

УДК 621.396.96

## КЛАССИФИКАЦИЯ ВОЗДУШНЫХ ЦЕЛЕЙ НА ОСНОВЕ СИСТЕМЫ СО СЛУЧАЙНОЙ СКАЧКООБРАЗНОЙ СТРУКТУРОЙ С ИСПОЛЬЗОВАНИЕМ ИНФОРМАЦИИ ОТ НЕЙРОСЕТЕВЫХ КЛАССИФИКАТОРОВ

*Мариам Мохаммад Хасан, адъюнкт Военного учебно-научного центра Военно-воздушных сил «Военно-воздушная академия им. профессора Н.Е. Жуковского и Ю.А. Гагарина» (г. Воронеж), e-mail: mohammad-mariam@mail.ru*  
*Рязанцев Л. Б., д.т.н., доцент, доцент Военного учебно-научного центра Военно-воздушных сил «Военно-воздушная академия им. профессора Н.Е. Жуковского и Ю.А. Гагарина» (г. Воронеж), e-mail: kernel386@mail.ru*

## CLASSIFICATION OF AIR TARGETS BASED ON A RANDOM JUMP STRUCTURE SYSTEM USING INFORMATION FROM NEURAL NETWORK CLASSIFIERS

*Mariam M.H., Ryazantsev L.B.*

*The article is devoted to the study of the classification of small-sized air targets according to their trajectory features and radar portraits obtained by the method of inverse aperture synthesis. An approach based on combining information from Bayesian and neural network classifiers is considered. Complexing is proposed to be carried out using the provisions of the theory of systems with a random jump structure. The results of modeling are presented, including an assessment of the probabilistic and temporal characteristics of the proposed classifier.*

**Key words:** classification of air targets, inverse synthesis, random jump structure system, neural network classifier.

**Ключевые слова:** классификация воздушных целей, инверсное синтезирование, система со случайной скачкообразной структурой, нейросетевой классификатор.

### Актуальность

Невысокая стоимость, относительная простота использования и общедоступность малогабаритных беспилотных летательных аппаратов (БПЛА) обусловили их широкое распространение как в гражданской сфере, так и при ведении боевых действий. Ни один из военных конфликтов последних лет не обходится без применения БПЛА, где они зачастую используются для решения не только разведывательных, но и ударных задач. Из-за недостаточного эффективного противодействия в настоящее время они представляют серьезную угрозу для потенциально опасных и критически важных объектов, объектов вооружения и техники. Их массированное применение способно оказать сильное негативное влияние на моральное состояние войск и мирного населения и даже изменить ход ведения боевых действий. Процесс контроля за применением БПЛА и противодействия им связан с необходимостью решения задач обнаружения, оценки их координат и параметров движения, с последующим принятием решения о принадлежности обнаруженной цели к определенному классу (распознаванием). Эффективным инструментом для решения этих задач являются средства радиолокации, способные получать информацию круглосуточно, не зависимо от условий освещенности и состояния атмосферы.

Распознавание малых БПЛА представляет собой непростую задачу из-за схожести радиолокационных характеристик таких целей и параметров их движения как между собой, так, например, и с птицами [1]. Результаты распознавания определяют приоритет формирования


*Статья посвящена исследованию вопросов классификации малоразмерных воздушных целей по их траекторным признакам и радиолокационным портретам, полученным методом инверсного синтезирования апертуры. Рассматривается подход, основанный на комплексировании информации байесовского и нейросетевого классификаторов. Комплексирование предложено осуществлять с использованием положений теории систем со случайной скачкообразной структурой. Представлены результаты моделирования, включающие оценку вероятностных и временных характеристик предложенного классификатора.*

очереди заявок на противодействие с учетом степени опасности данного класса целей [2]. Так, например, к наиболее опасному типу целей можно отнести БПЛА самолетного типа, которые обладают большей дальностью и скоростью полета по сравнению с БПЛА мультиторторного типа. Наименее опасными целями являются птицы, которые должны исключаться из обработки для предотвращения перегрузки каналов средств радиолокации и противодействия.

### Постановка задачи

Распознавание целей может осуществляться на основе следующих признаков: характер доплеровского портрета отраженного сигнала, обусловленного особенностями вращения винтов конкретного типа летательного аппарата или взмахами крыльев птиц [1]; радиолокационное изображение цели, сформированное методами инверсного синтезирования апертуры [4, 5, 6]; траекторные признаки полета цели [3] и др.

Наиболее распространенными методами распознавания, осуществляющими классификацию целей на основе рассмотренных признаков, являются вероятностные (байесовские) [7] и нейросетевые [8]. Первые традиционно применяются для обработки небольшого объема данных, вторые, напротив, совершив настоящую



революцию в области так называемого «глубокого обучения» хорошо подходят для обработки больших слабо структурируемых данных.

Байесовский классификатор в качестве основы использует наблюдаемые признаки и производит соотношение объектов к определенному классу на основе принципа максимума правдоподобия, заключающегося в оценке степени невязки статистических характеристик полученных выборок значений параметров с их априорными значениями. Преимуществом байесовского классификатора является простота практической применимости и невысокая вычислительная сложность, особенно при аппроксимации случайных величин нормальным законом распределения, позволяющей свести задачу интегрирования многомерных плотностей вероятности к линейным операциям с всего лишь двумя векторными параметрами – вектором математических ожиданий и ковариационной матрицей. Классификатор работает и в том случае, когда средние значения параметров для различных классов являются близкими, а основное отличие заключается в различных значениях их дисперсий. Однако для корректной работы классификатора необходимо наличие информативных данных для построения функций правдоподобия, что требует тщательного подбора обучающих выборок с предварительным исследованием всех факторов, которые могут повлиять на результат классификации.

Классификаторы на основе нейронных сетей обладают высоким быстродействием, однако добавление нового класса приводит к необходимости повторного выполнения процедуры полного обучения сети на всем имеющемся наборе. Такая процедура требует значительных вычислительных ресурсов и занимает большое количество времени (от нескольких часов до нескольких дней). Кроме того, решение существующих проблем математического характера, связанных с выбором рациональной архитектуры сети (количество нейронов, слоев, структура связей) и оптимального шага для нахождения глобального оптимума, до сих пор основано на личном опыте и интуиции разработчика. Также присущий нейронным сетям эффект переобучения, заключающийся в появлении устойчивых доминирующих связей между нейронами и слоями из-за чрезмерной фокусировки на обучающей выборке, ограничивает их способность к обобщению. Следует отметить, что нейросетевые классификаторы на сегодняшний день пока еще являются «черными ящиками» с трудно интерпретируемыми результатами работы.

В настоящее время также предложены методы нейробайесовской классификации, в которых весовые коэффициенты рассматриваются с позиций функций правдоподобия, что позволяет исключить излишнюю настройку параметров в ходе машинного обучения и справиться с эффектом переобучения [9]. Сочетание байесовских и нейросетевых методов считается весьма перспективным направлением, которому уделяется значительное внимание. Полученные результаты активно обсуждаются на тематических конференциях и форумах [10].

Подход, позволяющий объединить преимущества нейронного и байесовского методов, может быть осно-

ван на представлении объекта классификации как системы со случайной скачкообразной структурой (ССС) [3, 11, 12]. Оценка параметров таких систем осуществляется байесовскими методами, а нейронные классификаторы выступают в роли так называемых индикаторов, обеспечивающих формирование окончательного решения с учетом их вероятностных характеристик по соотношению объекта к заданному классу. Рассмотрим это более подробно.

### Классификатор на основе системы со случайной скачкообразной структурой

С позиций теорий оптимального оценивания классификация динамического объекта может быть осуществлена на основе последовательной оценки в каждый  $k$ -й момент времени (т.е. через равные промежутки  $T = t_k - t_{k-1}$ ) вектора его состояния  $\mathbf{x}$  по измеренному вектору наблюдаемых параметров  $\mathbf{z}_k$ . Рассмотрим задачу оценивания состояния  $s_k \in \mathbb{S}$  объекта, которая заключается в определении принадлежности ее к конкретному классу из множества  $\mathbb{S}$  по данным измерений  $\mathbf{z}_k$ , полученных на конечном интервале наблюдений. Связь вектора состояния с вектором измерений для каждого  $s_k$ -го состояния (индекса структуры) описывается уравнениями

$$\mathbf{x}_k = \mathbf{F}_k (\mathbf{x}_{k-1}, s_k) + \boldsymbol{\xi}_{k-1}, \quad (1)$$

$$\mathbf{z}_k = \mathbf{H}_k \mathbf{x}_k + \boldsymbol{\eta}_k, \quad (2)$$

где  $\mathbf{F}_k$  – матрица перехода, задаваемая в соответствии с моделью поведения объекта во времени;  $\mathbf{Q}_{k-1}$  – ковариационная матрица формирующего шума;  $\boldsymbol{\xi}_{k-1} \sim \mathcal{N}[\boldsymbol{\xi}_{k-1} | 0, \mathbf{Q}_{k-1}]$  и  $\boldsymbol{\eta}_k \sim \mathcal{N}[\boldsymbol{\eta}_k | 0, \mathbf{R}_k]$  – некоррелированные между собой отсчеты последовательностей формирующего шума и шума измерений с ковариационными матрицами  $\mathbf{Q}_{k-1}$  и  $\mathbf{R}_k$  соответственно;  $\mathcal{N}[\alpha | \mathbf{m}, \mathbf{D}]$  – плотность вероятности  $n$ -мерной нормальной случайной величины  $\alpha$  с вектором математических ожиданий  $\mathbf{m}$  и ковариационной матрицей  $\mathbf{D}$ , определяемая выражением

$$\mathcal{N}[\alpha | \mathbf{m}, \mathbf{D}] = (2\pi)^{-n/2} \det(\mathbf{D})^{-1/2} \exp\left\{-\frac{1}{2}(\alpha - \mathbf{m})^T \mathbf{D}^{-1}(\alpha - \mathbf{m})\right\}. \quad (3)$$

Алгоритм байесовской оценки вектора состояния заключается в рекурсивном вычислении на каждом  $k$ -м шаге по полученным измерениям  $\mathbf{z}_k$  апостериорной плотности вероятности вектора состояния  $p(\mathbf{x}_k, s_k | \mathbf{z}_k)$  и состоит из двух последовательных этапов прогноза и коррекции, осуществляемых в соответствии с выражениями [11]:

$$p(\mathbf{x}_k, s_k | \mathbf{z}_k) = \int \lambda(r_k | s_k) p(\mathbf{x}_k | \mathbf{x}_{k-1}, s_k) \sum_{s_{k-1}} p(\mathbf{x}_{k-1}, s_{k-1} | \mathbf{z}_{k-1}) q(s_k | s_{k-1}) d\mathbf{x}_{k-1}, \quad (4)$$

$$p(\mathbf{x}_k, s_k | \mathbf{z}_k) = \frac{p(\mathbf{z}_k, s_k | \mathbf{x}_k) p(\mathbf{x}_k, s_k | \mathbf{z}_k)}{p(\mathbf{z}_k, s_k)}, \quad (5)$$

где  $p(\mathbf{z}_k, s_k) = \int p(\mathbf{z}_k, s_k | \mathbf{x}_k) p(\mathbf{x}_k, s_k | \mathbf{z}_k) d\mathbf{x}_k$  и определяется из условия нормировки плотности вероятности  $p(\mathbf{x}_k, s_k | \mathbf{z}_k)$ ;  $q(s_k | s_{k-1})$  – условные вероятности переходов структуры объекта из состояния  $s_{k-1}$  в состояние  $s_k$ . Классификация объекта также осуществляется с учетом информации дополнительных индикаторов, характеризующихся вероятностными характеристиками  $\lambda(r_k | s_k)$  соотнесения объекта к классу  $r_k$  при его истинном классе  $s_k$ ;  $r_k$  – индекс структуры, определенный по показаниям индикатора.

Выражение (4) реализует этап прогноза в соответствии с вероятностной моделью эволюции вектора состояния  $p(\mathbf{x}_k | \mathbf{x}_{k-1}, s_k)$  и апостериорной вероятностью  $p(\mathbf{x}_{k-1}, s_{k-1} | \mathbf{z}_{k-1})$ , полученной на предыдущем шаге по выражению (5). В свою очередь выражение (5) реализует этап коррекции в соответствии с рассчитанной функцией правдоподобия  $p(\mathbf{z}_k, s_k | \mathbf{x}_k)$ , определяемой вектором полученных измерений на текущем шаге. Вероятностная модель эволюции вектора состояния  $p(\mathbf{x}_k | \mathbf{x}_{k-1}, s_k)$  определяется уравнением (1) с известными статистическими характеристиками формирующего шума  $\xi_{k-1}$ , а функция правдоподобия  $p(\mathbf{z}_k, s_k | \mathbf{x}_k)$  – моделью измерения (2) с известными статистическими характеристиками шума измерения  $\eta_k$ , которые согласно уравнению Фокера-Планта-Колмогорова могут быть найдены по следующим выражениям [11]:

$$p(\mathbf{x}_k | \mathbf{x}_{k-1}, s_k) = (2\pi)^{-n_x} \iint e^{i\omega^T (\mathbf{F}_k(\mathbf{x}_{k-1}, s_k) - \mathbf{x}_k)} d\Phi(\xi_{k-1}) d\omega, \quad (6)$$

$$p(\mathbf{z}_k | \mathbf{x}_k) = (2\pi)^{-n_z} \iint e^{i\omega^T (\mathbf{H}_k \mathbf{x}_k - \mathbf{z}_k)} d\Phi(\eta_k) d\omega, \quad (7)$$

где  $i$  – мнимая единица;  $\Phi(\xi_{k-1})$  и  $\Phi(\eta_k)$  – функции вероятности случайных величин  $\xi_{k-1}$  и  $\eta_k$  соответственно;  $n_x$  и  $n_z$  – размерности векторов  $\mathbf{x}$  и  $\mathbf{z}$  соответственно;  $T$  – символ операции транспонирования матрицы.

В большинстве практических случаев реализация алгоритма, основанного на выражениях (1)-(7), является довольно сложной задачей, требующей решения функциональных интегральных уравнений. Применяя метод двухмоментной параметрической аппроксимации [11] можно существенно упростить алгоритм, ограничившись операциями над векторами математических ожиданий и ковариационными матрицами законов распределения случайных величин. В то же время существуют разнообразные алгоритмы по реализации данного подхода, характеризующиеся различной степенью приближения и вычислительными затратами. К числу наиболее известных можно отнести: автономный многомодельный алгоритм (Autonomous Multiple-Model (AMM) Algorithm), обобщенный псевдобайесовский алгоритм первого порядка (First-Order Generalized Pseudo-Bayesian (GPB1) Algorithm), обобщенный псевдобайесовский алгоритм

второго порядка (Second-Order Generalized Pseudo-Bayesian (GPB2) Algorithm) и многомодельный алгоритм с межмодельным взаимодействием (Interacting Multiple-Model (IMM) Algorithm) [3, 12]. Далее рассмотрим алгоритм IMM для решения задачи классификации объектов, как обладающий лучшими характеристиками по соотношению «точность – вычислительные затраты» [3].

Динамическое поведение объекта, описываемое уравнением состояния (1), представляется набором моделей  $M = \{m_i, i = 1, 2, \dots, N\}$ , каждая из которых характеризует динамику объекта в конкретном состоянии. Смена моделей является случайным марковским процессом с вероятностями переходов из одного состояния в другое  $q^{(ji)} = q(s_k = j | s_{k-1} = i)$ . Уравнения состояния и измерения для каждой  $i$ -й модели представляются в виде:

$$\mathbf{x}_k^{(i)} = \mathbf{F}_k^{(i)} \mathbf{x}_{k-1} + \xi_{k-1}^{(i)}, \quad (8)$$

$$\mathbf{z}_k^{(i)} = \mathbf{H}_k^{(i)} \mathbf{x}_k + \eta_k^{(i)}, \quad (9)$$

где  $\mathbf{F}_k^{(i)}$  и  $\mathbf{H}_k^{(i)}$  – матрицы перехода и измерения для каждой  $i$ -й модели соответственно.

В этом случае получение оценки вектора состояния  $\hat{\mathbf{x}}_k$  и её ковариации  $\hat{\mathbf{P}}_k$  осуществляется путем комбинации частных оценок параллельно работающих  $N$  дискретных калмановских фильтров, каждый из которых переинициализируется с учетом оценок других фильтров. Алгоритм фильтрации и классификации описывается следующими уравнениями, условно сгруппированных по этапам [3, 14]. Диактрическими знаками « $\leftarrow$ », « $\sim$ » и « $\wedge$ » обозначены оценки, получаемые на этапах переинициализации, прогноза и коррекции соответственно.

**Этап 1.** Переинициализация фильтров:

$$\bar{\mathbf{x}}_{k-1}^{(i)} = \sum_{j=1}^N \hat{\mathbf{x}}_{k-1}^{(j)} \hat{W}_{k-1}^{(ji)}, \quad \bar{\mathbf{P}}_{k-1}^{(i)} = \sum_{j=1}^N \hat{\mathbf{W}}_{k-1}^{(ji)} \left[ \hat{\mathbf{P}}_{k-1}^{(j)} + (\bar{\mathbf{x}}_{k-1}^{(i)} - \bar{\mathbf{x}}_{k-1}^{(j)}) (\bar{\mathbf{x}}_{k-1}^{(i)} - \bar{\mathbf{x}}_{k-1}^{(j)})^T \right], \quad (10)$$

$$\tilde{\mathbf{W}}_k^{(i)} = \sum_{j=1}^N \lambda(r_k | s_k) q^{(ji)} \hat{\mathbf{W}}_{k-1}^{(j)}, \quad \hat{\mathbf{W}}_{k-1}^{(ji)} = \frac{\lambda(r_k | s_k) q^{(ji)} \hat{\mathbf{W}}_k^{(i)}}{\tilde{\mathbf{W}}_k^{(i)}}. \quad (11)$$

**Этап 2.** Вычисление оценок фильтров и их ковариаций:

$$\tilde{\mathbf{x}}_{k-1}^{(i)} = \mathbf{F}_{k-1}^{(i)} \bar{\mathbf{x}}_{k-1}^{(i)}, \quad \tilde{\mathbf{P}}_k^{(i)} = \mathbf{F}_{k-1}^{(i)} \bar{\mathbf{P}}_{k-1}^{(i)} (\mathbf{F}_{k-1}^{(i)})^T + \mathbf{Q}_k^{(i)}, \quad (12)$$

$$\hat{\mathbf{x}}_k^{(i)} = \tilde{\mathbf{x}}_k^{(i)} + \mathbf{K}_k^{(i)} \mathbf{v}_k^{(i)}, \quad \hat{\mathbf{P}}_k^{(i)} = (\mathbf{I} - \mathbf{K}_k^{(i)} \mathbf{H}_k^{(i)}) \tilde{\mathbf{P}}_k^{(i)}, \quad (13)$$

где  $\mathbf{K}_k^{(i)} = \tilde{\mathbf{P}}_k^{(i)} (\mathbf{H}_k^{(i)})^T (\mathbf{V}_k^{(i)})^{-1}$ ;  $\mathbf{V}_k^{(i)} = \mathbf{H}_k^{(i)} \tilde{\mathbf{P}}_k^{(i)} (\mathbf{H}_k^{(i)})^T + \mathbf{R}_k^{(i)}$ ;  $\mathbf{v}_k^{(i)} = \mathbf{z}_k - \mathbf{H}_k^{(i)} \tilde{\mathbf{x}}_k^{(i)}$ ;  $\mathbf{I}$  – единичная матрица.

**Этап 3.** Объединение оценок отдельных фильтров в итоговую оценку и нахождение ее ковариации:

$$\hat{\mathbf{x}}_k = \sum_{i=1}^N \hat{\mathbf{W}}_k^{(i)} \hat{\mathbf{x}}_k^{(i)}, \quad (14)$$

$$\hat{\mathbf{P}}_k = \sum_{i=1}^N \hat{\mathbf{W}}_k^{(i)} [\hat{\mathbf{P}}_k^{(i)} (\hat{\mathbf{x}}_k - \hat{\mathbf{x}}_k^{(i)}) (\hat{\mathbf{x}}_k - \hat{\mathbf{x}}_k^{(i)})^T].$$




Рис. 1. Структурная схема алгоритма классификации на основе системы со случайной скачкообразной структурой

$$\hat{W}_k^{(i)} = \frac{\mathcal{N}[\mathbf{v}_k^{(i)} | 0, \mathbf{V}_k^{(i)}] \tilde{W}_k^{(i)}}{\sum_{j=1}^N \mathcal{N}[\mathbf{v}_k^{(j)} | 0, \mathbf{V}_k^{(j)}] \tilde{W}_k^{(j)}}, \quad (15)$$

где значение функций правдоподобия  $\mathcal{N}[\mathbf{v}_k^{(i)} | 0, \mathbf{V}_k^{(i)}]$  вычисляются по выражению (3).

Величина  $\hat{W}_k^{(i)}$  представляет собой вероятность нахождения объекта в  $k$ -й момент времени в состоянии  $s_k = j$ , то есть его принадлежность к  $j$ -му классу.

Структурная схема алгоритма классификации воздушных целей на основе системы со ССС, учитывающего информацию от внешних индикаторов и реализующего операции (8)-(15), представлена на рис. 1.

Нейросетевой индикатор осуществляет классификацию целей по их радиолокационному изображению (РЛИ), сформированному методами инверсного синтеза апертуры или по характеру доплеровского портрета отраженного сигнала, обусловленного особенностями вращения винтов конкретного типа летательного аппарата или взмахами крыльев птиц [16].

#### Динамические модели поведения объекта в системе со ССС

Каждый класс объектов характеризуется траекторными особенностями их полета. Так, например, беспилотные летательные аппараты самолетного типа из-за использования автопилота, характеризуются в значительной степени прямолинейным полетом с постоянной скоростью. Мультикоптеры из-за своей специфики применения, в основном управляются вручную с использованием системы стабилизации, что обуславливает значительное изменение скорости и траектории во время полета даже на достаточно непродолжительных временных промежутках. В проведенном исследовании [15] динамики полета птиц, выполненном с использованием радиолокационных измерений, представлены статистические характеристики динамики их траекторных характеристик для более чем 130 различных видов. Это позволяет обеспечить выбор соответствующих моделей

для решения задачи классификации объектов по траекторным признакам на основе систем со ССС.

Рассмотрим модели прямолинейного движения с постоянной скоростью и постоянным ускорением [13]. Первая из них может применяться для описания траектории полета БПЛА самолетного типа, вторая – для описания траектории полета БПЛА мультикоптерного типа и птиц. Компонентами вектора состояния при этом будут являться координаты объекта в прямоугольной системе координат и их первые и вторые производные, т.е.

$\mathbf{x} = [x, \dot{x}, \ddot{x}, y, \dot{y}, \ddot{y}]^T$ . Отличия моделей траектории полета БПЛА мультикоптерного типа и птиц заключаются в различных значениях спектральной плотности формирующего шума, которые задаются исходя из анализа статистических характеристик их полета. Для повышения достоверности их классификации при схожем характере полета необходимо также учитывать информацию нейросетевого классификатора, работа которого в этом случае может быть основана, например, на анализе доплеровского портрета отраженных сигналов.

Модель движения цели с постоянной скоростью представляет собой уравнение (8), в котором матрица перехода и ковариационная матрица формирующего шума имеют вид

$$\mathbf{F} = \text{diag}[\mathbf{F}_{cv}, 0, \mathbf{F}_{cv}, 0], \quad \mathbf{F}_{cv} = \begin{bmatrix} 1 & T \\ 0 & 1 \end{bmatrix}, \quad (16)$$

$$\mathbf{Q} = q_\xi \text{diag}[\mathbf{Q}_{cv}, 0, \mathbf{Q}_{cv}, 0], \quad \mathbf{Q}_{cv} = \begin{bmatrix} T^4/3 & T^2/2 \\ T^2/2 & T^2 \end{bmatrix}, \quad (17)$$

где  $\text{diag}[a_1, a_2, \dots]$  – оператор формирования диагональной матрицы с диагональными элементами  $a_1, a_2, \dots$ ;  $q_\xi$  – спектральная плотность формирующего шума.

Модель движения цели с постоянным ускорением также основана на уравнении (8), в котором ускорение цели представляется как винеровский процесс с независимыми приращениями. Матрица перехода и ковариационная матрица формирующего шума задаются как

$$F = \text{diag}[F_{ca}, F_{ca}], F_{ca} = \begin{bmatrix} 1 & T & T^2/2 \\ 0 & 1 & T \\ 0 & 0 & 1 \end{bmatrix}, \quad (18)$$

$$Q = q_\xi \text{diag}[Q_{ca}, Q_{ca}], Q_{ca} = \begin{bmatrix} T^5/20 & T^4/8 & T^3/6 \\ T^4/8 & T^3/3 & T^2/2 \\ T^3/6 & T^2/2 & T \end{bmatrix}. \quad (19)$$

**Моделирование работы алгоритма**

Проверка функционирования предложенного подхода осуществлена путем имитационного моделирования в программном пакете Matlab. Радиолокатор осуществляет получение оценок координат цели с периодом  $T = 0,2$  с. Структура системы со ССС представляет собой два фильтра, первый основан на модели движения цели с постоянной скоростью, второй – на модели движения цели с постоянным ускорением. Спектральная плотность формирующего шума  $q_\xi$  для первого фильтра принята равной 0,01, для второго – 1,0. Элементы матрицы вероятностей переходов заданы значениями  $q^{(11)} = q^{(22)} = 0,98$ ,  $q^{(12)} = q^{(21)} = 0,02$ . Матрица измерения задана в виде  $H = [1, 0, 0; 1, 0, 0]$ , а элементы ковариационной матрицы шума измерения  $R$  приняты равными 0,1.

Нейросетевой индикатор представляет собой нейронную сеть глубокого обучения, основанную на архитектуре SqueezeNet и реализованную с использованием расширения Neural Networks Toolbox программного пакета Matlab. В качестве обучающей выборки использовались РЛИ летательных аппаратов – мультикоптера DJI Matrice S900, БПЛА «Орлан-10» и «Bayraktar TB2», а также крылатой ракеты Tomahawk BGM-109, представленные на рис. 2. РЛИ сформированы в среде электродинамического моделирования CST Microwave Studio с использованием реализованного в ней метода инверсного синтезирования апертуры.

Обучающая выборка представляла собой набор из

700 РЛИ для каждого летательного аппарата, полученных с различных ракурсов наблюдения. Изображения сформированы для горизонтальной поляризации электромагнитной волны при моностатическом методе радиолокации и средней длине волны зондирующего сигнала – 5,5 см. Ширина спектра зондирующего сигнала – 1 ГГц, что обеспечивает разрешение по горизонтальной дальности (координате  $x$ ) около 15 см. Ширина сектора угла наблюдения при инверсном синтезировании апертуры принята равной 10 градусам, что также обеспечивает получение разрешения по поперечной дальности (координате  $y$ ) около 15 см. Нейросетевой индикатор осуществлял соотнесение объекта по его РЛИ к двум классом: БПЛА самолетного типа ( $r_k = 1$ ) и мультикоптерного типа ( $r_k = 2$ ). Вероятностные характеристики нейросетевого индикатора, определенные на основе тестовой выборки, представлены в табл. 1.

Таблица 1. Вероятностные характеристики нейросетевого индикатора

$\lambda(r_k   s_k)$	$s_k = 1$	$s_k = 2$
$r_k = 1$	0,78	0,22
$r_k = 2$	0,36	0,64

Траектория полета цели моделировалась на основе выражений (8), (9), (16)-(19) и представляла собой набор участков маршрута, на которых цель имитировала полет различных типов летательных аппаратов – БПЛА самолетного типа (участок 1 и 3 на рис. 3) и мультикоптерного типа (участок 2 и 4 на рис. 3). Продолжительность полета на каждом участке – 10 с. Для первого и третьего участков характерен прямолинейный полет с постоянной скоростью, для второго и четвертого – с эволюциями как по скорости, так и по направлению. Элементы вектора состояния  $x = [x_0, \dot{x}_0, \ddot{x}_0, y_0, \dot{y}_0, \ddot{y}_0]^T$ , характеризующие его начальное состояние, приняты равными:  $x_0 = 1$  м,  $y_0 = 4$  м,  $\dot{x}_0 = 20$  м/с,  $\dot{y}_0 = -10$  м/с,  $\ddot{x}_0 = 3$  м/с<sup>2</sup>,  $\ddot{y}_0 = 5$  м/с<sup>2</sup>.




Рис. 2. Вид летательных аппаратов и их радиолокационные изображения, сформированные методом обратного синтезирования апертуры в среде CST Microwave Studio: DJI Matrice S900 (а), «Орлан-10» (б), «Bayraktar TB2» (в), Tomahawk BGM-109 (г)




Рис. 3. Траектория полета цели и ее оценки, полученные системой со ССС




Рис. 4. Вероятности соотношения объекта к классу БПЛА самолетного (вверху) и мультироторного (внизу) типа без учета показаний индикатора (—), с учетом показаний индикатора (—) при истинном значении (---)

На рис. 4 представлены временные зависимости вероятности соотношения цели к классу БПЛА самолетного или мультироторного типа, а также истинные значения классов. Анализ показывает, что подход, основанный на применении системы со ССС обеспечивает возможность классификации по статистическим характеристикам траектории полета цели. Средняя вероятность классификации составила около 0,7...0,8 при запаздывании выдачи результата распознавания около 1,5...2 с. Дополнительное использование показаний нейросетевого классификатора обеспечивает повышение вероятности классификации до значений 0,95...0,98 при уменьшении времени запаздывания результата классификации до 0,5...1 с.

#### Заключение

Таким образом, разработанный подход, основанный на объединении многомодельного байесовского и

нейросетевого подходов с использованием положений систем со случайной скачкообразной структурой, обеспечивает уверенную классификацию воздушных целей по траекторным признакам и их радиолокационным изображениям. Использование информации нейросетевых классификаторов обеспечивает повышение вероятности распознавания в 1,2...1,4 раза при уменьшении времени запаздывания результата классификации в 2...3 раза. Использование предложенного классификатора в средствах радиолокации позволит повысить эффективность выбора приоритета на противодействие с учетом степени опасности целей и исключить из обработки второстепенные цели для предотвращения перегрузки каналов средств радиолокации и противодействия.

#### Литература

1. Воробьев Е.Н. Исследование сигнальных признаков распознавания малых БПЛА в полуактивной РЛС.

Вестник Новгородского государственного университета, 2019. № 4 (116). С. 72-77.

2. Мариам М., Похвощев В.Н., Рязанцев Л.Б. К вопросу повышения эффективности противодействия малоразмерным беспилотным летательным аппаратам. Военная мысль, 2022, № 6, С. 45-52.

3. Рязанцев Л.Б. Многомодельное байесовское оценивание вектора состояния маневренной воздушной цели в дискретном времени. Вестник ТГТУ, 2009. № 4. С. 729-739.

4. Zekun Jiao, Chibiao Ding, Longyong Chen, Fubo Zhang. Three-Dimensional Imaging Method for Array ISAR Based on Sparse Bayesian Inference. Sensors, 2018. DOI:10.3390/s18103563.

5. Qian Lv, Tao Su, Jibin Zheng, Jiancheng Zhang. Three-dimensional interferometric inverse synthetic aperture radar imaging of maneuvering target based on the joint cross modified Wigner-Ville distribution. Journal of Applied Remote Sensing, 2016. DOI:10.1117/1.JRS.10.015007.

6. Lazarov A., Minchev C. ISAR Image Recognition Algorithm and Neural Network Implementation. Cybernetics and Information Technologies, 2017, pp. 183-199.

7. Barber D. Bayesian Reasoning and Machine Learning. Cambridge University Press, 2010. 590 p.

8. Kevin P. Murphy. Machine Learning: A Probabilistic Perspective. Massachusetts Institute of Technology, 2012. 1067 p.

9. Hao Wang, Dit-Yan Yeung. Towards Bayesian Deep

Learning: A Framework and Some Existing Methods. IEEE Transactions on Knowledge and Data Engineering, 2016, vol. 28, no. 12, pp. 3395-3408.

10. Bayesian Deep Learning [Электронный ресурс]. <http://bayesiandeeplearning.org> (дата обращения: 29.01.2021).

11. Бухалев В.А. Распознавание, оценивание и управление в системах со случайной скачкообразной структурой. М.: Физматлит. 1996. 288 с.

12. Bar-Shalom Y., Li X.R., Kirubarajan T. Estimation with Applications to Tracking and Navigation: Theory, Algorithms and Software. John Wiley & Sons, 2001. 580 p.

13. Li X.R., Jilkov V.P. Survey of Maneuvering Target Tracking. Part I: Dynamic Models. IEEE Transactions on Aerospace and Electronic Systems, 2003, vol. 39(4), pp. 1333-1364.

14. Лихачев В.П., Рязанцев Л.Б. Вероятностные характеристики индикатора маневра воздушной цели на основе фазоразностной оценки ускорения сближения. Успехи современной радиоэлектроники, 2010. № 11. С. 10-14.

15. Bruderer B., Boldt A. Flight characteristics of birds: I. Radar measurements of speeds. Ibis, 2001, no. 143(2), pp. 178-204.

16. Купряшкин И.Ф., Соколик Н.В. Моделирование дальностно-доплеровских портретов мультикоптеров, формируемых РЛС с непрерывным частотно-модулированным излучением. Журнал радиоэлектроники [электронный журнал], 2021. № 3.

## НОВЫЕ КНИГИ

Воскресенский Д.И., Добычина Е.М.

**Цифровые антенные решетки: Монография. М.: Изд-во Радиотехника, 2020 г. 240 с.: ил.**

Рассмотрен новый класс антенных систем – цифровых антенных решеток бортовых радиолокационных комплексов, позволяющих повысить энергетический потенциал за счет использования новых методов оптимизации режима работы высокоэффективных активных устройств и обеспечения высокой точности формирования амплитудно-фазового распределения с помощью предложенной системы автоматической калибровки. Представлены результаты экспериментальных исследований возможностей цифрового диаграммообразования и точностных характеристик калибровки макета цифровой решетки.

Для научных работников и инженеров, занимающихся исследованиями в области разработки, создания и применения цифровых решеток в современных радиоэлектронных системах. Может быть рекомендована в качестве учебного пособия студентам радиотехнических специальностей, а также аспирантам и магистрантам по направлениям «Радиотехника», «Радиофизика и электроника».

### Уважаемые коллеги!

В связи с ликвидацией АО «Роспечать» подписка на журнал «Цифровая обработка сигналов» открыта в офисе РНТОРЭС им. А.С. Попова. Заявки можно подать в любое время Карпушкиной Галине Ивановне по нашему электронному адресу: [vznos-rntores@mail.ru](mailto:vznos-rntores@mail.ru) на **2022** год. Стоимость одного номера **800 руб.** Годовой выпуск – **4 номера**. Подписка оформляется по Договору или выставлением счёта на оплату для юридических и физических лиц. Готовые тиражи журнала будут доставлены в наш офис. Их можно будет получить по адресу: ул. Авиамоторная, д. 8 «Научный центр» МТУСИ или по почте на адрес, указанный при подписке, при предварительной оплате почтовых услуг на наш расчётный счёт (200,0 руб.)

