

Использование детализирующего вектора для нейросетевой классификации сигналов электрокардиограммы.

М.Р. Киладзе, П.А. Ляхов, Н.Н. Нагорнов

Северо-Кавказский Федеральный университет

Аннотация: Заболевания сердечно-сосудистой системы - основная причина смертности населения планеты. Основным способом диагностики таких заболеваний является снятие электрокардиограммы пациента. Автоматическая обработка сигналов электрокардиограммы позволит врачам своевременно выявить кардиологические проблемы пациента. В данной статье представлен метод вычисления детализирующего вектора для нейросетевой обработки двенадцати канального сигнала электрокардиограммы. Добавление детализирующего вектора к сигналам электрокардиограммы увеличивает точность классификации заболеваний до 87,50 %. Предложенный метод может быть использован для автоматической классификации двух и более канальных сигналов электрокардиограммы.

Ключевые слова: Электрокардиограмма, рекуррентная нейронная сеть, нейронная сеть с долгосрочной короткой памятью, детализирующий вектор, PhysioNet Computing in Cardiology Challenge 2021.

Введение

Кардиологические заболевания - самые распространённые заболевания среди населения Российской Федерации. Российская Федерация занимает первое место по количеству смертей от патологии сердца и сосудов. В год в нашей стране от этого недуга погибает более 900 тысяч человек [1]. Для диагностики заболеваний сердца используют электрокардиограф, прибор регистрирующий электрические поля, образующиеся при работе сердца. Результатом регистрации является электрокардиограмма (ЭКГ). Графически сигналы электрокардиограммы записываются в виде пиков, которые принято называть зубцами и обозначать латинскими буквами Q, R, S, P и T (рис. 1) [2]. Увеличение числа пациентов, страдающих заболеваниями сердца и сосудов, влечет к увеличению числа зарегистрированных ЭКГ. Быстрая и точная классификация сигналов ЭКГ позволяет своевременно оказать медицинскую помощь пациенту. Системы автоматической классификации,

основанные на нейросетевой обработке [3] или машинном обучении [4], решают данную проблему.

В одних из первых работ, посвященных автоматизированным способам обработки сигналов ЭКГ, нейронную сеть обучали определять Р-пики на сигналах ЭКГ, преобразованных вейвлет-преобразованием [5]. Современные автоматизированные системы обработки одноканальных сигналы ЭКГ могут включать в себя различные способы предобработки, такие, как: нормализация, фильтрация, шумоподавление, сегментация на волны, нейронные сети и так далее. Так, в работе [6], для предварительной обработки одноканальных сигналов ЭКГ использованы все перечисленные способы с последующей классификацией сверточной нейронной сетью.

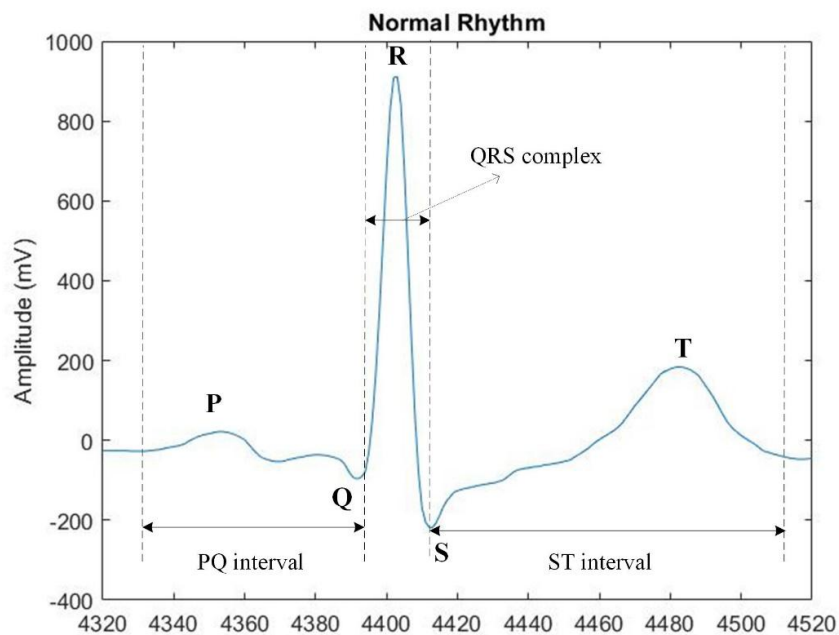


Рис. 1. – Пики электрокардиограммы.

Для предварительной обработки и классификации двенадцати канальных сигналов ЭКГ используют те же методы, что и для одноканальных сигналов [7 - 9]. В данной работе мы предлагаем в качестве предварительной обработки использовать детализирующий вектор сигналов ЭКГ с последующей классификацией рекуррентной нейронной сетью LSTM (long

short-term memory). В следующем пункте детально описан метод вычисления детализирующего вектора сигналов ЭКГ.

Математическая модель

В статье представлен метод классификации сигналов двенадцати канальных ЭКГ сетью LSTM с предварительной обработкой сигналов. На рис. 2 представлена архитектура предложенного метода.

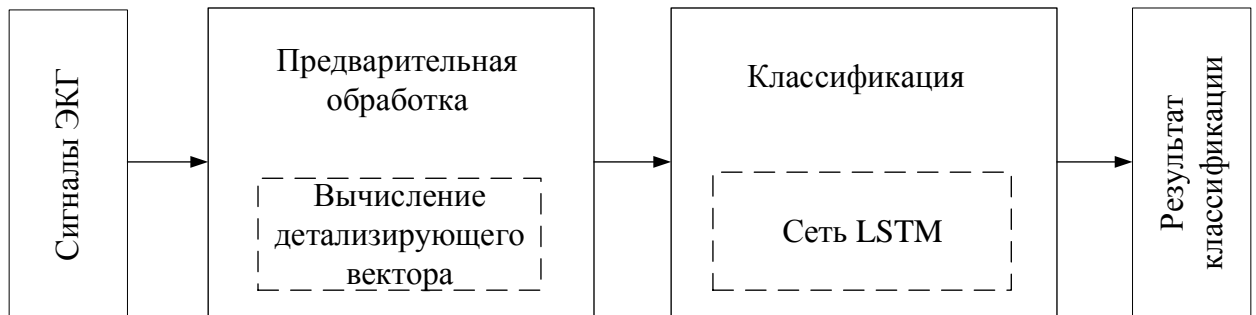


Рис. 2. – Архетектура предложенного метода.

Сигналы 12 канальной ЭКГ регистрируется в виде матрицы (1), где число строк соответствует числу датчиков регистрации, а число столбцов – числу отчетов.

$$S = \begin{pmatrix} a_{1,1} & a_{1,2} & a_{1,3} & \dots & a_{1,n-2} & a_{1,n-1} & a_{1,n} \\ a_{2,1} & a_{2,2} & a_{2,3} & \dots & a_{2,n-2} & a_{2,n-1} & a_{2,n} \\ a_{3,1} & a_{3,2} & a_{3,3} & \dots & a_{3,n-2} & a_{3,n-1} & a_{3,n} \\ \vdots & \vdots & \vdots & \dots & \vdots & \vdots & \vdots \\ a_{10,1} & a_{10,2} & a_{10,3} & \dots & a_{10,n-2} & a_{10,n-1} & a_{10,n-1} \\ a_{11,1} & a_{11,2} & a_{11,3} & \dots & a_{11,n-2} & a_{11,n-1} & a_{11,n-1} \\ a_{12,1} & a_{12,2} & a_{12,3} & \dots & a_{12,n-2} & a_{12,n-1} & a_{12,n} \end{pmatrix}, \quad (1)$$

где $a_{i,j}$ - значение регистрируемых потенциалов с i -ого датчика в j -ый момент отсчета. Формула (1) описывает сигналы, регистрируемые 12 датчиками, тогда $i = 1, 2, \dots, 12$, $j = 1, 2, \dots, n$, n - число отсчетов.

Предварительная обработка включает в себя расчет детализирующего вектора D сигналов ЭКГ. Вектор состоит D из значений определителей $d_1, d_2, d_3, \dots, d_{n-14}, d_{n-13}, d_{n-12}$, вычисляемых следующим образом:

$$d_1 = \begin{vmatrix} a_{1,1} & a_{1,2} & a_{1,3} & \dots & a_{1,10} & a_{1,11} & a_{1,12} \\ a_{2,1} & a_{2,2} & a_{2,3} & \dots & a_{2,10} & a_{2,11} & a_{2,12} \\ a_{3,1} & a_{3,2} & a_{3,3} & \dots & a_{3,10} & a_{3,11} & a_{3,12} \\ \vdots & \vdots & \vdots & \dots & \vdots & \vdots & \vdots \\ a_{10,1} & a_{10,2} & a_{10,3} & \dots & a_{10,10} & a_{10,11} & a_{10,12} \\ a_{11,1} & a_{11,2} & a_{11,3} & \dots & a_{11,10} & a_{11,11} & a_{11,12} \\ a_{12,1} & a_{12,2} & a_{12,3} & \dots & a_{12,10} & a_{12,11} & a_{12,12} \end{vmatrix},$$

$$d_2 = \begin{vmatrix} a_{1,2} & a_{1,3} & a_{1,4} & \dots & a_{1,11} & a_{1,12} & a_{1,13} \\ a_{2,2} & a_{2,3} & a_{2,4} & \dots & a_{2,11} & a_{2,12} & a_{2,13} \\ a_{3,2} & a_{3,3} & a_{3,4} & \dots & a_{3,11} & a_{3,12} & a_{3,13} \\ \vdots & \vdots & \vdots & \dots & \vdots & \vdots & \vdots \\ a_{10,2} & a_{10,3} & a_{10,4} & \dots & a_{10,11} & a_{10,12} & a_{10,13} \\ a_{11,2} & a_{11,3} & a_{11,4} & \dots & a_{11,11} & a_{11,12} & a_{11,13} \\ a_{12,2} & a_{12,3} & a_{12,4} & \dots & a_{12,11} & a_{12,12} & a_{12,13} \end{vmatrix},$$

$$d_3 = \begin{vmatrix} a_{1,3} & a_{1,4} & a_{1,5} & \dots & a_{1,12} & a_{1,13} & a_{1,14} \\ a_{2,3} & a_{2,4} & a_{2,5} & \dots & a_{2,12} & a_{2,13} & a_{2,14} \\ a_{3,3} & a_{3,4} & a_{3,5} & \dots & a_{3,12} & a_{3,13} & a_{3,14} \\ \vdots & \vdots & \vdots & \dots & \vdots & \vdots & \vdots \\ a_{10,3} & a_{10,4} & a_{10,5} & \dots & a_{10,12} & a_{10,13} & a_{10,14} \\ a_{11,3} & a_{11,4} & a_{11,5} & \dots & a_{11,12} & a_{11,13} & a_{11,14} \\ a_{12,3} & a_{12,4} & a_{12,5} & \dots & a_{12,12} & a_{12,13} & a_{12,14} \end{vmatrix}$$

$$d_{n-14} = \begin{pmatrix} a_{1,n-13} & a_{1,n-12} & a_{1,n-11} & \dots & a_{1,n-4} & a_{1,n-3} & a_{1,n-2} \\ a_{2,n-13} & a_{2,n-12} & a_{2,n-11} & \dots & a_{2,n-4} & a_{2,n-3} & a_{2,n-2} \\ a_{3,n-13} & a_{3,n-12} & a_{3,n-11} & \dots & a_{3,n-4} & a_{3,n-3} & a_{3,n-2} \\ \vdots & \vdots & \vdots & \dots & \vdots & \vdots & \vdots \\ a_{10,n-13} & a_{10,n-12} & a_{10,n-11} & \dots & a_{10,n-4} & a_{10,n-3} & a_{10,n-2} \\ a_{11,n-13} & a_{11,n-12} & a_{11,n-11} & \dots & a_{11,n-4} & a_{11,n-3} & a_{11,n-2} \\ a_{12,n-13} & a_{12,n-12} & a_{12,n-11} & \dots & a_{12,n-4} & a_{12,n-3} & a_{12,n-2} \end{pmatrix}$$

$$d_{n-13} = \begin{pmatrix} a_{1,n-12} & a_{1,n-11} & a_{1,n-10} & \dots & a_{1,n-3} & a_{1,n-2} & a_{1,n-1} \\ a_{2,n-12} & a_{2,n-11} & a_{2,n-10} & \dots & a_{2,n-3} & a_{2,n-2} & a_{2,n-1} \\ a_{3,n-12} & a_{3,n-11} & a_{3,n-10} & \dots & a_{3,n-3} & a_{3,n-2} & a_{3,n-1} \\ \vdots & \vdots & \vdots & \dots & \vdots & \vdots & \vdots \\ a_{10,n-12} & a_{10,n-11} & a_{10,n-10} & \dots & a_{10,n-3} & a_{10,n-2} & a_{10,n-1} \\ a_{11,n-12} & a_{11,n-11} & a_{11,n-10} & \dots & a_{11,n-3} & a_{11,n-2} & a_{11,n-1} \\ a_{12,n-12} & a_{12,n-11} & a_{12,n-10} & \dots & a_{12,n-3} & a_{12,n-2} & a_{12,n-1} \end{pmatrix}$$

$$d_{n-12} = \begin{pmatrix} a_{1,n-11} & a_{1,n-10} & a_{1,n-9} & \dots & a_{1,n-2} & a_{1,n-1} & a_{1,n} \\ a_{2,n-11} & a_{2,n-10} & a_{2,n-9} & \dots & a_{2,n-2} & a_{2,n-1} & a_{2,n} \\ a_{3,n-11} & a_{3,n-10} & a_{3,n-9} & \dots & a_{3,n-2} & a_{3,n-1} & a_{3,n} \\ \vdots & \vdots & \vdots & \dots & \vdots & \vdots & \vdots \\ a_{10,n-11} & a_{10,n-10} & a_{10,n-9} & \dots & a_{10,n-2} & a_{10,n-1} & a_{10,n} \\ a_{11,n-11} & a_{11,n-10} & a_{11,n-9} & \dots & a_{11,n-2} & a_{11,n-1} & a_{11,n} \\ a_{12,n-11} & a_{12,n-10} & a_{12,n-9} & \dots & a_{12,n-2} & a_{12,n-1} & a_{12,n} \end{pmatrix}$$

Детализирующий вектор позволяет определить общее расположение R пиков на всех каналах. Добавление детализирующего вектора в поток сигналов ЭКГ позволяет нейронной сети точнее классифицировать сигналы ЭКГ.

Для классификации сигналов ЭКГ выбрана нейронная рекуррентная нейронная сеть с долгой краткосрочной памятью LSTM из-за его способности к обучению долгосрочными зависимостями. Это позволяет точнее классифицировать сигналы ЭКГ, так как при различных кардиологических заболеваниях видоизменяются различные пики, интервалы и волны. Более подробно архитектура сети LSTM приведена в работе [10].

Результаты моделирования

Моделирование предложенного нами метода было проведено в среде MatLab 2020b. База PhysioNet Computing in Cardiology Challenge 2021 для проведения моделирования была взята из открытого источника [11]. Эта база данных сигналов ЭКГ в двенадцати отведениях создана в Университете Чемпена, Шаосинской народной больницы и Первой больнице Нинбо. База содержит сигналы ЭКГ, снятые у 45 152 пациентов с частотой дискретизации 500 Гц [12]. Нами были использованы сигналы, полученные от 1 000 пациентов со следующими сердечными аритмиями: артериальная фибрилляция, мерцание желудочков, синусовая тахикардия, синусовая брадикардия, синусовый ритм.

После вычисления детализирующего вектора (рис. 3), он добавляется значением тринадцатого датчика к основной матрице сигналов ЭКГ. Таким образом на вход нейронной сети поступают матрица размером 13×4989 и вектор с метками кардиологических заболеваний.

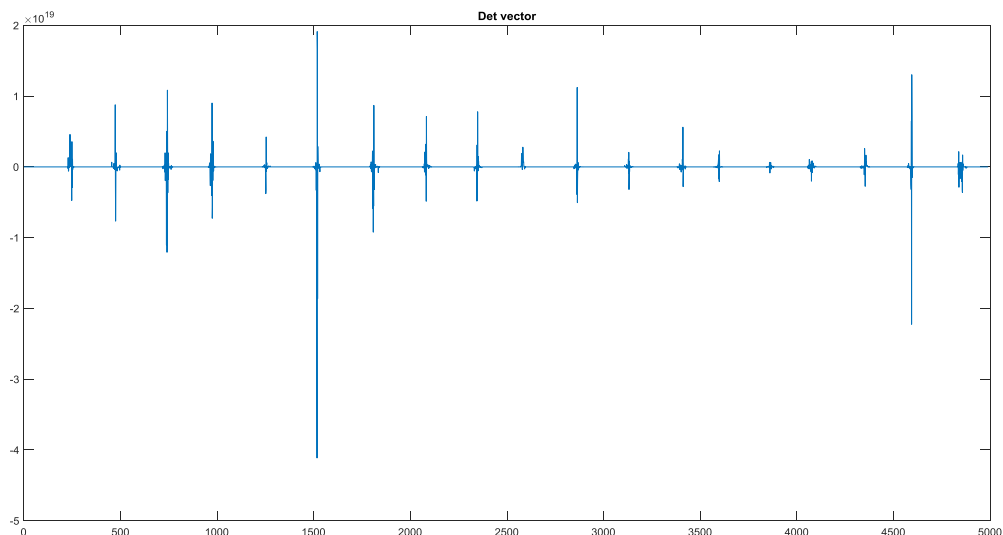


Рис. 3. – Пример детализирующего вектора.

Сеть LSTM была обучена с тремя разными наборами данных: двенадцати каналные сигналы ЭКГ (12-load), детализирующий вектор (det_vec) и двенадцати каналные сигналы ЭКГ с детализирующим вектором (12 load+det_vec). Результаты моделирования представлены в таблице № 1 и рис. 4-6. Оценка использованных методов была проведена метриками точность и функция потерь.

Таблица № 1

Результаты моделирования предложенных архитектур

№ п/п	Входные данные	Точность классификации, %	Значение функции потерь
1	12-load	78,13	0,0011
2	det_vec	48,44	1,3733
3	12 load+det_vec	87,50	0,0008

Наибольшая точность классификации и наименьшее значение функции потерь достигается при обучении нейронного классификатора на данных, содержащих сигналы ЭКГ и детализирующий вектор. Наименьшая точность классификации и наибольшее значение функции потерь достигается при обучении нейроклассификатора только на детализирующих векторах. Это происходит из-за недостаточного числа признаков на потоке сигналов, что подтверждается процессом переобучения заметным на рис. 5.

Известные методы классификации сигналов ЭКГ, основанных на использовании глубокой нейронной сети [7] и рекуррентной сети ResNet [8] достигают 75% и 68% точности классификации, соответственно. Метод классификации сигналов ЭКГ, описанный в работе [6] включает в себя предварительную обработку сигналов ЭКГ (в том числе, и решение проблемы дисбаланса данных), нейросетевую классификацию с использованием рекуррентных нейронных сетей BiLSTM и BiGRU, а также святочной нейронной сети.

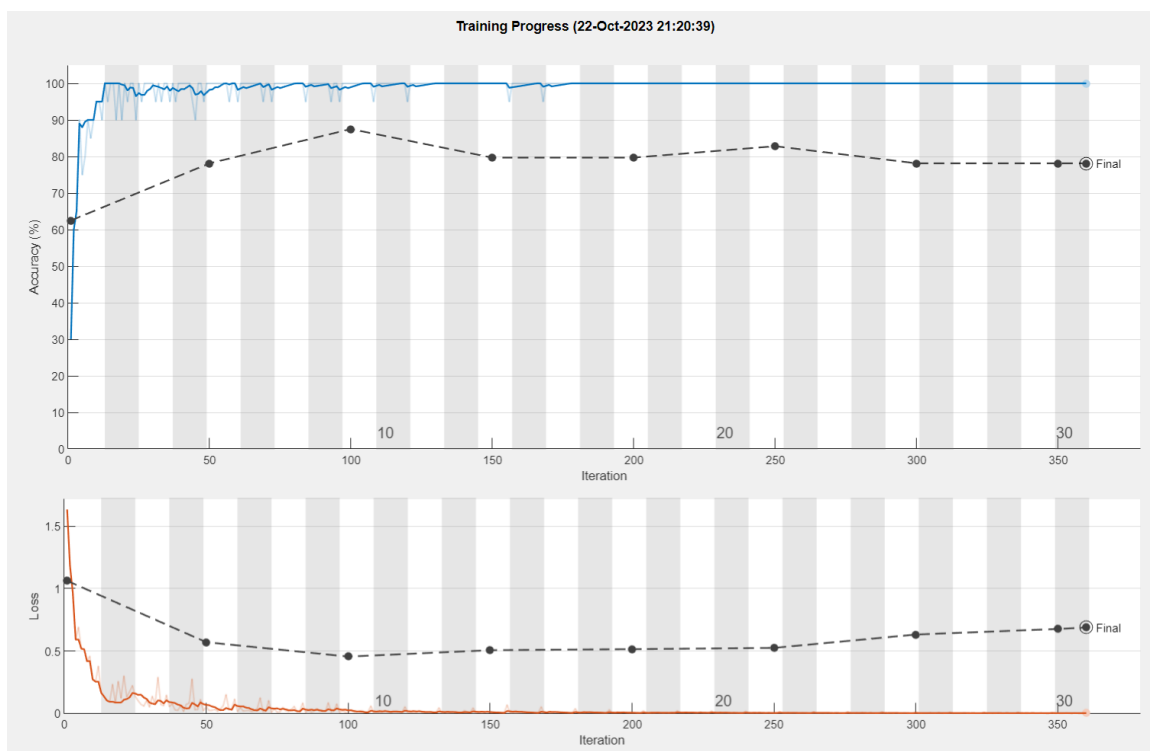


Рис. 4. – Результат обучения сети LSTM на двенадцати канальных ЭКГ.

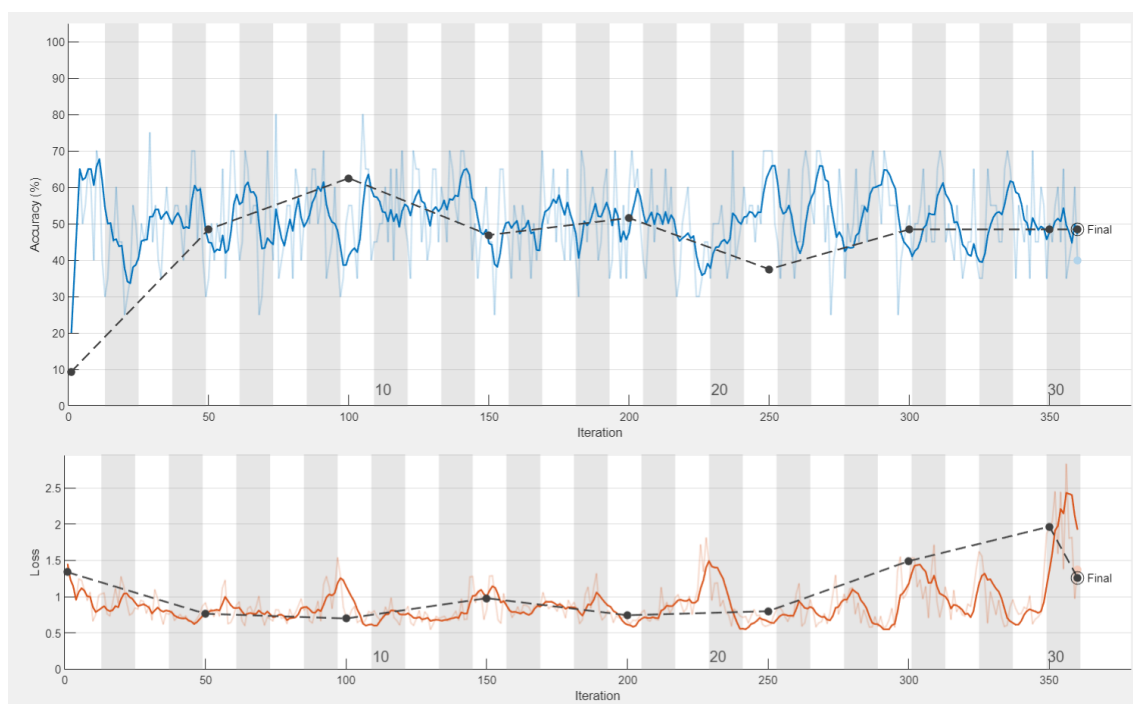


Рис. 5. – Результат обучения сети LSTM на детализирующих векторах двенадцати канальных ЭКГ.

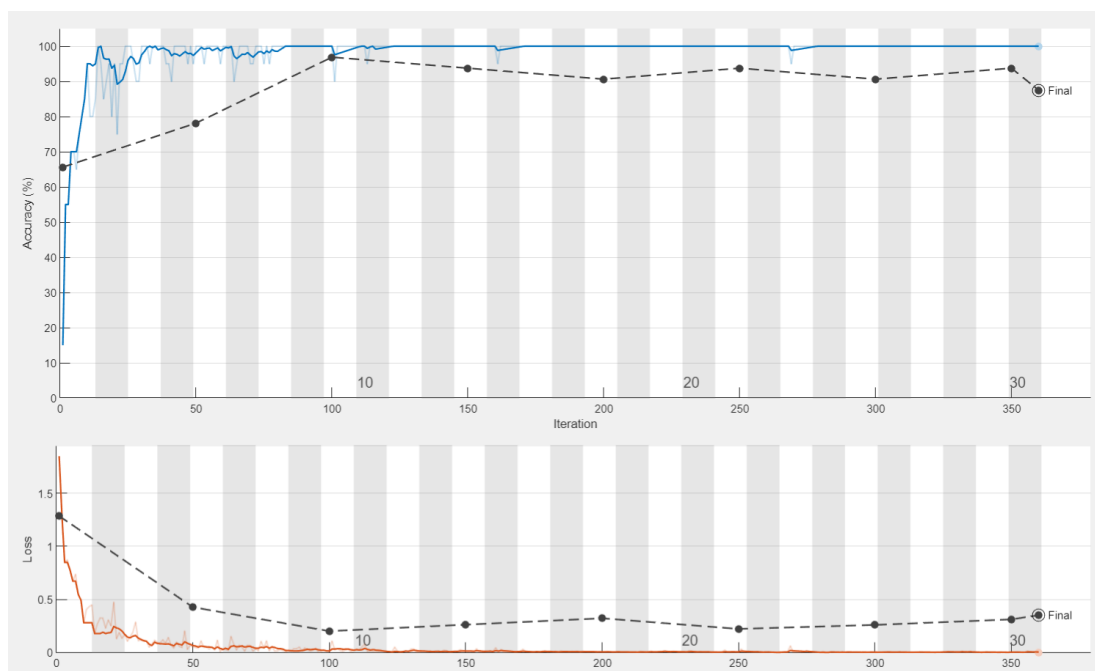


Рис. 6. – Результат обучения сети LSTM на детализирующих векторах двенадцати канальных ЭКГ и двенадцати канальных ЭКГ.

Авторами работы [6] была достигнута точность классификации в 99,6 %, однако данный метод протестирован лишь на двуканальных сигналах ЭКГ. Метод классификации, предложенный в этой работе, имеет гораздо более простую структуру и вычислительную сложность и достигает точности классификации в 87,5%.

Заключение

Предложенный метод нейросетевой классификации может быть применен для классификации сигналов ЭКГ, снятых с использованием двух и более каналов регистрации электрических импульсов работы сердца. Улучшить результат классификации возможно при классификации ансамблевыми методами [4].

Благодарности

Исследование проведено при поддержке проекта Российского научного фонда (проект № 22-71-00009).

Литература (References)

1. McDonagh T., Metra M., Adamo M., Gardner R.S., Baumbach A., et. al. 2021 ESC Guidelines for the diagnosis and treatment of acute and chronic heart failure. European Heart Journal. 2021. Pp. 1-128.
2. Goldberger A.L., Goldberger Z.D., Shvilkin A. Goldberger's Clinical Electrocardiography. Elsevier. 2017. 275 p.
3. Hong S., Zhou Y., Shang J., Xiao C., Sun J. Opportunities and challenges of deep learning methods for electrocardiogram data: A systematic review. Computers in Biology and Medicine. 2020. V. 122. P. 103801.
4. Wu L., Xie X., Wang Y. ECG Enhancement and R-Peak Detection Based on Window Variability. Healthcare. 2021. V. 9. P. 227.
5. Anant K.S., Dowla F.U., Rodrigue G.H. Detection of the electrocardiogram P-wave using wavelet analysis. International Society for Optics and Photonics. 1994. V. 2242. Pp. 744-749.
6. Islam M.S., Hasan K.F. Sultana S. HARDC: A novel ECG-based heartbeat classification method to detect arrhythmia using hierarchical attention based dual structured RNN with dilated CNN. Neural Networks. 2023. V 162. Pp. 271-287.
7. Shang Z., Zhao Zh., Fang H., Murphy D. Deep Discriminative Domain Generalization with Adversarial Feature Learning for Classifying ECG Signals. Computing in Cardiology 2021. Brno, Czech Republic. 2021. Pp. 1-4.
8. Zhao Z., Murphy D., Gifford H., Williams S. Analysis of an adaptive lead weighted ResNet for multiclass classification of 12-lead ECGs. Physiological Measurement. 2022. V.41. № 3. P. 034001.



9. Alday E.A., Annie G., Amit J.Sh., Robochaux Ch., Chengyu L. Classification of 12-lead ECGs: the PhysioNet/Computing in Cardiology Challenge 2020. *Physiological Measurement*. 2021. V. 41 № 12. P. 124003.
10. Hochreiter S., Schmidhuber J. Long Short-term Memory. *Neural Computation*. 1997. V. 9 № 8. Pp. 1735-1780.
11. Zheng J., Guo H., Chu H. A large scale 12-lead electrocardiogram database for arrhythmia study, *PhysioNet*. 2022.
12. Goldberger A., Amaral L., Glass L., Hausdorff L., Ivanov P.C. PhysioBank, PhysioToolkit, and PhysioNet: Components of a new research resource for complex physiologic signals. *Circulation*. 2000. V. 101. № 23. Pp. 215-220.