



## МЕТОДИКА ОБУЧЕНИЯ НЕЙРОННЫХ СЕТЕЙ, ИСПОЛЬЗУЕМЫХ В БЛОКЕ ПРИНЯТИЯ РЕШЕНИЯ СИГНАЛИЗАЦИОННЫХ СРЕДСТВ ОБНАРУЖЕНИЯ

*В статье рассматривается вопрос обучения нейронной сети при построении алгоритмов обнаружения нарушителей в блоке принятия решения современных средств обнаружения. Особенность обучения нейронных сетей в средствах обнаружения заключается в использовании модифицированной функции потерь, учитывающей различный ущерб от реализации ошибок первого и второго рода в системах охранной сигнализации. Исходя из критерия минимума среднего риска, в средствах обнаружения целесообразно минимизировать вероятность ложной тревоги (ошибка первого рода) при фиксированном значении вероятности пропуска цели (ошибка второго рода). Получено новое выражение для обновления весов нейронной сети при обучении, исходя из минимизации новой функции потерь. На примере магнитометрических средств обнаружений распределенного типа показан процесс обучения нейронной сети на представительном банке данных расчетных реализаций информационного сигнала и моделирования помех. Показано, что рекуррентная нейронная сеть имеет высокие характеристики обнаружения нарушителей: при заданном значении правильного обнаружения 0,95 вероятность ложной тревоги составила 5,9·10<sup>-4</sup>.*

**Ключевые слова:** магнитометрические средства обнаружения, система охранной сигнализации, нейронные сети, функция потерь, блок принятия решения, вероятность обнаружения.

# TRAINING METHODS FOR NEURAL NETWORKS USED IN THE DECISIONMAKING BLOCK OF SIGNALING DETECTION TOOLS

*The article deals with the issue of training a neural network when building algorithms for detecting violators in the decision-making block of modern detection tools. The feature of training neural networks in modern detection tools is to change the loss function under consideration, which takes into account the possible damage from the implementation of errors of the first and second kind in alarm systems. Based on the criterion of minimum average risk, it is advisable to minimize the probability of a false alarm (error of the first kind) with a fixed value of the probability of missing the target (error of the second kind). A new expression is obtained for updating the weights of the neural network during training, based on minimizing the new loss function. The process of training a neural network on a representative dataset of calculated information signal realizations and interference modeling is shown on the example of distributed magnetometric systems. It is proved that the recurrent neural network has high characteristics of detecting violators: for a given value of correct detection of 0,95, the probability of a false alarm was 5,9·10<sup>-4</sup>.*

**Keywords:** detection tools, magnetometric security alarm system, neural network, loss function, decision block, detection probability.

Сигнализационные средства обнаружения (СО) являются сложными техническими системами, состоящими из взаимодействующих составных частей, важнейшими из которых являются чувствительный элемент (ЧЭ), тракт выделения и усиления сигналов, блок принятия решений об обнаружении (БПР). Современный подход к исследованию и разработке СО, представленный в [1], предусматривает разработку математической модели процессов формирования информационного сигнала (ИС), обусловленного воздействием человека-нарушителя (ЧН) на ЧЭ (полезного сигнала), а также проведение натурных экспериментов в объеме, достаточном для подтверждения адекватности разработанной математической модели. Кроме того, при анализе предметной области проводятся оценка влияния шумов на качественные показатели работы СО, натурное измерение шумовых сигналов на выходе ЧЭ в отсутствие нарушителя, составление их адекватной статистической модели. Дальнейшие оптимизация параметров чувствительного элемента и аналогового тракта, выбор и тестирование алгорит-

мов функционирования БПР средства осуществляются путем всестороннего компьютерного моделирования.

Для автоматизации натурных и теоретических исследований СО, анализа их потенциальных характеристик в [1] рекомендовано разрабатывать и реализовать многофункциональный программно-аппаратный комплекс. На рис. 1 представлен пример такого комплекса для исследования магнитометрических СО с протяженным винтовым ЧЭ [2]. Структура комплекса основывается на анализе его требуемой функциональности и включает в себя блоки:

- расчета реализаций полезных сигналов с учетом типа нарушителя;
- моделирования шума и получение аддитивной смеси с ИС;
- формирования представительных баз данных (БД) сигналов и помех, а также частных выборок реализаций аддитивной смеси ИС с шумом;
- навигации по БД;
- синтеза и тестирования алгоритмов принятия решения.

Наличие математических моделей полезных сигналов и шумов, адекватность которых подтверждена экспериментально, позволяет формировать исчерпывающую базу данных расчетных реализаций ИС с обоснованной дискретностью вариации входных параметров моделей, таких, как скорость движения ЧН, параметры его траектории, модуль и ориентация эквивалентного магнитного момента (для магнитометрических СО) и т.д. Вычислительная мощность современных компьютеров позволяет создавать и обрабатывать БД расчетных сигналов весьма подробно, с дискретностью, при которой «соседние» реализации отличаются друг от друга на уровне шума. Функциональные возможности комплекса позволяют на основе исходной базы данных для каждого этапа исследований создавать обучающие выборки смесей расчетных реализаций полезных сигналов (с учетом типа нарушителя) и шума, а также только шумовых воздействий.

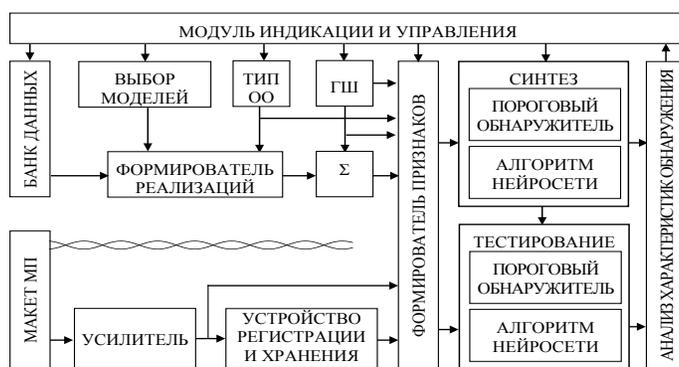


Рис. 1. Структурная схема программно-аппаратного комплекса для исследования потенциальных характеристик СО с распределенным магнитометрическим ЧЭ

Основные тенденции развития устройств, средств и систем охранной сигнализации связаны с совершенствованием алгоритмов обработки информационных сигналов [3]. На сегодняшний день для построения блоков принятия решения об обнаружении СО все чаще используются алгоритмы машинного обучения, в том числе искусственные нейронные сети (ИНС). При этом процесс обучения ИНС при построении блоков принятия решений в средствах обнаружения имеет ряд особенностей.

Проведенные исследования показывают эффективность применения рекуррентной нейронной сети при построении алгоритма принятия решения в магнитометрических СО [4]. В процессе обучения ИНС происходит пересчет весовых коэффициентов по антигра-

диенту выбранной функции потерь. Обычно в практике построения ИНС в качестве минимизируемой функции потерь применяется среднеквадратическая ошибка:

$$E_n = \frac{1}{2} \sum_{j=1}^K e_j^2 = \frac{1}{2} \sum_{j=1}^K (d_i - y_i)^2, \quad (1)$$

где  $d_i$  – ожидаемое выходное значение на выходе сети;  $y_i$  – реально полученное значение на  $j$ -м нейроне выходного слоя ИНС;  $K$  – количество нейронов в выходном слое сети.

Такой подход оправдан при одинаковом влиянии на качество работы технической системы в целом ошибок первого и второго рода. Стоимость ошибок типа «пропуск цели» и «ложная тревога» в системах охранной сигнализации существенно различны. В [5] показана целесообразность учета возможного ущерба от реализации ошибок при обучении нейронных сетей БПР средств обнаружения. В сигнализационных системах применяется так называемый «обратный критерий Нейма-

на-Пирсона» (как частый случай критерия минимума среднего риска), при котором минимизируется вероятность ложной тревоги (ошибка первого рода) при фиксированном (минимально допустимом) значении вероятности пропуска цели (ошибка второго рода).

Функция потерь (1) в [5] представляется в виде двух слагаемых, каждое из которых соответствует ошибкам первого и второго рода соответственно. Модифицированная функция потерь имеет вид:

$$\sum_{j=1}^K e_j^2 = \sum_{j \in Y} (\alpha_1 \cdot f_1(y_i))^2 + \sum_{j \in N} (\alpha_2 \cdot f_2(y_i))^2,$$

где  $\alpha_1$  и  $\alpha_2$  – линейные коэффициенты;  $f_1$  и  $f_2$  – некоторые функции от выходного значения сети  $y_j$ ;  $Y$  – подмножество нейронов, для которых ожидаемое значение равно 1;  $N$  – под-

множество нейронов, для которых ожидаемое значение равно 0;  $K=N+Y$ .

В простейшем случае функции  $f_1$  и  $f_2$  могут быть линейными, а коэффициенты  $\alpha_1$  и  $\alpha_2$  равны единице и разнице между желаемым значением правильного обнаружения и выходным значением сети соответственно:

$$\sum_{j=1}^K e_j^2 = \sum_{j \in Y} (\alpha_1 \cdot (1 - y_j))^2 + \sum_{j \in N} (-\alpha_2 \cdot y_j)^2, \quad (2)$$

Тогда функция потерь по всей обучающей выборке для пакетного режима обучения с учетом того, что выходной слой сети имеет только один нейрон, принимает вид:

$$E_{av}(n) = \frac{1}{L} \cdot \sum_{n=1}^L E_n = \frac{1}{2 \cdot L} \cdot \sum_{n=1}^L \sum_{j=1}^K e_j^2 = \frac{1}{2 \cdot L} \cdot \sum_{n=1}^L \left( \sum_{j \in Y} (\alpha_1 \cdot (1 - y_j))^2 + \sum_{j \in N} (-\alpha_2 \cdot y_j)^2 \right) + \sum_{j \in N} (-\alpha_2 \cdot y_j)^2, \quad (3)$$

где  $E_{av}$  – средняя ошибка по выборке;  $e_j$  – сигнал ошибки  $j$ -го нейрона в слое;

$Y$  – подмножество объектов обучающей выборки, для которых ожидаемое значение равно 1;  $N$  – подмножество объектов, для которых ожидаемое значение равно 0;  $L=N+Y$  – мощность обучающей выборки.

Обновление весов происходит по следующей формуле:

$$\Delta w_{j,i} = -\eta \cdot \frac{\partial E_{av}}{\partial w_{j,i}} = \frac{-\eta}{N} \cdot \sum_{n=1}^N e_j(n) \frac{\partial e_j(n)}{\partial w_{j,i}}, \quad (4)$$

где  $\eta$  – норма обучения.

Поскольку ошибка известна на каждом шаге, то  $\frac{\partial e_j(n)}{\partial w_{j,i}}$  можно просто вычислить для выходного слоя:

$$\frac{\partial e_j(n)}{\partial w_{j,i}} = -\alpha \cdot q'(\text{net}_j(n)) \cdot y_j, \quad (5)$$

где  $\text{net}_j$  – взвешенная сумма нейрона;  $q$  – функция активации нейрона; коэффициент  $\alpha$  принимает значения  $\alpha_1$  или  $\alpha_2$  в зависимости от класса ожидаемого ответа.

Проведенные для магнитометрических средств обнаружения компьютерные эксперименты показали, что учет различия стоимости ошибок первого и второго рода на одних и тех же выборках позволяет снизить вероятность формирования ложной тревоги более, чем на порядок при неснижаемом значении вероятности правильного обнаружения.

Одним из ключевых этапов обучения ИНС, является оценка ее качества на данных, которые не использовались при обучении. Популярным методом оценки обобщающей способности нейронных сетей является двух-

блочная перекрестная проверка, при которой часть данных «откладывается» для тестирования и оценки качества ИНС и не принимает участия в ее обучении. Для улучшения качества модели требуется итерационная настройка гиперпараметров сети или отбор модели. Однако, если тот же самый тестовый набор данных использовать во время отбора модели неоднократно, то он станет частью тренировочных (обучающих) данных, что приведет к переобучению ИНС [6].

Более эффективный способ заключается в разделении исходных данных на три части: тренировочный, проверочный и тестовый наборы. Тренировочный набор используется для выполнения настройки разных моделей, а полученная на проверочном наборе оценка качества используется для отбора модели. Таким образом, тестовый набор не участвует в тренировке и настройке модели сети, а служит только для формирования итоговой оценки. Чтобы оценка модели была менее чувствительна к способу деления на тренировочный и проверочный наборы, применяют  $k$ -блочную перекрестную проверку. При  $k$ -блочной перекрестной проверке тренировочные данные случайным образом делятся на  $k$  блоков, где  $k-1$  блоков используются для тренировки модели, а один блок – для проверки. Эта процедура повторяется  $k$  раз, в результате чего формируется  $k$  моделей (с одинаковыми гиперпараметрами ИНС) и оценок их качества [7]. Чаще всего на практике используют  $k=5$  или  $k=10$  (для небольших наборов данных).

В результате  $k$ -блочной перекрестной проверки формируется предварительная оценка работы ИНС при определенной настройке параметров конфигурации сети (гиперпараметров). Для получения окончательной оценки необходимо обучить ИНС на всем тренировочном наборе данных при параметрах сети, которые демонстрируют наилучшие результаты при предварительной оценке на этапе  $k$ -блочной перекрестной проверки. Данный процесс представлен схематично на рис. 2.

Для реализации алгоритмов  $k$ -блочной перекрестной проверки требуется предварительная обучающая выборка. С учетом большого разнообразия форм и параметров информационных сигналов в сигнализационных средствах обнаружения каждая из частных выборок должна содержать аддитивные смеси шума и всех информационных сигнала-

лов из БД, сформированной с обоснованной дискретностью входных параметров модели для конкретного типа нарушителя. Тестовую выборку для итоговой оценки качества работы синтезируемого алгоритма принятия решения следует формировать также путем аддитивного смешивания всех реализаций ИС из исходной БД и сгенерированных на основе статистической модели шумов вариативных шумовых воздействий.

сировки классов. После разбиения в каждом блоке находилось примерно равное число обоих классов.

Исходя из данных, представленных в табл. 1, можно сделать вывод о том, что предварительная оценка качества модели показывает низкое значение вероятности ложной тревоги при фиксировании вероятности пропуска цели и использовании модифицированной функции потерь.

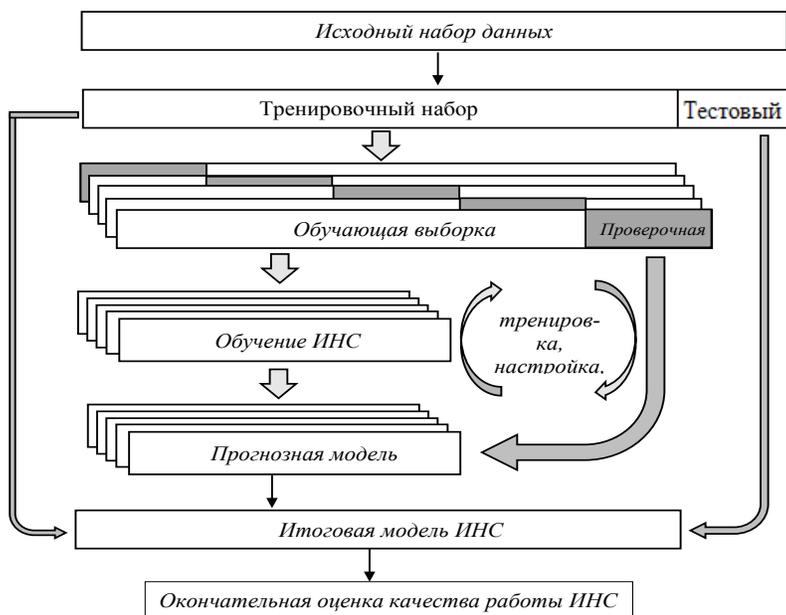


Рис. 2. Схема процесса обучения, проверки и тестирования ИИС

С использованием выражений (2) – (5) была проведена 5-блочная перекрестная проверка модели ИИС для магнитометрического средства обнаружения с протяженным чувствительным элементом на основе винтового преобразователя. Полученные результаты представлены в таблице 1 в виде матриц ошибок. Обучающая выборка содержала

Итоговое тестирование разработанной модели происходило после обучения ИИС по всей обучающей выборке и тестировании на отложенной. Отложенная выборка для тестирования представляла собой весь набор расчетных реализаций аддитивной смеси ИС с шумом на основании БД и реализации моделированного шума (с балансировкой клас-

Таблица 1

Матрица ошибок при проверке ИИС

	Реальное значение класса									
	$k=1$		$k=2$		$k=3$		$k=4$		$k=5$	
Прогноз класса	1	0	1	0	1	0	1	0	1	0
1 (есть объект)	21012	13	21008	12	21013	14	21015	14	21017	13
0 (нет объекта)	1106	22105	1110	22106	1105	22104	1104	22105	1102	22106

110592 расчетные реализации аддитивной смеси ИС с шумом (класс 1) и столько же просто шумовых реализаций (класс 0) для балан-

сов). При этом реализации шума при тестировании отличались от реализаций шума в тренировочных данных, что обеспечивало пред-

ставительность этих выборок в отношении всех возможных форм, уровней и длительностей сигналов. Результаты окончательной оценки качества модели представлены в таблице 2 в виде матрицы ошибок.

Проведенные исследования показывают, что с учетом особенностей обучения и фор-

дают основания говорить о высоких характеристиках обнаружения магнитометрических СО распределенного типа, БПР которых построен на основе ИНС: при заданном значении правильного обнаружения 0,95 вероятность ложной тревоги составила  $5,9 \cdot 10^{-4}$ . Полученное значение вероятности ложной тре-

Таблица 2

Матрица ошибок итогового тестирования ИНС

Прогноз класса	Реальное значение класса	
	1	0
1	105062	130
0	5530	221054

мирования обучающих выборок искусственные нейронные сети целесообразно использовать при синтезе блоков принятия решений в сигнализационных средствах обнаружения. Так полученные авторами данные

воги существенно ниже, чем соответствующее значение, наблюдаемое при простом пороговом алгоритме принятия решений ( $6,3 \cdot 10^{-3}$ ) [4].

### Литература

1. Духан, Е.И. Методология научного исследования средств обнаружения / Радиотехника: территориально распределенные системы охраны. – 2015. – № 13. – С. 31–33.
2. Духан Е.И., Захаркин Г.Ф., Звездинский С.С. Специализированный комплекс для исследования характеристик магнитометрического средства обнаружения нарушителей / Сборник трудов XI Международной отраслевой научно-технической конференции «Технологии информационного общества», 15–16 марта 2017 г. Москва, МТУСИ. – С. 299–300.
3. Магауенов Р.Г. Системы охранной сигнализации: основы теории и принципы построения: учебное пособие для вузов – М.: Горячая линия-Телеком, 2004. – 367с.
4. Духан Е.И., Захаркин Г.Ф., Духан А.Е., Звездинский С.С. Алгоритмы обработки информации магнитометрического средства обнаружения на основе нейросети / Спецтехника и связь, 2015. – № 5. – С. 29–32.
5. Звездинский С.С., Духан А.Е., Духан Е.И., Парфенцев И.В. Интеллектуализация принятия решений в системах физической защиты объектов / Т Comm: Телекоммуникации и транспорт. 2018. Том 12. №1. С. 40–43.
6. Рашка С., Python и машинное обучение / пер. с англ. А.В. Логунова. – М.: ДМК Пресс, 2017. – 418 с.: ил.
7. Жерон О. Прикладное машинное обучение с помощью Scikit-Learn и TensorFlow: концепции, инструменты и техники для создания интеллектуальных систем.: Пер. с англ. – СПб.: ООО «Альфа-книга», 2018. – 688 с.: ил.

### References

1. Dukhan, E.I. Metodologiya nauchnogo issledovaniya sredstv obnaruzheniya / Radiotekhnika: territorial'no raspredelennye sistemy okhrany. – 2015. – №13. – С. 31–33.
2. Dukhan E.I., Zakharkin G.F., Zvezhinskiy S.S. Spetsializirovannyi kompleks dlya issledovaniya kharakteristik magnitometricheskogo sredstva obnaruzheniya narushiteley / Sbornik trudov XI Mezhdunarodnoy otraslevoy nauchno-tekhnicheskoy konferentsii «Tekhnologii informatsionnogo obshchestva», 15–16 marta 2017 g. Moskva, MTUSI. – S. 299-300.
3. Magauenov R.G. Sistemy okhrannoy signalizatsii: osnovy teorii i printsipy postroeniya: uchebnoe posobie dlya vuzov – M.: Goryachaya liniya-Telekom, 2004. – 367s.
4. Dukhan E.I., Zakharkin G.F., Dukhan A.E., Zvezhinskiy S.S. Algoritmy obrabotki informatsii magnitometricheskogo sredstva obnaruzheniya na osnove neyroseti / Spetsstekhnika i svyaz, 2015. – № 5. – S. 29–32.

5. Zvezhinskiy S.S., Dukhan A.E., Dukhan E.I., Parfentsev I.V. Intellectualizatsiya prinyatiya resheniy v sistemakh fizicheskoy zashchity ob"ektov / T Comm: Telekommunikatsii i transport. 2018. Tom 12. №1. S. 40-43.

6. Rashka S., Python i mashinnoe obuchenie / per. s angl. A.V. Logunova. – M.: DMK Press, 2017. – 418 s.: il.

7. Zheron O. Prikladnoe mashinnoe obuchenie s pomoshch'yu Scikit-Learn i TensorFlow: kontseptsii, instrumenty i tekhniki dlya sozdaniya intellektual'nykh sistem.: Per. s angl. – SpB.: ООО «Al'fa-kniga», 2018. – 688 s.: il.

---

**ДУХАН Евгений Изович**, доктор технических наук, доцент, профессор Учебно-научного центра «Информационная безопасность» ИРИТ-РТФ ФГАОУ ВО «Уральский федеральный университет имени первого Президента России Б.Н. Ельцина». 620002, Россия, г. Екатеринбург, ул. Мира, 19. Email: Evgeny.Duchan@urfu.ru

**ЗАХАРКИН Григорий Федорович**, инженер департамента радиоэлектроники и связи ИРИТ-РТФ ФГАОУ ВО «Уральский федеральный университет имени первого Президента России Б.Н. Ельцина». 620002, Россия, г. Екатеринбург, ул. Мира, 19. Email: zakharkin88@gmail.com

**ДУХАН Андрей Евгеньевич**, аспирант ФГАОУ ВО «Уральский федеральный университет имени первого Президента России Б.Н. Ельцина». 620002, Россия, г. Екатеринбург, ул. Мира, 19. Email: andmo901@gmail.com

**DUKHAN Evgeny Izovich**, doctor of technical Sciences, associate Professor, Professor Of the educational and scientific center "Information security" of the URAL Federal University named after the first President of Russia B. N. Yeltsin. 19 Mira str., Yekaterinburg, 620002, Russia. Email: Evgeny.Duchan@urfu.ru

**ZAKHARKIN Grigoriy Fedorovich**, engineer of the Department of Radioelectronics and communications, URAL Federal University named after the first President of Russia B. N. Yeltsin. 19 Mira str., Yekaterinburg, 620002, Russia. Email: zakharkin88@gmail.com

**DUKHAN Andrey Evgenyevich**, graduate student of Ural Federal University named after first President of Russia B. N. Yeltsin. 19 Mira str., Yekaterinburg, 620002, Russia. Email: andmo901@gmail.com