

УДК 621.376.3

# ГЛУБОКОЕ ОБУЧЕНИЕ ДЛЯ ЗАДАЧИ ВРЕМЕННОЙ СИНХРОНИЗАЦИИ СИГНАЛОВ С OFDM МОДУЛЯЦИЕЙ

Л. И. Аверина, Н. Е. Гутерман

*Воронежский государственный университет*

Поступила в редакцию 09.02.2022 г.

**Аннотация.** Изложен алгоритм оценки временного положения сигнала с цифровой схемой модуляции OFDM, основанный на применении глубокого обучения. Описан подход к формированию репрезентативной обучающей выборки данных, на основе которой реализована модель одномерной сверточной нейронной сети. Выбор архитектуры определён схожестью успешно решаемой средствами глубокого обучения задачи классификации изображений и задачи, поставленной в рамках временной синхронизации. На основе полученных результатов проведен сравнительный анализ эффективности существующей и сформированной нейронной сетью оценок.

**Ключевые слова:** глубокое обучение, сверточная нейронная сеть, OFDM, временная синхронизация.

## DEEP LEARNING APPROACH FOR TIMING SYNCHRONIZATION OF OFDM-SYSTEM

L. I. Averina, N. E. Guterman

**Abstract.** Deep learning approach for fine timing synchronization of OFDM signal was stated in this work. Method of representative training data forming was described. On the basis of this the model of a one-dimensional convolutional neural network was implemented. The choice of architecture is defined by similarity of the image classification problem successfully solved by deep learning and the problem of timing synchronization. Based on the obtained results, a comparative analysis of the existing and formed by neural network estimator efficiency was carried out.

**Keywords:** deep learning, convolutional neural network, OFDM, timing synchronization.

## ВВЕДЕНИЕ

В последнее время идеи искусственного интеллекта (ИИ) привлекают все большее внимание исследователей в различных областях науки, тесно связанных с непрерывной обработкой информации и анализом временных рядов. Благодаря увеличению быстродействия и достаточно большому вычислительному ресурсу ЭВМ, становится возможной реализация искусственных нейронных сетей, дающих достаточную точность и способных выполнять свои основные функции в масштабе времени близком к реальному. При этом в центр внимания попадает концепция глубокого обучения, как новая область исследований в машинном обучении. Эта идеология подразумевает наличие иерархии между слоями нейронов, позволяющей

упорядочить важность выделяемых из входной реализации признаков, и нелинейную обработку информации каждым скрытым слоем. Глубокое обучение является достаточно прогрессивным направлением в изучении ИИ, открывающим новые возможности для внедрения высокоинтеллектуальных моделей в беспроводные сети с крупномасштабной топологией и сложными условиями радиосвязи [1-3]. Наибольший интерес к себе привлекают алгоритмы работы физического уровня, механизм которых может быть усовершенствован с помощью ИИ. Одним из них является временная синхронизация сигналов с OFDM (Orthogonal Frequency-Division Multiplexing) модуляцией. Применение глубокого обучения, а в частности архитектуры сверточных нейронных сетей, обусловлено тем, что постановка задачи здесь схожа с задачей распознавания изображений, успешно решаемой искусственным интеллектом. Алгоритм синхронизации сводится к двум этапам: обнаружению во входной временной реализации характерного признака – наличия известной преамбулы и формированию оценки положения первого информационного символа.

Цели данной работы заключались в следующем:

- сформулировать задачу временной синхронизации OFDM сигнала на основе нейронных сетей глубокого обучения;
- выбрать подходящую архитектуру нейронной сети для решения поставленной задачи, сформировать обучающий набор данных, с достаточной степенью достоверности моделирующий прохождение сигнала через реальный канал, провести обучение модели сети;
- провести сравнительный анализ качества работы существующего алгоритма временной синхронизации и построенной на основе глубокого обучения модели.

В первом разделе статьи детально описан существующий алгоритм синхронизации сигналов с OFDM модуляцией [4, 5], изложена структура синхронизирующих преамбул, с помощью которых вычисляется оценка временного положения первого информационного символа и устраняется частотный уход, вносимый расстройкой тактовых частот передатчика и приемника. Второй раздел посвящен постановке задачи с точки зрения глубокого обучения, описанию алгоритма формирования обучающего набора данных, выбранной архитектуре сети. В третьем разделе приведены результаты моделирования и сравнение среднеквадратических отклонений оценок.

## 1. АЛГОРИТМ ВРЕМЕННОЙ СИНХРОНИЗАЦИИ OFDM СИГНАЛА

Рассмотрим классический алгоритм синхронизации сигналов с OFDM модуляцией во временной области. Для формирования соответствующих оценок необходимо размещение перед основным потоком информационных символов двух специальных преамбул. Первая из них служит для проведения временной синхронизации, вторая – для устранения частотного ухода. Структура преамбул представлена на рисунке 1. Здесь поля  $N_g$ , выделенные серым цветом, обозначают циклические префиксы,  $p_{1,i}$  – части преамбулы для синхронизации во времени,  $p_2$  – преамбула для синхронизации по частоте.

На четные поднесущие первого OFDM символа расставляются промодулированные (например, QAM или QPSK) символы псевдослучайной последовательности, нечетные поднесущие имеют нулевое заполнение. После обратного дискретного преобразования Фурье такая структура порождает две одинаковые части преамбулы  $p_{1,1}$  и  $p_{1,2}$ . Второй OFDM символ содержит ту же псевдослучайную последовательность на нечетных поднесущих и отличную последовательность на четных. При этом необходимо, чтобы символьная энергия сигнала была нормированной.

При прохождении через канал обе половины первой преамбулы останутся практически идентичными за исключением сдвига фазы, поэтому их скалярное произведение даст макси-

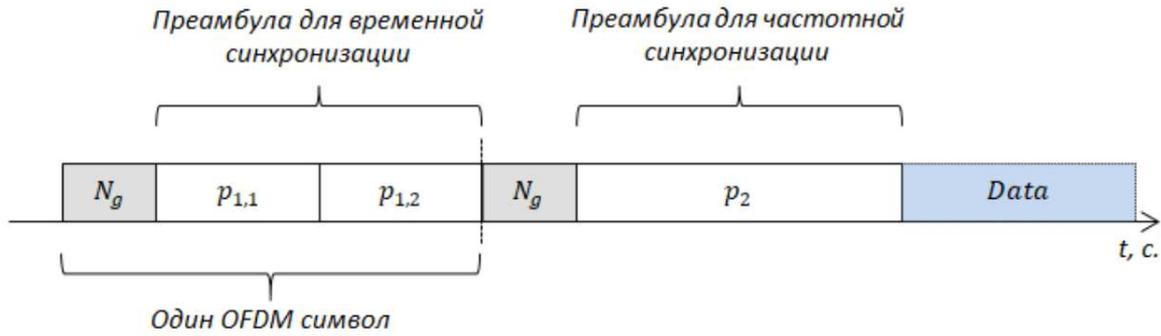


Рис. 1. Структура синхронизирующих преамбул OFDM сигнала.

мум. Рассмотрим следующую корреляцию:

$$\Lambda(d) = \sum_{m=0}^{N_{sub}/2-1} r^*(d+m)r(d+m+N_{sub}/2),$$

где  $N_{sub}$  — количество поднесущих одного OFDM символа,  $r(m)$  — оцифрованная, принятая антенной приемника временная реализация. Ее энергия вычисляется по следующей формуле:

$$P(d) = \frac{1}{2} \sum_{m=0}^{N_{sub}-1} |r(d+m)|^2.$$

Временная метрика, которая используется для проверки статистических гипотез наличия и отсутствия сигнала, имеет вид:

$$M(d) = \frac{1}{N_g + 1} \sum_{k=0}^{N_g} \frac{|\Lambda(d-k)|^2}{P^2(d-k)}. \quad (1)$$

Скользящее среднее, вычисляемое по длине циклического префикса  $N_g$ , здесь необходимо для устранения неоднозначности в определении временного положения первого информационного символа. Его оценка дается следующей формулой:

$$\hat{\tau} = \arg \max_d M(d). \quad (2)$$

Существующий алгоритм временной синхронизации имеет различные модификации, формирующие более эффективные оценки [6]. В рамках данной статьи сравнение эффективности предложенного алгоритма синхронизации производилось именно с подходом, изложенным в [4].

## 2. ПРИМЕНЕНИЕ ГЛУБОКОГО ОБУЧЕНИЯ К ЗАДАЧЕ СИНХРОНИЗАЦИИ

Задача синхронизации, заключающаяся в формировании оптимальной по какому-либо статистическому критерию оценки временного положения первого информационного символа, с точки зрения глубокого обучения является задачей регрессии. То есть, весь процесс построения модели сети сводится к аппроксимации следующего отображения:

$$f : \mathbb{R}^{M \times N} \rightarrow \mathbb{R}.$$

Таким образом, индуцированное локальное поле единственного нейрона, находящегося в выходном слое, и будет являться оценкой временного положения сигнала в случае, когда была принята гипотеза о наличии преамбулы во входной реализации. При выборе альтернативной гипотезы модель сети на выходе формирует специально закодированное для данного случая значение.

Наряду с выбором архитектуры нейронной сети ее обучение является ключевым моментом в построении правильно функционирующей модели. Под обучением здесь понимается процесс моделирования среды, в которую встроена сеть, и оптимизация синаптических связей и смещений для достижения успешной работы алгоритма. При этом необходимо предоставить репрезентативную выборку обучающих примеров, в достаточной мере описывающих условия задачи. В рамках данной статьи в качестве модели канала, через который проходили сверхвысокочастотные электромагнитные волны, была выбрана модель стандарта связи *IEEE 802.11ac* [7]. Она представляет собой многолучевой рэлеевский канал с замираниями и доплеровским смещением. Объем обучающей выборки при моделировании был равен 120000 реализаций случайного процесса. В 50% случаев на вход сети поступала аддитивная смесь случайно смещенной, прошедшей через модель канала синхронизирующей преамбулы и реализации белого гауссовского шума случайной мощности. Остальные 50% содержали лишь часть преамбулы в смеси с шумом или же просто реализацию шума. При составлении выборки данных варьировались следующие параметры: дисперсия шума, равномерно распределенная в некотором диапазоне; доплеровское смещение частоты; величина потерь при распространении; мощности отраженных лучей в точке приема; временная задержка сигнала. Длина импульсной характеристики канала считалась постоянной и равной 80 нс. В процессе обучения и верификации работы нейронной сети набор входных реализаций был случайно перемешан и разделен в следующем соотношении: 68% — объем обучающей выборки; 17% — объем контрольной выборки; 15% — объем тестовой выборки.

Для решения сформулированной задачи в качестве модели были выбраны сверточные нейронные сети. Такая архитектура, показавшая хорошие результаты в обработке изображений и анализе речи, является наиболее подходящей и здесь. Для систем связи с одной передающей и одной приемной антеннами входная временная реализация одномерна, поэтому и сверточные слои нейронной сети должны производить свертку в одном измерении. В таблице 1 детально описана архитектура выбранной сети, приведено общее число параметров.

Таблица 1.

Тип слоя	Размерность выхода	Количество параметров
Conv1D + ReLU	(1, 57, 8)	1032
Conv1D + ReLU	(1, 26, 8)	2056
Max Pooling	(1, 13, 8)	0
Flatten	(1, 1, 104)	0
FC + ReLU	(1, 1, 52)	5460
Dropout (30%)	(1, 1, 52)	0
FC + ReLU	(1, 1, 26)	1378
FC + Linear	(1, 1, 1)	27
Всего параметров сети: 9953		

Программная реализация модели нейронной сети была проведена с использованием библиотек *Keras*, *TensorFlow* языка *Python* [8]. В качестве функции потерь выбрана средняя абсолютная ошибка:

$$L_{MAE}(\tau_s, \hat{\tau}_s) = \frac{1}{N_b} \sum_{i=1}^{N_b} |\tau_{s,i} - \hat{\tau}_{s,i}|,$$

где  $N_b$  — размер пакета входных реализаций. При обучении были выбраны следующие параметры: количество эпох обучения — 100; размер пакета — 240; для минимизации функции потерь использовался метод стохастического градиентного спуска *ADAM* со скоростью обучения  $\alpha = 0.001$ ,  $\beta_1 = 0.9$ ,  $\beta_2 = 0.999$ .

### 3. РЕЗУЛЬТАТЫ МОДЕЛИРОВАНИЯ

Для обучения и верификации работы сверточной нейронной сети был сформирован OFDM сигнал с шириной полосы 20 МГц и частотой несущей 1720.32 МГц. На рисунке 2 представлены зависимости ошибки предсказаний нейронной сети от номера эпохи обучения для обучающего и проверочного наборов.

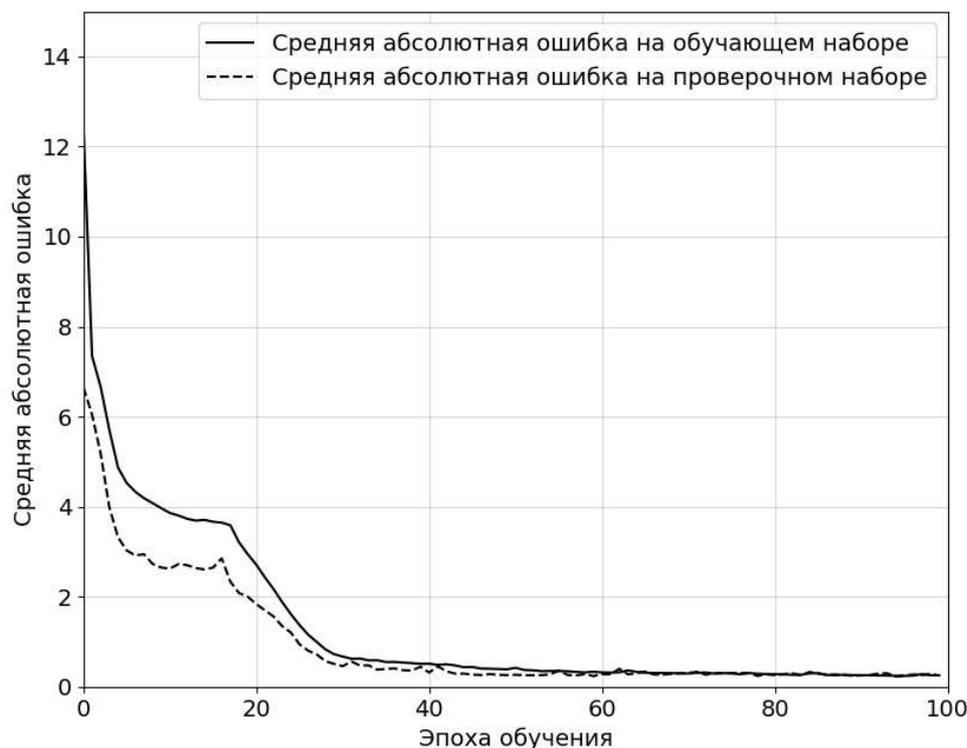


Рис. 2. Процесс обучения одномерной сверточной нейронной сети.

Из графиков видно, что ошибка на обучающем наборе данных практически не отличается от ошибки на проверочном наборе, что свидетельствует о малой дисперсии формируемой оценки и отсутствии переобучения модели. Алгоритм стохастического градиентного спуска сходится к минимальному значению функции потерь и, таким образом, мы получаем оценку с малым смещением. Рисунки 3 и 4 иллюстрируют результаты верификации обученной сверточной нейронной сети на тестовом наборе данных. Здесь величина ошибки измеряется в символах, расставленных по поднесущим OFDM сигнала.

На рисунке 5 изображены зависимости вероятности пропуска сигнала  $\beta$  (или принятия ложноотрицательного решения) от отношения сигнал/шум (ОСШ), под которым понимается отношение символьной энергии к односторонней спектральной плотности мощности шума, полученные при компьютерном моделировании с применением классического метода синхронизации и сверточной нейронной сети. Видно, что нейросетевой подход синхронизации имеет большую статистическую мощь по сравнению с существующим алгоритмом.

Рисунок 6 иллюстрирует зависимости среднеквадратических отклонений существующей

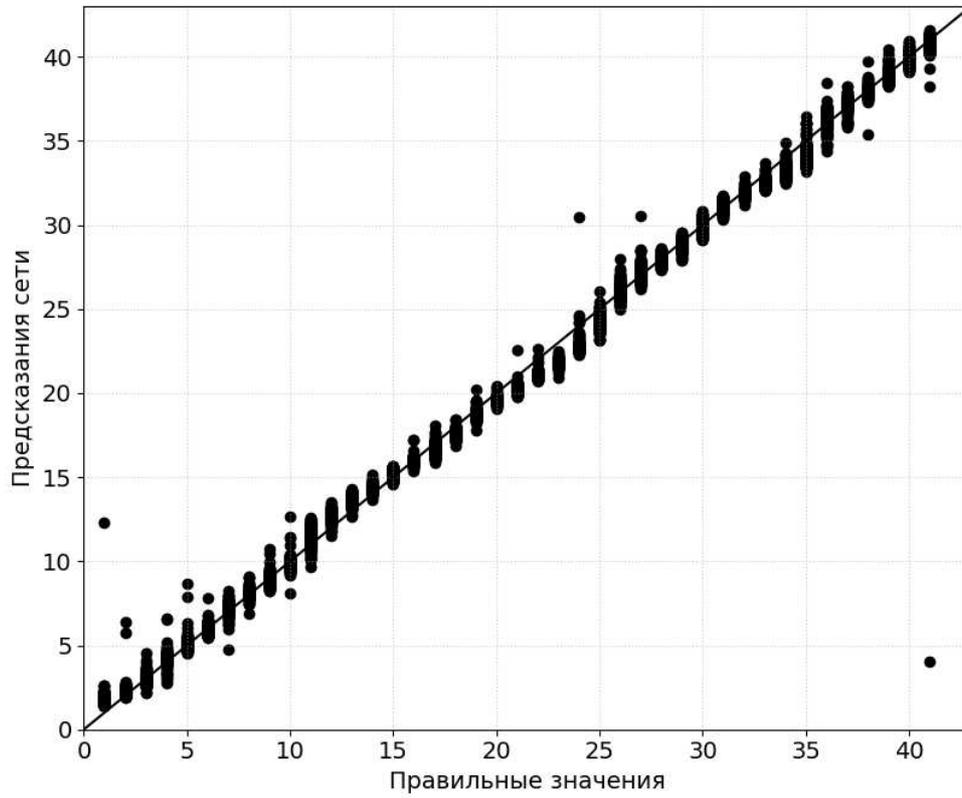


Рис. 3. Верификация работы сверточной нейронной сети.

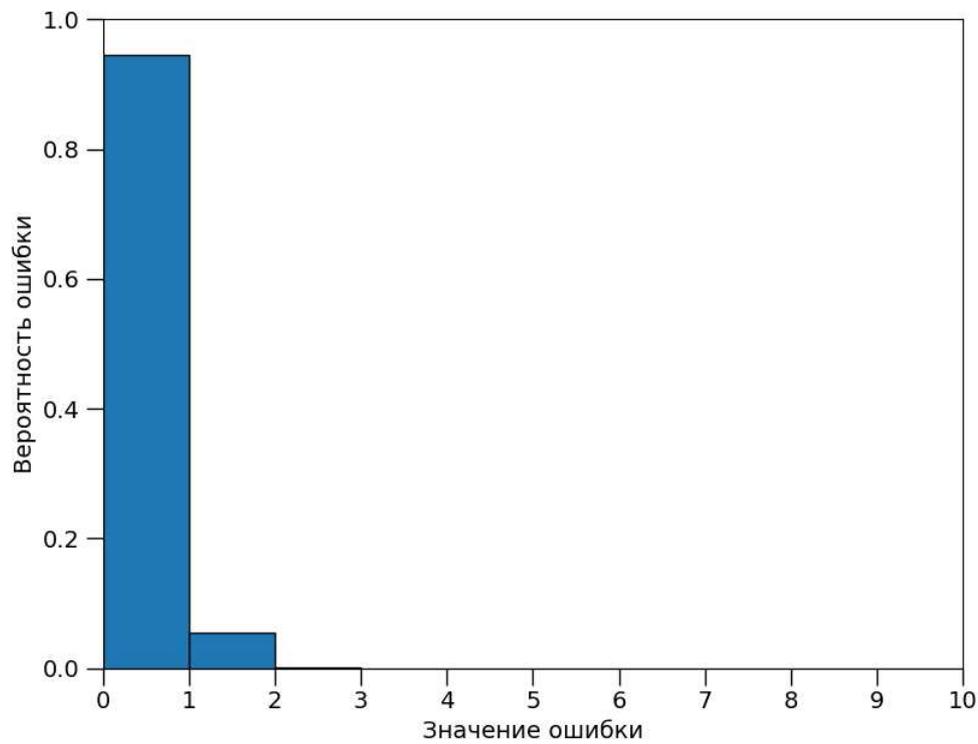


Рис. 4. Гистограмма ошибок сверточной нейронной сети.

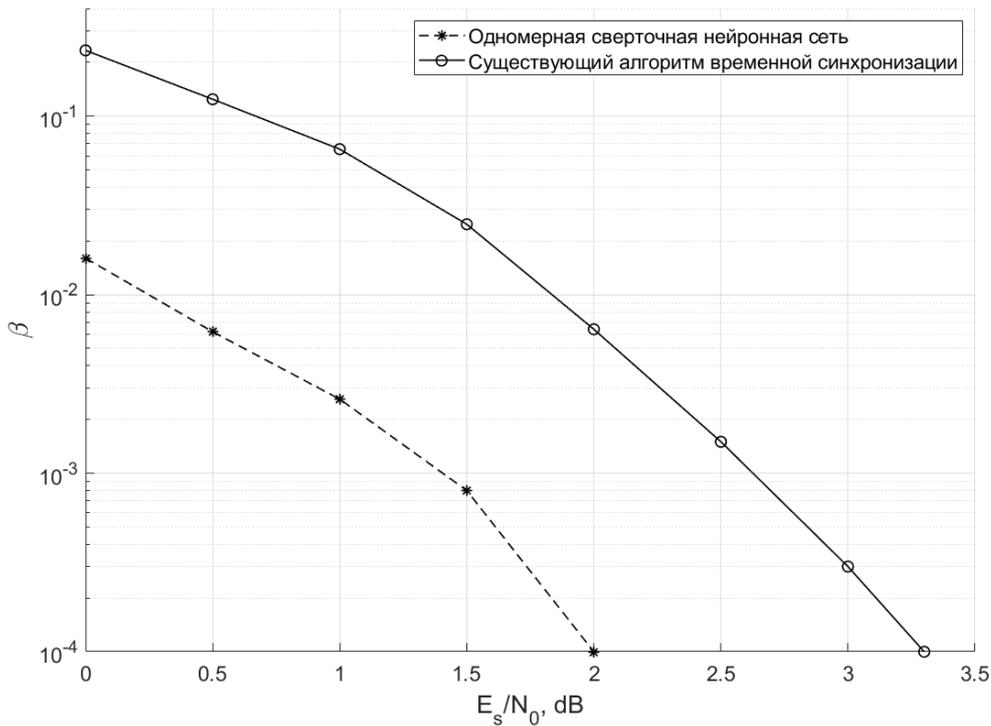


Рис. 5. Вероятности принятия ложноотрицательного решения.

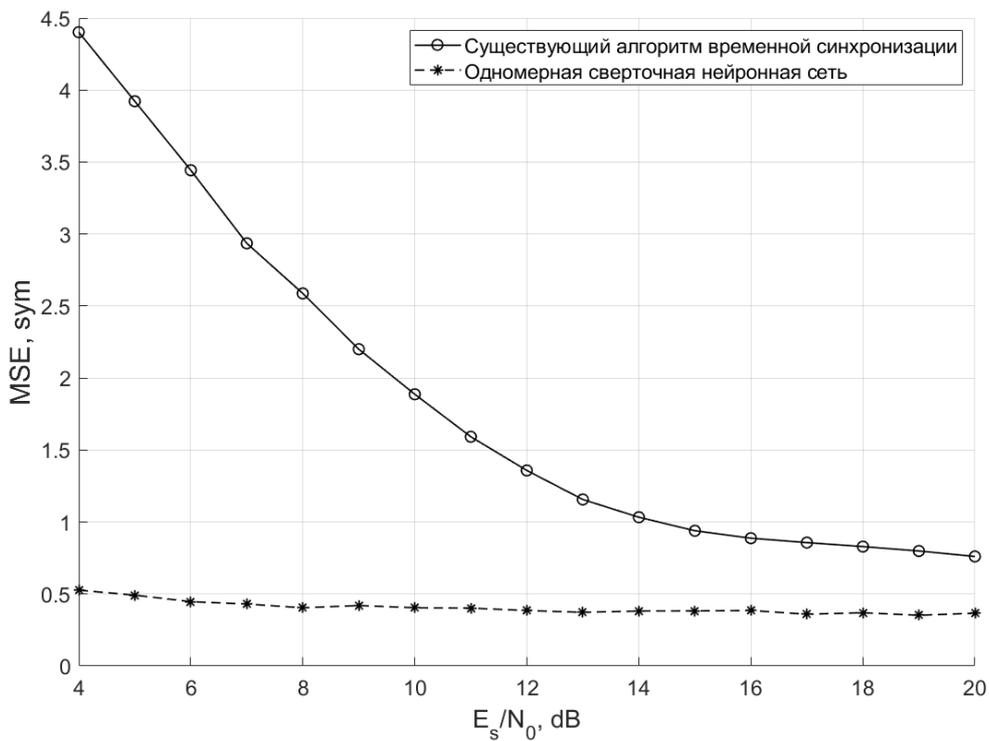


Рис. 6. Среднеквадратическое отклонение оценок.

оценки времени синхронизации и оценки, формируемой одномерной сверточной нейронной сетью. Сравнение их эффективностей уместно при таких значениях ОСШ, на которых достигается минимальная вероятность ошибки второго рода. Из полученных результатов можно сделать вывод о том, что оценка временного положения, сформированная одномерной сверточной нейронной сетью, обладает меньшей дисперсией.

## ЗАКЛЮЧЕНИЕ

В работе сформулирована задача временной синхронизации сигналов с OFDM модуляцией на основе глубокого обучения. Описан способ генерации репрезентативной обучающей выборки данных. С ее помощью произведено обучение одномерной сверточной нейронной сети, продемонстрированы отсутствие переобучения и хорошая обобщающая способность модели. На основании полученных в ходе моделирования данных построены зависимости среднеквадратического отклонения и вероятности ошибки второго рода от ОСШ для существующей оценки временного положения и оценки, сформированной обученной сетью. Результаты свидетельствуют о том, что новый алгоритм обладает большей статистической мощностью и эффективностью.

## СПИСОК ЛИТЕРАТУРЫ

1. Artificial Neural Networks-Based Machine Learning for Wireless Networks: A Tutorial / M. Chen et. al. // IEEE Communications Surveys and Tutorials. — 2019. — V. 21, № 4. — P. 3039–3071.
2. Mao, Q. Deep Learning for Intelligent Wireless Networks: A Comprehensive Survey / Q. Mao, F. Hu, Q. Hao // IEEE Communications Surveys and Tutorials. — 2018. — V. 20, № 4. — P. 2595–2621.
3. Comprehensive Survey on Machine Learning in Vehicular Network: Technology, Applications and Challenges / F. Tang, B. Mao, N. Kato, G. Gui // IEEE Communications Surveys and Tutorials. — 2021. — V. 23, № 3. — P. 2027–2057.
4. Schmidl, T. M. Robust Frequency and Timing Synchronization for OFDM / T. M. Schmidl, D. C. Cox // IEEE Transactions on Communications. — 1997. — V. 45, № 12. — P. 1613–1621.
5. Minn, H. On Timing Offset Estimation for OFDM Systems / H. Minn, M. Zeng, V. K. Bhargava // IEEE Communications Letters. — 2000. — V. 4, № 7. — P. 242–244.
6. Synchronization Method Based on a New Constant Envelop Preamble for OFDM Systems / G. Ren, Y. Chang, H. Zhang, H. Zhang // IEEE Transactions on Broadcasting. — 2005. — V. 51, № 1. — P. 139–143.
7. IEEE 802.11 Wireless LANs: TGn Channel Models / V. Erceg et. al. — 2004. — V. 4. — URL: <https://www.iitk.ac.in/mwn/papers/11-03-0940-01-000n-tgn-channel-models.pdf>.
8. Джулли, А. Библиотека Keras – инструмент глубокого обучения / А. Джулли, С. Пал; пер. с англ. Слинкин А. А. — М. : ДМК Пресс, 2018. — 294 с.

## REFERENCES

1. Chen M., Challita U., Saad W., Yin C., Debbah M. Artificial Neural Networks-Based Machine Learning for Wireless Networks: A Tutorial. IEEE Communications Surveys and Tutorials, 2019, vol. 21, no. 4, pp. 3039–3071.
2. Mao Q., Hu F., Hao Q. Deep Learning for Intelligent Wireless Networks: A Comprehensive Survey. IEEE Communications Surveys and Tutorials, 2018, vol. 20, no. 4, pp. 2595–2621.
3. Tang F., Mao B., Kato N., Gui G. Comprehensive Survey on Machine Learning in Vehicular Network: Technology, Applications and Challenges. IEEE Communications Surveys and Tutorials, 2021, vol. 23, no. 3, pp. 2027–2057.

- 0] Schmidl T.M., Cox D.C. Robust Frequency and Timing Synchronization for OFDM. IEEE Transactions on Communications, 1997, vol. 45, no. 12, pp. 1613–1621
4. Minn H., Zeng M., Bhargava V.K. On Timing Offset Estimation for OFDM Systems. IEEE Communications Letters, 2000, vol. 4, no. 7, pp. 242–244.
5. Ren G., Chang Y., Zhang H., Zhang H. Synchronization Method Based on a New Constant Envelop Preamble for OFDM Systems. IEEE Transactions on Broadcasting, 2005, vol. 51, no. 1, pp. 139–143.
6. Erceg V. et. al. IEEE 802.11 Wireless LANs: TGn Channel Models. 2004, vol. 4. URL: <https://www.iitk.ac.in/mwn/papers/11-03-0940-01-000n-tgn-channel-models.pdf>.
7. Gulli A., Pal S. Deep Learning with Keras. [Dzhulli A., Pal S. Библиотека Keras – instrument glubokogo obucheniya]. Moscow, 2018, 294 p.

*Аверина Лариса Ивановна, д. ф.-м. н., профессор кафедры электроники Воронежского государственного университета, Воронеж, Россия*  
*E-mail: averina@phys.vsu.ru*

*Averina Larisa Ivanovna, Doctor of physical and mathematical sciences, Full Professor, Department of Electronics, Voronezh State University, Voronezh, Russia*  
*E-mail: averina@phys.vsu.ru*

*Гутерман Никита Евгеньевич, магистр кафедры электроники Воронежского государственного университета, Воронеж, Россия*  
*E-mail: guterman.nik@mail.ru*

*Guterman Nikita Evgenievich, Masters student, Department of Electronics, Voronezh State University, Voronezh, Russia*  
*E-mail: guterman.nik@mail.ru*