



Международный журнал информационных технологий и энергоэффективности

Сайт журнала:

<http://www.openaccessscience.ru/index.php/ijcse/>



УДК 004.8

СРАВНИТЕЛЬНЫЙ АНАЛИЗ ТРАДИЦИОННЫХ И НЕЙРОСЕТЕВЫХ МЕТОДОВ ОБНАРУЖЕНИЯ БПЛА

Ильюшкин А.С.

ФГБОУ ВО САНКТ-ПЕТЕРБУРГСКИЙ ГОСУДАРСТВЕННЫЙ УНИВЕРСИТЕТ ТЕЛЕКОММУНИКАЦИЙ ИМ. ПРОФЕССОРА М. А. БОНЧ-БРУЕВИЧА, Санкт-Петербург, Россия (193232, г. Санкт-Петербург, просп. Большевиков, 22, корп. 1), e-mail: guesty1test@gmail.com

В статье проведен сравнительный анализ традиционных методов обработки сигналов и нейросетевых подходов для обнаружения беспилотных летательных аппаратов (БПЛА). Рассмотрены классические алгоритмы, такие как байесовский подход, критерии Неймана-Пирсона и алгоритмы минимизации среднего риска, а также их эффективность в условиях шумов и помех. Особое внимание уделено использованию искусственных нейронных сетей (ИНС) для повышения точности детекции, автоматического выделения признаков и адаптации к изменяющимся условиям. Оценена эффективность различных методов с применением метрик F1-мера и AUC-ROC, что позволяет обоснованно сравнить их преимущества и недостатки в задачах мониторинга воздушного пространства.

Ключевые слова: БПЛА, обработка сигналов, нейросети, классификация сигналов, фильтрация шума, байесовский подход, критерий Неймана-Пирсона, искусственные нейронные сети (ИНС), радиолокация, акустический мониторинг, машинное обучение, F1-мера, AUC-ROC.

COMPARATIVE ANALYSIS OF TRADITIONAL AND NEURAL NETWORK METHODS OF UAV DETECTION

Ilyushkin A. S.

ST. PETERSBURG STATE UNIVERSITY OF TELECOMMUNICATIONS NAMED AFTER PROFESSOR M. A. BONCH-BRUEVICH, St. Petersburg, Russia (193232, St. Petersburg, ave. Bolshevikov, 22, bldg. 1), e-mail: guesty1test@gmail.com

The article provides a comparative analysis of traditional signal processing methods and neural network approaches for detecting unmanned aerial vehicles (UAVs). Classical algorithms such as the Bayesian approach, the Neiman-Pearson criteria, and algorithms for minimizing average risk are considered, as well as their effectiveness in the face of noise and interference. Special attention is paid to the use of artificial neural networks (ANN) to improve detection accuracy, automatically identify features and adapt to changing conditions. The effectiveness of various methods using the F1-measure and AUC-ROC metrics is evaluated, which makes it possible to reasonably compare their advantages and disadvantages in air space monitoring tasks.

Keywords: UAVs, signal processing, neural networks, signal classification, noise filtering, Bayesian approach, Neiman-Pearson criterion, artificial neural networks (ANN), radar, acoustic monitoring, machine learning, F1-measure, AUC-ROC.

Эффективное обнаружение беспилотных летательных аппаратов (БПЛА) требует применения классических методов обработки сигналов, которые позволяют выделить полезный сигнал на фоне шума. Эти подходы базируются на строгих математических принципах и зарекомендовали себя как надёжные инструменты в радиолокации, акустике и инфракрасных системах [1]. Рассмотрим классические подходы к обработке данных.

Байесовский подход основан на теории вероятностей и позволяет определить, с какой вероятностью наблюдаемый сигнал относится к целевому объекту. Основным инструментом этого подхода — формула Байеса, что отражено в формуле 1.

$$P(H|X) = \frac{P(X|H)P(H)}{P(X)} \quad (1)$$

Где $P(H|X)$ - апостериорная вероятность гипотезы H при наблюдении данных X , $P(X|H)$ - правдоподобие, $P(H)$ - априорная вероятность гипотезы, $P(X)$ - нормирующая константа.

В задачах обнаружения БПЛА гипотеза H_1 может означать, что сигнал принадлежит объекту (БПЛА), а гипотеза H_0 - что сигнал является шумом. Байесовский подход позволяет минимизировать вероятность ошибки за счёт оптимального выбора порога принятия решения.

Критерии Неймана-Пирсона направлены на максимизацию вероятности обнаружения объекта P_D при фиксированной вероятности ложной тревоги P_{FA} . Оптимальное решение в этом подходе основано на сравнении отношения правдоподобия $L(X)$ с порогом η , что отобразено в формуле 2:

$$L(X) = \frac{f(X|H_1)}{f(X|H_0)} < \eta \quad (2)$$

Где $f(X|H_1)$ и $f(X|H_0)$ — функции плотности вероятности наблюдений при гипотезах H_1 и H_0 .

Применение критерия Неймана-Пирсона позволяет строго контролировать вероятность ложных тревог, что особенно важно в условиях высокого уровня помех, например, в радиолокационных системах.

Алгоритмы минимизации среднего риска.

Этот подход основывается на минимизации математического ожидания потерь, вызванных ошибочными решениями. Средний риск определяется по формуле 3:

$$R = \sum_{i,j} \lambda_{ij} P(H_i|X_j) P(X_j) \quad (3)$$

Где λ_{ij} – стоимость ошибки принятия решения H_i , если истинной является гипотеза H_j , $P(H_i|X_j)$ — апостериорная вероятность, $P(X_j)$ — вероятность наблюдения X_j .

В контексте обнаружения БПЛА минимизация риска позволяет учитывать как вероятность ошибок, так и их последствия, что делает этот метод особенно ценным при работе с системами высокой чувствительности [2].

Рассмотренные классические подходы, такие как Байесовский метод, критерии Неймана-Пирсона и алгоритмы минимизации среднего риска, предоставляют эффективные инструменты для принятия решений на основе математического анализа [3]. Однако их практическая реализация в задачах обнаружения БПЛА тесно связана с необходимостью выделения полезного сигнала на фоне разнообразных помех.

Шумы, создаваемые окружающей средой, инфраструктурой или другими техническими устройствами, накладывают серьёзные ограничения на точность систем мониторинга. Именно поэтому задача выделения сигнала на фоне шума становится ключевым этапом обработки данных. Рассмотрим основные аспекты её реализации.

1. Классификация сигналов

Классификация заключается в разделении входящих данных на категории "сигнал от БПЛА" и "шум". Для этого применяются:

- Линейные классификаторы, такие как дискриминантный анализ. Например, решение задачи классификации формируется на основе критерия, отображенного в формуле 4:

$$g(X) = w^T X + w_0 \quad (4)$$

Где w - вектор весов, X - вектор входных данных, w_0 – порог.

- Нелинейные методы, такие как использование ядерных функций, которые позволяют учитывать сложные зависимости в данных.

2. Фильтрация шума.

Фильтрация направлена на подавление фоновых помех для выделения полезного сигнала. Основные методы включают:

- Фильтры нижних частот для устранения высокочастотных шумов, часто используемых в акустических системах.
- Узкополосные фильтры для выделения сигналов с известной частотой, характерной для дронов (например, шумов винтов).

Временные и частотные методы фильтрации часто используются совместно, чтобы повысить эффективность обработки сигналов в сложных условиях.

3. Оценка соотношения сигнал/шум (SNR)

Для успешного выделения полезного сигнала часто используется параметр SNR (signal-to-noise ratio), определяемый по формуле 5:

$$SNR = \frac{P_{signal}}{P_{noise}} \quad (5)$$

Где P_{signal} — мощность полезного сигнала, P_{noise} — мощность шума. Чем выше SNR, тем легче выделить сигнал на фоне помех. Методы повышения SNR включают усиление полезного сигнала или подавление шумов.

Обнаружение беспилотных летательных аппаратов (БПЛА) связано с решением задач классификации, выделения сигнала на фоне шума и анализа данных в условиях высокой изменчивости и помех. Традиционные методы обработки данных, такие как Байесовские подходы и критерии Неймана-Пирсона, эффективно справляются с обработкой линейных зависимостей, однако в условиях сложных многомерных данных их точность существенно снижается. Искусственные нейронные сети (ИНС) предоставляют возможность анализа нелинейных зависимостей и автоматического извлечения признаков из больших массивов данных, что делает их перспективным инструментом в задачах мониторинга воздушного пространства.

Для количественной оценки эффективности системы обнаружения БПЛА можно использовать стандартные метрики из области машинного обучения и обработки сигналов [4]. Основной показатель, демонстрирующий точность работы системы, — F1-мера. Она определяется как гармоническое среднее между точностью P и полнотой R , что отображено в формуле 6:

$$F1 = 2 \times \frac{P \times R}{P + R} \quad (6)$$

Где $P = \frac{TP}{TP+FP}$ — доля правильно классифицированных положительных объектов среди всех классифицированных как положительные, а $R = \frac{TP}{TP+FN}$ — доля правильно классифицированных положительных объектов среди всех фактически положительных.

Здесь TP (True Positive) — число корректно обнаруженных БПЛА, FP (False Positive) — число ложных тревог и FN (False Negative) — число пропущенных БПЛА.

Дополнительно для оценки устойчивости системы можно использовать ROC-кривую и площадь под ней (AUC-ROC), что позволяет сравнивать качество различных подходов.

Традиционные подходы, такие как Байесовские методы или критерии Неймана-Пирсона, предполагают ручное выделение признаков и настройку порогов. Это ограничивает их точность в условиях сложных данных, например, при обработке шумов или слабых сигналов от малых БПЛА [5]. Искусственные нейронные сети устраняют эти ограничения благодаря способности автоматически извлекать признаки и адаптироваться к условиям задачи.

Пример обработки данных акустической системы:

- Традиционный метод: использует спектральный анализ с ручной настройкой фильтров для выделения частот, характерных для шума двигателей БПЛА. В городских условиях (высокий уровень фонового шума) точность составляет около 70%, а полнота — 60%, что даёт $F1 \approx 64\%$.
- ИНС: Применение рекуррентных или свёрточных нейронных сетей позволяет автоматически анализировать временные зависимости и спектры. При обучении на большом наборе данных точность возрастает до 85%, а полнота — до 80%, что даёт $F1 \approx 82\%$.

Пример обработки данных радиолокационной системы:

- Традиционный метод: Критерии Неймана-Пирсона, настроенные на низкую вероятность ложной тревоги (P_{FA}), могут терять слабые сигналы от малых БПЛА. В результате, полнота обнаружения снижается до 65%.
- ИНС: Свёрточные сети, обученные на спектральных картах радиолокационных сигналов, демонстрируют высокую устойчивость к шуму и достигают полноты около 90%, а точность остаётся на уровне 88%, что даёт $F1 \approx 89\%$.

Анализ показывает, что использование искусственных нейронных сетей (ИНС) приводит к значительному повышению показателей эффективности систем обнаружения беспилотных летательных аппаратов. По сравнению с традиционными подходами, ИНС обеспечивают более высокие значения F1-меры, демонстрируют лучшую устойчивость к шумам и позволяют автоматизировать процесс обработки данных. Это доказывает целесообразность интеграции ИНС в радиолокационные, акустические и визуальные системы, особенно в условиях высокой изменчивости данных и сложности задач.

Список литературы

1. Krasov A., Vitkova L., Pestov I. Behavioral analysis of resource allocation systems in cloud infrastructure // 2019 International Russian Automation Conference (RusAutoCon). – IEEE, 2019. – С. 1–5.
2. Баскаков, С. И. Радиолокационные системы: учебник для вузов / С. И. Баскаков. — 2-е изд., перераб. и доп. — М.: Высшая школа, 2005. — 584 с.

3. Гудков, В. В. Искусственные нейронные сети: структура, обучение, применение / В. В. Гудков. — СПб.: Питер, 2019. — 320 с.
4. Шемякин, С. Н., Гельфанд, А. М., Орлов, Г. А. Критическая информационная инфраструктура // Наука и инновации – современные концепции. – 2020. – С. 114–118.
5. Сахаров, Д. В., и др. Моделирование защищенной масштабируемой сети предприятия с динамической маршрутизацией на основе IPv6 // Защита информации. Инсайд. – 2020. – № 1. – С. 51–57.

References

1. Krasnov A., Vitkova L., Pestov I. Behavioral analysis of resource allocation systems in cloud infrastructure // 2019 International Russian Automation Conference (RusAutoCon). – IEEE, 2019. – pp. 1-5.
 2. Baskakov, S. I. Radar systems: a textbook for universities / S. I. Baskakov. — 2nd ed., reprint. and add. — M.: Higher School, 2005. — 584 p.
 3. Gudkov, V. V. Artificial neural networks: structure, training, application / V. V. Gudkov. St. Petersburg: Peter, 2019. 320 p.
 4. Shemyakin, S. N., Gelfand, A.M., Orlov, G. A. Critical information infrastructure // Science and innovation – modern concepts. 2020. pp. 114-118.
 5. Sakharov, D. V., et al. Modeling of a secure, scalable enterprise network with dynamic IPv6-based routing // Information security. Insider. – 2020. – No. 1. – pp. 51–57.
-