments for the class "apnea" and 273 segments for the class "hypopnea", a total of 798 simultaneous ECG and EEG recordings.

The aim of this work is to identify and compare informative signs of sleep apnea episodes in terms of heart rate variability (HRV) and brain electrical activity, as well as the choice of classification methods that provide the highest accuracy for this task. Features of cardiogram in time and frequency domains, spectral-temporal and wavelet characteristics, as well as parameters of EEG signals based on energy ratio of EEG rhythms, Hearst index, Higuchi fractal dimension and sample entropy for EEG signals are considered. Using different sets of features, the accuracy of classifiers based on decision trees, discriminant analysis, support vector machines, k-nearest neighbor method, and ensemble training was determined. Based on this, combination of features and classifiers is proposed, which provides the highest accuracy of recognition of sleep apnea episodes according to single-channel ECG and EEG signals, taken separately and in the case of a combination of their features.

The best results of classification of signals "norm", "apnea" and "hypopnea" were obtained for the model trained using weighted method k nearest neighbors with 25 features of HRV: the total percentage of correctly identified cases for three classes was 99.9% (797 correctly identified cases of 798). By reducing the number of HRV parameters to 9, the best machine learning result was achieved using the bagging ensemble algorithm with 30 decision trees: the total percentage of correctly identified cases for all three classes was 99.4% (793 correctly identified cases from 798: for "norm" — 265 cases from 267, for "apnea" — 257 cases from 258, for "hypopnea" — 271 cases from 273). The use of EEG parameters as features for apnea/hypopnea recognition showed worse results compared to HRV parameters. In this case, the best result of machine learning was achieved using support vector machines with quadratic kernel function: the total percentage of correctly identified cases for three classes was 91.9% and the signals corresponding to norm were most badly recognized (27 cases were classified as hypopnea, and in 9 cases — as sleep apnea). The combination of HRV and EEG parameters gave the best accuracy of 99.1%, but the results are comparable to using only HRV parameters. The obtained results indicate that HRV parameters allow recognizing sleep apnea and hypopnea with higher accuracy than EEG parameters, but EEG signal undoubtedly reflects signs of sleep apnea/hypopnea and also can be used for apnea recognition.

**Keywords** — *sleep apnea and hypopnea; heart and brain electrical activity; heart rate variability; spectral analysis; spectral-temporal analysis; wavelet analysis; fractal analysis; entropy; classification; machine learning.*

