

8-29-2020

## ECG PROCESSING AND ANALYSIS TECHNIQUE BASED ON NEURAL NETWORK LEARNING VECTOR QUANTIZATION

Talat Madievich Magrupov

*Tashkent State Technical University, Address: 2 Universitetskaya st., 100095, Tashkent city, Republic of Uzbekistan E-mail: talatmt@rambler.ru, Phone: +998-93-535-17-30,; talatmt@rambler.ru*

Sherzod Kalandarovich Nematov

*Tashkent State Technical University, Address: 2 Universitetskaya st., 100095, Tashkent city, Republic of Uzbekistan E-mail: sh.nemato@hotmail.com, Phone:+998-97-454-09-77,; sh.nemato@hotmail.com*

Yokubjon Talatovich Talatov

*PhD student, Tashkent State Technical University, Address: 2 Universitetskaya st., 100095, Tashkent city, Republic of Uzbekistan E-mail: yokubtt@rambler.ru, Phone: +998-93-385-25-21., yokubtt@rambler.ru*

Follow this and additional works at: <https://uzjournals.edu.uz/ijctcm>



Part of the [Complex Fluids Commons](#), [Controls and Control Theory Commons](#), [Industrial Technology Commons](#), and the [Process Control and Systems Commons](#)

---

### Recommended Citation

Magrupov, Talat Madievich; Nematov, Sherzod Kalandarovich; and Talatov, Yokubjon Talatovich (2020) "ECG PROCESSING AND ANALYSIS TECHNIQUE BASED ON NEURAL NETWORK LEARNING VECTOR QUANTIZATION," *Chemical Technology, Control and Management*. Vol. 2020 : Iss. 4 , Article 3.

DOI: <https://doi.org/10.34920/2020.4.15-22>

Available at: <https://uzjournals.edu.uz/ijctcm/vol2020/iss4/3>

This Article is brought to you for free and open access by 2030 Uzbekistan Research Online. It has been accepted for inclusion in *Chemical Technology, Control and Management* by an authorized editor of 2030 Uzbekistan Research Online. For more information, please contact [sh.erkinov@edu.uz](mailto:sh.erkinov@edu.uz).



ISSN 1815-4840, E-ISSN 2181-1105

Himičeskaâ tehnologiâ. Kontrol' i upravlenie

## CHEMICAL TECHNOLOGY. CONTROL AND MANAGEMENT

2020, №4 (94) pp.15-22. <https://doi.org/10.34920/2020.4.15-22>

International scientific and technical journal

journal homepage: <https://uzjournals.edu.uz/ijctcm/>



Since 2005

UDC 004:616.1/12

### ECG PROCESSING AND ANALYSIS TECHNIQUE BASED ON NEURAL NETWORK LEARNING VECTOR QUANTIZATION

Magrupov Talat Madievich<sup>1</sup>, Nematov Sherzod Kalandarovich<sup>2</sup>,  
Talatov Yokubjon Talatovich<sup>3</sup>

<sup>1</sup>Tashkent State Technical University, Address: 2 Universitetskaya st., 100095, Tashkent city, Republic of Uzbekistan  
E-mail: [talatmt@rambler.ru](mailto:talatmt@rambler.ru), Phone: +998-93-535-17-30;

<sup>2</sup>Tashkent State Technical University, Address: 2 Universitetskaya st., 100095, Tashkent city, Republic of Uzbekistan  
E-mail: [sh.nemato@hotmail.com](mailto:sh.nemato@hotmail.com), Phone: +998-97-454-09-77;

<sup>3</sup>Tashkent State Technical University, Address: 2 Universitetskaya st., 100095, Tashkent city, Republic of Uzbekistan  
E-mail: [yokubtt@rambler.ru](mailto:yokubtt@rambler.ru), Phone: +998-93-385-25-21.

**Abstract:** The main parameters of the electrocardiogram (ECG) were processed on the basis of the neural network apparatus. A decision support algorithm for ECG analysis using a neural network for learning vector quantization is proposed. For the study was chosen such features as the duration of QRS complex, RR interval, amplitude of R-wave and the change in the slope of ST segment and heart rate, which are five inputs to the neural network learning vector quantization. Methods of pre-processing and analysis of extraction of ECG functions based on the ECG database of a medical institution in Matlab are presented. The generalized algorithm of the generated LVQ network and the architecture of the LVQ neural network created using MATLAB are proposed. A method for training a neural network that classifies an ECG signal is presented, based on the training data obtained during the extraction of signs - 5 inputs (R-R interval, R wave amplitude, QRS complex duration, ST segment slope, heart rate), in one of five classes: bradycardia, tachycardia, premature ventricular contraction (PVC) (PVC), myocardial infarction, or in the absence of diseases class.

**Keywords:** Electrocardiogram, Neural Network, Training, Quantization, Processing, Analysis, Disease.

**Аннотация:** Нейрон тармоқлари асосида электр-кардиограмма (ЭКГ) нинг асосий кўрсаткичларига ишлов берилган. Векторли квантлаш асосида нейрон тармоқларини ўқитишдан фойдаланган ҳолда ЭКГ таҳлили учун ечимлар қабул қилиш алгоритми таклиф этилган. Тадқиқот учун қўйидаги функциялар танланди: QRS комплексининг давомийлиги, RR оралиги, R тўлқинининг амплитудаси ва ST сегментининг қиялиги ва юрак уриши тезлигининг ўзгариши. Ушбу беш функция нейрон тармоғини ўрганишида векторли квантлаш учун бешта кириш ҳисобланади. Тиббий муассасадан олинган ЭКГ маълумотлар базаси асосида ЭКГ функцияларини олишидаги дастлабки ишлов бериш ва таҳлил қилиш усулларини MATLAB да амалга оширилиши келтирилган. LVQ тармоғининг умумий алгоритми ва MATLAB ёрдамида яратилган LVQ нейрон тармоғининг архитектураси таклиф этилган. Белгиларни олиш жараёнида олинган маълумотларга асосланган ЭКГ сигнални таснифлаш учун нейрон тармоқни ўргатиш усули - 5 кириш (R-R оралиги, R тўлқин амплитудаси, QRS комплексининг давомийлиги, ST сегментининг қиялиги, юрак уриши) брадикардия, тахикардия, қоринчани эрта қисқариши (КЭК), миокард инфаркти ёки касаллик бўлмаганлиги каби бешта синфнинг биттасига келтирилган.

**Таянч сўзлар:** электр-кардиограмма, нейрон тармоғи, ўқитиш, квантлаш, ишлов бериш, таҳлил, касаллик.

**Аннотация:** Основные показатели электрокардиограммы (ЭКГ) обрабатывались на основе аппарата нейронных сетей. Предложен алгоритм поддержки принятия решений для анализа ЭКГ с использованием нейронной сети обучения векторного квантования. Для исследования были выбраны такие функции, как длительность комплекса QRS, интервал RR, амплитуда зубца R и изменение наклона сегмента ST и частота сердечных сокращений, которые являются пятью входами в нейронную сеть обучения векторного квантования. Приведены способы предварительной обработки и анализа извлечения функций ЭКГ на основе базы данных ЭКГ медицинское учреждения в MATLABe. Предложен обобщенный алгоритм сгенерированной сети LVQ и архитектура нейронной сети LVQ, созданной с помощью MATLAB. Приведен способ обучения нейронной сети

классифицирующей сигнал ЭКГ, на основе полученных обучающих данных в процессе извлечения признаков - 5 входов (интервал R-R, амплитуда зубца R, длительность комплекса QRS, наклон сегмента ST, частота сердечных сокращений), в один из пяти классов: брадикардия, тахикардия, преждевременное сокращение желудочков (ПЖ), инфаркт миокарда или в класс отсутствие заболеваний.

**Ключевые слова:** электрокардиограмма, нейронная сеть, обучение, квантование, обработка, анализ, заболевание.

### Введение

В настоящее время развитие компьютерной и информационной технологии открыло новые пути для здравоохранения: в профилактике, диагностике и терапии заболеваний. В медицине сегодняшнего дня сердечно-сосудистые заболевания является наиболее важной проблемой. Сердечно-сосудистые заболевания – основная причина смертности людей в трудоспособном возрасте [1], [2], [3], [4], [5]. Анализ данных кардиологических исследований необходим для постановки диагноза, составления прогноза и лечения.

В настоящее время автоматический расчет и обработка кардиологической информации с помощью компьютерной и информационной технологии дает большие преимущества и требует меньше времени. Среди кардиологической информации самым информативным для диагностики сердечно-сосудистых заболеваний (ССЗ) является электрокардиограмма (ЭКГ), автоматический анализ которой представляет собой достаточно сложную проблему. Это, в первую очередь, связано с физиологическим происхождением сигнала, которое обуславливает его недетерминированность, разнообразие, изменчивость, непредсказуемость, нестационарность и подверженность многочисленным видам помех. В то же время существующие компьютерные системы не обеспечивают требуемой достоверности результатов диагностики. Такая ситуация прежде всего обусловлена ошибками при распознавании информативных признаков ЭКГ, отражающих отдельные стадии электрического возбуждения предсердий и желудочков сердца. Актуален вопрос повышения точности методов и алгоритмов анализа ЭКГ путем корректного определения временных параметров сигнала.

В последнее время для диагностики сердечно-сосудистых заболеваний, а именно: обработки и анализа ЭКГ широко применяются нейронные сети [6, 7, 8], позволяющие оптимизировать диагностический процесс и избегать ошибочных диагнозов.

В связи с этим в данной работе предлагается алгоритмы обработки и анализа электрокардиограмм и его классификация с применением нейронных сетей.

### Методика обработки и анализа электрокардиограмм и его классификация с применением нейронных сетей.

В работе предлагается методика диагностики сердечно-сосудистых системы на основе анализа и обработки характеристик ЭКГ на базе нейронных сетей (Рис.1). Для исследования были выбраны такие функции, как: длительность комплекса QRS, интервал R-R, амплитуда зубца R и изменение наклона сегмента ST [9-11].




Рис.1. Блок-схема алгоритма поддержки принятия решений для анализа ЭКГ с использованием нейронной сети LVQ.

Для проведения исследования получена база данных ЭКГ медицинского учреждения. База данных включает 100 сигналов ЭКГ, которые имеют электрические помехи или шумы и

зарегистрированы из источников, отличных от электронных сигналов сердца. Предложен алгоритм, для реализации которого используют программное обеспечение MATLAB [12]. Для этого сначала загружают сигналы ЭКГ нужной длины (вводимые пользователем) из базы данных и сохраняют их в массиве.

На этапе предварительной обработки обеспечивается сосредоточение данных по нулю и нормализации информации для этапа обучения и вычисления классификатора. Задача состоит в том, чтобы иметь хорошо выделенную морфологию ЭКГ с минимально возможной потерей информации. При удалении шума или помех требуется, не устранять жизненно важные показатели сигнала ЭКГ (рис. 2).

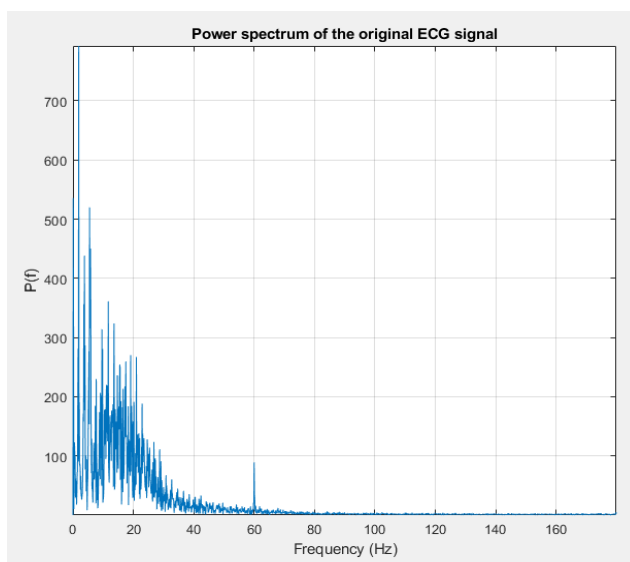


Рис. 2. Спектр мощности исходного сигнала ЭКГ.

Чтобы удалить шум линии электропередачи при 60 Гц, используем полосовой фильтр Баттерворта с частотой среза 59 Гц и 61 Гц. Это достигается с помощью функцией предварительной обработки с помощью MATLAB. При этом, сначала необходимо стандартизировать сигнал ЭКГ и уменьшить его до среднего значения, чтобы сигнал был центрирован около нуля (рис.3).

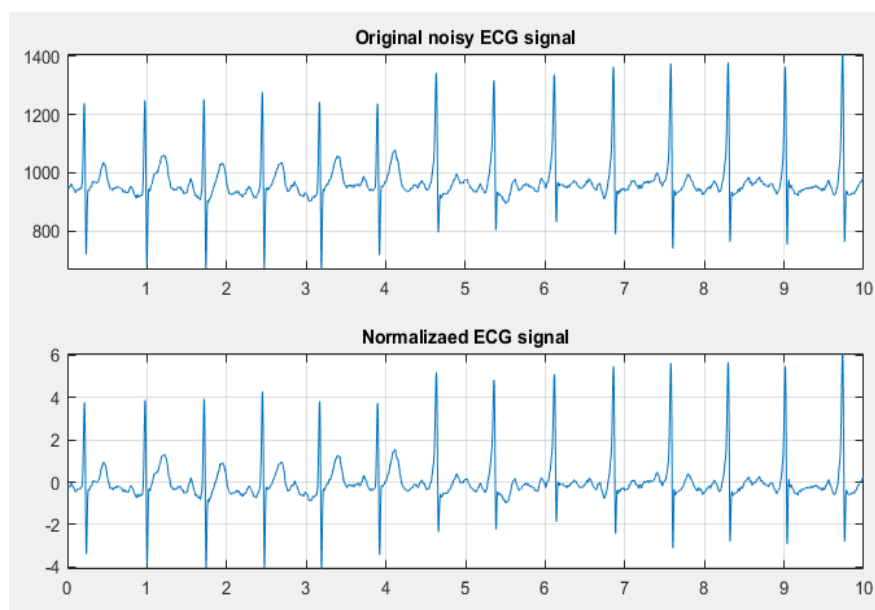


Рис.3. Исходный а нормализованный сигнал ЭКГ.

Затем приступаем к удалению блуждания по базовой линии или дрейфа по базовой линии. Это достигается с помощью использования фильтра верхних частот Баттерворта. После удаления базового блуждания, полученный сигнал ЭКГ является более стационарным и точным, чем исходный сигнал (рис. 4).




Рис.4. Сравнение рекурсивного фильтра (красная) с фильтрацией нулевой фазы (зеленая линия), выполненные на MATLAB.

Видно, что фильтрация с использованием метода нулевой фазы дает лучшие результаты. Однако некоторые другие типы шумов могут по-прежнему влиять на извлечение признаков сигнала ЭКГ. Шум может быть сложным случайным процессом в пределах широкополосный, поэтому невозможно удалить их с помощью традиционных цифровых фильтров. Для этого будем использовать дискретное вейвлет-преобразование с максимальным перекрытием (MODWT). MODWT — это неопределенное вейвлет-преобразование, которое обрабатывает произвольные размеры выборки.

На рис. 5 показаны сигналы ЭКГ, обработанные вейвлет- анализом из исходного ЭКГ- сигнала. Здесь мы можем обнаружить, что пики и впадины (особенно точки Q и S) становятся более четкими после вейвлет-анализа с множественным разрешением.

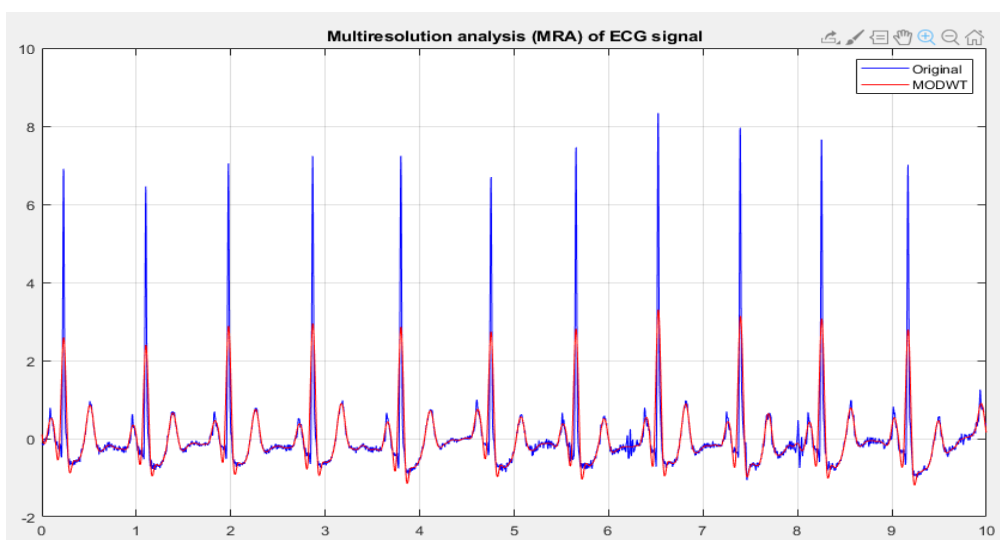


Рис.5. Анализ мультиразрешения дает нам наиболее гладкую линию ЭКГ-сигнала.

Следующим этапом является извлечение функций. На основе проведенных исследований можно сказать, что обнаружение функций ЭКГ можно осуществить с помощью алгоритма Пан-Томпкинса. При этом получены пики R и амплитуды R-волны, а интервалы RR рассчитываются как разница во времени между двумя последовательными пиками R. Затем осуществлен расчет частоты сердечных сокращений для каждого удара ЭКГ. Для определения длительности комплекса QRS, сначала необходимо найти пики Q и S. Последовательность реализации процесса извлечения функций ЭКГ приведена на рис.6.

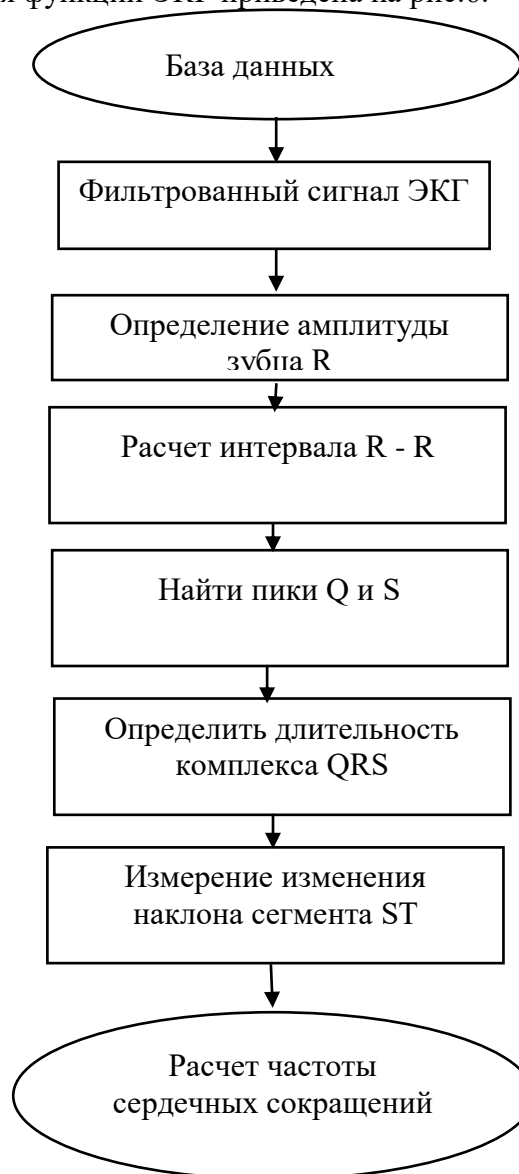


Рис.6. Последовательность реализации процесса извлечения функций ЭКГ.

Как описано выше, вычисляем все пять описанных функций для каждого ритма ЭКГ. Сигнал ЭКГ содержит много ритмов, в зависимости от времени измерения. Для каждой функции у нас может быть только одно значение. Это будет представлять один из входов в нейронной сети обучения векторного квантования (LVQNN). Поэтому для каждой функции мы вычисляем среднее значение. Выходные данные этой функции в MATLABe представляют собой пять средних значений (средний интервал RR, средняя амплитуда волны R, среднее изменение наклона ST, средняя частота сердечных сокращений, средняя продолжительность QRS), которые представляют ЭКГ сигнал. Эти пять средних значений являются пятью входами в нейронной сети обучения векторного квантования.

### Алгоритм нейронной сети обучения векторного квантования

Нейронная сеть обучения векторного квантования имеет два слоя: первый - конкурентный слой и второй - линейный слой. Конкурентный слой учится классифицировать входные векторы. Линейный слой преобразует классы конкурентного слоя в целевые классификации, определяемые пользователем. Классы, относящиеся конкурентным слоям называются подклассами, а классы линейного слоя – целевыми классами [13].

Обучение нейронной сети в конкурентном слое основано на наборе пары вход / цель. Каждый целевой вектор имеет одну 1. Остальные его элементы равны 0. 1 говорит о правильной классификации связанных входных данных. При этом каждому входному вектору должен быть присвоен один из классов. Сеть должна быть обучена так, чтобы она классифицировала входной вектор, в соответствующий класс. Для обучения сети представлен входной вектор  $X$ , и весовая матрица  $M$ .

Обучающий вектор сети квантования классифицируют входные векторы на целевые классы, используя конкурентный слой для поиска подклассов входных векторов, а затем объединяют их в целевые классы. В отличие от персептронов, нейронные сети LVQ могут классифицировать любой набор входных векторов, а не только линейно разделимые наборы входных векторов. Единственное требование состоит в том, что в конкурентном слое должно быть достаточно нейронов. Каждому классу должно быть назначено достаточное количество конкурентоспособных нейронов. При этом целевые векторы, используемые для инициализации сети LVQ, должны иметь распределение целей, как в обучающих сетях. Таким образом достигается объединение большего количества подклассов в целевые классы с большим количеством векторов.

Обучение векторного квантования - это метод классификации моделей. Он основан на прототипе алгоритма контролируемой классификации и является одной из конкурентных нейронных сетей [6]. На рис. 7 представлена графическая архитектура нейронной сети LVQ.




Рис. 7. Архитектура нейронной сети LVQ с 7 скрытыми нейронами на конкурентном уровне и 5 скрытыми нейронами на линейном уровне.

Рассмотрим архитектуру нейронной сети LVQ с 7 скрытыми нейронами на конкурентном слое и 5 скрытыми нейронами на линейном слое. В общем, архитектура LVQNN содержит входной слой, два скрытых слоя и выходной слой. Первый скрытый слой - это конкурентный слой, а второй скрытый слой - это линейный слой. Первый уровень, который является конкурентным уровнем, учится классифицировать входы. Классы конкурентного слоя преобразуются в целевые классификации с помощью линейного слоя.

Количество нейронов для ввода - это количество извлеченных объектов, а число выходного слоя - это номер целевого класса. Чтобы достичь оптимального количества скрытых нейронов, нужно протестировать несколько типов нейронных сетей с разными скрытыми нейронами. Затем выбирается нейронная сеть, которая имеет наименьшее количество ошибок.

Прежде, чем генерировать LVQNN, мы разделяем все данные выборки на две части. 80% выборочных данных представляют собой данные обучения / обучения (learning/training), а другие 20% - являются данными тестирования. LVQNN использует данные обучения для тренировки (Рис.8).

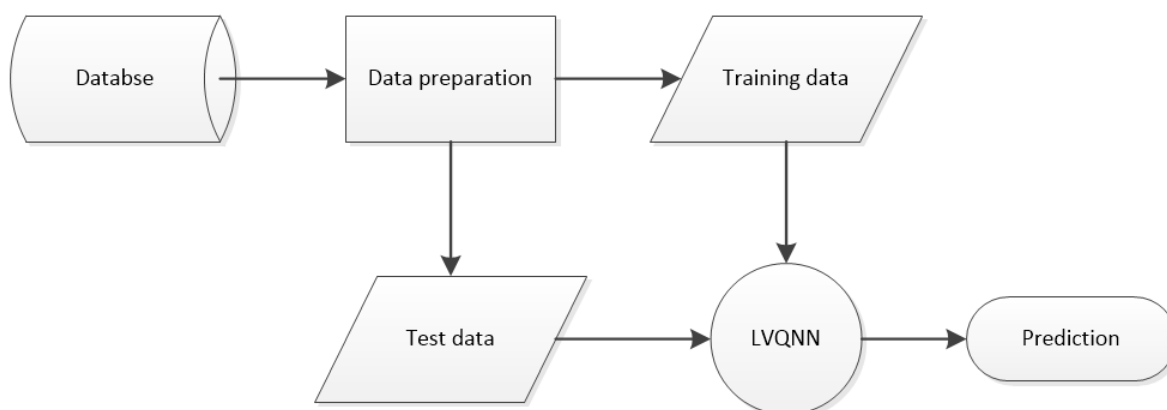


Рис. 8. Обобщенная блок-схема алгоритма сгенерированной сети LVQ.

Таким образом, мы берем обучающие данные, полученные в процессе извлечения признаков - 5 входов (интервал R-R, амплитуда зубца R, длительность комплекса QRS, наклон сегмента ST, частота сердечных сокращений) и обучаем нашу сеть классифицировать сигнал ЭКГ, представленный в качестве входных данных, в один из пяти классов: брадикардия, тахикардия, преждевременное сокращение желудочков (ПСЖ) (PVC), инфаркт миокарда или в класс отсутствия заболеваний. На основе предоставленных целевых классов нейронная сеть классифицирует входные данные на выбранные пять классов. На рисунке 9 показан наш LVQNN, сгенерированный в MATLAB.




Рис. 9. Архитектура сети LVQ, созданной с помощью MATLAB.

Как конкурентный, так и линейный слои имеют по одному нейрону на (под- или целевой) класс. Таким образом, конкурентный уровень может учиться до L1 подклассов. Они, в свою очередь, объединяются линейным слоем для формирования целевых классов L2. (L1 всегда больше, чем L2).

### Классификация с применением нейронных сетей и анализ результатов

После обучения и тестирования сети LVQ, приступаем к оценке моделей классификации. Мы создаем разреженную матрицу (confusion) или классификацию аномалий сердца, которая показывает правильные и неправильные прогнозы. Матрица позволяет определить эффективность алгоритма (рис.1). Каждая строка матрицы представляет отдельный модуль в



прогнозируемом классе, в то время как каждый столбец представляет отдельный модуль в реальном классе. Строки соответствуют прогнозируемому классу (выходной класс), а столбцы соответствуют истинному классу (целевой класс). Диагональные элементы соответствуют высказываниям, которые правильно классифицированы. Недиagonальные ячейки соответствуют неправильно классифицированным высказываниям. В каждом элементе матрицы приведено количество высказываний, также процент от общего количества высказываний.

В отдельности вычислены обучающая, тестовая и общая разреженные матрицы. Определена суммарная эффективность предлагаемой модели. Точность классификации нашей сети составляет 83,5%.

#### References:

1. T.M.Magrupov, S.A.Vasil'eva, M.T.Magrupova, "Analiz i obrabotka mediko-biologicheskoy informacii" [Analysis and processing of biomedical information], Tashkent: TashGTU 2012, 164 p.
2. S.Correia, J.Miranda, L.Silva, and A.Barreto, "Labview and Matlab for ECG Acquisition, Filtering and Processing", *3rd International Conference on Integrity, Reliability and Failure*, Porto/Portugal, 2009, pp. 20-24.
3. M.F.Haque, H.Ali1, M.A.Kiber, and M.T.Hasan "Detection of Small Variations of ECG Features Using Wavelet", *ARPN Journal of Engineering and Applied Sciences*, vol. 4, no. 6, pp 27-30, 2009.
4. Atul Sethi, Siddharth Arora, Abhishek Ballaney, "Frequency domain analysis of ECG signals using auto-associative neural networks", *International Conference on Biomedical and Pharmaceutical Engineering 2006*, (ICBPE 2006), pp. 531-536.
5. P.Sasikala, Wahida Banu Dr. R.S. "Extraction of P wave and T wave in electrocardiogram using wavelet transform", *International Journal of Computer Science and Information Technologies*, vol. 2(1), pp. 489-493. 2011.
6. A.T.Sayad, P.P.Halkarnikar "Diagnosis of heart disease using neural network approach" *International Journal of Advances in Science Engineering and Technology*, vol. 2, Iss. 3, pp. 88-92, 2014.
7. N.Ajam, "Heart diseases diagnoses using artificial neural network", *Network and Complex Systems*, vol. 5, no. 4, pp. 7-11, 2015.
8. J.Kojuri, R.Boostani, P.Deighani, F.Nowroozipour, N.Saki, "Prediction of acute myocardial infarction with artificial neural networks in patients with nondiagnostic electrocardiogram", *Journal of Cardiovascular Disease Research*, vol 6, Iss. 2, pp. 51-60, 2015.
9. Y.Talatov, T.Magrupov, A.A.Radjabov, "Device for Measuring of Frequency Response Function of Biopotentials", *International Multi-Conference on Engineering, Computer and Information Sciences (SIBIRCON)*. Novosibirsk, Russia, 2019, pp. 7-10.
10. Y.Talatov, T.Magrupov, "Algorithmic and Software Analysis and Processing of ECG Signals" *International Multi-Conference on Engineering, Computer and Information Sciences (SIBIRCON)*, Novosibirsk, Russia, 2019, pp. 403-406.
11. S.N.Sivanandam, S.Sumathi, and S.N.Deepa, "Introduction to Neural Networks using - MATLAB 6.0. learning vector quantization", pp.237 -239, 2006. Tata McGraw-Hill. <https://www.mathworks.com/help/deeplearning/ug/learning-vector-quantization-lvq-neural-networks-1.html> [accessed Sept 1 2019].