

ОБРАБОТКА ИЗОБРАЖЕНИЙ, РАСПОЗНАВАНИЕ ОБРАЗОВ

РАСПОЗНАВАНИЕ ОБЪЕКТОВ ПО ДИАГРАММАМ РАССЕЯНИЯ ЭЛЕКТРОМАГНИТНОГО ИЗЛУЧЕНИЯ НА ОСНОВЕ МЕТОДА ОПОРНЫХ ПОДПРОСТРАНСТВ

Жердев Д.А., Казанский Н.Л., Фурсов В.А.

Институт систем обработки изображений РАН,

*Самарский государственный аэрокосмический университет имени академика С.П. Королёва
(национальный исследовательский университет) (СГАУ)*

Аннотация

В работе предлагается метод распознавания объектов по диаграммам рассеяния отражённого электромагнитного излучения. В качестве эталонов используются диаграммы рассеяния, полученные путём моделирования рассеяния электромагнитного излучения трёхмерными моделями объектов. На этапе распознавания в качестве меры близости используется показатель сопряжённости с так называемым опорным подпространством, образованным векторами признаков распознаваемого класса. Исследуется зависимость качества распознавания от размерности опорных подпространств. Показано, что качество распознавания возрастает с увеличением размерности опорных подпространств. Приводятся также результаты экспериментов, показывающие, что предлагаемый метод обеспечивает более высокое качество распознавания объектов по диаграммам рассеяния по сравнению с методом опорных векторов и алгоритмом, основанным на вычислении коэффициента корреляции со средним вектором класса.

Ключевые слова: цифровая обработка изображений, электромагнитное излучение, поле рассеяния, распознавание, показатель сопряжённости.

Введение

В задачах определения типа объекта по отражённому им радиолокационному сигналу часто используется радиолокационная характеристика – эффективная площадь рассеяния (ЭПР), определяемая как отношение энергии эквивалентного изотропного источника к плотности потока энергии зондирующего радиоизлучения. При зондировании местности на принимающую антенну поступает сигнал, подверженный помехам, которые вносятся переотражениями, отражениями от подстилающей поверхности и др.

В случае, если тип подстилающей поверхности точно не известен, на основании одного измеренного значения ЭПР трудно дать оценку типа объекта, т.к. для близких по величине объектов эффективная площадь рассеяния может принимать также близкие значения. Поэтому используют диаграммы рассеяния – набор значений ЭПР, полученных при разных ракурсах.

Получение значений ЭПР под разными ракурсами наблюдения объекта возможно с помощью перемещающейся в пространстве радиолокационной станции, установленной, например, на борту самолёта. Сформированная при этом диаграмма рассеяния (high range profile) [1] даёт более богатую информацию для распознавания цели.

Используются различные подходы к распознаванию по диаграммам рассеяния. В работе [2] применяется модель Марковского процесса. В работе [3] исследуется распознавание при помощи Байесовского классификатора. В статье [4] демонстрируется пример моделирования обратной диаграммы рассеяния трёх различных кораблей и их последующего распознавания с использованием метода главных компонент.

Основная проблема при распознавании по диаграммам рассеяния заключается в априорной неопределённости, связанной с их высокой чувствительностью к изменениям ракурса наблюдения, формы объекта, характеристикам подстилающей поверхности и др. При этом повышение надёжности распознавания может достигаться увеличением числа эталонов, полученных путём моделирования при вариациях указанных характеристик. В рамках этого подхода представляется важным построение эффективных технологий обучения и распознавания при использовании множества моделей эталонов.

В настоящей работе предлагается и исследуется метод, основанный на использовании так называемых опорных эталонных подпространств. В частности, предлагаются и исследуются процедуры формирования наиболее информативных опорных эталонных подпространств с использованием эталонных диаграмм рассеяния, полученных путём моделирования.

Приводятся результаты экспериментов, показывающие возможность повышения качества распознавания методом опорных подпространств по сравнению с методом опорных векторов [5] и с алгоритмом, основанным на определении нормированного коэффициента корреляции [6] распознаваемого вектора со средним вектором класса.

1. Постановка задачи

Диаграмма рассеяния получается путём наблюдения объекта под определённым ракурсом и представляется в виде совокупности точек, каждая из которых характеризует ЭПР объекта в данном направлении. Изображение диаграммы в целом представляется в виде множества заданных с некоторым шагом точек на контуре. На рис. 1 приведён пример изображения

диаграммы рассеяния легкого самолёта на фоне подстилающей поверхности.

Здесь показан случай диаграммы, построенной в интервале углов места $\phi \in [0^\circ; 180^\circ]$. Каждая точка диаграммы представляет собой значение ЭПР, вычисленное при соответствующем угле места и азимута. Если «облёт» объекта совершается при фиксированном угле места, например, по кругу, как показано на рис. 2, то значения ЭПР диаграммы рассеяния зависят только от угла азимута. При многократном «облёте» объекта можно сформировать множество диаграмм рассеяния.

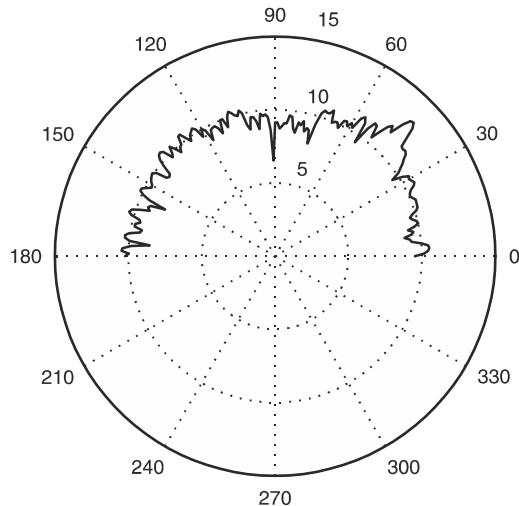


Рис. 1. Пример изображения диаграммы рассеяния

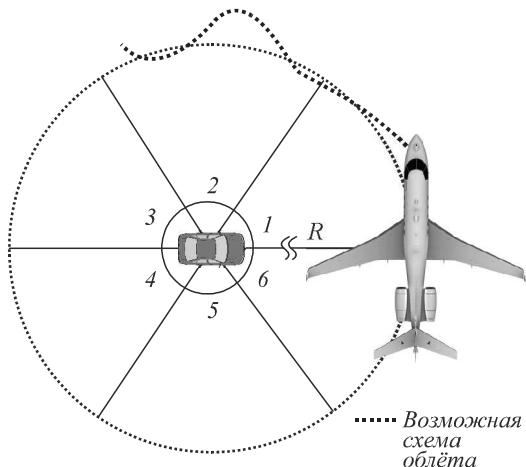


Рис. 2. Схема наблюдения за объектом

Каждой, например, j -й диаграмме рассеяния может быть поставлен в соответствие $N \times 1$ -вектор признаков

$$\mathbf{x}_j = [x_1, x_2, \dots, x_i, \dots, x_N], \quad (1)$$

компонентами которого являются числовые значения ЭПР объекта, вычисленные по измерениям отражённого сигнала в N точках контура. Поскольку при регистрации текущего (подлежащего распознаванию) вектора признаков могут быть измерены углы азимута и места, соответствующие этим измеренным параметрам, то числовые значения ЭПР могут быть также получены для всех подлежащих распознаванию объ-

ектов путём моделирования рассеяния электромагнитного поля трёхмерными моделями [7].

Вследствие неизбежных ошибок измерения и моделирования этот эталонный образ, скорее всего, будет отличаться от наблюдаемого. Совокупность векторов признаков, сформированных путём моделирования диаграмм рассеяния одного объекта при некоторых вариациях параметров регистрации для некоторого заданного режима «облёта», образует класс. Далее полагаем, что режимы регистрации диаграмм рассеяния выбираются так, чтобы текущие и эталонные векторы признаков формировались при одинаковом числе и последовательности ракурсов, т.е. имели одинаковые размерности.

Поскольку параметры движения платформы, с которой осуществляется регистрация, измеряются с ошибками, для информативности моделируемого эталона класса он должен содержать достаточно большое число векторов признаков при всех возможных отклонениях условий регистрации от номинальных. При больших вариациях отклонений условий регистрации использование в качестве представителя (эталонного образа) класса вектора, вычисленного как среднее значение векторов, принадлежащих классу, может привести к существенной потере информации.

В работе [8] было предложено для обучения и распознавания по малому числу наблюдений использовать показатель сопряжённости с подпространством, образованным векторами признаков распознаваемого класса. В работах [9], [10] показано, что этот подход эффективен при распознавании объектов, образы которых обладают значительной изменчивостью внутри класса. В частности, в [11], [12], [13] приводятся примеры успешного применения этой меры близости к распознаванию лиц. В работе [14] показано, что эта мера близости позволяет получить более высокое по сравнению с методом спектрального угла качество тематической классификации гиперспектральных изображений.

Математически задача формулируется следующим образом [14]. Пусть задано K классов и для каждого (k -го) класса сформирована квадратная $N \times M$ -матрица \mathbf{Q}_k :

$$\mathbf{Q}_k = \mathbf{X}_k \left[\mathbf{X}_k^T \mathbf{X}_k \right]^{-1} \mathbf{X}_k^T, \quad k = \overline{1, K}, \quad (2)$$

Где

$$\mathbf{X}_k = [\mathbf{x}_1(k), \mathbf{x}_2(k), \dots, \mathbf{x}_i(k), \dots, \mathbf{x}_M(k)], \quad (3)$$

$k = \overline{1, K}$ – $N \times M$ -матрица, составленная из M , полученных при разных условиях регистрации, векторов-признаков (1) этого класса. Напомним, что матрицы-эталоны \mathbf{X}_k , $k = \overline{1, K}$ всех возможных (K) классов в данном случае формируются путём моделирования, после того как становятся известными число и последовательность ракурсов, при которых произошла регистрация текущего вектора признаков \mathbf{x}_j реального объекта.

Для принятия решения о принадлежности этого вектора одному из K классов вычисляется так называемый показатель сопряжённости:

$$R_k(\mathbf{x}_j) = \frac{\mathbf{x}_j^T \mathbf{Q}_k \mathbf{x}_j}{\mathbf{x}_j^T \mathbf{x}_j}, \quad k = \overline{1, K}. \quad (4)$$

Полагаем, что вектор \mathbf{x}_l принадлежит m -му классу, если

$$R_m(\mathbf{x}_j) = \max_{k=1, K} R_k(\mathbf{x}_j). \quad (5)$$

В случае, когда матрицы $\mathbf{X}_k, k = \overline{1, K}$ составлены из одного вектора: $\mathbf{X}_k = [\bar{\mathbf{x}}_k]$, например, являющегося средним вектором класса, описанное решающее правило реализуется как известный коэффициент корреляции:

$$R_k(\mathbf{x}_j) = \frac{\langle \mathbf{x}_j, \bar{\mathbf{x}}_k \rangle}{\|\mathbf{x}_j\| \|\bar{\mathbf{x}}_k\|}, \quad k = \overline{1, K}. \quad (6)$$

Ключевым в рамках описанного подхода является вопрос о том, какие векторы и какое их количество следует отобрать в эталонное множество (подпространство). Например, в работе [14] матрица \mathbf{X}_k , характеризующая эталонное подпространство, формировалась путём случайного выбора более 60 векторов признаков из известного класса. Экспериментальные исследования показали существенное улучшение качества тематической классификации гиперспектральных изображений при таком выборе.

Вместе с тем использование такого большого количества векторов в качестве представителей классов приводит к большим вычислительным затратам при вычислении матриц $\mathbf{Q}_k, k = \overline{1, K}$ (эталонов классов) по соотношению (2). Поскольку в рамках рассматриваемого подхода предполагается, что эталоны формируются по измерениям параметров регистрации (углов азимута и места) текущего отражённого сигнала, это может быть неприемлемым с точки зрения оперативности реализации сквозной технологии моделирования эталонов и распознавания.

Поэтому представляется важным выяснить вопрос: существуют ли эталонные подпространства меньшей размерности, при которых качество классификации остаётся почти таким же или даже возрастает? Другими словами, мы ставим задачу построения регулярной процедуры формирования эталонных подпространств небольшой размерности (далее называемых опорными), максимально сохраняющих информацию об объекте.

2. Построение эталонных подпространств

Вначале рассмотрим процедуру построения эталонных опорных подпространств небольшой размерности для задачи бинарной классификации (выбора одного из двух классов). При этом для принятия решения об отнесении распознаваемого вектора к одному из них необходимо иметь пару принадлежащих этим классам эталонов.

Предположим, что для каждого из двух классов – k, l сформированы обучающие наборы данных. Для простоты будем полагать, что эти наборы включают одинаковое число – M векторов признаков вида (1), т.е. могут быть представлены $N \times M$ -матрицами $\mathbf{X}_k, \mathbf{X}_l$. Поставим задачу поиска таких пар минимальных подмножеств (пар $N \times D_k, N \times D_l$ -матриц $\mathbf{X}_k(D_k), \mathbf{X}_l(D_l)$), для которых значение заданного функционала качества $I(\mathbf{X}_k(D_k), \mathbf{X}_l(D_l))$ имеет максимальное значение.

Обозначим $n_k \leq M - D_k, n_l \leq M - D_l$ число правильно распознаваемых обучающих векторов из числа принадлежащих классам k, l . Критерием качества распознавания векторов признаков, из которых составлены матрицы $\mathbf{X}_k(D_k), \mathbf{X}_l(D_l)$, будет служить суммарное число правильно распознанных векторов признаков из обоих классов обучающего набора данных:

$$I(\mathbf{X}_k(D_k), \mathbf{X}_l(D_l)) = n_k + n_l. \quad (7)$$

Как видно из обозначений, размерности эталонных подпространств, вообще говоря, могут быть различными. В настоящей статье мы сузим постановку и рассмотрим только случай, когда размерности D подпространств в перебираемых парах эталонных подпространств одинаковы. В рамках указанной более узкой постановки возможно по крайней мере две формулировки задачи построения эталонных подпространств.

Задача 1. Предполагается, что для двух классов задана размерность D эталонных подпространств (пара $N \times D$ -матриц $\mathbf{X}_i, \mathbf{X}_j; i, j = \overline{1, C_M^D}$) и критерий качества (7): $I[\mathbf{X}_i(D), \mathbf{X}_j(D)], i, j = \overline{1, C_M^D}$. Среди всех возможных пар подпространств на двух классах ищется пара, для которой

$\mathbf{X}_k(D), \mathbf{X}_l(D)$:

$$I(\mathbf{X}_k(D), \mathbf{X}_l(D)) = \max_{i, j = \overline{1, C_M^D}} I(\mathbf{X}_i(D), \mathbf{X}_j(D)), \quad (8)$$

где $I(\mathbf{X}_i(D), \mathbf{X}_j(D))$ – суммарное число правильно распознанных векторов из классов i, j , определяемое соотношением (7).

Задача 2. Заданы $Q = \sum_{i=2}^{M-1} C_M^i$ матриц (3) – $\mathbf{X}_i, \mathbf{X}_j; i, j = \overline{1, Q}$. В обучающем множестве среди всех возможных сформированных на этом множестве пар матриц (подпространств) ищется такая пара подпространств, образованных векторами из матриц $\mathbf{X}_i, \mathbf{X}_j; i, j = \overline{1, Q}$, для которой

$\mathbf{X}_k(D), \mathbf{X}_l(D)$:

$$G(\mathbf{X}_k(D), \mathbf{X}_l(D)) = \max_{i, j = \overline{1, Q}} I(\mathbf{X}_i(D), \mathbf{X}_j(D)), \quad (9)$$

$$I(\mathbf{X}_k(D), \mathbf{X}_l(D)) = \max_{D=2, M-1} G(\mathbf{X}_k(D), \mathbf{X}_l(D)),$$

где $I(\mathbf{X}_i(D), \mathbf{X}_j(D))$, $i, j = \overline{1, Q}$, $D = \overline{2, M - 1}$ – тот же, что и в (7).

В соответствии с указанными формулировками задач соответствующие алгоритмы обучения строятся следующим образом.

Алгоритм обучения в рамках первой задачи состоит в формировании пары матриц (подпространств) заданной размерности путём реализации следующих шагов. Формируется некоторая пара эталонных подпространств ($N \times D$ -матриц \mathbf{X}_i , \mathbf{X}_j). Для этой пары эталонов решается задача распознавания всех векторов из обучающего множества в соответствии с соотношениями (4), (5). Далее по полученным числам n_k , n_l вычисляется и сохраняется в памяти значение критерия (7). Затем формируется новая пара матриц (подпространств) и повторяется процедура распознавания и вычисления критерия. Если величина критерия оказывается меньше хранящегося в памяти, соответствующая пара матриц не сохраняется. Если величина критерия равна хранящемуся в памяти, то его значение и соответствующие ему матрицы сохраняются в памяти наравне с другими. Если величина критерия оказывается больше, чем их значения, хранящиеся в памяти, все предшествующие удаляются и заменяются новым значением и соответствующей парой матриц.

Таким образом, перебираются все возможные пары обучающих матриц. В результате может быть получена либо одна, «наилучшая» по критерию (7) пара матриц, либо некоторое множество таких пар матриц, имеющих одинаковые значения критерия.

Алгоритм решения второй задачи отличается от описанного выше алгоритма тем, что все указанные этапы повторяются для разных размерностей эталонных подпространств. При этом в результате будут определены либо одна, либо множество пар эталонных подпространств и их размерностей, для которых значения критерия (7) одинаковы. Поэтому завершающим этапом является выбор «наилучшей» в некотором смысле пары опорных подпространств.

Рассмотрим решение этой задачи. Для определённости положим, что на предшествующем этапе для двух классов, характеризующихся $N \times M$ -матрицами \mathbf{X}_k , \mathbf{X}_l , получено P пар эталонных подпространств $\mathbf{X}_{k,p}$, $\mathbf{X}_{l,p}$, $p = \overline{1, P}$ размерности D с одинаковыми значениями критерия (7). Пусть $\mathbf{x}_{k,j}$, $\mathbf{x}_{l,j}$, $j = \overline{1, M}$ – векторы, из которых составлены матрицы классов \mathbf{X}_k , \mathbf{X}_l соответственно. Обозначим

$$R_{k,p}(\mathbf{x}_{k,j}), \quad p = \overline{1, P}, \quad j = \overline{1, M},$$

$$R_{l,p}(\mathbf{x}_{l,j}), \quad p = \overline{1, P}, \quad j = \overline{1, M}.$$

Показатели сопряжённости эталонных подпространств с векторами из соответствующих им классов.

С учётом сделанных обозначений функционал качества для определения наилучшей пары $\mathbf{X}_{k,p}^*$, $\mathbf{X}_{l,p}^*$ эталонных подпространств запишется как

$$\mathbf{X}_{k,p}^*, \mathbf{X}_{l,p}^* = \begin{cases} \max_{p=1, P} \min_{j=1, M} \left[\begin{array}{l} (R_{k,p}(\mathbf{x}_{k,j}) - R_{k,p}(\mathbf{x}_{l,j})) \\ (R_{l,p}(\mathbf{x}_{l,j}) - R_{l,p}(\mathbf{x}_{k,j})) \end{array} \right], \\ (R_{k,p}(\mathbf{x}_{k,j}) - R_{k,p}(\mathbf{x}_{l,j})) > 0, \\ (R_{l,p}(\mathbf{x}_{l,j}) - R_{l,p}(\mathbf{x}_{k,j})) > 0. \end{cases} \quad (10)$$

Неравенства в (10) устанавливают ограничение на множество используемых векторов. Они требуют, чтобы числовое значение меры близости вектора из «своего» класса было больше значения меры близости к «не своему» классу. Если это не так, вектор считается ошибочным и исключается из рассмотрения. Удовлетворяющие (10) пары эталонных подпространств $\mathbf{X}_{k,p}^*$, $\mathbf{X}_{l,p}^*$ далее будем называть опорными.

Существование предложенного критерия (10) в некотором смысле аналогично идею метода опорных векторов, в котором максимизируется расстояние между наиболее близко расположеными векторами из разных классов. В данном случае в качестве наилучшей пары опорных подпространств выбирается такая, для которой имеет место наибольшее значение показателя сопряжённости с векторами, имеющими минимальную разность показателей сопряжённости со «своим» и «чужим» классом. Таким образом, определяется наилучшая в указанном смысле пара подпространств для наихудшей пары векторов.

3. Описание алгоритма распознавания

Алгоритм распознавания состоит в определении близости текущего вектора признаков, составленного из значений ЭПР диаграммы рассеяния, полученной для некоторого маршрута, характеризующегося набором углов $\varphi \in [\varphi_0; \varphi_N]$, $\theta \in [\theta_0; \theta_M]$, к опорному эталонному подпространству заданной размерности D . Поскольку для определения опорных подпространств на этапе обучения использовалась схема бинарной классификации, необходимо рассмотреть особенности технологии распознавания для общего случая множественной классификации.

Известно два подхода к решению этой задачи. В рамках одного подхода классы сопоставляются по принципу «каждый с каждым». При этом на этапе обучения в соответствии с описанной выше схемой должны быть построены C_K^2 пар опорных эталонных подпространств. Например, в случае трёх распознаваемых объектов для реализации решающего правила (4), (5) последовательно выполняется три этапа бинарной классификации, и на каждом этапе выбирается класс, для которого имеет место максимальное значение показателя сопряжённости с соответствующим опорным эталонным пространством.

Другой подход заключается в том, что при определении принадлежности текущего вектора некоторому классу «противоположным» классом в схеме бинарной классификации является объединённое множество векторов признаков, не принадлежащих данному классу.

При этом можно поступить следующим образом. Объединить данные одного класса, а остальные данные объединить в один общий класс. После этого классификатор обучается по описанной в предыдущем разделе бинарной схеме. В результате обучения получим матрицы подпространств, описывающие некоторый класс (условно назовём его первым), и класс, полученный объединением данных всех остальных классов.

На этапе классификации для определения принадлежности текущего вектора (диаграммы рассеяния) к определённому классу необходимо проверить только одну пару матриц подпространств. Принадлежность вектора определяется по критерию (5). Если вектор принадлежит первому классу, то процедура распознавания считается завершённой. Если же классу, полученному путём объединения данных других классов, то аналогичная процедура классификации продолжается для других классов.

Для сравнения был реализован также алгоритм на основе коэффициента корреляции. При этом для определения класса объекта искомый вектор сравнивается со средним вектором класса обучающей выборки. Вектор принадлежит тому классу, со средним вектором которого он имеет наибольшее значение коэффициента корреляции (6).

4. Формирование данных для экспериментов

При исследовании зависимости качества распознавания от степени разброса параметров регистрации использовались результаты моделирования различных режимов «облёта» объектов. В частности, для формирования обучающего набора данных использовалась технология моделирования диаграмм рассеяния, описанная в работе [5]. Эта технология предусматривает моделирование формирования электромагнитного поля в непосредственной близости от объекта при помощи решения разностного уравнения Максвелла и последующее определение поля (отсчётов диаграммы рассеяния) в дальних точках. Моделирование проводилось для трёх объектов (классов) – самолёт, автомобиль, скоттер, различающихся размерами и формой (табл. 1).

Для указанных объектов, созданных в 3D-редакторе, генерировалась сетка, состоящая из множества тетраэдров, которые затем загружались в программу с учётом электромагнитных характеристик составных объектов.

Параметры сетки в разностной схеме уравнений Максвелла задавались следующими:

- 1) шаг дискретизации – 0,03 м;
- 2) длина волны – 0,3 м плоского электромагнитного импульса;
- 3) фактор Куранта – 0,98;
- 4) параметры среды – $\epsilon = 1$, $\mu = 1$, $\sigma = 0$.

Для каждого объекта значения ЭПР в дальних точках для углов места $\theta \in [0^\circ; 90^\circ]$ были рассчитаны с шагом в один градус, а для углов азимута $\phi \in [0^\circ; 360^\circ]$ – с шагом в 5 градусов. Таким образом, было сформировано поле точек сферической поверх-

ности с координатами (θ, ϕ) , и каждой точке присвоено полученное в ходе моделирования значение ЭПР.

Табл. 1. Параметры объектов

	Самолёт	Автомобиль	Скутер
Размер объекта, $m^3 (W \times L \times H)$	6,6 × 4,6 × 2,5	2,5 × 5 × 1,6	0,4 × 1,5 × 0,9
Размер сетки, m^3	10 × 10 × 7	5 × 5 × 5	3 × 3 × 3

В рамках рассматриваемой технологии предполагается, что распознаваемый объект «подсвечивается» отдельным источником радиолокационного сигнала, а регистрирующее устройство находится на подвижной платформе, например, самолёте. При этом может быть сформирована диаграмма рассеяния для некоторого маршрута, характеризующегося набором углов места и азимута.

На рис. 2 приведена схема «облёта» (вид сверху) объекта с самолёта, на котором находится приёмник радиолокационного излучения, регистрирующий сигналы, отражённые от цели. Расстояние R (от объекта до приёмника излучения) велико по сравнению с длиной волны регистрируемого излучения. Поскольку ЭПР не зависит от расстояния до объекта, то траектория движения средства, на котором расположен приёмник, может отличаться от круговой. При этом не вносятся значительные ошибки.

Предполагается, что на подвижной платформе имеются датчики, позволяющие измерять текущие угол места и азимута по отношению к распознаваемому объекту, а также тип подстилающей поверхности. Как указывалось выше, эти углы могут содержать погрешности измерения, поэтому формируемые векторы признаков образуют некоторое множество векторов в окрестности номинального режима.

Для экспериментальной проверки эффективности технологии в условиях ошибок измерений параметров съёмки моделировались три (далее называемые номинальными) режима наблюдения для угла места $\theta = 45^\circ$ и следующих трёх диапазонов азимутальных углов:

$$\phi \in [0^\circ, 360^\circ]; \phi \in [0^\circ, 180^\circ]; \phi \in [0^\circ, 60^\circ].$$

На рис. 2 показаны соответствующие указанным диапазонам секторы наблюдения объекта. В частности, первый режим соответствует объединению всех секторов с первого по шестой, второй – с первого по третий, а третий диапазон моделировался только в первом секторе наблюдения объекта. На всех трёх режимах использовался один и тот же угол падения плоской волны от источника подсвечивающего электромагнитного излучения: $\theta = 0$, $\phi = 0$. Электромагнитные параметры подстилающей поверхности задавались следующими: $\epsilon = 3$, $\mu = 1$, $\sigma = 0,0003$.

Данные для обучающей и контрольной выборок моделировались путём внесения случайных аддитивных ошибок в значения угла места – θ номинального режима. Ошибки задавались так, чтобы абсолютное значение степени отклонения от номинального режима $\theta = 45^\circ$ изменялось в пределах от пяти до восьми. Для этого угол места изменялся в следующих диапазонах θ :

$$\theta \in [41^\circ, 50^\circ]; \theta \in [40^\circ, 51^\circ]; \theta \in [39^\circ, 52^\circ]; \theta \in [38^\circ, 53^\circ].$$

При этом случайным образом формировалась последовательность, состоящая из неповторяющихся углов места, принадлежащих интервалам, указанным выше. В данном случае вероятностным распределением случайной величины является равномерное распределение.

Из полученной описанным способом последовательности формировались обучающая и контрольная выборки путём случайного выбора в равных количествах. В итоге размеры обучающей и контрольной выборок – M в пределах каждого из указанных диапазонов изменения углов места задавались одинаковыми и равными величине отклонения от номинального режима. В частности, для первого диапазона углов принималось $M = 5$, для второго – $M = 6$, для третьего – $M = 7$ и для четвёртого – $M = 8$.

5. Результаты экспериментов

Были проведены три серии экспериментов для трёх указанных выше режимов моделирования диаграмм рассеяния трёх объектов (классов): самолёт, автомобиль, скутер. Обучение заключалось в определении наилучших пар опорных эталонных подпространств в соответствии с методикой, описанной в разделе 3. В экспериментах использовались обучающие и контрольные выборки для проверки качества распознавания, сформированные в соответствии с приведённым в разделе 4 описанием схемы моделирования. Результаты доли распознаваний соответствующим образом были усреднены для всех размеров контрольных выборок.

Поскольку минимальный размер обучающей и контрольной выборок $M = 5$, опорные эталонные подпространства строились в диапазоне размерностей от двух до четырёх. На рис. 3 представлены графики зависимости доли верных распознаваний трёх указанных классов объектов от степени отклонения режима от номинального для первого, второго и третьего режимов наблюдения соответственно.

Как и следовало ожидать, доля верных распознаваний уменьшается с увеличением степени отклонения режима от номинального. Вместе с тем нетрудно заметить, что с использованием метода опорных подпространств достигается более высокое качество распознавания не только по сравнению с корреляционным методом, но также по сравнению с наиболее популярным методом опорных векторов. Указанный факт имеет место как при использовании опорных подпространств достаточно высокой размерности, так и при использовании небольшого числа обучающих векторов.

Это объясняется тем, что используемая мера близости менее чувствительна к изменчивости обучающих векторов признаков (диаграмм рассеяния), принадлежащих одному классу. Кроме того, использование в качестве эталона нескольких векторов признаков из класса обеспечивает существенное увеличение информативности этого эталона. При этом оказывается эффективной максиминная стратегия отбора этих векторов.

Заключение

Полученные в настоящей работе результаты являются ещё одним подтверждением эффективности методов, основанных на применении решающего правила (4) к распознаванию объектов, образы которых обладают существенной изменчивостью при наблюдении в разных ракурсах.

Предложен новый метод, в идеальном плане сходный с методом опорных векторов, но опирающийся на иную меру близости. При этом экспериментально удалось показать эффективность использования опорных подпространств различной, притом невысокой размерности.

Этот факт открывает перспективы для дальнейших исследований, поскольку в настоящее время метод опорных векторов, который удалось превзойти, большинством авторов признаётся одним из лучших.

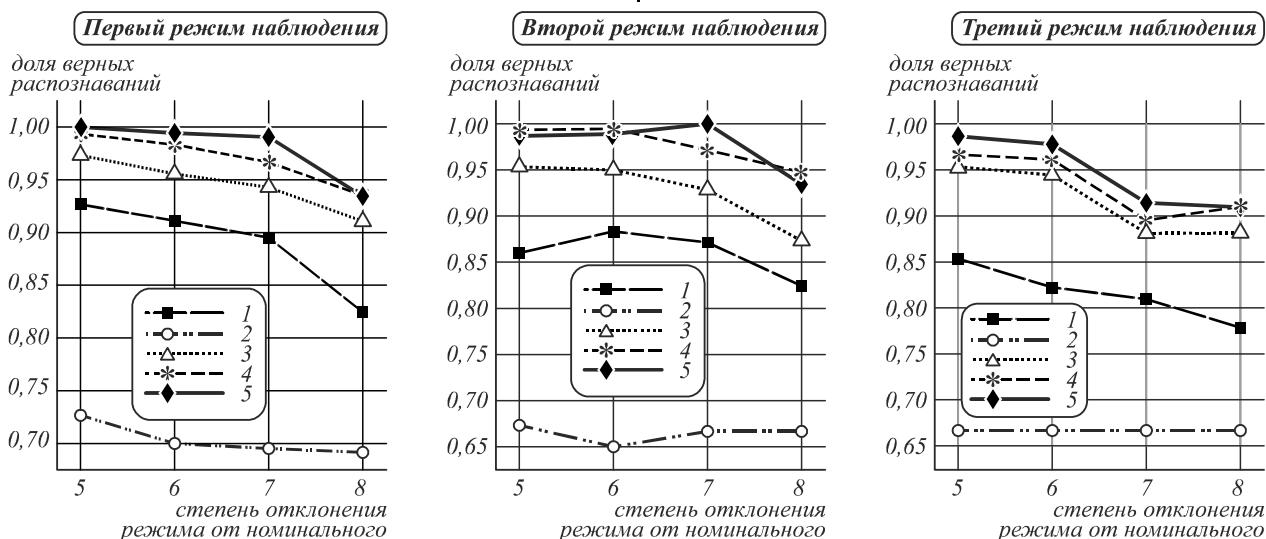


Рис. 3. Зависимости доли правильных распознаваний от степени отклонения от номинального режима при использовании: коррелятора – кривая 1, метода опорных векторов – кривая 2 и опорных подпространств размерности 2, 3, 4 – кривые 3, 4, 5 соответственно

Благодарности

Работа выполнена при поддержке Министерства образования и науки РФ и грантов РФФИ (проекты № 12-07-00581, 13-07-12030_офи_m 13-07-13166).

Литература

1. **Tait, P.** Introduction to Radar Target Recognition. – London: Published by The Institution of Engineering and Technology, 2005. – 428 p.
2. **Xuejun, L.** Identification of Ground Targets From Sequential Hight-Range-Resolution Radar Signatures / Liao Xuejun, Paul Runkle, Carin Lawrence // Aerospace and Electronic Systems, IEEE. – 2002. – Vol. 38. – P. 1230-1242.
3. **Nguyen, D.H.** Classification and Tracking of Moving Ground Vehicles / D.H. Nguyen, J.H. Kay, B.J. Orchard, R.H. Whiting // Lincoln Laboratory Journal. – 2002. – Vol. 13. – P. 275-308.
4. **Lee, K.-C.** Angular-diversity Radar Recognition of Ships by Transformation Based approaches – including Noise Effects / K.-C. Lee, J.-S. Ou and C.-W. Huang // Progress in Electromagnetics Research, PIER 72. – 2007. – Vol. 72. – P. 145-158.
5. **Вапник, В.Н.** Теория распознавания образов (статистические проблемы обучения) / В.Н. Вапник, А.Я. Червоненкис. – М.: Наука, 1946. – 416 с.
6. **Претт, У.** Цифровая обработка изображений / У. Претт; пер. с англ. – М.: Мир, 1982. – Кн. 1, 2 – 791 с.
7. **Жердев, Д.А.** Моделирование рассеяния электромагнитного поля от техногенных объектов на подстилающих поверхностях / Д.А. Жердев, Н.Л. Казанский, В.А. Фурсов, С.И. Харитонов // Компьютерная оптика. – 2012. – Т. 37, № 1. – С. 91-98.
8. **Fursov, V.A.** Training in Pattern Recognition from a Small Number / Vladimir A. Fursov // Proc. 15th International Conference on Pattern recognition (ISPR) 2000, Barcelona, Spain. – 2000. – Vol. 2. – P. 119-121.
9. **Fursov, V.A.** Building of Classifiers Based on Conjugation Indices / V.A. Fursov, I.A. Kulagina and N.E. Kozin // Optical Memory and Neural Networks (Information Optics). – 2007. – Vol. 16, Issue 3. – P. 136-143.
10. **Fursov, V.** Building of Classifier Based on Conjugation Indexes / Vladimir Fursov, Irina Kulagina, Nikita Kozin // Proceedings of the 5-th International Conference on Machine Learning and Data Mining. Leipzig, Germany, 18 - 20 July, 2007. – 2007. – P. 231-235.
11. **Козин, Н.Е.** Построение классификаторов для распознавания лиц на основе показателей сопряжённости / Н.Е. Козин, В.А. Фурсов // Компьютерная оптика. – 2005. – № 28. – С. 160-163.
12. **Fursov, V.** Constructing of Classifier for Face Recognition on the Basis of the Conjugation Indexes / Vladimir Fursov, Nikita Kozin // Transactions on Engineering Computing and Technology. – 2006. – Vol. 13. – P. 72-74.
13. **Fursov, V.** Recognition through Constructing the Eigenface Classifiers using Conjugation Indices / Vladimir Fursov, Nikita Kozin // 2007 IEEE International Conference on Advanced Video and Signal based Surveillance London (United Kingdom), 5-7 September 2007. – 2007. – P. 465-469. – ISBN: 978-1-4244-1696-7.
14. **Фурсов, В.А.** Тематическая классификация гиперспектральных изображений по показателю сопряжённости /

В.А. Фурсов, С.А. Бибиков, О.А. Байда // Компьютерная оптика. – 2014. – Т. 38, № 1. – С. 154-158. – ISSN 0134-2452.

References

1. **Tait, P.** Introduction to Radar Target Recognition. – London: Published by The Institution of Engineering and Technology, 2005. – 428 p.
2. **Xuejun, L.** Identification of Ground Targets From Sequential Hight-Range-Resolution Radar Signatures / Liao Xuejun, Paul Runkle, Carin Lawrence // Aerospace and Electronic Systems, IEEE. – 2002. – Vol. 38. – P. 1230-1242.
3. **Nguyen, D.H.** Classification and Tracking of Moving Ground Vehicles / D.H. Nguyen, J.H. Kay, B.J. Orchard, R.H. Whiting // Lincoln Laboratory Journal. – 2002. – Vol. 13. – P. 275-308.
4. **Lee, K.-C.** Angular-diversity Radar Recognition of Ships by Transformation Based approaches – including Noise Effects / K.-C. Lee, J.-S. Ou and C.-W. Huang // Progress in Electromagnetics Research, PIER 72. – 2007. – Vol. 72. – P. 145-158.
5. **Vapnik, V.N.** Pattern recognition theory (learning statistic problem) / V.N. Vapnik, A.Ia. Chervonenkis. – Moscow: "Nauka" Publisher, 1946. – 416 p. – (In Russian).
6. **Pratt, W.K.** Digital Image Processing / William K. Pratt. – New York: John Wiley and Sons, Inc., 1982. – V. 1, 2 – 791 p.
7. **Zherdev, D.A.** Electromagnetic field scattering simulation from anthropogenic objects on underlying surface / D.A. Zherdev, N.L. Kazanskiy, V.A. Fursov, S.I. Kharitonov // Computer Optics. – 2012. – Vol. 37(1). – P. 91-98.
8. **Fursov, V.A.** Training in Pattern Recognition from a Small Number / V.A. Fursov // Proc. 15th International Conference on Pattern recognition (ISPR) 2000, Barcelona, Spain. – 2000. – Vol. 2. – P. 119-121.
9. **Fursov, V.A.** Building of Classifiers Based on Conjugation Indices / V.A. Fursov, I.A. Kulagina and N.E. Kozin // Optical Memory and Neural Networks (Information Optics). – 2007. – Vol. 16, Issue 3. – P. 136-143.
10. **Fursov, V.** Building of Classifier Based on Conjugation Indexes / Vladimir Fursov, Irina Kulagina, Nikita Kozin // Proceedings of the 5-th International Conference on Machine Learning and Data Mining. Leipzig, Germany, 18 - 20 July, 2007. – 2007. – P. 231-235.
11. **Kozin, N.E.** Constructing of classifier for face recognition using conjugation indexes / N.E. Kozin, V.A. Fursov // Computer Optics. – 2005. – Vol. 28. – P. 160-163. – (In Russian).
12. **Fursov, V.** Constructing of Classifier for Face Recognition on the Basis of the Conjugation Indexes / Vladimir Fursov, Nikita Kozin // Transactions on Engineering Computing and Technology. – 2006. – Vol. 13. – P. 72-74.
13. **Fursov, V.** Recognition through Constructing the Eigenface Classifiers using Conjugation Indices / Vladimir Fursov, Nikita Kozin // 2007 IEEE International Conference on Advanced Video and Signal based Surveillance London (United Kingdom), 5-7 September 2007. – 2007. – P. 465-469. – ISBN: 978-1-4244-1696-7.
14. **Fursov, V.A.** Thematic classification of hyperspectral images using conjugacy indicator / V.A. Fursov, S.A. Bibikov, O.A. Bajda // Computer Optics. – 2012. – Vol. 38(1). – P. 154-158. – ISSN 0134-2452.

OBJECT RECOGNITION BY THE RADAR SIGNATURES OF ELECTROMAGNETIC FIELD SCATTERING ON BASE OF SUPPORT SUBSPACES METHOD

D.A. Zherdev, N.L. Kazanskiy, V.A. Fursov

*Image Processing Systems Institute, Russian Academy of Sciences,
Samara State Aerospace University*

Abstract

In the work study the object recognition problem by the radar signatures of scattering reflected electromagnetic radiation. As template we use diagrams that made by computing the scattering field of 3d object models. The conjugation index with so-called support subspace that formed by attribute vectors of recognition class used in recognition as metric distance. Recognition quality in depending upon the dimension of support subspaces is studied. In work give comparison of result obtained by support vector machine and the compute correlation index with average class vector.

Key words: digital image processing, electromagnetic field, scattering field, recognition, conjugation index.

Сведения об авторах

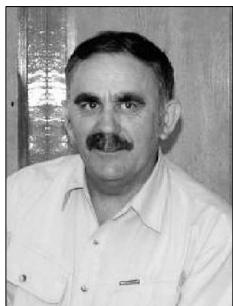


Жердев Денис Алексеевич, бакалавр прикладной математики и физики, по совместительству инженер лаборатории дифракционной оптики ИСОИ РАН, обучается в магистратуре Самарского государственного аэрокосмического университета. Область научных интересов: дифракционная оптика, численное моделирование.

E-mail: denis.zherdev.91@mail.ru.

Denis Alekseevich Zherdev, Bachelor of Applied Mathematics and Physics, part-time engineer IPSI RAS Diffraction Optics laboratory, is trained in the magistracy of Samara State Aerospace University. Research interests: diffractive optics, numerical modeling.

Сведения об авторе Казанский Николай Львович – см. стр. 433 этого номера.



Фурсов Владимир Алексеевич, д.т.н., профессор, заведующий кафедрой суперкомпьютеров и общей информатики в Самарском государственном аэрокосмическом университете. Область научных интересов: теория и методы оценивания по малому числу измерений, методы обработки и распознавания изображений, построение параллельных алгоритмов обработки и распознавания изображений, реализуемых с использованием многопроцессорных вычислительных систем.

E-mail: fursov@ssau.ru.

Vladimir Alekseevich Fursov, is Doctor of Engineering Science, Professor, head of General Informatics sub-department of Samara State Aerospace University, leading researcher. Research interests are development of the theory of estimation on small number of observations, development of methods of image processing and training to pattern recognition, development of hight-performance parallel methods both algorithms of image processing and pattern recognition oriented on application of multiprocessor computing systems.

Поступила в редакцию 11 июня 2014 г.