

# КИБЕРНЕТИКА

---

МРНТИ 28.23.15, 28.23.37

*Б.С. Карабаев<sup>1</sup>*

<sup>1</sup>Алматинский университет энергетики и связи,  
г. Алматы, Казахстан

## РАСПОЗНАВАНИЕ ЛЕТАТЕЛЬНЫХ АППАРАТОВ ПРИ ПОМОЩИ НЕЙРОСЕТЕВЫХ ТЕХНОЛОГИЙ

---

**Аннотация.** Предлагается методика построения автоматических распознавателей летательных аппаратов по набору радиолокационных измерений на основе каскада многослойных нейронных сетей прямого распространения. Система классификации состоит из отдельных нейросетевых блоков и каждый блок характеризуется простой функциональной задачей. Обучение блоков выполняется в определенной последовательности с использованием как результатов непосредственных наблюдений воздушных радиолокационных станций, так и результатов обучения других блоков. Демонстрируется практическое применение данной методики при распознавании летательных аппаратов 3-х типов. Приводятся числовые показатели распознавания. Методика применима в области контроля перемещений летательных аппаратов в воздушном пространстве с целью отслеживания и управления движением гражданской авиации и в интересах противовоздушной обороны.

**Ключевые слова:** автоматические распознаватели, летательные аппараты, динамические объекты, нейросетевая обработка, многослойные нейронные сети, радиолокационные станции.

**Түйіндеме.** Тікелей таратылатын көпқатпарлы нейронды желілер каскадының негізінде радиолокациялық өлшеулер жиынтығы бойынша ұшу аппараттарын автоматты танып білу едістемесін тұрғызу ұсынылған. Сыныптау жүйесі жекелеген нейрожелілік блоктардан тұрады және әрбір блок қарапайым функционалдық есеппен сипатталады. Оқыту блоктардан орындалады белгілі бір кезекпен пайдалана отырып, нәтижелерін тікелей бақылау өуе радиолокациялық станциялар, сондай-ақ оқыту нәтижелерін

басқа блоктар. Көрсетіледі практикалық қолдану осы әдістемені анықтау кезінде ұшу аппараттарының үш түрі келтіріледі сандық көрсеткіштерді танып білу. Әдістемесі қолданылады саласындағы бақылау орын ауыстыру ұшу аппараттарының қазақстанның әуе кеңістігінде қадағалау мақсатында қозғалысты басқару және азаматтық авиация мүддесінде әуе шабуылына қарсы қорғаныс.

**Түйінді сөздер:** автоматты танып білу, ұшу аппараттары, динамикалық объектілер нейрожелілік өңдеу, көп қабатты нейронды желілер, радиолокациялық станция.

---

**Abstract.** The paper proposes a method of constructing automatic recognizers flying devices on a set of radar measurements based on a cascade of multi-layer neural networks of direct distribution. Demonstrates the the practical application of this technique in recognizing the three types flying devices. The classification system consists of individual neural network blocks and each block is characterized by a simple functional task. Learning of blocks is performed in sequence using the results of direct observation, aerial radar stations, and learning outcomes of other units. De monsterquest the practical application of this technique in the detection of aircraft of three types are numeric indicators of recognition. The technique is applicable to control of movements of aircraft in the airspace to track and control the movement of civil aviation and in the interests of defense.

**Key words:** automatic recognizers, aircraft, dynamic objects, neural network processing, multi-layer neural network, radar.

**Введение.** Проблема классификации динамического объекта (ДО), состояние которого меняется с течением времени, встречается во многих предметных областях и является сложной и трудноразрешимой [1-3,5]. Единый подход к построению систем классификации таких объектов, пригодный для любых ситуаций и задач, в настоящее время не разработан [4-6]. Таким образом, процесс синтеза разнообразных методик построения автоматических классификаторов ДО очень важен и актуален [6]. Подобная задача возникает в контуре управления системы контроля воздушного пространства (СКП) [7]. СКП создается с целью отслеживания перемещений летательных аппаратов (ЛА) в заданной области воздушного пространства в интересах управления воздушным движением гражданской авиации

или в интересах противовоздушной обороны. При обслуживании большого числа ЛА с помощью ограниченных ресурсов СКП большое значение придается своевременной и достоверной информации о типах обслуживаемых ЛА, об их технических возможностях и режимах работы [7]. В частности, интерес представляет информация о применении летательных аппаратов радиолокационных ловушек (РЛ).

Основным источником информации для пунктов управления СКП, принимающих решения по распределению ресурсов системы между обслуживаемыми ЛА, являются наземные или воздушные радиолокационные станции (РЛС).

Нами предлагается методика построения компонента системы управления СКП - блока распознавания типа ЛА на основе каскада многослойных нейронных сетей прямого распространения. Разработанная система классификации состоит из отдельных нейросетевых блоков. Причем каждый блок характеризуется простой функциональной задачей, а обучение блоков выполняется в определенной последовательности с использованием как результатов непосредственных наблюдений РЛС, так и результатов обучения других блоков.

**Структура нейросетевого распознавателя.** Система  $F$  распознавания ЛА состоит из 2-х блоков (рис. 1), которые работают последовательно. Классификатор  $F_1$  осуществляет локальную во времени классификацию ЛА на основе текущего значения входного вектора  $S_i$ . Решения классификатора  $F_1$  принимаются независимо в каждый момент времени. Для учета предыстории принятых в отношении данного ЛА решений служит классификатор  $F_2$ .




Рис. 1. Структура системы классификации

Классификатор  $F_1$  состоит из нескольких блоков (рис. 2). Рассмотрим  $N$  нейросетевых блоков  $G_i, j = 1, 2, \dots, N$ , которые далее составят основу для нейросетевого классификатора  $F_1$ . Каждый блок  $G_j$  предназначен для классификации входного вектора  $S_j$  по принципу "тип  $j$  против всех". Каждый блок  $G_j$  обучается воспроизводить следующий желаемый выход:

$$g_j(S_j) = 1 \text{ – если вектор } S_j \text{ соответствует ЛА типа } j;$$

$$g_j(S_j) = 0 \text{ – в других случаях.}$$

Нейросетевые блоки  $G_i, j = 1, 2, \dots, N$ , выполняют локальную по типу и по времени классификацию ЛА. В связи с неточностью вычисленных по данным РЛС компонентов входного вектора  $S_j$ , а также с возможностью расположения вектора  $S_j$  вблизи границы классов классификаторы  $G_j$  могут не дать однозначного вывода о принадлежности вектора  $S_j$  определенному типу ЛА. Для устранения этой возможной неопределенности используется дополнительный нейросетевой классификатор  $G$ , который принимает на вход значения  $G_j, j = 1, 2, \dots, N$ , и обучается воспроизведению значения, равного номеру типа ЛА:

$$g(S_i) = \varphi(g_1(S_i), g_2(S_i), \dots, g_n(S_i)) = j \text{ – если вектор } S_j \text{ соответствует типу } j.$$




Рис. 2. Структура блока локальной классификации

Если для некоторого значения  $j$  выполняется неравенство

$$|g(S_i) - j| \leq \delta,$$

где  $\delta$  – заданный параметр;

$$\delta \in (0, 1),$$

то принимается решение о принадлежности цели с текущим входным вектором  $S_j$  типу  $j$ :  $r(S_j) = j$ .

Если ни для одного значения  $j = 1, 2, \dots, N$  данное неравенство не выполняется, классификатор принимает решение в пользу неизвестного типа ЛА:  $r(S_i) = 0$ . Все эти неравенства проверяются в выходном блоке  $L$  классификатора  $F_1$ .

Классификатор  $F_1$  вырабатывает предварительное решение о типе наблюдаемого ЛА. Финальное решение формируется с использованием расчетных данных о достоверности решения классификатора  $F_1$ . Локальные решения, вырабатываемые классификатором  $F_1$ , в разные моменты времени принимаются независимо друг от друга, без учета предыстории и накопления информации. Этот недостаток устранен далее введением дополнительного блока классификации  $F_2$ , который обеспечивает инерционность принятия решений.

**Учет предыстории локальных решений.** Рассмотрим временной интервал заданной длины, включающий  $M$  измерений перед текущим моментом принятия решения о типе ЛА, т.е. "скользящее окно" ширины  $M$ . В каждый момент времени на этом интервале локальным классификатором  $F_1$  принято предварительное решение. Среди возможных решений  $F_1$  могут быть и решения "неопознанный ЛА".

В блоке  $F_2$  происходит осреднение в "скользящем окне" ширины  $M$  локальных решений  $r(S_j)$ , полученных в предшествующие моменты времени. Для этого в блоке  $F_2$  (рис. 3) содержатся  $N$  накопителей. При поступлении новых данных переключатель  $K$  выбирает нужный накопитель с номером  $r(S_j)$  и добавляет в него текущее значение 1. В остальные накопители добавляется значение 0.

Осреднение локальных решений по каждому типу производится в каждом накопителе  $Q_i$ ,  $i = 0, \dots, N$  согласно выражению

$$q_i^* = \frac{1}{M+1} \sum_{j=k-M}^k q_i(t_j), \quad (2)$$

где  $M$  – ширина "скользящего окна" (размер накопителя  $Q_i$ );

$q_i(t_j)$  – значение локального решения в пользу этого типа, поступившее в момент  $j$ ;

$t_k$  – текущий момент времени.

Таким образом, на выходе блоков  $Q_p$   $i = 0, \dots, N$  получается вектор из осредненных локальных решений  $(q_0, q_1, \dots, q_N)$ . Этот вектор подается на логический блок  $L$ , который аналогичен одноименному блоку локального классификатора.

Полученное после работы блока  $L$  окончательное решение  $R(S_j)$  является результатом работы системы классификации. Применение выходного классификатора  $F_2$  обеспечивает накопление информации о предыстории принятых решений, отсутствие "скачков" и повышение точности решения о типе ЛА.




Рис. 3. Структура блока учета динамики локальных решений

Рекомендуется ширину "скользящего окна" на начальном этапе классификации выбрать небольшой и постепенно увеличивать до заданного максимального значения. Это позволит активно перестраивать решение в условиях, когда информации недостаточно для принятия уверенного решения.

**Алгоритм обучения системы классификации.** Для обучения системы классификации предлагается следующий алгоритм:

На первом шаге обучения системы производится настройка локальных по времени и по типу классификаторов  $G_p$   $i = 1, \dots, N$ .

Для этого формируется обучающая выборка  $T_1$ , включающая представителей всех распознаваемых типов ЛА. Каждый элемент обучающей выборки – вектор  $S_j$ , описывающий мгновенное состояние конкретного ЛА.

На втором шаге обучения производится тестирование качества обучения классификаторов  $G_j$ ,  $i = 1, \dots, N$ , на новой независимой тестовой выборке  $T_2$ . Фактические выходы классификаторов  $G_j$ , полученные в результате тестирования, представляют собой обучающую выборку для выходного локального классификатора  $G$ .

На третьем шаге алгоритма формируется независимая от  $T_1$  и  $T_2$  выборка  $T_3$ , которая предъявляется классификаторам  $G_j$  и косвенно – классификатору  $G$ . Получившиеся в результате тестирования классификатора  $G$  фактические выходные значения служат информационной основой для настройки пороговых значений в логическом блоке  $L$  локального классификатора  $F_1$ .

На четвертом шаге обучения системы формируется независимая выборка  $T_4$ , которая служит для настройки пороговых значений в логическом блоке  $L$  классификатора  $F_2$ . Обучение каждого нейросетевого модуля производится по алгоритму обратного распространения ошибки. В ходе исследований установлено, что наиболее быстрое и качественное обучение достигается с помощью алгоритма Левенберга – Марквардта.

**Показатели качества классификации.** Отдельные нейронные сети, входящие в состав предложенной системы классификации, осуществляют за один такт обработку одного обучающего примера, который соответствует отдельному траекторному измерению. Такую классификацию будем называть поточечной. Наиболее естественные показатели качества поточечной классификации приведены в табл. 1.

Для конечного пользователя системы классификации большой интерес представляют показатели, оценивающие качество распознавания типа всей траектории интегрально на некотором участке наблюдения. Для этого предлагается делать "временной срез" на каком-нибудь фиксированном измерении и отно-

Показатели качества поточечной классификации

| Формула                            | Описание  |
|------------------------------------|---|
| $\mu = \frac{K}{N}$                | Доля правильно распознанных примеров выборки по отношению к ее общему объему;<br>$N$ – общее число примеров выборки;<br>$K$ – число правильно распознанных примеров.  |
| $\eta_{ij} = \frac{n_{ij}}{n_i}$   | Доля примеров типа $i$ , отнесенных к типу $j$ ;<br>$n_i$ – количество примеров типа $i$ ;<br>$n_{ij}$ – количество примеров из числа $n_i$ , отнесенных к типу $j$   |
| $\theta_{ij} = \frac{m_{ij}}{m_i}$ | Доля примеров, отнесенных к типу $i$ , которые на самом деле относятся к типу $j$ ;<br>$m_i$ – количество примеров, отнесенных к типу $i$ ;<br>$m_{ij}$ – количество примеров из числа $m_i$ , которые на самом деле относятся к типу $j$ |

свить траекторию к типу  $i$ , если среди последних  $P$  измерений  $H$  измерений относилось к типу  $i$ . Если ни для одного типа данный критерий не выполняется, то предлагается считать траекторию неопознанной. Оценивать качество классификации по всей выборке данных предлагается с помощью интегрального показателя.

$$\rho_i = \frac{K_T^i}{N_T^i}, \quad (3)$$

где  $N_T^i$  – общее число траекторий типа  $i$ ;

$K_T^i$  – число траекторий типа  $i$ , которые были распознаны правильно в соответствии с указанным критерием.

**Результаты модельных экспериментов.** Изложенная выше методика распознавания типа ЛА проверена математическим моделированием. В качестве исходных данных для моделирования взяты типовые траектории движения трех видов ЛА.



Все рассмотренные при проведении экспериментальных исследований траектории сгенерированы с помощью математических моделей, адекватно представляющих реальные динамические характеристики ЛА.

В общей сложности сгенерировано по 100 траекторий для каждого типа ЛА. Полученные с помощью математических моделей траектории будем называть эталонными. На основе каждой эталонной траектории построено по 10 вариантов реализаций. При подготовке выборок данных учитывались характеристики РЛС по точности и дальности обнаружения и сопровождения ЛА. В модельные траекторные данные были введены аддитивные ошибки, соответствующие погрешностям измерений реальной РЛС. Общее число модельных измерений вдоль всех сгенерированных траекторий составило около 70 тыс.

Результаты тестирования классификатора  $F_1$  на независимой тестовой выборке приведены в табл. 2. В строках таблицы

Таблица 2

**Результаты тестирования блока  $F_1$  на независимой выборке**

| Фактический тип ЛА | Принятое классификатором решение |        |        |           |
|--------------------|----------------------------------|--------|--------|-----------|
|                    | тип 1                            | тип 2  | тип 3  | неопознан |
| Тип 1              | 0,9534                           | 0,0367 | 0,0037 | 0,0062    |
| Тип 2              | 0,0213                           | 0,8860 | 0,0600 | 0,0327    |
| Тип 3              | 0,0212                           | 0,1140 | 0,8184 | 0,0464    |

даны принятые локальным классификатором решения для разных типов ЛА, указанных в первом столбце. В ячейках приведены значения показателя  $n_{ij}$ . Как видно, доля правильно распознанных ЛА превышает 80 %. Лучше всего распознаются ЛА типа 1. При этом ошибка в пользу ЛА типа 3 и "неопознан" невелика (в сумме менее 1 %). Ошибки при распознавании ЛА типа 2 и ЛА типа 3 в пользу друг друга несколько выше. Полученные результаты свидетельствуют не только об удовлетворительной точности, но и о высокой обобщающей способности обученного локального классификатора  $F_1$ .

Моделирование показало, что на ограниченных временных отрезках траектории ЛА разных типов могут быть сходны и трудно различимы. В таких ситуациях наблюдается частая смена решений локального классификатора  $F_1$ . На рис. 4 показаны решения, которые принимал локальный классификатор  $F_1$  по мере приближения ЛА типа 3 к наблюдающей за ним РЛС. На горизонтальной оси отмечены номера наблюдений за ЛА от момента его обнаружения. На вертикальной оси указан номер типа, к которому классификатор  $F_1$  отнес этот ЛА в текущем наблюдении. На графике показаны 64 решения, последовательно принятых локальным классификатором. Из них 10 решений приняты в пользу неопознанного ЛА, 13 решений – в пользу ЛА типа 2 и типа 1 решение – в пользу ЛА типа 1. На графике хорошо видно, что на средних дальностях (наблюдения 18-52) локальный классификатор начинает принимать противоречивые решения в пользу ЛА типов 2 и 3. Более того, с 53-го наблюдения классификатор  $F_1$  практически стабильно начинает ошибочно относить ЛА к типу 2.




Рис. 4. Последовательность решений, принятых блоком  $F_1$  по ЛА типа 3: 1 – участок, где классификатор принимает верные решения на фоне локальных ошибок; 2 – участок, где классификатор стабильно принимает неправильные решения




Рис. 5. Демонстрация устранения локальных ошибок блоком  $F_2$

Для преодоления возникающей неопределенности используется классификатор  $F_2$  со "скользящим окном" длины 10. На рис. 5 изображены решения о типе ЛА, принятые по тем же исходным данным интегральным классификатором  $F_2$ . График наглядно демонстрирует эффект от использования интегрального классификатора. Практически на всей траектории движения ЛА классификатор  $F_2$  стабильно принимает правильное решение о его типе. Лишь на 3-х самых последних наблюдениях ЛА сначала воспринимается как неопознанный (наблюдение 62), а затем принимается ошибочное решение (наблюдения 63-64) о его принадлежности к типу 2. Для данной конкретной траектории интегральный классификатор  $F_2$  полностью подавляет колебания величины  $r(S_j)$  на средних дальностях, которые возникают в локальном классификаторе  $F_1$  (см. рис. 4), и существенно уменьшает область, где принимаются неправильные решения.

### Выводы

Разработана методика построения автоматических классификаторов динамических объектов на основе каскада многослойных нейронных сетей прямого распространения. Демонст-

рируется применение этой технологии при разработке классификатора летательных аппаратов и приводятся числовые показатели распознавания трех типов ЛА.

### Список литературы

1 *Bishop, Chris. M. Neural Networks for Pattern Recognition.* – Oxford: University Press, 2005. – 225 p.

2 *Ту Дж., Гонсалес Р.* Принципы распознавания образов. – М.: Мир, 1978. – 194 с.

3 *Фукунага К.* Введение в статистическую теорию распознавания образов. – М.: Наука, 1979. – С. 15-43.

4 *Потапов А.С.* Распознавание образов и машинное восприятие. – М.: Политехника, 2007. – 158 с.

5 *Хайкин С.* Нейронные сети: полный курс / пер. с англ. – М.: "Вильямс", 2006. – С. 15-18.

6 *Осовский С.* Нейронные сети для обработки информации. – М.: Финансы и статистика, 2004. – С. 56-61.

7 *Бакулев П.А.* Радиолокационные системы. – М.: Радиотехника, 2004. – 229 с.

**Карабаев Б.С.**, e-mail: bekstar37@gmail.com, bekstar7@mail.ru