

УДК 57.087

**Удовиченко Є.Є.**Національний технічний університет України  
«Київський політехнічний інститут імені Ігоря Сікорського»**Попов А.О.**Національний технічний університет України  
«Київський політехнічний інститут імені Ігоря Сікорського»**Чайковський І.А.**

Інститут кібернетики імені В.М. Глушкова Національної академії наук України

## МУЛЬТИКЛАСОВА КЛАСИФІКАЦІЯ КАРТ РОЗПОДІЛУ ГУСТИНИ СТРУМУ У МІОКАРДІ

Магнітокардіографія (МКГ) – одна з основних методик визначення стану серця і діагностики серцево-судинних захворювань. Основною перевагою МКГ є наявність багатовимірних даних про роботу серця, що дає змогу застосовувати більш складні методи аналізу даних для діагностики. У роботі розглянуто представлення даних у вигляді дискретних зображень – карт розподілу густини струму. Оглянуто та реалізовано три методи мультикласової класифікації таких карт:  $k$ -NN, метод опорних векторів, дерева прийняття рішень. Є результати застосування класифікаторів до 880 карт розподілу густини струму, було отримано такі показники: точність класифікації для всіх класифікаторів: 0,55–0,7, специфічність: 0,93–0,97, селективність: 0,18–0,39.

**Ключові слова:** магнітокардіографія, карти розподілу густини струму, діагностика серцево-судинних захворювань, міокард,  $k$ -NN, метод опорних векторів, дерева прийняття рішень.

**Аналіз останніх досліджень і публікацій.** Магнітокардіографія є одним з найпрогресивніших інструментів для діагностики і дослідження серцевих захворювань, наприклад, таких як ішемічна хвороба серця. Завдяки тому, що магнітокардіографія є неінвазивним безконтактним методом з високою чутливістю, вона є ефективним і зручним у використанні для лікаря інструментом діагностики [1]. Аналіз МКГ-даних використовується для діагностики ішемічної хвороби серця [2], синдрому Вольфа-Паркінсона-Уайта [3] та інших захворювань. Карта розподілу струмів у серці, що включає в себе морфологічну інформацію про серце, може бути отримана шляхом проектування двовимірної (2-D) карти векторів, що розраховується з сигналів магнітокардіографа, на тривимірну (3-D) стандартну модель серця, що є спільною для всіх дорослих людей [4].

Для візуалізації густини струму перш за все вимірюється вектор локального магнітного поля, згенерованого струмом, що протікає всередині тканини, і знаходиться ротор цього поля для розрахунку щільності струму. Магнітне поле вимірюється за допомогою SQUID, така методика є за своєю суттю неінвазивною і безконтактною, що запобігає виникненню артефактів, пов'язаних з

недостатньою надійністю контактів між електродами і шкірою. Таким чином, за умови подальшого розв'язання оберненої задачі можна точно отримати детальну інформацію про щільність струму всередині тіла з подальшою її візуалізацією.

**Постановка завдання.** Задачею дослідження є оцінка різних методів класифікації під час їх застосування для аналізу карт розподілу густини струму й автоматизованої постановки діагнозу на основі такого аналізу.

1. Підготовка даних

1.1 Формування карт розподілу густини струму (CDDM) з МКГ-даних.

Одним із підходів до вивчення магнітного поля у серці людини є аналіз карт розподілу густини струму. Для просторової реєстрації даних у магнітокардіографії використовуються спеціальні точки, що є вузлами перетину квадратної сітки, що мають прив'язку до анатомічних орієнтирів на грудній клітці. Оскільки кількість вузлів обмежена, для локалізації областей патологічної активності міокарда і для побудови миттєвих карт розподілу магнітного поля у серці застосовується інтерполяція функції двох змінних у точках за межами стандартної сітки. Іншими словами, ґрунтуючись на усереднених МКГ кривих,




Рис. 1. Карта розподілу густини струму здорової людини (а) та хворого на ішемічну хворобу серця (б)




Рис. 2. Карта розподілу густини струму

використовуючи алгоритми двовимірної інтерполяції, будуються миттєві карти розподілу магнітного поля. Потім, застосовуючи алгоритм розв'язки оберненої задачі, карти розподілу магнітного поля можуть бути перетворені на миттєві карти розподілу густини струму (CDDM). Таким чином, кожна CDDM формується шляхом обробки векторів густини струму, отриманих за допомогою МКГ. Кожна CDDM – це дискретне зображення у відтинках сірого розміром  $M \times N$  пікселів, у якому білий колір відповідає найбільшій яскравості (рис. 1). Таким чином, яскравість зображення відповідає величині густини струму у відповідній точці. CDDM будуються для визначених моментів часу з деяким кроком (до 10 мс) протягом Т-зубця QT – інтервалу електрокардіограми. Це дає можливість зіставлення даних електрокардіографії (ЕКГ) з відповідними значеннями, порашованими з карт розподілу густини струму [5].

1.1. Формування характеристик карт розподілу густини струму в міокарді

У цьому дослідженні кожна CDDM ділиться на чотири рівні частини (чверті), як показано на рис. 2. Кожен елемент CDDM має два параметри: яскравість, що відповідає густині струму у відповідній точці, та кут вектора магнітного поля в кожній точці. Для цих двох наборів даних у кожній чверті були обчислені такі характеристики: середнє значення елементів, дисперсія, ексцес та асиметрія елементів.

Оскільки кожна CDDM ділиться на чотири частини, для яких обчислюються вісім значень (чотири для яскравості і чотири для кутів), кожна карта описується 32-ма характеристиками.

## 2. Опис методик класифікації

У цьому дослідженні було використано три методики класифікації різної міри складності: k-NN, SVM і дерева прийняття рішень.

### 2.1. k-NN

Одним із методів класифікації є правило k-найближчих сусідів (k-NN). Він класифікує кожен новий об'єкт відповідно до групи більшості своїх k-найближчих сусідів у навчальній вибірці. Незважаючи на свою простоту, метод k-NN часто дає непогані результати, а в певних областях, особливо у правильній комбінації з попередньою обробкою даних, точність класифікації з допомогою цього методу є досить високою.

Результат класифікації з допомогою k-NN істотно залежить від метрики, використовуваної для обчислення відстаней між різними векторами ознак. У [6] показано, що використання різних метрик для k-NN класифікації зменшувало частоту помилок у разі використання класифікації для вирішення різних завдань, таких як розпізнавання облич, розпізнавання усного мовлення, категоризація текстів тощо. У тому ж дослідженні було показано, що класифікатор k-NN з правильно підбраною метрикою показує кращі результати

навіть порівняно з SVM, що використовувався для тих же завдань класифікації. У попередніх роботах [7, 8] було використано k-NN класифікатор з різними метриками для завдання класифікації CDDM людей з різним станом серцево-судинної системи.

Розглянемо  $X$  як вектор характеристик CDDM розмірністю 1 на 32, що класифікується, а  $Y$  як вектор характеристик кожної CDDM у навчальній вибірці. У нашому дослідженні були побудовані k-NN класифікатори з чотирма різними метриками. Для класифікатора з евклідовою метрикою відстань між двома точками  $X_s$  і  $Y_t$ , координатами яких є значення  $X$  і  $Y$  відповідно, визначається таким чином:

$$d_{st}^2 = (x_s - y_t)(x_s - y_t)' \quad (1)$$

Для метрики Махаланобіса це значення визначається таким чином:

$$d_{st}^2 = (x_s - y_t)C^{-1}(x_s - y_t)', \quad (2)$$

де  $C$  – матриця коваріації.

Для метрики міських кварталів:

$$d_{st} = \sum_{j=1}^n |x_{sj} - y_{tj}|, \quad (3)$$

де  $n$  – довжина векторів  $X$  та  $Y$ , котра у нашому разі дорівнює 32 – кількості характеристик.

Для метрики Чебишева:

$$d_{st} = \max_j \{|x_{sj} - y_{tj}|\}. \quad (4)$$

## 2.2. Метод опорних векторів (SVM)

Основна ідея методу – переведення вихідних векторів у простір більш високої розмірності і пошук розділяючої гіперплощини з максимальним зазором у цьому просторі. Дві паралельні гіперплощини будуються по обидва боки гіперплощини, що розділяє класи. Розділяючою гіперплощиною буде гіперплощина, що максимізує відстань до двох паралельних гіперплощин. Алгоритм припускає, що чим більша різниця або відстань між цими паралельними гіперплощинами, тим менше буде середня помилка класифікатора.

Метод опорних векторів – метод бінарної класифікації, тому кожна точка може належати лише одному з двох класів. Тоді можна припустити, що точки мають вигляд  $\{(x_1, c_1), (x_2, c_2), \dots, (x_n, c_n)\}$ , де  $c_i$  приймає значення 1 або -1 залежно від того, до якого класу належить точка. Тоді рівняння розділяючої гіперплощини матиме вигляд:

$$w \cdot x_i - b = 0, \quad (5)$$

де вектор  $w$  – перпендикуляр до розділяючої гіперплощини.

Проблема побудови оптимальної розділяючої гіперплощини зводиться до мінімізації  $\|w\|$  за умови

$c_i (w \cdot x_i - b) \geq 1, 1 \leq i \leq n$ , оскільки потрібно виключити з полоси між гіперплощинами всі точки.

За теоремою Куна-Таккера ця задача еквівалентна двоїтій задачі знаходження сідлової точки функції Лагранжа, котра, своєю чергою, зводиться до еквівалентної задачі квадратичного програмування, котра містить лише двоїсті змінні:

$$\begin{cases} -L(\lambda) = -\sum_{i=1}^n \lambda_i + \frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n \lambda_i \lambda_j c_i c_j (x_i \cdot x_j) \rightarrow \min_{\lambda} \\ \lambda_i \geq 0, \quad 1 \leq i \leq n \\ \sum_{i=1}^n \lambda_i c_i = 0 \end{cases} \quad (6)$$

Після розв'язання такої задачі стає можливим знаходження  $w$  і  $b$ :

$$w = \sum_{i=1}^n \lambda_i c_i x_i \quad (7)$$

$$b = w \cdot x_i - c_i, \quad \lambda_i > 0 \quad (8)$$

Вищенаведені формули справедливі для лінійної класифікації. Однак у цьому дослідженні було побудовано ще класифікатори на основі ядрових функцій, суть котрих полягає у заміні кожного скалярного добутку на нелінійну ядрову функцію. Зокрема, були використані такі ядрові функції:

Многочленна (2 і 3 порядку):  $k(x_i, x_j) = (x_i, x_j)^d$

Радіальна базисна функція Гаусса:

$$k(x_i, x_j) = \exp\left(-\frac{x_i - x_j^2}{2\sigma^2}\right)$$

Оскільки метод опорних векторів використовується для бінарної класифікації, для мультикласової класифікації було використано підхід один-проти-одного, за якого класифікація здійснюється за стратегією голосування «максимум перемагає», в якій кожен з бінарних класифікаторів відносить зразок до одного з двох класів, тоді голос за призначений клас збільшується на одиницю, остаточно клас із більшістю голосів визначає класифікацію зразка.

## 2.3. Дерева прийняття рішень

Бінарні дерева також називають двійковими, значить, що кожен вузол дерева у розбитті має тільки двох нащадків. Для побудови бінарного дерева прийняття рішення використовується метод CART. На кожному кроці побудови дерева правило, що формується у вузлі, ділить задану множину зразків на дві частини: частина, в якій виконується правило (правий нащадок), і частина, в якій правило не виконується (лівий нащадок). Для вибору правила розбиття на кожному кроці використовується оціночна функція якості моделі розбиття. За методом CART шукається такий варіант розбиття, за якого мінімальним буде значення такої функції:

$$Gini_{split} = N - \left( \frac{1}{L} \sum_{i=1}^n l_i^2 + \frac{1}{R} \sum_{i=1}^n r_i^2 \right), \quad (9)$$

де  $N$  – число елементів у вузлі-попереднику,  $L$ ,  $R$  – число елементів відповідно в лівому




Рис. 3. Параметри, що характеризують якість класифікації для кожного з класифікаторів

і правому нащадку,  $l_i$  і  $r_i$  – число елементів  $i$ -го класу в лівому/правому нащадку.

### 3. Експериментальні результати

У цьому дослідженні було використано 880 карт розподілу густини струму, по 80 для кожної з 11 груп стану серця, причому половина карт була використана для тренування класифікаторів і половина – для перевірки якості класифікації. Ці класи: здорові добровольці, спортсмени, хворі на ішемічну хворобу серця різного рівня складності (де IBS-1 – найлегший випадок хвороби, а IBS-3 – найтяжчий), пацієнти з ушкодженнями міокарда, жінки і чоловіки, хворі на мікросудинні (дифузні) розлади та хворі на гіпертрофію лівого шлуночка різного рівня складності (де Нурег-1 – найлегший випадок хвороби, а Нурег-3 – найтяжчий). Кожна з груп характеризується специфічною структурою карт розподілу густини струму. Для оцінки класифікації були розраховані такі параметри: чутливість (TPR), специфічність (SPC) і точність (PPV і ACC). Ці параметри визначаються таким чином:

$$TPR = \frac{TP}{P} \quad (10)$$

$$SPC = \frac{TN}{N} \quad (11)$$

$$PPV = \frac{TP}{TP + FP} \quad (12)$$

$$ACC = \frac{TP + TN}{P + N} \quad (13)$$

Де TP – кількість CDDM людей, що належать до «позитивного» класу, визначених правильно, TN – кількість CDDM людей, що належать до «негативного» класу, визначених правильно, P – загальна кількість CDDM людей, що належать до «позитивного» класу, N – загальна кількість CDDM людей, що належать до «негативного» класу. Ці формули були застосовані в оцінці класифікатора для кожної з груп станів серця, а потім були порашовані усереднені значення для кожного класифікатора (рис. 3).

Як видно з рис. 3, точність класифікації для всіх класифікаторів лежить у межах 0,55–0,7. При цьому найнижчою є точність класифікації з допомогою k-NN класифікаторів. Незалежно від обраної метрики вона є нижчою за точність класифікації з допомогою SVM і лиш використання метрики Махаланобіса дає змогу отримати дещо кращий результат порівняно з класифікацією за допомогою дерев прийняття рішень. Окрім того, слід зазначити, що специфічність для всіх класифікаторів є досить високою, а саме 0,93–0,97. Це свідчить про те, що всі класифікатори добре справляються із задачею класифікації зразків, що є «негативними», тобто не належать до класу, який є «позитивним» для кожної окремо взятої класифікації. Водночас селективність усіх класифікаторів є доволі низькою: вона варіюється від

0,18–0,3 для k-NN класифікаторів до 0,35–0,39 для SVN, що свідчить про проблеми саме з класифікацією зразків, котрі належать до «позитивного» класу у кожній класифікації. Як результат якраз це і впливає на зниження підсумкової точності класифікації.

**Висновки.** Як видно з результатів оцінки різних класифікаторів, точність класифікації є не досить високою – залежно від типу класифікатора вона варіюється від 0,55 до 0,65. При цьому характерним є те, що всі класифікатори мають доволі високу специфічність і низьку селективність. Це свідчить про те, що такі класифікатори не досить підходять для задач класифікації карт

розподілу густини струму. Однак у попередніх роботах було показано, що деякі із застосованих у цьому дослідженні класифікаторів непогано проявили себе у разі бінарної класифікації [7; 8]. Можливими шляхами покращення точності мультикласової класифікації є використання інших характеристик карти, котрі вираховуються для класифікації, або використання іншого, комплексного методу мультикласової класифікації, наприклад методу класифікації, оснований на кореляційному аналізі. З допомогою запропонованого методу вдалося досягнути точності класифікації у 95% для випадку розподілу карт на 14 класів [9].

#### Список літератури:

1. Chaikovsky I. et al. "Magnetocardiography in clinical practice: algorithms and technologies for data analysis". Medical Science 3–4, June 2011. pp. 21–38.
2. Tsukada K. et al. "Magnetocardiographic mapping characteristic for diagnosis of ischemic heart disease". Computers in Cardiology 2000. Cambridge, MA. Sept. 2000. pp. 505–508.
3. Geselowitz, David B. "Magnetocardiography: an overview". IEEE Transaction on Biomedical Engineering. Vol. BME-26. Sept. 1979. pp. 497–504.
4. Ogata K. et al. "Projecting cardiac-current images onto a 3-D standard heart model". Engineering in Medicine and Biology Society. 2003, Vol. 1. Sept. 2003. pp. 517–520.
5. Udovychenko Y., Popov A., Chaikovsky I. "Effective Surface Area of Current Density Distribution Maps". Electronics and Communications 2014, Vol. 19. No5(82). pp. 68–72.
6. Kilian Q. Weinberg, et al. "Distance Metric Learning for Large Margin Nearest Neighbor Classification". Journal of Machine Learning Research 10 (2009). Sept. 2009. pp. 207–244.
7. Udovychenko Y., et al. "k-NN Binary Classification of Heart Failures Using Myocardial Current Density Distribution Maps". Signal Processing Symposium (SPSymo). June 2015, pp. 98–102.
8. Udovychenko Y., Popov A., Chaikovsky I. "Binary Classification of Heart Failures Using k-NN with Various Distance Metrics". International Journal of Electronics and Telecommunications. 2015. vol. 61. no. 4. pp. 339-344.
9. Удовиченко С., Попов А., Чайковский І. Метод класифікації карт розподілу густини струму в міокарді, оснований на кореляційному аналізі. Вчені записки Таврійського національного університету імені В.І. Вернадського. 2018, том 29 (68), № 3.

#### МУЛЬТИКЛАССОВАЯ КЛАССИФИКАЦИЯ КАРТ РАСПРЕДЕЛЕНИЯ ПЛОТНОСТИ ТОКА В МИОКАРДЕ

*Магнитокардиография (МКГ) – одна из основных методов определения состояния сердца и диагностики сердечно-сосудистых заболеваний. Основным преимуществом МКГ является возможность предоставления данных, полученных с ее помощью в виде многомерных массивов. Это, в свою очередь, дает возможность применять более сложные методы анализа данных для диагностики. В работе рассмотрено предоставление данных в виде дискретных изображений – карт распределения плотности тока. Представлен обзор методов мультиклассовой классификации таких карт, а также представлена оценка эффективности каждого из классификаторов.*

**Ключевые слова:** магнитокардиография, карты распределения плотности тока, диагностика сердечно-сосудистых заболеваний, миокард, k-NN, метод опорных векторов, деревья принятия решений.

#### MULTICLASS CLASSIFICATION OF CURRENT DENSITY DISTRIBUTION MAPS

*Magnetocardiography (MCG) is one of the main methods for determining the heart state and diagnosis of cardiovascular diseases. The main advantage of MCG is ability to represent the data obtained with this technique in the form of multidimensional arrays. This, in its turn, makes it possible to apply more sophisticated data analysis methods for diagnostics. The paper considers the representation of data in the form of discrete images – current density distribution maps. An overview of the methods of multiclass classification of such maps is presented, as well as an assessment of the efficiency of each classifier.*

**Key words:** magnetocardiography, maps of current density distribution, cardiovascular disease diagnostics, myocardium, k-NN, method of reference vectors, decision tree.