

СИСТЕМИ ТА МЕТОДИ ОБРОБКИ ІНФОРМАЦІЇ

УДК 004.451.51:621.396

В.В. Баранник,

доктор технических наук, профессор,

А.А. Подорожняк,

кандидат технических наук, старший научный сотрудник

МЕТОД ИНТЕЛЛЕКТУАЛИЗАЦИИ ОБРАБОТКИ ДАННЫХ В БОРТОВОЙ АППАРАТУРЕ СИСТЕМЫ ДИСТАНЦИОННОГО ЗОНДИРОВАНИЯ ЗЕМЛИ

Приведено описание современных спутниковых систем дистанционного зондирования, показано противоречие между тенденциями повышения разрешающей способности, увеличением количества спектральных каналов бортовой аппаратуры и ограниченностью бортовых вычислительных средств и каналов связи, использующих современные технологии. Предложено решение в виде интеллектуализации обработки данных в бортовой аппаратуре системы ДЗЗ.

Ключевые слова: интеллектуальная обработка данных, материалы дистанционного зондирования земли, искусственная нейронная сеть.

Наведено опис сучасних супутникових систем дистанційного зондування, показано суперечність між тенденціями підвищення роздільної здатності, збільшення кількості спектральних каналів бортової апаратури й обмеженістю бортових обчислювальних засобів та каналів зв'язку, що використовують сучасні технології. Запропоновано рішення у вигляді інтелектуалізації обробки даних в бортовій апаратурі системи ДЗЗ.

Ключові слова: інтелектуальна обробка даних, матеріали дистанційного зондування землі, штучна нейромережа.

The description of the modern satellite systems of the remote sensing is resulted, several contradictions between the tendencies of the increase of discriminability, the increasing of an amount of the spectral ductings of airborne equipment and of the narrow-mindedness of side computing facilities and ductings of connection, utilizing of modern technologies are shown. The solution is offered as data processing intellectualization in the airborne equipment of the system of ERS.

Keywords: intellectual data processing, earth remote sensing data, artificial neuronet.

Введение

В последние десятилетия устойчиво и динамично развиваются технологии дистанционного зондирования Земли (ДЗЗ), которые являются одним из основных результатов космической деятельности и вносят значительный вклад в экономику

передовых стран мира. Данные, получаемые с космических аппаратов (КА) ДЗЗ, используются для исследования и рационального использования природных ресурсов; мониторинга и ликвидации последствий природных катастроф и техногенных аварий; метеорологии и климатологии; городского, лесного и сельского хозяйства; картографии; геологии, геофизики, геохимии и океанологии и других наук о Земле.

Качественные изменения в техническом оснащении спутников и технологии обработки космической информации привели к быстрому увеличению количества КА на орбите: успешно работают американские КА с оптико-электронными системами сверхвысокого разрешения (до 0.4 м) нового поколения WorldView и GeoEye [1]. На орбиту запущены спутники, оснащенные радаром с синтезированной апертурой высокого и сверхвысокого разрешения COSMOSkyMed-1,-2,-3,-4 (Италия), TerraSAR-X и TanDEM-X (Германия), RADARSAT-2 (Канада) и RISAT-2 (Индия), ALOS (Япония).

ДЗЗ находится на стыке многих областей: инструменты ДЗЗ создаются космической отраслью, продукты создаются отраслью информационной, а используются как основа для принятия решений во многих других отраслях экономики. Постоянное улучшение разрешающей способности является основной тенденцией развития систем наблюдения из космоса на протяжении всего периода их существования и развития. Сегодня потребителям доступна панхроматическая цифровая информация с высоким разрешением, например КА ДЗЗ "GeoEye-1" помимо панхроматических изображений с разрешением 0,41 метра, обеспечивает одно-временную съемку и в 4 мультиспектральных диапазонах с разрешением 1,64 метра.

Информационная производительность лучших КА ДЗЗ уже достигла 1 Гигапикселя/с [1; 2]. Этому соответствуют внутренние потоки информации порядка 10 Гигабит и больше, которые обрабатываются на борту КА в реальном масштабе времени. Имеется устойчивая тенденция к увеличению информационных потоков, причем количество информации, получаемой космическими аппаратами, увеличилось приблизительно в 10 раз за последние 10 лет.

Современную научную проблематику ДЗЗ высокого разрешения можно разделить на два основных направления: первое – это инструментальные проблемы, связанные с разработкой аппаратуры и алгоритмов первичной обработки информации; второе – проблемы тематической (вторичной) обработки или интерпретации полученной информации.

Актуальной также является проблема разработки эффективных алгоритмов сжатия информационного потока на выходе бортовой аппаратуры высокоразрешающих радиолокаторов с синтезированной апертурой (РСА), который на сегодняшний день на порядок превышает возможности современной передающей информации аппаратуры и существенно ограничивает эффективность космических систем.

До сих пор не решена проблема получения радиолокационных изображений (РЛИ) в реальном масштабе времени на борту КА. Поэтому, несмотря на впечатляющие успехи современной вычислительной техники, проблема работы алгоритмов синтеза изображений РСА в реальном времени также продолжает оставаться актуальной.

Продолжаются исследования по разработке эффективных алгоритмов обнаружения и оценки параметров движущихся целей на РЛИ. В начальной стадии

находяться роботи по совместному анализу РЛИ и изображений, полученных в оптическом и инфракрасном диапазонах.

Целью работы является разработка метода интеллектуализации обработки данных в бортовой аппаратуре системы ДЗЗ, который может обеспечить обработку результатов ДЗЗ в режиме реального времени.

Основной материал

Для обеспечения обработки получаемой информации в режиме реального времени на борту средств ДЗЗ высокого разрешения предлагается применять методы интеллектуальной обработки данных ДЗЗ. Для этого предлагается использовать систему, обобщенная схема которой приведена на рисунке 1.




Рис. 1 Обобщенная схема системы интеллектуальной обработки материалов ДЗЗ

На данном рисунке видно, что один и тот же набор данных поступает на вход бортового устройства обработки и параметрического анализатора, в котором определяются параметры этих данных. После этого параметры поступают на вход нейронной сети. В нейронной сети определяются вероятности оптимальности всех имеющихся алгоритмов обработки [3; 4; 5]. Далее выбирается тот алгоритм, который имеет наибольшую вероятность оптимальности, и он используется для обработки тех самых данных, которые подавались на вход системы автоматического выбора алгоритма обработки. В свою очередь, алгоритмы обработки результатов ДЗЗ также могут быть реализованы в нейросетевом базисе.

Рассмотрим, какие именно параметры более полно и качественно характеризуют данные. Параметры, отправляемые на вход нейронной сети, можно разделить на несколько классов по способу их расчета и по тому, какие характеристики данных они собой представляют. В данной работе предлагается использовать 3 класса параметров для блоков переменного размера: гистограммы интенсивностей пикселей, выборка коэффициентов вейвлет-преобразования и выборка коэффициентов дискретно-косинусного преобразования (ДКП).

В качестве первого класса используются гистограммы данных, определяемые по блокам пикселей различного размера. Будем рассматривать распределение элементов блока относительно среднего арифметического этих элементов в блоке. Эти гистограммы покажут, каким распределением обладают данные в зависимости от размера блоков. При этом на меньших блоках необходимо брать меньшее количество диапазонов для построения гистограммы, причем диапазоны необходимо распределить неравномерно, в соответствии с методом золотого сечения. В качестве примера использования [6] в классификаторе предлагается брать следующие размеры блоков и соответствующие им диапазоны:

– блок размером 16 элементов распределяется по 5 диапазонам. Пусть среднее арифметическое всех значений в этой выборке равно x . В этом наборе используются следующие значения: от минимального значения до $10/16 \cdot x$, от $10/16 \cdot x$ до $14/16 \cdot x$, от $14/16 \cdot x$ до $18/16 \cdot x$, от $18/16 \cdot x$ до $22/16 \cdot x$, от $22/16 \cdot x$ до максимального значения;

– блок размером 64 элемента распределяется по 9 диапазонам, распределенным аналогично;

– блок размером 1024 элемента распределяется по 17 диапазонам, распределенным аналогично.

В качестве второго класса входных параметров нейросетевого классификатора используются данные, получаемые при помощи дискретного вейвлет-преобразования Хаара для коэффициентов преобразования, полученных для блоков различной размерности.

В качестве третьего класса входных параметров нейросетевого классификатора используются данные, получаемые при помощи дискретного косинусного преобразования для коэффициентов преобразования, полученных для блоков различной размерности.

Для каждого алгоритма обработки нейросеть будет состоять из нескольких нейросетевых подклассификаторов. Каждый из подклассификаторов отвечает за определенный вид входов: гистограммные, вейвлетные, ДКП-входы. В результате нейросеть состоит из 3 нейросетевых подклассификаторов и одного выходного нейрона, их объединяющих. Схематически нейросетевой классификатор для каждого из алгоритмов обработки изображен на рисунке 2.

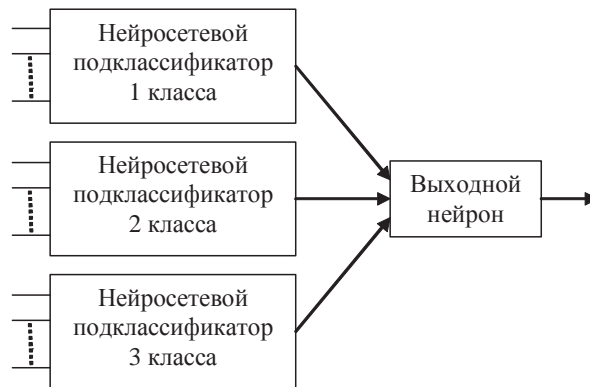


Рис. 2. Классификация параметров данных ДЗЗ, подаваемых на вход нейросети.

Предлагается структуру классификаторов определять в зависимости от выделенных признаков по предлагаемому алгоритму.

В общем случае нейронная сеть представляет собой набор адаптивных элементов (искусственных нейронов), имеющих непустое множество входов и связанных между собой синаптическими соединениями [7].

Базовым элементом нейронной сети является формальный нейрон, имеющий несколько входов и один выход. Каждому i -му входу ставится в соответствие весовой коэффициент (синаптический вес) w_i , что соответствует его значению. Дискриминантная функция (весовая функция) нейрона превращает взвешенные входы и подает их на функцию активации (передаточная функция), результат

вычисления которой является выходом нейрона. Таким образом, формальный нейрон реализует скалярную функцию векторного аргумента.

Как дискриминантные функции используются взвешенная сумма, взвешенное произведение, функция расстояния, а как функции активации – линейная, пороговая, сигмоидная, функция Гаусса, гиперболический тангенс и др. Как правило, применяются взвешенная сумма (как дискриминантная функция) и сигмоидная функция (как функция активации).

Математическая модель искусственного нейрона описывается соотношением:

$$y = \psi(\varphi(w, x)),$$

где y – значение сигнала на выходе нейрона;

ψ – функция активации;

φ – дискриминантная функция;

w – вектор, содержащий значения весовых коэффициентов и значение смещения (предельное значение);

x – вектор входных аргументов.

Таким образом, основными параметрами формальных нейронов являются: количество входов L ; значения весовых коэффициентов w_1, w_2, \dots, w_L ; значение смещения (порога) w_0 ; используемая дискриминантная функция; вид и параметры функции активации.

Как правило, количество входов, дискриминантная функция и функция активации определяются спецификой задачи. Поэтому параметрами формального настраиваемого нейрона являются значения весовых коэффициентов и значения смещения. Все модели искусственных нейронных сетей представляют собой совокупность нейронов, связанных между собой определенным образом. Основными различиями нейросетевых моделей являются способы связи нейронов между собой, а также механизмы и направления распространения сигналов по сети.

При решении реальных практических задач обработки результатов ДЗЗ предлагается применение нейросетей прямого распространения, которые имеют достаточно простую структуру. Многослойная нейросеть прямого распространения состоит из формальных нейронов. При этом внешний сигнал управляемых переменных x поступает только на входы нейронов первого слоя, выходы нейронов μ -го слоя поступают только на входы $(\mu + 1)$ -го слоя, а выходы нейронов последнего M -го слоя являются выходами сети.

Параметрами такой сети являются: количество слоев сети M ; количество нейронов на каждом слое N_1, N_2, \dots, N_M ; матрица связей между нейронами сети; параметры формальных нейронов, образующих сеть.

В силу теорем Колмогорова-Арнольда и Хехт-Нильсена [7] трех слоев достаточно для получения эффективного решения с помощью нейронных сетей прямого распространения. Поэтому при поиске оптимальной структуры нейросети актуальны настройки таких параметров, как количество нейронов на каждом слое, матрица связей между нейронами сети, а также выбор параметров нейронов, образующих сеть.

Таким образом, нейросеть может быть представлена в виде многомерной функции f , зависящей от структуры и параметров модели:

$$y = f(w, x),$$

где w – множество значений весовых коэффициентов и сдвигов нейросети;
 x – вектор аргументов, принадлежащих пространству признаков.

Пусть задана начальная выборка исходных данных в виде:

$$\begin{aligned} X &= \{X_1, X_2, \dots, X_L\} = \{X_i\}, \\ Y &= \{y_1, y_2, \dots, y_m\} = \{y_p\}, \end{aligned}$$

где X – набор значений признаков, характеризующих исследуемый объект или процесс, Y – массив значений выходного параметра в заданной выборке; $X_i = \{x_{ip}\}$ – i -й признак в выборке, $i = 1, 2, \dots, L$; x_{ip} – значение i -го признака для p -го экземпляра выборки, $p = 1, 2, \dots, m$; y_p – значение прогнозируемого параметра для p -го экземпляра; L – общее количество признаков в исходном наборе; m – количество экземпляров выборки.

Тогда задача синтеза нейросетевой модели [8] по учебной выборке заключается в построении нейросети вида:

$$НС = НС(C, W, B, D, AF),$$

для которой:

$$\xi(НС, X, Y) \rightarrow \min,$$

где C – матрица, определяющая наличие синаптических связей между элементами сети (рецепторами, нейронами) $W = W(C)$ – матрица весовых коэффициентов, соответствующие присутствующим в сети НС связям; $B = B(C)$ – вектор смещений нейронов сети; $D = D(C)$ – вектор дискриминантных функций нейронов; $AF = AF(C)$ – вектор функций активации нейронов сети; $\xi(НС, X, Y)$ – критерий, определяющий эффективность использования нейросети НС для аппроксимации зависимости между набором входных параметров X и соответствующим ему вектором значений выходного параметра Y .

Как правило, в качестве критерия оптимальности нейросетей принимают среднеквадратичную ошибку:

$$\xi = \sum_{p=1}^m (y_p - y(НС, Z_p))^2,$$

где Z_p – набор значений признаков для p -го экземпляра; $(НС, Z_p)$ – значение выхода нейросетей НС, вычисленное для набора значений Z_p .

Для построения эффективной нейросетевой модели, наилучшим образом позволяющей аппроксимировать исследуемую зависимость, необходимо выполнить структурный и параметрический синтез такой модели на основе наиболее информативного набора признаков.

Процесс построения эффективных нейросетей на основе известной выборки исходных данных может быть представлен в виде последовательности этапов [9]:

- выбор системы информативных признаков;
- структурный синтез;
- параметрический синтез;

– оптимизация построенных нейросетей.

Эти этапы приведены в соответствие с хронологией их выполнения, однако результаты, полученные на некоторых поздних этапах, могут приводить к необходимости возврата к предыдущему этапу. В связи с высокой вычислительной сложностью и неоднозначностью получаемых результатов на всех предполагаемых этапах построения нейросетей предлагается использовать эволюционные методы [10; 11].

Выделение наиболее значимой комбинации информативных признаков является тяжелой и ресурсоемкой задачей, поскольку связано с необходимостью комбинаторного перебора. В наше время предложены различные методы выделения набора признаков, среди которых наибольшее распространение получили: метод полного перебора; поиск в глубину; поиск в ширину; метод ветвей и границ или сокращенный поиск в глубину; метод группового учета аргументов или сокращенный поиск в ширину; метод последовательного добавления признаков; метод последовательного удаления признаков; метод поочередного добавления и удаления признаков; ранжирование признаков; кластеризация признаков; случайный поиск с адаптацией; эволюционный поиск.

Этап структурного синтеза нейросетей является важнейшим заданием при построении нейросетей [8; 9], поскольку на этом этапе формируется топология связей, избираются функции активации нейронов, далее определяют принцип функционирования сети и ее эффективность для решения исследуемой задачи. Так, нейросети, имеющие небольшое количество нейронов и линейные функции активации, как правило, из-за своих ограниченных аппроксимационных способностей не позволяют решать реальные практические задачи. В то же время выбор избыточного количества нейронов в сети приводит к проблеме переобучения и потери аппроксимационных свойств нейросетей [12].

Задача структурного синтеза нейросетей заключается в поиске структуры сети вида $HC = HC(C, AF)$, для которой $\xi(HC, X, Y) \rightarrow \min$, где $C = C(L, A)$ – матрица, определяющая наличие синаптических связей между элементами сети (рецепторами, нейронами), A – максимально допустимое количество нейронов в сети.

Задача выбора структуры сводится к поиску математическими методами оптимизации по апостериорной данными с использованием имеющейся дополнительной информации. Использование данных методов допускает формирование определенных гипотез о топологии сети, которые, как правило, проверяют на основе критериев, базирующихся на достижении компромисса между сложностью модели и точностью его оценки, а также поиске модели, наиболее устойчивой к варьированию состава данных, на основе которых она оценивается.

На этапе параметрического синтеза происходит обучение нейросетевой модели, то есть подбираются такие значения весовых коэффициентов сети, а иногда и параметров функций активации, при которых сеть наиболее эффективным путем позволяет решать поставленную задачу [12]. Задача параметрического синтеза нейросетей заданной структуры состоит в поиске такого набора значений весовых коэффициентов и порогов, при котором достигается минимум критерия ошибки нейросетей. Обучение нейронной сети заключается в изменении значений синаптических весов в результате последовательного предъявления экземпляров обучающей выборки.

На возможность использования нейросетевых моделей на практике существенно влияют сложность построенной нейросети и скорость вычисления значения целевого параметра по набору данных, не входящих в обучающую выборку. Поэтому актуальным является упрощение структуры синтезированной нейронной сети. Задача оптимизации построенной нейросети вида $НС(C, W, B, D, T)$, заключается в поиске таких новых значений $C' \subseteq C, W', B', D', T'$, при которых достигаются оптимальные значения заданных критериев оптимальности $\xi_1, \xi_2, \dots, \xi_K$, учитывающие основные характеристики нейросетей, где K – количество целевых критериев.

В наше время существует два основных подхода к оптимизации структуры синтезированной нейросетевой модели: методы удаления связей; методы удаления нейронов.

Все вышеперечисленные этапы создания элементов нейроструктур системы могут быть выполнены с использованием эволюционных методов.

Выводы

Предложен метод интеллектуальной обработки материалов ДЗЗ, позволяющий обеспечить режим реального времени для бортовых устройств систем ДЗЗ высокого разрешения и базирующийся на использовании нейросетевых структур при выборе и реализации алгоритмов обработки результатов ДЗЗ. В свою очередь, построение элементов нейроструктур интеллектуальной системы предлагается проводить с помощью эволюционных методов. Конкретизация реализации структурных элементов интеллектуальной системы обработки материалов зондирования и методов ее построения является целью дальнейших исследований автора.

СПИСОК ИСПОЛЬЗОВАННЫХ ИСТОЧНИКОВ

1. Бакланов А.И. Анализ состояния и тенденции развития систем наблюдения высокого и сверхвысокого разрешения / А.И. Бакланов // Вестник Самарского государственного аэрокосмического университета. – 2010. – № 2. – С. 80–91.
2. Подорожняк А.О. Анализ форматов данных систем дистанционного зондирования Земли / А.О. Подорожняк // Сучасна спеціальна техніка. – 2013. – № 4 (35). – С. 32–40.
3. Гонсалес Р. Цифровая обработка изображений / Р. Гонсалес, Р. Вудс. – М.: Техносфера, 2005. – 1072 с.
4. Подорожняк А.О. Локалізація об'єкта пошуку на поточному зображенні навігаційної системи з радіометричними датчиками / А.О. Подорожняк, О.І. Тимочко, Ю.Б. Васильев // Збірник наукових праць Харківського університету Повітряних Сил. – Харків: ХУ ПС, 2007. – Вип. 1 (13) – С. 47–50.
5. Подорожняк А.А. Обработка изображений в системах дистанционного зондирования Земли / А.А. Подорожняк, Р.А. Москаленко // Проблемы информатики і моделювання. Тезиси тринадцятої міжнародної науково-технічної конференції. Секція “Молоді вчені”. – Харків: НТУ “ХПІ”. – 2013. – С. 36.
6. Коробков С.В. Выбор алгоритма сжатия большого объема данных на суперкомпьютерах с применением нейронных сетей / С.В. Коробков // Вопросы радиоэлектроники. Электронная вычислительная техника. – 2012. – № 2. – С. 48–51.
7. Хайкин С. Нейронные сети : полный курс / С. Хайкин. – СПб: Издательский дом “Вильямс”, 2006. – 1104 с.
8. Субботин С.А. Синтез распознающих нейро-нечетких моделей с учетом информативности признаков / С.А. Субботин // Нейрокомпьютеры : разработка, применение. – 2006. – № 10. – С. 50–56.

9. Олейник А.А. Автоматизированная система построения нейросетей на основе эволюционного подхода / А.А. Олейник // Радиоэлектроника і молодь в ХХІ сторіччі : Матеріали 12-го міжнародного молодіжного форуму. – Харків : ХНУРЕ, 2008. – Ч. 2. – С. 162.

10. Zhengjun L., Aixia L., Changyao W., Zheng N. Evolving neural network using real coded genetic algorithm for multispectral image classification // Future Generation Computer Systems. – 2004. – № 20. – P. 1119–1129.

11. Подорожняк А.А. Использование генетических алгоритмов для оптимизации структуры нейросети обработки изображений / А.А. Подорожняк // Системи обробки інформації. – Харків : НАНУ, ПАНМ, ХВУ. – Вип. 1 (17). – 2002. – С. 241–243.

12. Галушкин А.И. Нейронные сети. Основы теории / А.И. Галушкин. – М. : Горячая Линия – Телеком, 2012. – 496 с.

Отримано 04.02.2014