

ПАРАЛЛЕЛЬНЫЙ АЛГОРИТМ ФОРМИРОВАНИЯ ЭТАЛОННЫХ ПОДПРОСТРАНСТВ В ТЕХНОЛОГИИ РАСПОЗНАВАНИЯ ПО ДИАГРАММАМ РАССЕЯНИЯ РАДИОЛОКАЦИОННЫХ СИГНАЛОВ

Д.А. Жердев, В.А. Фурсов

Самарский государственный аэрокосмический университет имени академика С.П.Королева (НИУ) Институт систем обработки изображений РАН

Введение

В задачах определения типа объекта по отраженному им радиолокационному сигналу часто используется такая радиолокационная характеристика как эффективная площадь рассеяния (ЭПР). Данная характеристика определяется как отношение энергии эквивалентного изотропного источника к плотности потока энергии зондирующего радиоизлучения. При отражении радиолокационного сигнала от земной поверхности на полезный сигнал от объекта накладывается шум, обусловленный типом и характеристиками подстилающей поверхности. На основании одного измеренного значения ЭПР трудно дать оценку типа объекта, если тип подстилающей поверхности точно не известен, так как для близких по величине объектов ЭПР может принимать также близкие значения. Поэтому используют диаграммы рассеяния – набор значений ЭПР, полученных при разных ракурсах положения приемка радиолокационного излучения [1].

Для решения этой задачи обычно используют эталонные диаграммы рассеяния, полученные путем облучения объектов на специально оборудованных полигонах. В настоящей работе используется технология, в рамках которой эталонные диаграммы рассеяния формируются путем моделирования. Проблемы моделирования диаграмм рассеяния объектов на подстилающих поверхностях рассматривались в работе [2]. При этом использовались методы формирования диаграмм рассеяния, состоящих из значений двухпозиционной эффективной площади рассеяния: при различных положениях приемника и источника излучения, с помощью конечно-разностного метода во временной области. На конференциях [3], [4] (ПаВТ) были представлены работы по эффективной высокопроизводительной параллельной реализации алгоритма моделирования рассеяния радиолокационного излучения с помощью CUDA-технологии моделирования. В настоящей работе эта технология развивается в направлении построения эффективных методов и алгоритмов распознавания.

Используются различные подходы распознавания по диаграммам рассеяния. В работе [5] применяется модель марковского процесса. Недостатком алгоритма распознавания основанного на использовании скрытой марковской модели является неопределенность в выборе степеней свободы модели [6]. В работе [7] исследуется распознавание при помощи байесовского классификатора. Стоит заметить, что для методов распознавания с использованием байесовского классификатора главным недостатком является проблема переобучения алгоритмов. В статье [8] демонстрируется пример моделирования обратной диаграммы рассеяния трех различных кораблей с помощью того же конечно-разностного метода и их последующего распознавания с использованием метода главных компонент [9]. При обучении классификатора строится ковариационная матрица, а после ищутся ее собственные числа и собственные вектора. Недостатком данного метода является то, что не для любой матрицы можно определить собственные числа и собственные вектора.

Основная проблема при распознавании по диаграммам рассеяния заключается в априорной неопределенности, связанной с их высокой чувствительностью к изменениям ракурса наблюдения, формы объекта, характеристикам подстилающей поверхности и др. В этих условиях повышение надежности распознавания может достигаться увеличением числа эталонов, полученных путем моделирования при вариациях указанных характеристик. В рамках этого подхода важным представляется вопрос наиболее полного учета информации, содержащейся в моделях эталонов, как на этапе обучения, так и на этапе распознавания.

В настоящей работе ставится задача построения и исследования процедуры формирования эталонных подпространств небольшой размерности (так называемых опорных подпространств), аккумулирующих всю информацию об объекте, что обеспечивает повышение качества распознавания. Процедура формирования таких подпространств имеет высокую вычислительную сложность. Поэтому здесь предлагаются возможные реализации параллельного алгоритма поиска опорных подпространств.

1. Постановка задачи

Вектором признаков объекта в данной постановке задачи является диаграмма рассеяния радиолокационного сигнала, отраженного от объекта, расположенного на подстилающей поверхности. Будем полагать, что векторы признаков для распознавания класса объекта формируются из значений ЭПР в диаграмме рассеяния. Пусть приемник излучения находится на подвижной платформе, например, самолете. При измерении ЭПР в N разных точках ракурса объекта получаем некоторый j -ый вектор признаков размера $N \times 1$:

$$x_j = [x_1, x_2, \dots, x_N] \quad . \quad (1)$$

Предполагается, что при регистрации текущего (подлежащего распознаванию) вектора признаков могут быть измерены углы азимута и места, соответствующие каждой компоненте вектора признаков. Совокупность векторов признаков, сформированных при регистрации одного и того же объекта при одинаковом числе и последовательности ракурсов, но при вариациях условий регистрации, образует класс.

Полагаем, что характеристики условий регистрации могут быть известны неточно или не известны вовсе. Поэтому для обеспечения информативности моделируемого эталона класса он должен содержать достаточно большое число векторов признаков при всех возможных отклонениях условий регистрации от номинальных. При достаточно больших вариациях отклонений условий регистрации использование в качестве представителя вектора класса, вычисленного как среднее значение векторов, принадлежащих классу, может привести к существенной потере информации.

В работах [10]-[16] показано, что для распознавания объектов, обладающих изменчивостью при изменении ракурса наблюдения, например, лиц, весьма эффективным является применение в качестве меры близости так называемого показателя сопряженности [10] с подпространством, образованным всеми векторами признаков распознаваемого класса. При этом эталон образует некоторое пространство, а эффект достигается за счет того, что в исходных векторах, из которых составлен этот эталон, сохраняется вся исходная информация об объекте.

Математически задача формулируется следующим образом [16]. Пусть задано K классов и для каждого класса сформирована матрица Q_k размера $N \times M$:

$$Q_k = X_k [X_k^T X_k]^{-1} X_k^T, \quad (2)$$

где

$$X_k = [x_1(k), x_2(k), \dots, x_M(k)], \quad k = \overline{1, K}, \quad (3)$$

матрица размера $N \times M$, составленная из M , полученных при разных условиях регистрации, векторов-признаков (1) этого класса. Подчеркнем, что матрицы-эталонны $X_k, k = \overline{1, K}$ всех возможных классов формируются путем моделирования после того как становятся известными число и последовательность ракурсов, при которых произошла регистрация текущего вектора признаков x_j реального объекта.

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

$$R_k(x_j) = \frac{x_j^T Q_k x_j}{x_j^T x_j}. \quad (4)$$

Вектор x_j принадлежит m -му классу, если удовлетворяет следующему условию

$$R_m(x_j) = \max_{k=\overline{1, K}} R_k(x_j). \quad (5)$$

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

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

Применение решающего правила (4) дает положительный эффект, так как использование в эталоне большого числа векторов, обеспечивает более полную характеристику класса. Однако остается открытым вопрос о размерности подпространства, в котором качество распознавания наилучшее. Обычно чем выше размер подпространства, тем лучше качество распознавания. Далее в работе дадим количественные оценки качества распознавания и вычислительной сложности разработанного алгоритма обучения классификатора, основанного на вычислении показателя сопряженности.

2. Построение эталонных подпространств

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), то есть могут быть представлены матрицами X_k, X_l размера $N \times M$. Поставим задачу поиска таких пар минимальных подмножеств, пар матриц $X_k(D_k), X_l(D_l)$ размера $N \times D_k, N \times D_l$, для которых значение заданного функционала качества $I(X_k(D_k), X_l(D_l))$ 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 , но не используемые при составлении матриц $X_k(D_k), X_l(D_l)$. В качестве критерия качества распознавания векторов признаков примем суммарное число правильно распознанных векторов признаков из обоих классов обучающего набора данных:

$$I(X_k(D_k), X_l(D_l)) = n_k + n_l. \quad (7)$$

В общем случае размерности эталонных подпространств могут быть различными. В настоящей статье мы сузим постановку и рассмотрим только случай, когда размерности D подпространств в перебираемых парах эталонных подпространств одинаковы. Сформулируем задачу определения множества наилучших пар подпространств.

Предполагается, что для двух классов задана, размерность D эталонных подпространств (пара матриц X_i, X_j , $i, j = 1, \dots, C$ размера $N \times D$) и критерий качества $I(X_k(D), X_l(D))$, $i, j = 1, \dots, C$.

(7). Среди всех возможных пар подпространств на двух классах ищется пара, для которой

$$X_k(D), X_l(D): I(X_k(D), X_l(D)) = \max_{i, j = 1, \dots, C} I(X_i(D), X_j(D)), \quad (8)$$

где $I(X_i(D), X_j(D))$ – суммарное число правильно распознанных векторов из классов i, j , определяемое соотношением (7). В результате решения описанной выше задачи «хороших» пар матриц $X_k(D), X_l(D)$ может оказаться значительное количество. Предлагается следующий критерий определения наилучшей пары матриц из этого множества.

Блок схема предлагаемого выше алгоритма изображена на рисунке 1.

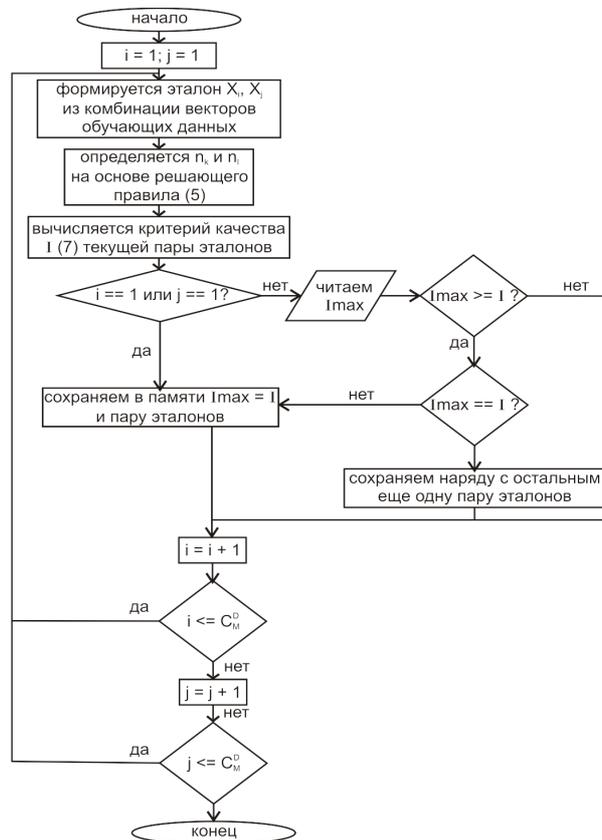


Рис. 1. Блок схема алгоритма построения опорных подпространств

Для определенности положим, что на предшествующем этапе для двух классов, характеризующихся матрицами X_k, X_l размера $N \times M$ получено P пар эталонных подпространств $X_{k,p}, X_{l,p}$, $p = \overline{1, P}$ размерности D с одинаковыми значениями критерия (7). Пусть $x_{k,j}, x_{l,j}$, $j = \overline{1, M}$ – векторы, из которых составлены матрицы классов X_k, X_l соответственно. Обозначим показатели сопряженности эталонных подпространств с векторами из соответствующих им классов:

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

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

С учетом сделанных обозначений функционал качества для определения наилучшей пары $\tilde{X}_{k,p}, \tilde{X}_{l,p}$ эталонных подпространств запишется как

$$\tilde{X}_{k,p}, \tilde{X}_{l,p} = \begin{cases} \max_{p=1,P} \min_{j=1,M} (R_{k,p}(x_{k,j}) - R_{k,p}(x_{l,j})), \\ \max_{p=1,P} \min_{j=1,M} (R_{l,p}(x_{l,j}) - R_{l,p}(x_{k,j})), \\ (R_{k,p}(x_{k,j}) - R_{k,p}(x_{l,j})) > 0, \\ (R_{l,p}(x_{l,j}) - R_{l,p}(x_{k,j})) > 0, \end{cases} \quad (9)$$

Неравенства в (9) устанавливают ограничения 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 условию (9) пары эталонных подпространств $\tilde{X}_{k,p}, \tilde{X}_{l,p}$ далее будем называть опорными.

3. Анализ вычислительной сложности и параллельная реализация метода опорных подпространств

Проведем анализ вычислительной сложности описанного выше метода. В работе [17] проведен анализ вычислительной сложности вычисления показателя сопряженности. Для определения величины Q_k необходимо следующее число операций:

$$F_1 = D(D(2,5D + 4N) - 0,5) + N(D(4D + 2N - 1) - N) .$$

Необходимо иметь в виду, что в данном случае требуется вычисление матриц Q_k для $P = C \frac{D}{M}$ различных комбинаций векторов из матрицы класса в матрице подпространства. При вычислении же показателей сопряженности двух различных классов по методу, описанному в данной работе, потребуется:

$$F_2 = 4M(2N^2 + 3N - 2) ,$$

арифметических операций. В итоге для различных пар комбинаций при вычислении значения $I(X_i(D), X_j(D))$ по критерию (7) необходимо следующее число операций

$$(F_1 + F_2 C \frac{2}{P}) P .$$

На рисунке 2 представлен график зависимости числа арифметических операций метода опорных подпространств от размера матрицы класса M . На графике приведены кривые для трех различных размеров подпространств. Размер векторов признаков $N = 18$. Видно, что при увеличении размера подпространства и увеличении размера обучающего множества класса возрастает вычислительная сложность разработанного алгоритма определения опорных подпространств.

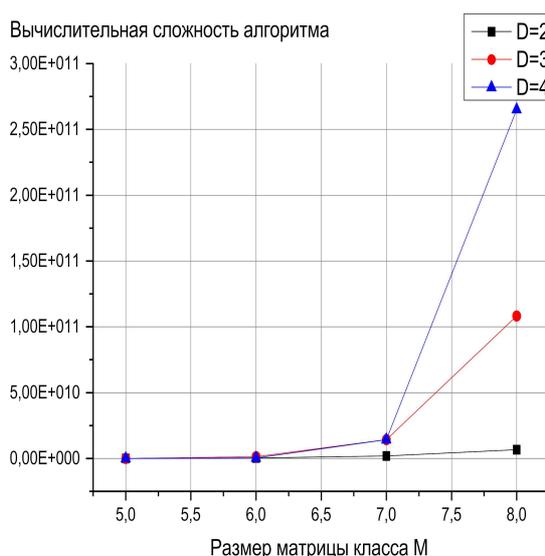


Рис. 2. Вычислительная сложность алгоритма построения опорных подпространств

Был проведен эксперимент по распознаванию трех смоделированных объектов: самолета, автомобиля, скутера по диаграммам рассеяния. В качестве векторов признаков в эксперименте использовались диаграммы

рассеяния размера $N = 18$ для углов азимута $\phi \in [0; 360]$. Были сформированы одинаковые по размерам выборки данных для обучения классификатора, а так же контрольная выборка для распознавания. Данные в обучающих и контрольных выборках задавались с определенной степенью шума такого параметра как угол места наблюдения за объектом θ . При проведении экспериментальных исследований были выбраны следующие диапазоны изменения угла места θ :

- 1) $\theta \in [41, 50]$;
- 2) $\theta \in [40, 51]$;
- 3) $\theta \in [39, 52]$;
- 4) $\theta \in [38, 53]$.

Из указанных диапазонов угла места в обучающую и контрольную выборки диаграммы рассеяния выбирались случайным образом, путем формирования случайной последовательности из каждого диапазона по равномерному закону распределения с шагом в один градус. Размеры M обучающей и контрольной выборки задавались одинаковыми: для первого диапазона $M = 5$, для второго $M = 6$, для третьего $M = 7$, для четвертого $M = 8$. На рисунке 3 представлены результаты эксперимента.

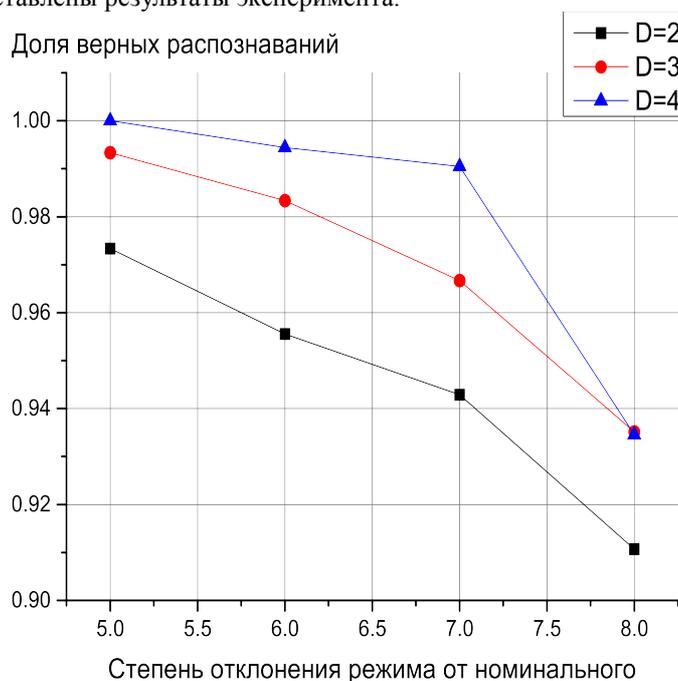


Рис. 3. Зависимость качества распознавания от степени отклонения от номинального режима

Разрабатываются два подхода реализации параллельной программы определения опорных подпространств: с использованием библиотеки MPI, а также на основе CUDA технологии. При реализации на MPI главный узел рассылает подчиненным узлам матрицы классов. Далее каждый подчиненный узел рассчитывает свою комбинацию векторов, которые составляют матрицы эталона $X_k(D)$, $X_l(D)$. После этого осуществляется рассылка рассчитанных по критерию (7) величин $I(X_k(D), X_l(D))$ на главный узел. На главном узле затем определяется «лучшая» пара эталонов $\tilde{X}_{k,p}$, $\tilde{X}_{l,p}$ по критерию (9).

При реализации параллельного алгоритма решения описанной задачи с использованием графических процессоров, необходимо чтобы в каждом потоке выполнялось вычисление показателя сопряженности для одного вектора признаков. Недостатком использования CUDA является то, что на выходе «функции-ядра» видеопроцессора необходимо хранить все значения показателя сопряженности для дальнейшего определения «лучшей» пары эталонных подпространств.

Заключение

Проведен анализ вычислительной сложности разработанного алгоритма определения опорного подпространства. Предложена схема реализации параллельной программы для двух технологий: MPI, CUDA. Согласно предложенному алгоритму реализация с использованием CUDA, скорее всего, не целесообразна. Разрабатываемый параллельный алгоритм может быть реализован с высокой производительностью с использованием библиотеки MPI. В настоящее время алгоритмы параллельной реализации поиска опорных подпространств еще не были реализованы. Как показано в работах [2,3], этап моделирования диаграмм рассеяния с использованием разностного решения уравнений Максвелла может быть эффективно реализован на графических процессорах, сквозная информационная технология, по-видимому, должна быть ориентирована на использование гибридных вычислительных систем.

ЛИТЕРАТУРА:

1. Tait, P. Introduction to Radar Target Recognition. – London: Published by The Institution of Engineering and Technology. 2005. – 428 P.
2. Жердев Д. А. Моделирование рассеяния электромагнитного поля от техногенных объектов на подстилающих поверхностях / Жердев Д.А., Казанский Н.Л., Фурсов В.А., Харитонов С.И. // Компьютерная оптика. – 2012. – № 37-1. – С. 91-99. ISSN 0134-2452.
3. Жердев Д. А. Высокпроизводительное моделирование распространения электромагнитного поля с использованием технологии CUDA / Жердев Д. А., Фурсов В.А. // Труды международной научной конференции ПаВТ 2013. Челябинск. 2013. С. 338-345.
4. Жердев Д.А. Высокпроизводительное моделирование распространения электромагнитного поля на графических процессорах с гибким использованием ресурсов / Жердев Д.А., Фурсов В.А. // Труды международной научной конференции ПаВТ 2014. Ростов-на-Дону. 2014. С. 264-269.
5. Xuejun Liao. Identification of Ground Targets From Sequential High-Range-Resolution Radar Signatures / Xuejun Liao, Paul Runkle, Lawrence Carin / Aero-space and Electronic Systems, IEEE. – 2002. – V. 38(4), P. 1230-1242. – ISSN 0018-9251.
6. Rabiner L., Juang B.H. An introduction to hidden Markov models // ASSP Magazine, IEEE. – 1986. – V. 3(1). P. 4-16.
7. Duy H. Nguyen. Classification and Tracking of Moving Ground Vehicles / Duy H. Nguyen, John H. Kay, Bradley J. Orchard, and Robert H. Whiting / Lincoln Laboratory Journal. – 2002. – V. 13, P. 275-308.
8. Lee K.-C. Angular-diversity Radar Recognition of Ships by Transformation Based Approaches—including Noise Effects / Lee K.-C. , Ou J.-S. , and Huang C.-W. / Progress In Electromagnetics Research, PIER 72. – 2007. – V. 72, P. 145–158. – ISSN: 1070-4698.
9. Pearson K. On lines and planes of closest fit to systems of points in space, // Philosophical Magazine. – 1901. – V. 2. P. 559-572.
10. 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.
11. Fursov V.A. Building of Classifiers Based on Conjugation Indices / Fursov V. A., Kulagina I. A. and Kozin N. E. // Optical Memory and Neural Networks (Information Optics). – 2007. – Vol. 16, No. 3. – P. 136-143.
12. Fursov V.A. Building of Classifier Based on Conjugation Indexes / Fursov Vladimir, Kulagina Irina, Kozin Nikita. // Proceedings of The 5-th International Conference on Machine Learning and Data Mining. Leipzig, Germany, 18 - 20 July, 2007. – 2007. – P. 231-235.
13. Козин Н.Е. Построение классификаторов для распознавания лиц на основе показателей сопряженности / Козин Н.Е. , Фурсов В.А. // Компьютерная оптика. – 2005. – № 28. – С. 160-163.
14. Fursov V.A. Constructing of Classifier for Face Recognition on the Basis of the Conjugation Indexes / Fursov Vladimir, Kozin Nikita // Transactions on Engineering Computing and Technology. – 2006. – Vol. 13. – P. 72-74.
15. Fursov V.A. Recognition through Constructing the Eigenface Classifiers using Conjugation Indices / Fursov Vladimir, Kozin Nikita // 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.
16. Фурсов В.А. Тематическая классификация гиперспектральных изображений по показателю сопряженности / Фурсов В.А., Бибииков С.А., Байда О.А. // Компьютерная оптика. – 2014. – № 38-1. – С. 154-158. ISSN 0134-2452.
17. Козин Н.Е. Анализ вычислительной сложности алгоритмов по показателям сопряженности / Козин Н.Е. // Сборник трудов Третьей Всероссийской научной конференции «Математическое моделирование и краевые задачи». Самара. – 2006.