

МИНОБРНАУКИ РОССИИ

ФЕДЕРАЛЬНОЕ ГОСУДАРСТВЕННОЕ БЮДЖЕТНОЕ  
ОБРАЗОВАТЕЛЬНОЕ УЧРЕЖДЕНИЕ ВЫСШЕГО ОБРАЗОВАНИЯ  
«САРАТОВСКИЙ НАЦИОНАЛЬНЫЙ ИССЛЕДОВАТЕЛЬСКИЙ  
ГОСУДАРСТВЕННЫЙ УНИВЕРСИТЕТ  
ИМЕНИ Н.Г. ЧЕРНЫШЕВСКОГО»

Кафедра радиофизики и нелинейной динамики

**Разделение сигналов при помощи искусственных нейронных сетей**  
**АВТОРЕФЕРАТ БАКАЛАВРСКОЙ РАБОТЫ**

студента 4 курса 4032 группы  
направления 03.03.03 Радиофизика  
Института физики  
Сачек Виктора Дмитриевича

Научный руководитель

профессор, д.ф.-м.н., доцент

\_\_\_\_\_ А.В. Шабунин

Зав. кафедрой радиофизики

и нелинейной динамики,

д.ф.-м.н., доцент

\_\_\_\_\_ Г. И. Стрелкова

Саратов 2026 г.

## **ВВЕДЕНИЕ**

Актуальность темы бакалаврской работы определяется развитием методов цифровой обработки сигналов и необходимостью выделения полезных компонент из наблюдаемых смесей при отсутствии полной информации о канале смешивания. В радиофизике, телекоммуникационных системах, акустике и обработке измерительных данных часто возникает ситуация, когда приемная система регистрирует не отдельный источник, а совокупный сигнал, сформированный несколькими компонентами и помехами.

Традиционные методы частотной, временной или пространственной селекции эффективны в тех случаях, когда сигналы хорошо различаются по заранее известным признакам. Если матрица смешивания, параметры источников и характеристики среды заранее неизвестны, более естественной становится постановка слепого разделения источников. В этой постановке требуется восстановить исходные сигналы по наблюдаемым смесям без точного знания механизма смешивания.

Одним из подходов к решению такой задачи является применение искусственных нейронных сетей и информационных критериев обучения. В работе рассматривается нейронный разделитель прямого распространения, параметры которого представлены матрицей весов. Настройка этой матрицы выполняется по принципу Infomax, связанному с уменьшением статистической зависимости между выходными компонентами.

Бакалаврская работа состоит из введения, трех глав, заключения, списка использованных источников и приложений. В первой главе рассматриваются теоретические основы разделения сигналов, во второй главе описывается нейросетевой метод и используемые метрики качества, в третьей главе приводятся результаты вычислительного эксперимента и их анализ.

### **Теоретические основы разделения сигналов**

В первой главе рассмотрена задача восстановления исходных компонент из наблюдаемых смесей. В общем виде модель линейного смешивания связывает матрицу исходных сигналов  $S$ , матрицу смешивания  $A$  и матрицу

наблюдений  $X$  соотношением  $X = A S$ . Цель алгоритма разделения состоит в построении такого преобразования  $W$ , при котором выход  $Y = W X$  становится оценкой исходных источников.

Для задачи слепого разделения характерны неоднозначности порядка, масштаба и знака восстановленных компонент. Эти особенности не являются ошибкой метода, поскольку без дополнительных сведений о физических источниках невозможно заранее определить точный порядок выходов и абсолютный масштаб сигналов.

Современные глубокие модели разделения источников требуют больших наборов данных и дополнительной настройки. Для анализа принципа разделения двух модельных сигналов в работе выбран более интерпретируемый линейный нейронный разделитель. Такой выбор позволяет явно проследить связь между матрицей смешивания, правилом обучения и количественными метриками результата.

### **Нейросетевой метод разделения сигналов**

Во второй главе описана математическая модель искусственного нейрона и нейронного разделителя. В качестве основной модели используется однослойная сеть прямого распространения, параметры которой представлены матрицей весов  $W$ . Каждый элемент этой матрицы задает вклад соответствующего наблюдаемого канала в восстановленную компоненту.

Обучение выполняется без учителя: эталонные исходные сигналы не используются для изменения матрицы  $W$ , а применяются только для последующей оценки качества в вычислительном эксперименте. На каждой итерации вычисляется линейный выход  $Y$ , затем нелинейно преобразованный выход  $Z$ , после чего по правилу Infomax изменяется матрица  $W$ .

Минимизации взаимной информации можно при помощи градиентного спуска при котором происходит корректировка весов. Правило коррекции весов имеет следующий вид :

$$W(n + 1) = W(n) + \eta [I + (1 - 2z(n))y^T(n)]W(n)$$

Метод Infomax связывает настройку разделителя с информационными характеристиками выходных сигналов. Энтропия используется в обучающем принципе, а для количественной оценки качества разделения в работе применяется взаимная информация между двумя выходными каналами. Чем меньше взаимная информация после разделения, тем слабее статистическая зависимость восстановленных компонент.

Итоговое восстановление после завершения обучения выполняется линейным преобразованием  $Y = W X$ . Сигмоидальная нелинейность участвует в вычислении обучающего градиента, но не является самостоятельным восстановителем сигнала. Это позволяет рассматривать обученную сеть как линейный разделитель, параметры которого были найдены по информационному критерию.

Качество разделения оценивается совокупностью показателей: среднеквадратичной ошибкой, среднеквадратичной нормой разности, коэффициентом корреляции между исходными и восстановленными сигналами, корреляцией между выходными каналами и взаимной информацией между ними. При расчете взаимной информации непрерывные сигналы предварительно нормировались и квантовались по уровню на  $K = 32$  интервала в диапазоне  $[-3; 3]$ ; шаг квантования составил 0,1875, а результат вычислялся в битах.

Программная реализация используется как инструмент воспроизводимого вычислительного эксперимента. В ней задаются типы источников, формируется матрица исходных сигналов, выполняется линейное смешивание, проводится нормировка, запускается обучение по правилу Infomax и сохраняются показатели качества разделения.




Рисунок 1 - Схема вычислительного эксперимента

Схема показывает общий порядок вычислительного эксперимента: исходные сигналы смешиваются матрицей  $A$ , после чего нейронная сеть с матрицей  $W$  формирует оценки исходных компонент.

### **Вычислительный эксперимент и анализ результатов**

В третьей главе представлены условия вычислительного эксперимента и результаты разделения регулярных, стохастических и хаотических сигналов. Для регулярных источников использовались гармонический и прямоугольный периодические сигналы. Стохастические источники формировались на основе нормального распределения и распределения Лапласа с последующим сглаживанием методом скользящего среднего. Хаотические сигналы задавались логистическим отображением при параметрах, соответствующих хаотическому режиму.

В базовой серии экспериментов два источника смешивались невырожденной матрицей  $A = \begin{bmatrix} 0.8 & 0.4 \\ 0.3 & 0.9 \end{bmatrix}$ , определитель которой равен 0,60. Количество эпох обучения составляло 600, скорость обучения была равна 0,03. После генерации и смешивания сигналы нормировались, так как правило обучения чувствительно к масштабу входных компонент.

Всего рассмотрено девять сочетаний модельных источников. Во всех базовых случаях средний коэффициент корреляции между исходными и восстановленными сигналами оказался выше 0,99. Это показывает, что нейронный разделитель в целом корректно восстанавливает форму исходных компонент после линейного смешивания.




Рисунок 2 - Средний коэффициент корреляции по девяти сочетаниям сигналов

На графике видно, что средний коэффициент корреляции во всех рассмотренных случаях остается выше 0,99, что подтверждает сохранение формы восстановленных сигналов.




Рисунок 3 - Среднее SKO по девяти сочетаниям сигналов

График SKO дополняет корреляционный анализ и показывает, в каких сочетаниях сохраняется наибольшая остаточная ошибка восстановления.

Наилучший результат получен для сочетания регулярного прямоугольного и стохастического сигналов: средняя корреляция составила 0,998473, среднее SKO - 0,055264. Наиболее сложным оказался случай разделения гармонического и прямоугольного регулярных сигналов: среднее SKO составило 0,110800 при средней корреляции 0,993862.




Рисунок 4 - Исходные, смешанные и восстановленные сигналы для лучшего случая

Для сочетания регулярного прямоугольного и стохастического сигналов восстановленные компоненты наиболее близки к исходным, что соответствует максимальной средней корреляции и минимальному СКО.




Рисунок 5 - Исходные, смешанные и восстановленные сигналы для наиболее сложного случая

Наиболее сложный случай демонстрирует, что разделение сохраняет основную форму сигналов, но на выходах заметны остаточные отклонения. Поэтому результат следует характеризовать как качественное, но не полное разделение.

Случаи с хаотическими сигналами также демонстрируют возможность разделения источников со сложной непериодической динамикой. Для сочетания хаотический + хаотический средняя корреляция составила 0,994014. Вместе с тем увеличение ошибки в таких случаях связано со сложной структурой хаотических сигналов и чувствительностью их формы к малым изменениям.

Дополнительно анализировалась динамика зависимости между выходными каналами. В среднем модуль корреляции между двумя каналами уменьшился с 0,710768 до 0,001264, а взаимная информация снизилась с 1,747970 до 0,716390 бит. Ненулевые значения взаимной информации после разделения показывают сохранение остаточной зависимости между восстановленными компонентами.

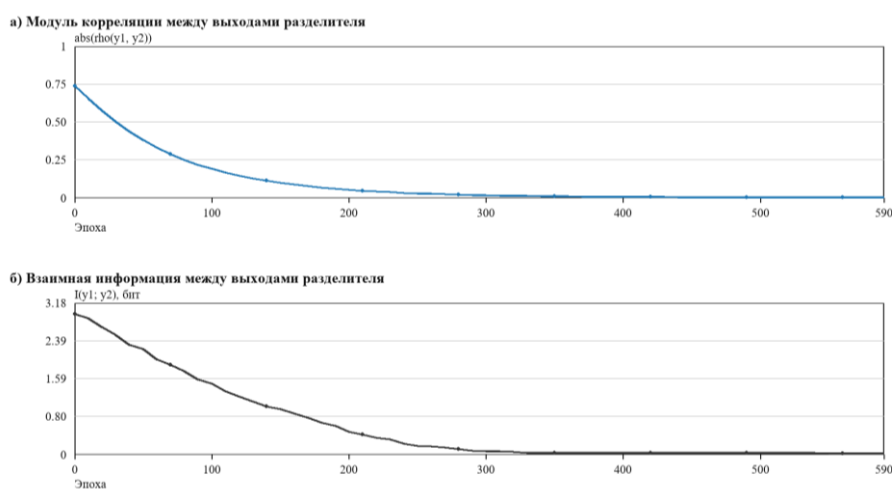


Рисунок 6 - Динамика корреляции выходов и взаимной информации в процессе обучения

Убывание корреляции выходов и взаимной информации показывает, что в процессе обучения выходные каналы становятся менее зависимыми друг от друга.

Таким образом, результаты вычислительного эксперимента подтверждают работоспособность выбранного метода, но одновременно показывают его ограничения. Разделение является качественным, но не полным: среднее СКО остается ненулевым, на графиках сохраняются малые остаточные отклонения, а точность восстановления зависит от различимости источников и параметров обучения.

## ЗАКЛЮЧЕНИЕ

В бакалаврской работе рассмотрена задача разделения сигналов при помощи искусственных нейронных сетей. Теоретическая часть работы связана с постановкой слепого разделения источников, линейной моделью смешивания, анализом независимых компонент и информационными методами обучения.

В качестве основного метода использован нейронный разделитель прямого распространения, обучаемый по правилу Infomax. Показано, что такая модель может быть представлена как линейная матрица разделения  $W$ , настраиваемая по информационному критерию. Итоговое восстановление сигналов выполняется линейным преобразованием, а сигмоидальная функция используется в процедуре обучения.

Вычислительный эксперимент показал высокое качество восстановления для регулярных, стохастических и хаотических сигналов. Во всех девяти базовых случаях средняя корреляция превысила 0,99. Лучший результат составил 0,998473 по средней корреляции при среднем СКО 0,055264, наиболее сложный случай имел среднее СКО 0,110800.

Полученные результаты позволяют сделать вывод, что нейросетевой метод на основе Infomax обеспечивает качественное разделение сигналов различной природы. Вместе с тем разделение не является полным, поскольку сохраняются ненулевые значения СКО, остаточные отклонения формы сигналов и ненулевая взаимная информация между выходными компонентами после обучения.

## СПИСОК ИСПОЛЬЗОВАННЫХ ИСТОЧНИКОВ

1. Хайкин С. Нейронные сети: полный курс / С. Хайкин ; пер. с англ. — 2-е изд. — Москва : Вильямс, 2006. — 1104 с.
2. Hyvärinen A. Independent Component Analysis / A. Hyvärinen, J. Karhunen, E. Oja. — New York : John Wiley & Sons, 2001. — 504 p. — DOI: 10.1002/0471221317.
3. Cardoso J.-F. Blind signal separation: statistical principles / J.-F. Cardoso // Proceedings of the IEEE. — 1998. — Vol. 86, no. 10. — P. 2009–2025. — DOI: 10.1109/5.720250.
4. Comon P. Independent component analysis, a new concept? / P. Comon // Signal Processing. — 1994. — Vol. 36, no. 3. — P. 287–314. — DOI: 10.1016/0165-1684(94)90029-9.
5. Jutten C. Blind separation of sources, Part I: An adaptive algorithm based on neuromimetic architecture / C. Jutten, J. Héroult // Signal Processing. — 1991. — Vol. 24, no. 1. — P. 1–10. — DOI: 10.1016/0165-1684(91)90079-X.
6. Bishop C. M. Pattern Recognition and Machine Learning / C. M. Bishop. — New York : Springer, 2006. — 738 p.
7. Гудфеллоу Я. Глубокое обучение / Я. Гудфеллоу, И. Бенджио, А. Курвилль ; пер. с англ. А. А. Слинкина. — 2-е изд., испр. — Москва : ДМК Пресс, 2018. — 652 с.
8. Amari S. Natural gradient works efficiently in learning / S. Amari // Neural Computation. — 1998. — Vol. 10, no. 2. — P. 251–276. — DOI: 10.1162/089976698300017746.
9. LeCun Y. Deep learning / Y. LeCun, Y. Bengio, G. Hinton // Nature. — 2015. — Vol. 521, no. 7553. — P. 436–444. — DOI: 10.1038/nature14539.
10. Oja E. Neural networks, principal components, and subspaces / E. Oja // International Journal of Neural Systems. — 1989. — Vol. 1, no. 1. — P. 61–68. — DOI: 10.1142/S0129065789000475.

11. Lee D. D. Learning the parts of objects by non-negative matrix factorization / D. D. Lee, H. S. Seung // *Nature*. — 1999. — Vol. 401, no. 6755. — P. 788–791. — DOI: 10.1038/44565.
12. Virtanen T. Monaural sound source separation by nonnegative matrix factorization with temporal continuity and sparseness criteria / T. Virtanen // *IEEE Transactions on Audio, Speech, and Language Processing*. — 2007. — Vol. 15, no. 3. — P. 1066–1074. — DOI: 10.1109/TASL.2006.885253.
13. Proakis J. G. *Digital Signal Processing: Principles, Algorithms, and Applications* / J. G. Proakis, D. G. Manolakis. — 4th ed. — Upper Saddle River : Pearson Prentice Hall, 2007. — 1004 p.
14. Рабинер Л. Р. *Теория и применение цифровой обработки сигналов* / Л. Р. Рабинер, Б. Гоулд ; пер. с англ. ; под ред. Ю. Н. Александрова. — Москва : Мир, 1978. — 848 с.
15. Сергиенко А. Б. *Цифровая обработка сигналов* / А. Б. Сергиенко. — Санкт-Петербург : Питер, 2002. — 608 с.