

УДК 519.254

МАТЕМАТИЧЕСКИЕ МОДЕЛИ КЛАССИФИКАЦИИ МНОГОКАНАЛЬНЫХ СИГНАЛОВ ЭЛЕКТРИЧЕСКОГО ПОЛЯ СЕРДЦА

И. П. Полякова, Т. Б. Феофанова, Н. В. Лукьянова
(НЦ ССХ им. А. Н. Бакулева, МГИУ, г. Москва)

Предлагаются нейросетевые модели для понижения размерности массива данных, полученных при многоканальной регистрации электрокардиограммы. Для выявления во множестве входных данных существенных признаков применяется модель, основанная на алгоритме обучения без учителя. Для классификации сигнала используется нейронная сеть, основанная на алгоритмах самоорганизации. Проведена апробация предлагаемых моделей для определения локализации аномального пути проведения электрического импульса в сердце пациентов с синдромом предвозбуждения.

Ключевые слова: нейронные сети, обобщенный алгоритм Хебба, карты самоорганизации, многоканальные сигналы электрокардиограммы.

Введение

Наиболее признанным направлением в кардиологии и ведущим в диагностике различных заболеваний сердца является изучение деятельности сердца путем исследования его электрической активности. При возбуждении определенного участка сердца на его поверхности и в его тканях возникает разность потенциалов, закономерно меняющаяся по величине и направлению по мере того, как вовлекаются в возбуждение новые участки сердца. Биоэлектрическая активность разных отделов сердца возникает в строго определенной последовательности, повторяющейся в каждом сердечном цикле возбуждения. Возникающие при этом изменения зарядов поверхности сердца создают в окружающей сердце проводящей среде динамическое электрическое поле, регистрируемое с поверхности тела-проводника в виде переменной разности потенциалов.

Широко известный метод кардиологической диагностики — электрокардиография — основан на регистрации электрической активности сердца в определенных точках на поверхности тела человека. Традиционно регистрируют 12 характерных кривых (из них 6 — на строго определенных участках на поверхности грудной клетки), совокупность которых получила название электрокардиограммы (ЭКГ).

Изучение основных электрофизиологических процессов в миокарде — активации (деполяризации) и процессов восстановления (реполяризации) в разных отделах сердца — важная составляющая кардиологической диагностики, основанная на том, что при различных заболеваниях сердца форма ЭКГ существенно меняется. Однако хорошо известны неоднозначность, двусмысленность некоторых изменений ЭКГ [1, 2] и, как следствие, затруднения в интерпретации данных ЭКГ и сложность диагностики некоторых видов сердечной патологии.

В связи с этим большой интерес вызывает современная модификация электрокардиографии — исследование электрического поля сердца с помощью многоканальной регистрации ЭКГ со всей поверхности грудной клетки, или поверхностное ЭКГ-картирование (ПК). В настоящее время данный метод рассматривают как неинвазивный (исследующий организм без повреждения кожных покровов или слизистых оболочек) метод исследования электрофизиологических процессов в сердце человека.

Регистрация большого числа каналов ЭКГ со всей поверхности грудной клетки является одним из наиболее информативных методов исследования электрической активности миокарда и позволяет получить максимальную информацию об особенностях электрического поля сердца в

любой момент деполяризации и реполяризации сердечной мышцы. В отличие от традиционной ЭКГ-12 здесь важна не только динамика потенциала во времени, но в первую очередь анализ интенсивности потенциалов в конкретный момент сердечного цикла в различных пространственных точках.

Для отображения полученных данных традиционно используют карты распределения кардиоэлектрического потенциала на развертке поверхности торса с указанием анатомических ориентиров: изопотенциальные карты в различные фазы сердечного цикла, изоинтегральные и разностные карты [3, 4]. В клинической практике поверхностные распределения или поверхностные карты анализируются программными или визуальными методами, при этом учитывается только малая часть полученной информации, необходимая точность классификации не обеспечивается, часто врачу трудно уточнить подкласс уже установленного класса заболевания.

С целью создания современных диагностических средств для выделения существенных признаков и классификации сигналов ПК, проведенного в ходе обследования кардиологических больных, была начата разработка математических моделей, методик и соответствующего автоматизированного программного комплекса.

Для обработки сигналов, как правило, используются статистические методы. Однако применение нейросетей на основе самоорганизации (или обучения без учителя) также позволяет эффективно обрабатывать сигнал. Модели нейросетей, обучаемые на основе принципа самоорганизации, хорошо отражают свойства биологических структур, что делает их использование более предпочтительным. Применение нейросетей при обработке полученных данных позволяет учесть наиболее важные характеристики ЭКГ и провести правильную классификацию имеющихся патологий.

Обобщенный алгоритм Хебба для анализа главных компонент

Основной сложностью при анализе многоканальных сигналов является выделение существенных признаков исследуемого массива данных без потери информативности. В представляемой работе для этого использовался обобщенный алгоритм Хебба (ГНА) — нейросетевой аналог анализа главных компонент [5]. Применение

данного алгоритма позволило выявить наиболее значимые признаки обрабатываемых сигналов и уже по ним провести классификацию.

При использовании статистического метода пространство данных преобразуется в пространство признаков, теоретически имеющее ту же размерность, что и исходное пространство. Однако обычно преобразования выполняются так, чтобы пространство данных могло быть представлено сокращенным количеством *эффективных* признаков. Таким образом, остается только существенная часть информации, содержащейся в данных, т. е. множество данных подвергается сокращению размерности.

Предположим, что существует \mathbf{x} — m -мерный случайный вектор, имеющий нулевое среднее значение, который необходимо представить в виде l компонент, где $l < m$. Требуется выяснить, существует ли такое линейное преобразование A , для которого обрезание вектора $A\mathbf{x}$ будет оптимальным в смысле среднеквадратичной ошибки. При этом преобразование A должно обладать малой дисперсией своих отдельных компонент.

Пусть \mathbf{q} — единичный вектор, на который проецируется вектор \mathbf{x} . Эта проекция определяется следующим образом: $A = \mathbf{x}^T \mathbf{q}$ при ограничении $\|\mathbf{q}\| = (\mathbf{q}^T \mathbf{q})^{\frac{1}{2}} = 1$.

Дисперсия A равна

$$\begin{aligned} \sigma^2 &= E(A^2) = E\left((\mathbf{q}^T \mathbf{x})(\mathbf{x}^T \mathbf{q})\right) = \\ &= \mathbf{q}^T E(\mathbf{x}\mathbf{x}^T) \mathbf{q} = \mathbf{q}^T R \mathbf{q}. \end{aligned} \quad (1)$$

Матрица R является матрицей корреляции случайного вектора \mathbf{x} . Из выражения (1) видно, что дисперсия σ^2 проекции A является функцией единичного вектора и данную функцию можно представить как дисперсионный зонд:

$$\psi(\mathbf{q}) = \sigma^2 = \mathbf{q}^T R \mathbf{q}.$$

Взяв в качестве единичного вектора собственные векторы \mathbf{q}_j матрицы корреляции R , получим основные направления, вдоль которых дисперсионный зонд $\psi(\mathbf{q}_j)$ принимает экстремальные значения, а собственные значения матрицы корреляции R определяют экстремальные значения дисперсионного зонда $\psi(\mathbf{q}_j)$:

$$\psi(\mathbf{q}_j) = \lambda_j, \quad j = 1, 2, \dots, m.$$

Исходный вектор \mathbf{x} может быть реконструирован в следующем виде (Q — матрица, составленная из собственных векторов \mathbf{q}_j):

$$\mathbf{x} = Q\mathbf{a} = \sum_{j=1}^m a_j \mathbf{q}_j.$$

Количество признаков, необходимых для эффективного представления данных, можно сократить, устранив те линейные комбинации, которые имеют малые дисперсии, и оставив те, чьи дисперсии велики. Если взять l наибольших собственных значений матрицы R , то можно аппроксимировать вектор \mathbf{x} , отсекая члены разложения после l -го слагаемого:

$$\hat{\mathbf{x}} = \sum_{j=1}^l a_j \mathbf{q}_j.$$

Вектор ошибки аппроксимации \mathbf{e} равен разности между вектором исходных данных \mathbf{x} и вектором приближенных данных $\hat{\mathbf{x}}$:

$$\mathbf{e} = \mathbf{x} - \hat{\mathbf{x}} = \sum_{j=l+1}^m a_j \mathbf{q}_j. \quad (2)$$

Таким образом, для того чтобы обеспечить сокращение размерности входных данных, нужно вычислить собственные значения и векторы матрицы корреляции векторов входных данных, а затем ортогонально спроецировать эти данные на подпространство, задаваемое собственными векторами, соответствующими доминирующим собственным значениям этой матрицы [6].

Существует тесная взаимосвязь между поведением самоорганизующихся нейронных сетей и статистическим методом анализа главных компонент. Один линейный нейрон с хеббовским правилом адаптации синаптических весов [7] может быть преобразован в фильтр для выделения первой главной компоненты входного распределения. Линейная модель с одним нейроном может быть расширена до сети прямого распространения с одним слоем линейных нейронов с целью анализа главных компонент для входного сигнала произвольной размерности.

Рассмотрим m -мерное пространство. Вектор входного пространства и матрицу синаптических весов обозначим так:

$$\mathbf{x}(n) = \{x_1(n), x_2(n), \dots, x_m(n)\}^T, \\ W(n) = \{\mathbf{w}_1(n), \mathbf{w}_2(n), \dots, \mathbf{w}_l(n)\}^T.$$

В данном случае используется сеть прямого распространения, имеющая следующую структуру: — все нейроны выходного слоя сети являются линейными;

- сеть имеет m входов и l выходов ($m < l$);
- обучению подлежит только множество синаптических весов w_{ij} , соединяющих узлы i входного слоя с вычислительными узлами j выходного слоя ($i = 1, 2, \dots, m; j = 1, 2, \dots, l$).

Теорема [8]. Если элементы матрицы синаптических весов $W(n)$ на шаге $n = 0$ принимают случайные значения, то с вероятностью 1 обобщенный алгоритм Хебба будет сходиться к фиксированной точке, а $W^T(n)$ достигнет матрицы, столбцы которой являются первыми l собственными векторами матрицы корреляции R , упорядоченными по убыванию собственных значений.

Данная теорема гарантирует нахождение по обобщенному алгоритму Хебба первых l собственных векторов матрицы корреляции R (в предположении, что соответствующие собственные значения отличны друг от друга). При этом важен факт, что саму матрицу R не требуется вычислять: ее первые l собственных векторов определяются непосредственно на основании входных данных.

Выходной сигнал $y_j(n)$ нейрона j в момент времени n определяется по формуле

$$y_j(n) = \sum_{i=1}^m w_{ji}(n) x_i(n), \quad j = 1, 2, \dots, l.$$

Синаптический вес $w_{ji}(n)$ настраивается в соответствии с обобщенной формой правила Хебба:

$$\Delta w_{ji}(n) = \eta \left(y_j(n) x_i(n) - y_j(n) \sum_{k=1}^j w_{ki}(n) y_k(n) \right), \quad (3)$$

где $\Delta w_{ji}(n)$ — коррекция, применяемая к синаптическому весу $w_{ji}(n)$ в момент времени n ; η — параметр скорости обучения. Как правило, параметр η берут зависимым от времени: $\eta(n) = 1/n$.

Перепишем уравнение (3) в следующем виде:

$$\Delta w_{ji}(n) = \eta y_j(n) (x'_i(n) - w_{ji}(n) y_j(n)),$$

где $x'_i(n) = x_i(n) - \sum_{k=1}^{j-1} w_{ki}(n) y_k(n)$, или в векторном представлении

$$\Delta \mathbf{w}_j(n) = \eta y_j(n) \mathbf{x}'(n) - \eta y_j^2(n) \mathbf{w}_j(n), \quad (4)$$

где вектор $\mathbf{x}'(n) = \mathbf{x}(n) - \sum_{k=1}^{j-1} \mathbf{w}_k(n) y_k(n)$ представляет собой модифицированную форму входного вектора.

Основываясь на представлении (4), можно заметить следующее: для первого нейрона ($j = 1$) сети прямого распространения $\mathbf{x}'(n) = \mathbf{x}(n)$. Как было показано выше, этот нейрон извлекает первую главную компоненту входного вектора $\mathbf{x}(n)$.

Для второго нейрона ($j = 2$) сети можно записать

$$\mathbf{x}'(n) = \mathbf{x}(n) - \mathbf{w}_1(n) y_1(n).$$

Поскольку первый нейрон уже извлек первую главную компоненту, второй нейрон "видит" входной вектор $\mathbf{x}'(n)$, из которого удален первый собственный вектор матрицы корреляции R . Таким образом, второй нейрон извлекает первую главную компоненту вектора $\mathbf{x}'(n)$, что эквивалентно второй главной компоненте исходного входного вектора $\mathbf{x}(n)$.

Продолжая эту процедуру для оставшихся нейронов сети прямого распространения, получаем, что каждый из выходов сети, обученный с помощью обобщенного алгоритма Хебба, представляет собой отклик на конкретный собственный вектор матрицы корреляции входного вектора, причем отдельные выходы упорядочены по убыванию ее собственных значений.

Увеличение параметра η ведет к более быстрой сходимости и увеличению асимптотической среднеквадратичной ошибки.

Далее необходимо оценить количество главных компонент, требуемых для восстановления сигнала с минимальной среднеквадратичной ошибкой. Вектор ошибки аппроксимации \mathbf{e} определяется по формуле (2).

Однако алгоритм Хебба не позволяет найти ошибку таким образом, так как при обучении сети получается только l собственных векторов. Поэтому найдем ошибку экспериментальным путем.

Возьмем в качестве обучающей выборки 100 сигналов ЭКГ. Обучим сеть для выделения l главных компонент. Полученные веса сохраним. Возьмем тестовую выборку — 100 сигналов ЭКГ. Найдем главные компоненты и восстановим по полученным данным исходный сигнал ЭКГ.

На рис. 1 приведен график зависимости средней ошибки восстановления сигнала от количества главных компонент для тестовой выборки (100 сигналов). Из графика видно, что




Рис. 1. Зависимость средней ошибки восстановления сигнала от количества главных компонент

8-10 компонент достаточно для восстановления сигнала и дальнейшее увеличение количества главных компонент существенного выигрыша не даст.

Пример восстановленного сигнала для 1, 3, 5 и 7 компонент приведен на рис. 2. Видно, что с ростом количества главных компонент восстановленный сигнал приближается к исходному. При небольшом количестве главных компонент (1—3) разница между исходным и восстановленным сигналами заметна. Однако уже при 5 главных компонентах ошибка восстановления достаточно мала.

Качество восстановленного сигнала для разных тестовых данных было также разным. Некоторые сигналы имели маленькую ошибку восстановления уже при 4-5 главных компонентах, а некоторые давали большую погрешность и при 10 главных компонентах. В данном случае это свидетельствует о несовершенстве обучающей выборки.

В условиях НИЦ ССХ для многоканальной регистрации ЭКГ используются 80 датчиков. Сигнал каждого из датчиков был подвергнут обработке с помощью обобщенного алгоритма Хебба. Для каждого сигнала было выделено 8 главных компонент. Для последующей классификации использовался вектор, составленный из главных компонент всех 80 датчиков.

Классификация при помощи самоорганизующихся карт Кохонена

Для определения принадлежности сигнала к той или иной группе использовались самоорга-

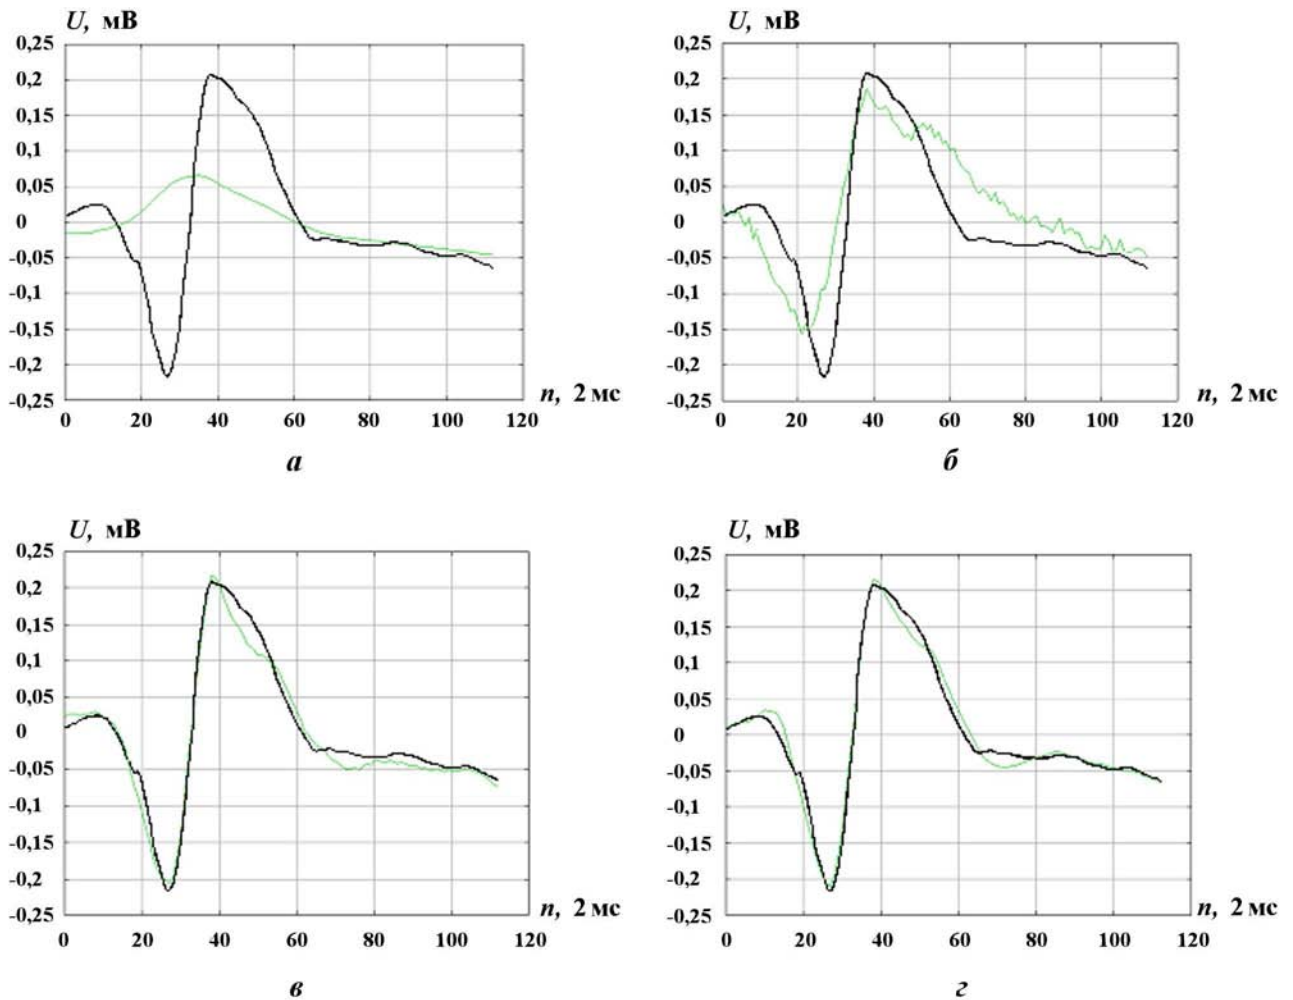


Рис. 2. Примеры сигналов, восстановленных по 1 (а), 3 (б), 5 (в), 7 (г) главным компонентам: — — исходный сигнал; — — восстановленный сигнал

низующиеся карты Кохонена [5]. Основной целью карт самоорганизации является преобразование поступающих векторов сигналов, имеющих произвольную размерность, в одно- или двумерную карту. При этом преобразование осуществляется адаптивно, в топологически упорядоченной форме. После окончания обучения самоорганизующихся карт Кохонена получается карта с разделением на области, где каждая область соответствует определенному классу.

Алгоритм формирования самоорганизующихся карт начинается с инициализации синаптических весов сети. После корректной инициализации сети активизируются три основных процесса: конкуренции, кооперации и синаптической адаптации [8].

Сущность алгоритма самоорганизации, предложенного Кохоненом, состоит в вычислении

свойств хеббоподобного правила обучения и латеральных взаимодействий. Существенными характеристиками этого алгоритма являются следующие:

- непрерывное входное пространство образов активации, которые генерируются в соответствии с некоторым распределением вероятности;
- топология сети в форме решетки, состоящей из нейронов (она определяет дискретное входное пространство);
- зависящая от времени функция окрестности, которая определена в окрестности *нейрона-победителя*;
- параметр скорости обучения, для которого задается начальное значение и который постепенно убывает во времени, но никогда не достигает нуля.

Рассмотрим m -мерное пространство. Вектор входного пространства и вектор синаптических весов обозначим так:

$$\mathbf{x}(n) = \{x_1(n), x_2(n), \dots, x_m(n)\}^T;$$

$$\mathbf{w}_j(n) = \{w_{j1}(n), w_{j2}(n), \dots, w_{jm}(n)\}^T,$$

$$j = 1, 2, \dots, l,$$

где l — общее количество нейронов в решетке.

После инициализации весов выбираем вектор из входного пространства. Находим наиболее подходящий ("победивший") нейрон на шаге n , используя критерий минимума евклидова расстояния (процесс конкуренции):

$$i(\mathbf{x}) = \arg \min_j \|\mathbf{x} - \mathbf{w}_j\|, \quad j = 1, 2, \dots, l.$$

Затем корректируем векторы синаптических весов всех нейронов, используя следующую формулу (синаптическая адаптация):

$$\mathbf{w}_j(n+1) = \mathbf{w}_j(n) + \eta(n) h_{j,i(\mathbf{x})}(n) (\mathbf{x} - \mathbf{w}_j(n)),$$

где $h_{j,i(\mathbf{x})}$ — функция окрестности с центром в победившем нейроне (процесс кооперации); $\eta(n)$ — параметр скорости обучения. Для улучшения процесса обучения рекомендуется использовать следующие значения указанных параметров [5]:

$$h_{j,i(\mathbf{x})}(n) = e^{\frac{-d_{j,i}^2}{2\sigma^2(n)}}; \quad \eta(n) = \eta_0 e^{\frac{-n}{\tau_2}}; \quad \sigma(n) = \sigma_0 e^{\frac{-n}{\tau_1}}.$$

Параметр σ называется эффективной шириной топологической окрестности. Этот параметр определяет уровень, до которого нейроны из окрестности победившего нейрона участвуют в обучении.

Процесс обучения можно условно разбить на два этапа: этап самоорганизации и этап сходимости.

На первом этапе происходит топологическое упорядочение векторов весов. Фактически на данном этапе происходит грубая настройка нейронной сети. В начале этапа функция окрестности $h_{j,i(\mathbf{x})}$ должна охватывать практически все нейроны сети и иметь центр в победившем нейроне. Когда размер $h_{j,i(\mathbf{x})}$ сократится до малого значения и будет содержать в себе только ближайших соседей победившего нейрона или только сам нейрон-победитель, первый этап закончится и начнется второй.

На втором этапе происходит тонкая настройка нейронной сети. Обычно количество итераций

на данном этапе в несколько сотен раз превышает количество нейронов сети. Параметр скорости обучения $\eta(n)$ во время второго этапа должен быть достаточно мал, но не приближаться к нулю. После завершения процесса сходимости (стабилизации нейронной сети) вычисленная карта признаков отображает важные статистические характеристики исходного пространства [9].

Обозначим символом Φ нелинейное преобразование, которое отображает входное пространство X в выходное пространство A : $\Phi: X \rightarrow A$. Для данного входного вектора \mathbf{x} по алгоритму, с использованием карты Φ , определяется наиболее подходящий нейрон $i(\mathbf{x})$ в выходном пространстве A . Вектор синаптических весов \mathbf{w}_i нейрона $i(\mathbf{x})$ можно рассматривать как указатель на этот нейрон из входного пространства X . Это значит, что синаптические элементы вектора \mathbf{w}_i можно рассматривать как координаты образа нейрона i , проецируемые во входное пространство.

Нейронам в двумерной решетке назначаются метки классов в зависимости от того, как каждый из векторов обучающей выборки возбудил конкретный нейрон в самоорганизующейся сети. В результате нейроны в двумерной решетке разбиваются на некоторое количество связанных областей [10], каждая из которых соответствует определенному классу патологий.

Результаты исследований

Проанализированы данные обследования 40 пациентов с синдромом предвозбуждения; это заболевание обусловлено наличием дополнительных аномальных путей проведения электрического импульса в сердце [2]. В исследовании участвовали данные пациентов с левой и правой локализацией аномального пути, установленной в ходе инвазивного электрофизиологического исследования сердца. Всем пациентам проведено ПК в покое с помощью электрокардиографической системы "Cardiag", которая обеспечивает синхронную запись 80 датчиков ЭКГ на поверхности всей грудной клетки. Анализировались данные, представленные в виде интегральных карт или массивов значений интегралов, рассчитанных в каждой точке регистрации от кривой ЭКГ на интервале QRS, соответствующем активации миокарда желудочков сердца.

Все данные делились на две группы. По данным первой группы происходило обучение, а по

данным второй группы — тестирование полученных результатов. В процессе исследования было случайным образом сформировано 10 обучающих выборок. Каждая выборка содержала данные из 20 многоканальных ЭКГ (20 векторов), 10 из которых — с левой локализацией аномального пути, 10 — с правой. Данные из остальных 20 ЭКГ (по 10 с левой и правой локализацией) использовались при формировании тестовых выборок — их также было взято 10.

На рис. 3 представлена карта Кохонена, построенная для одной из обучающих выборок. Светлосерая область соответствует левой локализации аномального пути, темная — правой локализации. Более светлым цветом выделены нейроны-победители для векторов из обучающей выборки.

Для всех тестовых выборок был получен высокий результат: от 17 до 20 правильно классифицированных локализаций аномального пути, что в среднем составило 92,5%. В большинстве случаев ошибки происходили на одних и тех же данных, как правило, полученных от пациентов с серьезными сопутствующими заболеваниями сердца. Однако после включения этих данных в обучающую выборку правильная классификация достигала 100%.

Синдром предвозбуждения представляет собой достаточно простую электрофизиологическую модель, что объясняет столь хорошие результаты уже при малых выборках. Однако использование рассмотренных математических моделей для других классов сердечно-сосудистых заболеваний также показывает высокое качество их применения уже при небольших обучающих выборках.




Рис. 3. Пример карты Кохонена

Таким образом, предлагаемые математические модели могут применяться для выделения существенных признаков и последующей классификации многоканальных сигналов электрического поля сердца.

Список литературы

1. Теоретические основы электрокардиологии / Под ред. К. В. Нельсона и Д. Б. Гезеловица. М.: Медицина, 1979.
2. *Морман Д., Хеллер Л.* Физиология сердечно-сосудистой системы. С.-Пб.: Питер, 2000.
3. Поверхностное картирование как метод диагностики нарушений ритма сердца // Клиническая аритмология. М.: Медпрактика-М, 2009. С. 157—175.
4. *Полякова И. П.* Диагностические возможности многоканального поверхностного ЭКГ-картирования // Креативная кардиология. 2007. № 1—2. С. 256—269.
5. *Хайкин С.* Нейронные сети. Полный курс. С.-Пб.: Вильямс, 2006.
6. *Oja E.* Subspace Methods of Pattern Recognition. Letchworth, England: Research study press, 1983.
7. *Brawn T. H.* Hebbian synapses: Biophysical mechanisms and algorithms // Annual Review of Neuroscience. 1990. Vol. 13. P. 475—511.
8. *Sanger T. D.* Optimal unsupervised learning in a single layer linear feedforward neural network // Neural Networks. 1989. Vol. 12. P. 459—473.
9. *Kohonen T.* Self-organized formation of topologically correct feature maps // Biological Cybernetics. 1982. Vol. 3. P. 59—69.
10. *Kohonen T.* Exploration of very large databases by self-organized maps // Int. Conf. on neural networks. Houston: IEEE Service Center, 1997. Vol. 1. P. PL1—PL6.

Статья поступила в редакцию 29.07.11.