УДК 621.396.96; 004.89 doi: 10.15827/0236-235X.152.682-693 2025. Т. 38. № 4. С. 682–693

Классификация воздушных целей в РЛС на основе нейросетевой модели с расширенным признаковым пространством

Е.И. Минаков [1], А.Н. Грачев [1, 2], М.С. Башеров [1, 2], Д.М. Шпрехер [1]✉

[1] Тульский государственный университет, г. Тула, 300012, Россия
[2] Центральное конструкторское бюро аппаратостроения, г. Тула, 300034, Россия

Ссылка для цитирования
Минаков Е.И., Грачев А.Н., Башеров М.С., Шпрехер Д.М. Классификация воздушных целей в РЛС на основе нейросетевой модели с расширенным признаковым пространством // Программные продукты и системы. 2025. Т. 38. № 4. С. 682–693. doi: 10.15827/0236-235X.152.682-693
Информация о статье
Группа специальностей ВАК: 1.2.1, 2.3.1
Поступила в редакцию: 30.07.2025 После доработки: 11.08.2025 Принята к публикации: 12.08.2025

Аннотация. Предметом исследования является автоматическая классификация объектов радиолокационного наблюдения в обзорных импульсно-доплеровских РЛС. Они функционируют в условиях ограниченного времени наблюдения, высокой плотности помех и значительного перекрытия признаковых пространств между объектами различной физической природы. Особое внимание уделено распознаванию малоразмерных и слабоотражающих целей с неэффективной поверхностью рассеяния, таких как беспилотные летательные аппараты и птицы. Предложен подход, основанный на использовании нейросетевого классификатора типа многослойного перцептрона прямого распространения, обучаемого на расширенном признаковом пространстве, включающем кинематические, статистические и амплитудные характеристики. Для повышения обобщающей способности модели использована комбинированная обучающая выборка, включающая реальные траектории, синтетически сгенерированные данные с применением методов аугментации и результаты статистического моделирования. Статистические признаки рассчитывались в скользящем временном окне. Точность классификации по итогам тестирования составила 96 %, при этом устойчивость модели к шумам и вариативности траекторных данных была подтверждена эмпирически. Проведен комплексный анализ значимости признаков: на этапе проектирования сети выполнена априорная оценка их информативности, а после обучения реализован апостериорный анализ их вкладов с использованием модифицированного алгоритма Гарсона. Полученные результаты позволили обосновать минимально необходимый и физически интерпретируемый состав признаков, обеспечивающий максимальную селективность модели при допустимой вычислительной сложности. Все этапы построения модели, формирования признакового пространства и обучения реализованы в среде MATLAB с использованием пакетов Neural Network Toolbox, Deep Learning Toolbox и Signal Processing Toolbox. Это позволило обеспечить воспроизводимость, адаптивность и техническую применимость разработанного решения. Практическая значимость работы заключается в возможности интеграции разработанного алгоритма в существующие РЛС без необходимости глубокой аппаратной модернизации, что делает данный подход актуальным для задач адаптивного распознавания в условиях реального времени.

Ключевые слова: нейросетевая модель, классификация, импульсно-доплеровская РЛС, искусственный интеллект, автоматическое распознавание, машинное обучение, программная реализация, MATLAB
Благодарности. Работа выполнена при финансовой поддержке правительства Тульской области в сфере науки и техники, грант ДС/174 от 28.12.2024 г.

Введение. Повышение эффективности автоматического распознавания целей в обзорных импульсно-доплеровских РЛС остается одной из ключевых задач научных исследований. В частности, в последние годы особое внимание уделяется распознаванию целей с малой эффективной поверхностью рассеяния, таких как *беспилотные летательные аппараты* (БПЛА) и птицы. Традиционные методы радиолокационного распознавания, основанные на кинематических характеристиках сигнала, обладают ограниченной информативностью при выделении малоразмерных объектов [1, 2]. Вместе с тем исследования последних лет показывают, что использование дополнительных признаков движения и алгоритмов машинного обучения, позволяет достичь более надежного разделения БПЛА и птиц, несмотря на схожесть их радиолокационных характеристик [3, 4]. Ошибки при классификации указанных целей могут приводить к критическим последствиям: от увеличения числа ложных тревог до снижения эффективности систем ПВО вследствие нецелевого расхода боекомплекта. При этом традиционных классифицирующих признаков (полная скорость, высота полета и *эффективная поверхность рассеяния* (ЭПР) в условиях значительного пересечения признаковых пространств таких целей и ограниченного временного окна наблюдения) зачастую оказывается недостаточно.

Современные подходы к решению задачи классификации целей в обзорных РЛС условно можно разделить на три основные категории: методы, связанные с построением радиолокационных портретов целей, использующие сверхразрешение по дальности и угловым координатам, методы спектрального анализа, опирающиеся на микродоплеровский эффект, а также классические методы, основанные на анализе траекторных признаков движения целей.

Методы классификации на основе дальностных портретов или двумерных радиолокационных изображений, как показано в работах [3, 5, 6], позволяют эффективно выделять и классы, и типы целей, используя геометрические и энергетические параметры рассеяния. Они обеспечивают высокую точность, даже в условиях вариативности ракурсов и шумов, что делает их использование в обзорных РЛС весьма перспективным [6].

Однако формирование дальностных или двумерных радиолокационных портретов с достаточным уровнем детализации требует не только специфических условий наблюдения (стабильность цели, длительное когерентное накопление сигнала), но и специализированной аппаратной реализации. В частности, для получения высокого разрешения по дальности, необходимого для выделения характерных конструктивных элементов малоразмерных целей, требуются широкополосные или многочастотные зондирующие сигналы [5]. Разрешающая способность таких систем должна составлять единицы или десятки сантиметров, что недостижимо для типовых импульсно-доплеровских РЛС, работающих с шириной полосы пропускания, обеспечивающей разрешение на уровне метров или десятков метров.

Несмотря на высокую эффективность данных методов, их практическое применение ограничено специализированными РЛС, такими как системы с синтезированной [6] или инверсной синтезированной апертурой, способными обеспечивать необходимые параметры пространственной когерентности и сигналов. Для обзорных РЛС общего назначения, выполняющих задачи кругового обзора и сопровождения множества динамически движущихся целей, применение подобных методов либо требует существенной модификации аппаратно-программного комплекса, либо оказывается нерентабельным и технически труднореализуемым.

В ряде работ для решения задачи классификации целей предлагается извлекать спектральные признаки, отражающие колебательные и вращательные компоненты в движении сопровождаемых воздушных объектов [7–9]. Эти признаки продемонстрировали высокую селективность при классификации целей с винтовым (микродоплеровским) эффектом, в том числе при дифференциации дронов и птиц [7].

Однако микродоплеровский эффект в условиях реальных радиолокационных измерений в импульсно-доплеровских РЛС проявляется не всегда. Одним из необходимых условий его появления является высокое отношение сигнал/шум радиолокационного сигнала, поскольку размытость спектра становится различимой только при достаточной энергетике отраженного сигнала. В случае наблюдения объектов с малой ЭПР на больших дистанциях уровень сигнал/шум оказывается недостаточным, что приводит к деградации информативности спектральных признаков.

Следует также отметить, что для надежного извлечения микродоплеровских признаков необходимо длительное накопление сигнала, что требует наличия когерентной обработки, увеличенной полосы пропускания и высокой стабильности приемо-передающих трактов. Это предполагает существенную модификацию архитектуры стандартной импульсно-доплеровской РЛС, в том числе переход к широкополосной обработке и перераспределению вычислительных ресурсов. При этом извлечение спектральных признаков, как правило, осуществляется на этапе первичной обработки сигнала, часто реализуемой в РЛС на программируемых логических интегральных схемах, которые имеют ограничения по объему доступной памяти и возможностям длительного хранения и интеграции данных.

Наконец, основным методом классификации целей по полученным микродоплеровским признакам являются сверточные нейронные сети [9], относящиеся к классу сетей глубокого обучения, содержащие десятки слоев нейронов и сотни тысяч подстраиваемых в процессе обучения весов. Реализация таких сетей в РЛС требует значительных вычислительных ресурсов.

Несмотря на успехи методов распознавания, основанных на использовании спектральных и радиолокационных портретов целей, не утратили своей актуальности и классические методы, базирующиеся на использовании траекторных признаков и ЭПР.

Так, в работах [10–12] показана эффективность использования параметров движения (скорость, ускорение, высота, угол поворота

и т.п.) при классификации воздушных и других типов целей. Например, в работе [13] применены методы главных компонент и опорных векторов на базе пяти признаков, полученных из 1 192 траекторий дронов и птиц. Точность классификации в этом случае не превысила 80 %, что авторы связывают с ограниченностью набора признаков и размеров выборки, а также с простотой алгоритма распознавания.

В работах других исследователей [12, 14] продемонстрировано улучшение результатов классификации за счет включения статистических признаков, таких как *среднеквадратичное отклонение* (СКО), составляющих скорости или ускорения. Однако следует отметить, что в этих работах исследования проводились с использованием двухкоординатных РЛС, не обладающих возможностью измерения вертикальных составляющих координат, скоростей и ускорений. В результате наиболее информативные признаки, связанные с поведением цели в вертикальной плоскости, не использовались. При этом в [15] было показано, что именно СКО вертикальных составляющих скорости и ускорения обладают более высокой информативностью по сравнению с горизонтальными составляющими при распознавании слабоотражающих воздушных целей, таких как птицы и БПЛА. Это связано с характерными особенностями движения таких целей в вертикальной плоскости: нерегулярные колебания у птиц и более стабильные траектории у управляемых БПЛА [13].

Таким образом, методы, опирающиеся на траекторные характеристики, остаются достаточно востребованными за счет простоты своей реализации, устойчивости к шумам и имеющейся возможности расширения признакового пространства путем нахождения и включения новых информативных признаков.

Целью настоящего исследования является разработка метода автоматической классификации воздушных объектов по радиолокационным данным в импульсно-доплеровских РЛС, основанного на использовании нейросетевой модели в виде многослойного перцептрона в сочетании с расширенным набором кинематических, статистических и амплитудных признаков. Особое внимание в работе уделяется обоснованию выбора признаков, формированию обучающих выборок и построению универсального классификатора, адаптивного к изменяющимся условиям наблюдения и разнообразию классов целей.

Формирование признакового пространства

Для решения задачи автоматической классификации объектов в обзорной РЛС было сформировано признаковое пространство, включающее 14 признаков. Их выбор осуществлялся на основании информативности, устойчивости к шумам, простоты вычисления, а также способности отражать характерные особенности движения и сигнальных проявлений различных классов целей.

Признаки условно могут быть разделены следующим образом:

- кинематические – высота, полные скорость и ускорение, горизонтальные и вертикальные составляющие скорости и ускорения, радиальная скорость, расстояние до цели;
- статистические – СКО горизонтальных и вертикальных составляющих скорости и ускорения;
- амплитудный – ЭПР, полученная по уровню принятого сигнала на фиксированном пороге детектирования.

Кинематические признаки описывают текущее состояние движения объекта, статистические – локальную вариативность кинематических характеристик, что особенно важно для выделения объектов с неравномерной динамикой полета (например, птиц). Амплитудный признак, формируемый на основе анализа отраженного сигнала, позволяет непосредственно учитывать не характер движения, а размеры целей. Представим полную структуру предлагаемого признакового пространства: 1 – эффективная площадь рассеяния (*EPR*); 2 – полная скорость (V_p); 3 – высота (H); 4 – полное ускорение (A_p); 5 – СКО вертикального ускорения $\left(\sigma_{A_h}\right)$; 6 – СКО вертикальной скорости $\left(\sigma_{V_h}\right)$; 7 – СКО горизонтального ускорения $\left(\sigma_{A_{xy}}\right)$; 8 – СКО горизонтальной скорости $\left(\sigma_{V_{xy}}\right)$; 9 – вертикальная составляющая скорости (V_h); 10 – горизонтальная составляющая скорости (V_{xy}); 11 – вертикальная составляющая ускорения (A_h); 12 – горизонтальная составляющая ускорения (A_{hy}); 13 – дальность (D); 14 – радиальная скорость (V_r).

Кинематические признаки

В традиционных подходах к распознаванию объектов по радиолокационным данным основное внимание уделялось ограниченному

числу траекторных признаков и ЭПР [1]. Наиболее распространенными из них являлись высота полета, полная скорость и ускорение. Эти характеристики позволяют в первом приближении разделять классы объектов по их кинематическому поведению и радиофизическим свойствам. Однако современные исследования и практическая эксплуатация РЛС показывают, что в пределах указанных признаков имеет место значительное пересечение признаковых пространств между такими классами, как БПЛА и птицы, самолеты и вертолеты, а также самолеты и управляемые ракеты [15]. Все это приводит к ошибкам классификации и не позволяет достичь общей точности распознавания, превышающей 80–90 %.

В связи с этим, как было отмечено ранее, для повышения точности классификации требуется расширение набора признаков за счет включения новых информативных траекторных характеристик, непосредственно связанных с классом цели, а также дополнительных признаков, которые совместно с основными способны повысить информативность последних.

В качестве новых информативных траекторных признаков предлагается использовать вертикальную и горизонтальную составляющие скорости и ускорения цели.

Одним из траекторных параметров, повышающих информативность других классифицирующих признаков, является дальность, напрямую никак не связанная с классом сопровождаемой цели. Однако в рамках задачи распознавания классов сопровождаемых объектов дальность все-таки может быть использована как дополнительный косвенный признак. Согласно основному уравнению радиолокации, мощность отраженного сигнала пропорциональна ЭПР цели и обратно пропорциональна четвертой степени расстояния до нее. При прочих равных условиях объекты с действительно малой ЭПР становятся невидимыми или слаборазличимыми на больших дальностях, поскольку отраженный от них сигнал опускается ниже порога чувствительности приемного тракта РЛС. Заметим, что в отличие от достаточно точно измеряемой дальности сама по себе даже усредненная ЭПР, рассчитываемая через амплитуду сильно зашумленного отраженного сигнала, обладает очень большой вариативностью: ее значения могут изменяться на 2 и даже более порядков. В этом случае при несоответствии значения ЭПР измеренной дальности, например, когда оно слишком мало, чтобы цель могла быть обнаружена, алгоритму классификации следует понизить или даже совсем исключить влияние ЭПР на принятие решения о классе сопровождаемой цели.

Другим значимым параметром, способным повысить эффективность классификации с использованием такого важного признака, как ЭПР, является радиальная скорость, хотя она тоже не является классическим траекторным признаком, и ее значение напрямую с классом цели не связано. Однако известно, что расчетное значение усредненной ЭПР существенно зависит от изменения ракурса цели, при этом сам ракурс коррелирован с радиальной скоростью. Например, движущаяся от РЛС цель характеризуется положительным значением радиальной скорости, а при ее движении на РЛС она имеет отрицательное значение. Наконец, при радиальной скорости, близкой к нулю, и при одновременно достаточно большом значении полной скорости цель либо разворачивается, либо проходит мимо РЛС – в любом случае по отношению к РЛС она будет располагаться боком. Таким образом, использование в качестве дополнительного признака радиальной скорости позволит алгоритму распознавания корректировать граничные значения ЭПР для разных классов целей в зависимости от их ракурса по отношению к РЛС.

Статистические признаки

Данные признаки позволяют зафиксировать характерные закономерности изменения движения цели во времени, которые не могут быть выявлены при анализе только моментальных текущих значений кинематических признаков. Поэтому, как было показано в работах [11, 12, 15], они обладают достаточно высокой информативностью. Так, полет птиц, как правило, сопровождается взмахами крыльев, что приводит к значительным нерегулярным флуктуациям высоты, а также к вертикальным составляющим скорости и ускорения. Известно также, что полет большинства видов птиц сопровождается хаотическими изменениями курса в горизонтальной плоскости. Напротив, БПЛА, управляемые автопилотом или оператором, демонстрируют более стабильные траектории с плавной динамикой как в вертикальной, так и в горизонтальной плоскости. Указанные различия могут быть эффективно зафиксированы через оценки дисперсии или СКО скорости и ускорения соответствующих компонент [12, 15].

Для расчета таких статистических признаков необходимо использовать скользящее окно

фиксированной длины, в котором производится оценка СКО по каждой компоненте. Длина такого скользящего окна – критически важный параметр. Так, в работе [15] по результатам эмпирического анализа использовалось окно длиной в 20 отсчетов (измерений) при частоте сопровождения цели 1–2 Гц, что позволяет одновременно сохранить локальную чувствительность к изменениям характера движения цели, а также сгладить имеющиеся случайные шумы измерений. Заметим, что в работе [16] в результате аналогичного исследования был получен график, из которого следует, что наилучшие результаты классификации целей по статистическим признакам получаются при размере скользящего окна, близкого к 20 отсчетам. При этом уменьшение длины окна резко снижает качество классификации, а его увеличение практически не повышает его.

На рисунке 1 представлены типовые гистограммы распределения СКО вертикальной и горизонтальной составляющих скорости БПЛА и птиц, построенные на основе 20 реальных траекторий каждого вида целей. Показано, что эти гистограммы хорошо аппроксимируются логнормальной плотностью распределения. Кроме того, из рисунка хорошо видно, что максимумы гистограмм птицы сдвинуты в сторону больших значений относительно максимумов гистограмм БПЛА. Это подтверждает информативность данных статистических признаков относительно этих классов целей.

Описание экспериментов и их результаты

В качестве классификатора была выбрана нейросетевая модель в виде *многослойного перцептрона прямого распространения* (МППР). Такая архитектура обладает достаточной аппроксимирующей способностью для моделирования нелинейных зависимостей между признаками и классами целей при сохранении умеренной вычислительной сложности. В модели реализованы два скрытых слоя, содержащих 28 и 14 нейронов с сигмоидальной функцией активации. Выходной слой состоит из 6 нейронов (по числу распознаваемых классов целей) и использует функцию активации softmax [17], обеспечивающую вероятностную интерпретацию выходов в многоклассовой постановке задачи классификации.

Архитектура данной сетевой модели представлена на рисунке 2.

Обучение модели проводилось на совокупности реальных и синтетически сгенерированных (суррогатных) данных для шести классов

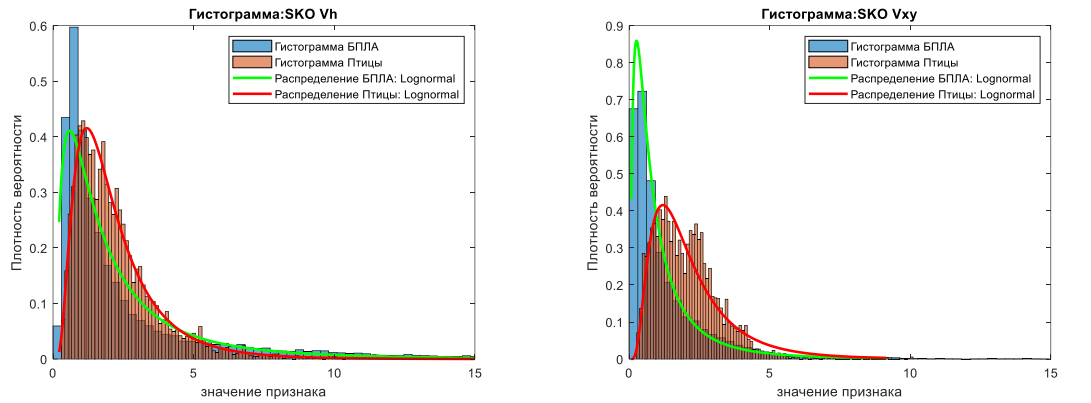

Рис. 1. Распределения статистических признаков БПЛА и птиц

Fig. 1. Distributions of statistical features for UAVs and birds

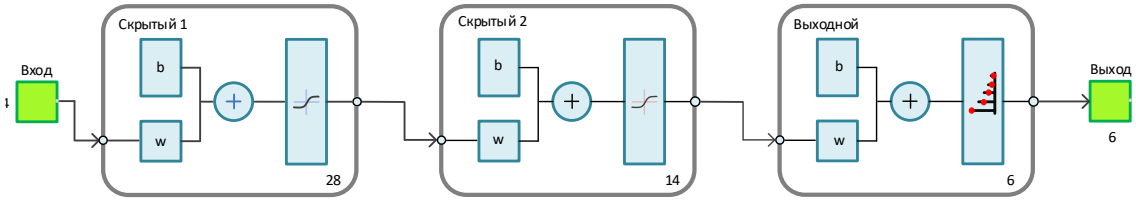

Рис. 2. Архитектура предлагаемой нейросетевой модели МППР

Fig. 2. Architecture of the proposed neural network model: MLP

сопровождаемых объектов: БПЛА, птицы, самолеты, вертолеты, ракеты и наземные объекты. При этом синтетические траектории генерировались на основе реальных методами аугментации [17], то есть с помощью поворотов, растягиваний и сжатий. Кроме того, синтетические данные для обучения нейросети генерировались не только в виде траекторий, но и в виде отдельных измерений с использованием статистической модели, построенной на основе информации о диапазонах варьирования отдельных признаков для различных типов целей, а также экспериментально полученных законов распределения этих признаков (см. рис. 1). Такой подход позволил сформировать репрезентативную и сбалансированную обучающую выборку, расширив покрытие пространства возможных траекторий и классифицирующих признаков, следовательно, повысив обобщающую способность классификатора.

Необходимо отметить, что для классификации радиолокационных целей по траекторным параметрам предпринимались попытки использования нейросетей глубокого обучения – рекуррентных [5, 18] и сверточных [5, 19]. Главным преимуществом использования первых является наличие у них памяти, благодаря чему решение о классе модели принимается не по одному текущему измерению признаков, а по некоторому участку траектории, предшествовавшему текущему моменту времени [18]. В работе [19] задачу классификации воздушных целей по траекторным признакам пробовали решать с помощью нейросетей глубокого обучения сверточного типа. И в этом случае решение принимается на основании вида трехмерного изображения участка траектории. Основным недостатком нейросетей глубокого обучения является их сложность и громоздкость, а также проблемы с их обучением. Так, простейшие нейросети глубокого обучения состоят из десятков скрытых слоев и включают сотни тысяч настраиваемых в процессе обучения весов [17].

В отличие от методов глубокого обучения предложенная нейросетевая модель МППР с расширенным признаковым пространством гораздо проще в обучении и реализации. При этом в ней также, хотя и в неявной форме, используется информация не только о текущих, но и о предыдущих измерениях траекторных параметров, поскольку вычисление статистических траекторных признаков происходит в скользящем окне.

Результаты обучения нейросетевой модели классификации

Обучение модели проводилось в среде MATLAB R2022b с использованием встроенного инструментария Neural Network Toolbox и Deep Learning Toolbox. Все вычисления выполнялись на центральном процессоре (CPU) без использования графических ускорителей. В процессе обучения была зафиксирована точка переобучения на 632-й эпохе – момент, когда ошибка на валидационной выборке начала возрастать, несмотря на продолжающееся уменьшение ошибки на обучающей выборке. Это послужило критерием для досрочной остановки обучения и выбора оптимальных весов модели.

На рисунке 3 представлены матрицы ошибок, соответствующие результатам работы классификатора на обучающей, валидационной и тестовой выборках, а также на полном датасете. При этом строки матриц соответствуют истинным меткам классов, столбцы – меткам, предсказанным моделью. Главная диагональ отражает число корректно классифицированных примеров, элементы вне диагонали – случаи переклассификации.

В целом по всем подвыборкам наблюдается высокая степень концентрации значений вдоль главной диагонали, что свидетельствует о высокой селективности классификатора и устойчивости к ошибкам распознавания. Максимальные показатели точности достигнуты для классов с четко выраженными динамическими характеристиками, например, самолеты, вертолеты, ракеты. Незначительное снижение точности наблюдается в областях, где классы демонстрируют схожее поведение по ряду признаков, в частности, между БПЛА и птицами, что обусловлено их близостью в статистическом и кинематическом пространствах. Однако даже в этих случаях корректная классификация сохраняется на уровне выше 95 %, что подтверждает эффективность предложенного подхода к формированию признакового описания.

По результатам тестирования на полностью независимой выборке, в которую были включены траектории всех типов реальных целей, не использованных в обучающей, валидационной и тестовой выборках, модель так же показала точность классификации около 96 %. Высокие значения метрик точности и F1-меры были устойчиво достигнуты при различных особенностях реальных данных, включая частичное зашумление и вариативность длины траекторий.

Рис. 3. Матрицы ошибок по результатам обучения и работы предлагаемой нейросетевой модели МППР: 1 – самолет, 2 – вертолет, 3 – БПЛА, 4 – наземная цель, 5 – ракета, 6 – птица

Fig. 3. Confusion matrices from training and testing of the proposed MLP neural network model: 1 – aircraft, 2 – helicopter, 3 – UAV, 4 – ground target, 5 – missile, 6 – bird

Апостериорный анализ значимости признаков

С целью интерпретации вкладов отдельных классификационных признаков в принимаемые моделью решения был проведен анализ их значимости на основе модифицированного метода Гарсона [20]. Данный метод позволяет оценить относительное влияние признаков в многослойном перцептроне путем разложения весов между слоями, что особенно актуально при использовании черных ящиков, то есть архитектур, не обладающих прозрачной интерпретацией внутренних зависимостей.

При этом метод Гарсона [20] был модифицирован с учетом дополнительного скрытого слоя в модели МППР (см. рис. 2). В таком случае относительное влияние каждого входного признака X_i вычисляется через сумму произведений весов между всеми слоями:

$$RI_i = \frac{\sum_{j=1}^{H_1}\sum_{k=1}^{H_2}\left|w_{ij}^{(1)} \cdot w_{jk}^{(2)} \cdot w_k^{(3)}\right|}{\sum_{i=1}^{I}\sum_{j=1}^{H_1}\sum_{k=1}^{H_2}\left|w_{ij}^{(1)} \cdot w_{jk}^{(2)} \cdot w_k^{(3)}\right|},$$

где $w_{ij}^{(1)}$ – веса от входного слоя к первому скрытому; $w_{jk}^{(2)}$ – веса от первого скрытого слоя ко второму; $w_k^{(3)}$ – веса от второго скрытого слоя к выходному нейрону; H_1, H_2 – количество нейронов в первом и втором скрытом слое соответственно; $I = 14$ – число входных признаков; RI_i – относительная важность i-го признака.

Расчет выполнен по финальной обученной модели после стабилизации метрик точности и F1-меры на независимой выборке. Полученные значения были нормированы и представлены в виде диаграммы (рис. 4).

Номера входных классификационных признаков на рисунке 4 соответствуют номерам из структуры признакового пространства.

Результаты анализа показали, что наибольший вклад в принятие решений нейросетью вносили следующие признаки: полная и радиальная скорости, горизонтальная составляющая скорости, высота, ЭПР, СКО вертикальной составляющей ускорения.

Менее значимыми признаками оказались: полное ускорение, СКО горизонтальной скорости и ускорения. Самое слабое влияние на результат продемонстрировали вертикальные составляющие скорости и ускорения, а также горизонтальная составляющая ускорения. При этом, согласно методу Гарсона, такие признаки не являются бесполезными – они могут обладать дополнительной различающей способностью в отдельных специфических сценариях, при наличии шумов, нестандартных траекторий или при атипичном поведении объекта. В связи с этим рекомендуется сохранять даже слабые признаки в составе признакового пространства, особенно при эксплуатации системы в непредсказуемых и быстро меняющихся условиях.

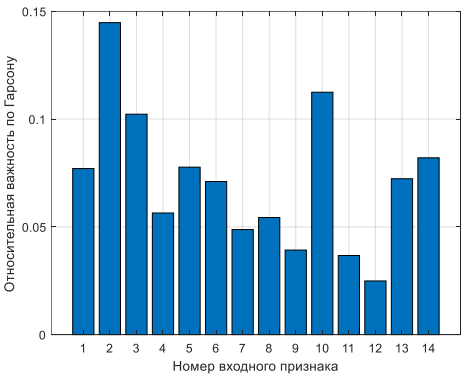

Рис. 4. Диаграмма значимости классификационных признаков, полученная по методу Гарсона

Fig. 4. Feature importance diagram obtained using the Garson method

Обсуждение и анализ результатов

Применение нейросетевого классификатора на основе многослойного перцептрона обеспечивает высокую точность распознавания воздушных объектов различных классов. При этом ключевым фактором, определившим эффективность предлагаемого подхода, стало расширение признакового пространства за счет включения не только классических кинематических параметров и амплитудного признака, но и нетрадиционных (дальность, радиальная скорость, составляющие скорости и ускорения) и статистических характеристик, рассчитанных в скользящем временном окне.

Проведенное исследование сопровождалось полной программной реализацией алоритма классификации в среде MATLAB R2022b, что сделало удобным отладку, визуализацию и контроль параметров обучения. Использование встроенных средств train, trainlm, а также функций визуализации (plotperform, plotconfusion, confusionchart) позволило эффективно отслеживать динамику обучения и метрики качества модели. Обучение нейросети проводилось на CPU, что подчеркивает доступность подхода с точки зрения вычислительных ресурсов.

В ходе анализа было установлено, что на 632-й эпохе началось переобучение: ошибка на валидационной выборке стала возрастать, в то время как ошибка на обучающей продолжала снижаться. Этот момент был использован для ранней остановки обучения и сохранения весов с наилучшей обобщающей способностью. Полученные результаты подтверждают, что реализованная архитектура обладает устойчивостью к переобучению при грамотной настройке параметров обучения и контроле по валидационным метрикам.

Особое значение при классификации слабоотражающих объектов, таких как БПЛА и птицы, показали признаки, фиксирующие вертикальную компоненту движения: СКО вертикальной скорости и ускорения. Эти параметры позволили отразить различия в динамике стабилизированного (автономного) движения БПЛА и нерегулярного поведения птиц, связанного с биомеханикой полета. Таким образом, эффективность классификации обеспечивается за счет не столько увеличения объема данных, сколько более глубокого и физически обоснованного описания структуры движения цели.

Применение многослойного перцептрона в данной задаче оправдано по ряду причин. Во-первых, модель МППР обладает достаточной аппроксимирующей способностью для выявления сложных нелинейных зависимостей между признаками, включая коррелированные и ча-

стично избыточные параметры. Во-вторых, в отличие от традиционных методов машинного обучения, таких как опорные векторы, решающие деревья или случайные леса, модель МППР способна эффективно обрабатывать признаки, распределенные по различным физическим шкалам и подверженные флуктуациям. При этом по сравнению с более сложными архитектурами глубокого обучения (например, LSTM, GRU или сверточные сети) многослойный перцептрон демонстрирует лучшую устойчивость к переобучению при ограниченном объеме обучающей выборки и характеризуется существенно меньшими вычислительными требованиями, что критически важно для задач, реализуемых в реальном времени.

Интерпретируемость модели, достигаемая с помощью модифицированного алгоритма Гарсона, представляет собой дополнительное преимущество. Полученные оценки значимости признаков подтверждают, что вклад в классификацию распределен неравномерно, а наибольшую дискриминационную способность обеспечивает лишь часть из них. Однако даже признаки с низкой относительной значимостью не являются избыточными. В условиях нестабильного поведения целей и флуктуаций траекторий они обеспечивают дополнительную устойчивость распознавания, что подтверждает целесообразность сохранения всех элементов признакового пространства.

Дополнительным фактором повышения точности распознавания стало использование для обучения составной обучающей выборки, полученной из реальных и аугментированных траекторий, а также суррогатных значений, сгенерированных с использованием статистических моделей. Это решение позволило компенсировать нехватку траекторий для редких сценариев и обеспечить более полное покрытие возможных вариантов поведения целей. В совокупности такие меры обеспечили итоговую точность классификации на уровне 96–98 %, что существенно превышает показатели, характерные для большинства ранее опубликованных подходов к траекторному распознаванию.

В долгосрочной перспективе наибольшую эффективность, вероятно, покажут гибридные системы, объединяющие траекторные, амплитудные и спектральные признаки в рамках единого классификационного контура. Формирование таких мультипризнаковых архитектур представляется логичным этапом дальнейшего развития, однако их построение требует отдельного теоретико-прикладного исследования и выходит за рамки настоящей работы.

Заключение

В настоящем исследовании предложен подход к автоматической классификации целей по радиолокационным данным, основанный на анализе траекторных признаков и применении нейросетевой модели типа многослойного перцептрона. Сформировано расширенное признаковое пространство, включающее кинематические, статистические и амплитудные характеристики.

Экспериментальные результаты подтвердили высокую эффективность разработанного метода: достигнута точность классификации на уровне 96 % при тестировании на реальных и синтетических траекториях. Использование статистических признаков, особенно СКО вертикальной скорости и ускорения, существенно повысило селективность алгоритма. Метод продемонстрировал устойчивость к шумам, дисбалансу классов и неполному описанию объектов.

Проведенный анализ важности признаков показал, что ключевой вклад вносят параметры, характеризующие пространственную динамику целей, тогда как амплитудные признаки (например, ЭПР) играют вспомогательную роль.

Перспективными направлениями дальнейших исследований являются: расширение набора траекторных признаков с учетом временных и интегральных характеристик, адаптация архитектуры нейросети к условиям онлайн-обработки данных, исследование методов самонастройки модели под изменяющиеся условия радиолокационной обстановки, применение ансамблей нейросетевых моделей для повышения устойчивости в неопределенной среде.

Результаты работы подтверждают целесообразность использования нейросетевых подходов в системах радиолокационного распознавания объектов и могут быть положены в основу прикладных решений для РЛС нового поколения.

Список литературы

1. Ширман Я.Д., Горшков С.А., Лещенко С.П. и др. Методы радиолокационного распознавания и их моделирование // Зарубежная радиоэлектроника. 1996. № 11. С. 3–62.

2. Jiang W., Wang Y., Li Y. et al. Radar target characterization and deep learning in radar automatic target recognition: A Review. Remote Sensing, 2023, vol. 15, no. 15, art. 3742. doi: 10.3390/rs15153742.

3. Schachter B.J. Automatic Target Recognition. Washington, 2020, 396 p.

4. Liu J., Xu Q.Y., Chen W.S. Classification of bird and drone targets based on motion characteristics and random forest model. IEEE Access, 2021, vol. 9, pp. 160135–160144. doi: 10.1109/ACCESS.2021.3130231.

5. Wang P., Chen T., Ding J. et al. Intelligent radar HRRP target recognition based on CNN-BERT model. EURASIP J. on Advances in Signal Proc., 2022, art. 89. doi: 10.1186/s13634-022-00909-9.

6. Бердышев В.П., Помазуев О.Н., Савельев А.Н. и др. Распознавание классов и типов воздушных объектов по двумерным радиолокационным изображениям в обзорной РЛС // Журнал СФУ. Техника и технологии. 2019. Т. 12. № 1. С. 18–29.

7. Sun Y., Abeywickrama S., Jayasinghe L., Yuen C. et al. Micro-Doppler signature-based detection, classification, and localization of small uav with long short-term memory neural network. IEEE TGRS, 2020, vol. 59, no. 8, pp. 6285–6300. doi: 10.1109/TGRS.2020.3028654.

8.Chen V.C. The Micro-Doppler Effect in Radar. Norwood, 2019, 341 p.

9.Park D., Lee S., Park S. et al. Radar-spectrogram-based UAV classification using convolutional neural networks. Sensors, 2021, vol. 21, no. 1, pp. 1–18. doi: 10.3390/s21010210.

10. Фалилеев В.Ю., Шатовкин Р.Р. Алгоритм распознавания типа беспилотных летательных аппаратов по траекторным признакам // Вестн. РосНОУ. Сер: Сложные системы: модели, анализ и управление. 2020. № 3. С. 34–40.

11. Doumard T., Riesco F.G., Petrunin I. et al. Radar discrimination of small airborne targets through kinematic features and machine learning. IEEE/AIAA DASC, 2022, pp. 1–10. doi: 10.1109/DASC55683.2022.9925778.

12. Лук Д.В., Коновалов А.А., Хоанг Л.М. Алгоритм распознавания малоразмерных воздушных целей по траекторным признакам в полуактивной РЛС // Изв. вузов России. Радиоэлектроника. 2023. Т. 26. № 5. С. 76–88. doi: 10.32603/1993-8985-2023-26-5-76-88.

13. Srigrarom S., Chew K.H., Da Lee D.M. et al. Drone versus bird flights: Classification by trajectories characterization. Proc. Annual Conf. SICE, 2020, pp. 343–348. doi: 10.23919/SICE48898.2020.9240313.

14. Пальгуев Д.А., Пархачёв В.В, Пиунов К.Н. и др. Распознавание воздушных объектов типа «птицы» по траекторным признакам // Радиотехнические и телекоммуникационные системы. 2022. № 4. С. 39–50.

15. Курбатский С.А., Грачев А.Н., Полынкин А.В., Башеров М.С. Перспективы использования траекторных и сигнальных признаков в алгоритмах распознавания типов целей РЛС S-диапазона // Сб. докладов XXV Всероссийской научно-практической конф. «Проблемы развития и применения средств ПВО на современном этапе. Средства ПВО России и других стран мира, их сравнительный анализ». ЯВВУ ПВО: матер. конф. 2024. С. 151–161.

16. Jochumsen L.W., Østergaard J., Jensen S.H. et al. A recursive kinematic random forest and alpha beta filter classifier for 2D radar tracks. EURASIP J. on Advances in Signal Proc., 2016, art. 82. doi: 10.1186/s13634-016-0378-3.

17. Гудфеллоу Я., Бенджио И., Курвилль А. Глубокое обучение; [пер. с англ.]. М.: ДМК Пресс, 2018. 652 с.

18. Bakkegaard S., Blixenkrone-Moller J., Larsen J.J., Jochumsen L. Target classification using kinematic data and a recurrent neural network. Proc. IRS, 2018, pp. 1–10. doi: 10.23919/IRS.2018.8448118.

19. Костючек М.И., Макаренко А.В. Применение свёрточных глубоких нейронных сетей для решения некоторых задач анализа траекторных данных // Журнал радиоэлектроники. 2021. № 11. С. 1–25. doi: 10.30898/1684-1719.2021.11.15.

20. Maozhun S., Maozhun Ji L. Improved garson algorithm based on neural network model. Proc. CCDC, 2017, pp. 4307–4312. doi: 10.1109/CCDC.2017.7979255.

Software & Systems doi: 10.15827/0236-235X.152.682-693 2025, 38(4), pp. 682–693

Classification of aerial targets in radar stations through neural network modeling with enhanced feature space

Evgeniy I. Minakov [1], Aleksandr N. Grachev [1, 2], Mikhail S. Basherov [1, 2], Dmitriy M. Shprekher [1]✉

[1] Tula State University, Tula, 300012, Russian Federation
[2] JSC Central Design Bureau of Apparatus Engineering, Tula, 300034, Russian Federation

For citation
Minakov, E.I., Grachev, A.N., Basherov, M.S., Shprekher, D.M. (2025) 'Classification of aerial targets in radar stations through neural network modeling with enhanced feature space', *Software & Systems*, 38(4), pp. 682–693 (in Russ.). doi: 10.15827/0236-235X.152.682-693

Article info
Received: 30.07.2025 After revision: 11.08.2025 Accepted: 12.08.2025

Abstract. This paper addresses the automatic classification of radar surveillance objects in pulse-Doppler surveillance radars. These systems operate under constrained observation times, high interference density, and substantial feature-space

overlap between objects of different physical nature. Special emphasis is placed on detecting of small-sized and low-reflectivity targets possessing small radar cross-sections, including unmanned aerial vehicles and birds. The authors propose an approach using a feedforward multilayer perceptron neural network classifier. This network trains on an expanded feature space that includes kinematic, statistical, and amplitude characteristics. To enhance the model's generalization capability, the authors employed a combined training dataset containing real trajectories, synthetically generated data using augmentation methods, and statistical modeling results. Statistical features were calculated within a sliding time window. Testing demonstrated a classification accuracy of 96%. Empirical evaluation confirmed the model's robustness to noise and trajectory data variability. The authors conducted a comprehensive feature significance analysis. During network design, an a priori assessment of feature informativeness. After training, they implemented a posteriori analysis of feature contributions using a modified Garson's algorithm. The obtained results justify a minimal and physically interpretable feature set. The obtained results justify maximum model selectivity within acceptable computational complexity. All stages of model construction, feature space formation, and training were implemented in the MATLAB environment using the Neural Network Toolbox, Deep Learning Toolbox, and Signal Processing Toolbox. This approach ensured reproducibility, adaptability, and technical applicability of the developed solution. The practical significance of this work lies in the ability to integrate the developed algorithm into existing radar systems without major hardware modifications, making this approach relevant for adaptive recognition tasks in real-time operational environments.

Keywords: neural network model, classification, pulse-Doppler radar, artificial intelligence, automatic recognition, machine learning, software implementation, MATLAB

Acknowledgements. This research was funded by the Grant of the Government of the Tula Region in the field of science and technology, no. DS/174 dated December 28, 2024

References

1. Shirman, Ya.D., Gorshkov, S.A., Leshchenko, S.P. et al. (1996) ‘Radar Recognition Methods and Their Simulation’, *Foreign Radio Electronics*, (11), pp. 3–62 (in Russ.).

2. Jiang, W., Wang, Y., Li, Y. et al. (2023) ‘Radar target characterization and deep learning in radar automatic target recognition: A review’, *Remote Sensing*, 15(15), art. 3742. doi: 10.3390/rs15153742.

3. Schachter, B.J. (2020) *Automatic Target Recognition*. Washington, 396 p.

4. Liu, J., Xu, Q.Y., Chen, W.S. (2021) ‘Classification of bird and drone targets based on motion characteristics and random forest model’, *IEEE Access*, 9, pp. 160135–160144. doi: 10.1109/ACCESS.2021.3130231.

5. Wang, P., Chen, T., Ding, J. et al. (2022) ‘Intelligent radar HRRP target recognition based on CNN-BERT model’, *EURASIP J. on Advances in Signal Proc.*, art. 89. doi: 10.1186/s13634-022-00909-9.

6. Berdyshev, V.P., Pomazuev, O.N., Savelev, A.N. et al. (2019) ‘Recognition of air object classes and types from 2D radar images in surveillance radar’, *J. SBU. Eng. & Tech.*, 12(1), pp. 18–29 (in Russ.).

7. Sun, Y., Abeywickrama, S., Jayasinghe, L., Yuen, C. et al. (2020) ‘Micro-Doppler signature-based detection, classification, and localization of small uav with long short-term memory neural network’, *IEEE TGRS*, 59(8), pp. 6285–6300. doi: 10.1109/TGRS.2020.3028654.

8. Chen, V.C. (2019) *The Micro-Doppler Effect in Radar*. Norwood, 341 p.

9. Park, D., Lee, S., Park, S. et al. (2021) ‘Radar-spectrogram-based UAV classification using convolutional neural networks’, *Sensors*, 21(1), pp. 1–18. doi: 10.3390/s21010210.

10. Falileev, V.Yu., Shatovkin, R.R. (2020) ‘UAV type recognition algorithm based on trajectory features’, *Vestn. of RosNOU*, (3), pp. 34–40 (in Russ.).

11. Doumard, T., Gañán Riesco, F., Petrunin, I. et al. (2022) ‘Radar discrimination of small airborne targets through kinematic features and machine learning’, *Proc. IEEE/AIAA DASC*, pp. 1–10. doi: 10.1109/DASC55683.2022.9925778.

12. Luk, D.V., Konovalov, A.A., Hoang, L.M. (2023) ‘Small air target recognition by trajectory features in semi-active radar’, *J. Russian Universities. Radioelectronics*, 26(5), pp. 76–88 (in Russ.). doi: 10.32603/1993-8985-2023-26-5-76-88.

13. Srigrarom, S., Chew, K.H., Da Lee, D.M., Ratsamee, P. (2020) ‘Drone versus bird flights: Classification by trajectories characterization’, *Proc. Annual Conf. SICE*, pp. 343–348. doi: 10.23919/SICE48898.2020.9240313.

14. Palguev, D.A., Parkhachev, V.V, Piunov, K.N. et al. (2022) ‘Recognition of air objects such as ‘birds’ through trajectory parameters’, *Radiotech. and Telecommunication Sys.*, (4), pp. 39–50 (in Russ.).

15. Kurbatsky, S.A., Grachev, A.N., Polynkin, A.V., Basherov, M.S. (2024) ‘Prospects for the use of trajectory and signal features in S-band radar target recognition algorithms’, *Proc. XXV All-Russ. Conf. on Air Defense Sys.*, pp. 151–161 (in Russ.).

16. Jochumsen, L.W., Østergaard, J., Jensen, S.H. et al. (2016) ‘A recursive kinematic random forest and alpha-beta filter classifier for 2D radar tracks’, *EURASIP J. on Advances in Signal Proc*., art. 82. doi: 10.1186/s13634-016-0378-3.

17. Goodfellow, I., Bengio, Y., Courville, A. (2016) *Deep Learning*. Cambridge, Massachusetts: MIT Press, 781 p. (Russ. ed.: (2018) Moscow, 652 p.).

18. Bakkegaard, S., Blixenkrone-Møller, J., Larsen, J.J., Jochumsen, L. (2018) ‘Target classification using kinematic data and a recurrent neural network’, *Proc. IRS*, pp. 1–10. doi: 10.23919/IRS.2018.8448118.

19. Kostiuchek, M.I., Makarenko, A.V. (2021) ‘Application of convolutional deep neural networks for solving some trajectory data analysis problems’, *J. of Radio Electronics*, (11), pp. 1–25 (in Russ.). doi: 10.30898/1684-1719.2021.11.15.

20. Maozhun, S., Maozhun Ji, L. (2017) ‘Improved garson algorithm based on neural network model’, *Proc. CCDC*, pp. 4307–4312. doi: 10.1109/CCDC.2017.7979255.

Авторы

Минаков Евгений Иванович [1], д.т.н., профессор, eminakov@bk.ru
Грачев Александр Николаевич [1, 2], к.т.н., доцент, главный специалист, ga150161@mail.ru
Башеров Михаил Сергеевич [1, 2], аспирант, инженер, basherov@icloud.com
Шпрехер Дмитрий Маркович [1], д.т.н., профессор, доцент, shpreher-d@yandex.ru

[1] Тульский государственный университет, г. Тула, 300012, Россия
[2] Центральное конструкторское бюро аппаратостроения, г. Тула, 300034, Россия

Authors

Evgeniy I. Minakov [1], Dr.Sci. (Engineering), Professor, eminakov@bk.ru
Aleksandr N. Grachev [1, 2], Cand. of Sci. (Engineering), Associate Professor, Chief Engineer, ga150161@mail.ru
Mikhail S. Basherov [1, 2], Postgraduate Student, Engineer, basherov@icloud.com
Dmitriy M. Shprekher [1], Dr.Sci. (Engineering), Professor, Associate Professor, shpreher-d@yandex.ru

[1] Tula State University, Tula, 300012, Russian Federation
[2] Central Design Bureau of Apparatus Engineering, Tula, 300034, Russian Federation