

Определение с помощью нейросетевого алгоритма количественных характеристик зондируемой поверхности, используя данные многоспектральной и радиолокационной съемки Земли

А.А. Ильин¹, В.В.Егоров², А.П.Калинин³, И.Д.Родионов⁴

¹Научно технический центр «Реагент»,
119991 Москва, ул. Косыгина, д.4;

²Институт космических исследований РАН,
117997 Москва, Профсоюзная 84/32,

E-mail:victor_egorov@mail.ru

³Институт Проблем Механики им. А.Ю. Ишлинского РАН,
19526 Москва, проспект Вернадского 101, корп. 1;

⁴Институт химической физики им. Н.Н. Семенова РАН,
119991 Москва, ул. Косыгина, д.4.

Предложено использование алгоритма нейронных сетей, обеспечивающего эффективную реализацию методов определения количественных характеристик зондируемой поверхности, используя данные многоспектральной и радиолокационной съемки Земли. Полученные по результатам наземных исследований данные разделялись на тестовые и обучающие, по которым производилось обучение нейросети для последующего решения обратной задачи. Проверка работоспособности разработанных методов показала их высокое качество - точность классификации составила 0,98, а величина среднеквадратичной ошибки оценки биометрических параметров конопли находилась в пределах 3-6%.

Ключевые слова: многоспектральная съемка, дистанционное зондирование, нейронная сеть, обучение, верификация, точность, данные *in situ*

Оценка количественных характеристик зондируемой поверхности на основании данных дистанционного зондирования и, в частности, растительности Земли – один из важнейших разделов тематической обработки данных дистанционного зондирования Земли (ДЗЗ).

Решение проблемы повышения эффективности обработки данных ДЗЗ возможно с помощью привлечения для этих целей алгоритма искусственных нейронных сетей (нейросетей). Основное преимущество нейросетей – возможность значительного повышения скорости вычислений. В частности, для решения задачи оценки количественных характеристик зондируемой поверхности по спектральным данным могут применяться нейронные сети с прямой связью (feed-forward), обучаемые по методу обратного распространения ошибок (backpropagation). Используемым нейросетевым алгоритмом является перцептрон [1], а способ его обучения (метод обратного распространения ошибки) представляет собой градиентный алгоритм обучения, который применяется для минимизации среднеквадратического отклонения текущего выхода и желаемого выхода нейросети.

Известен способ ДЗЗ, включающий съемку поверхности земли с помощью средств дистанционного спектрального зондирования, выбор обучающих и тестовых участков с последующим обучением нейросети [2]. Такой способ применяется для качественного определения характеристик зондируемой поверхности Земли.

Недостатком этого способа является невозможность его применения для определения количественных характеристик, что требуется для решения многих практических хо-

зяйственных задач, например, для определения проективного покрытия растительности на исследуемом участке земной поверхности [3-6].

В настоящей работе описывается способ оценки количественных характеристик зондируемой поверхности на основании данных дистанционного зондирования (многоспектрального и радиолокационного) и, в частности, количественных характеристик растительности на поверхности Земли. Он обеспечивает получение необходимых количественных характеристик исследуемой поверхности земли быстро и с невысокими трудозатратами в результате отказа от трудоемкой процедуры определения инвариантных функций связи за счет осуществления обучения нейронной сети по известным обучающим участкам, расположенным в пределах обрабатываемого изображения зондируемой поверхности.

Для обучения нейросети данные разделяют на обучающие и тестовые. После этого производят обучение нейросети с целью использования ее для определения искомой количественной характеристики по данным ДЗЗ. По обучающим участкам выполняют настройку (обучение) нейросети, то есть ее внутренние параметры (веса) подбираются так, чтобы ошибка определения искомых характеристик растительности была минимальна. Одновременно осуществляют контроль точности определения указанных характеристик на тестовых участках. Процесс обучения можно наблюдать на графиках зависимости упомянутых ошибок от шага обучения. Затем обученную нейросеть применяют для оценки количественных характеристик по результатам ДЗЗ.

Подобный контроль обучения позволяет определить, когда сеть настроилась на искомую количественную характеристику. В случае успешного обучения также оказывается известна ошибка определения количественной характеристики на тестовых участках. После обучения нейросеть применяют для определения искомой количественной характеристики в пределах всего снимка данных ДЗЗ.

Математические операции при реализации предлагаемого способа таковы [2]. Пусть имеется обучающая выборка $\{\mathbf{x}_i\}$, $i = 1, \dots, k$; здесь \mathbf{x}_i – векторы из пространства R^N . В качестве таких векторов используют спектры i -ых пикселов спектральной съемки. Обозначим $y_i = y_i(\mathbf{x}_i)$ – численное значение исследуемой характеристики i -го пикселя. Предполагается, что для элементов выборки априорно известны значения оцениваемой количественной характеристики $\{y_i\}$, $i = 1, \dots, k$. Задача состоит в том, чтобы построить аппроксимацию неизвестной зависимости $y = y(\mathbf{x})$ для любой точки из ее области определения, которая обозначена как X . Множество X состоит из полного набора рассматриваемых векторов (спектров зондируемой поверхности) R^N .

Нейросеть, обычно называемая в литературе перцептроном (однослойным перцептроном) с n нейронами скрытого слоя, реализует следующую аппроксимацию искомой зависимости:

$$y(\mathbf{x}) = C_0 + \sum_{j=1}^n C_j \sigma(a_j \cdot \mathbf{x} + b_j) \quad (1)$$

где a_j – вектор той же размерности, что и вектор \mathbf{x} , C_j и b_j – числа, выражение $a_j \cdot \mathbf{x}$ означает скалярное произведение. Функция σ – так называемая сигмоидная функция

$$\sigma(z) = (1 + e^{-z})^{-1}.$$

Числа C_j и b_j и вектора \mathbf{a}_j подбираются в процессе обучения перцептрона (в теории нейросетей эти параметры называются весами). Само обучение производится по набору $\{\mathbf{x}_i\}$, $\{y_i\}$, $i = 1, \dots, k$ путем минимизации выражения среднеквадратичной ошибки аппроксимации, а именно функционала

$$d = \sum_{i=1}^k (y(\mathbf{x}_i) - y_i)^2.$$

Как известно, наиболее распространенными методами минимизации функционалов указанного типа являются хорошо известные градиентные методы.

Для определения количественной характеристики зондируемой поверхности оказалось эффективным произвести предварительной масштабирование спектральной информации. Эта стандартная процедура заключается в переходе от векторов $\{\mathbf{x}_i\}$, к векторам $\{\mathbf{z}_i\}$, $i = 1, \dots, k$ с элементами

$$z_i^l = \frac{x_i^l - x_{\min}^l}{x_{\max}^l - x_{\min}^l}, \quad l = 1, \dots, n,$$

где x_i^l – l -я компонента вектора \mathbf{x}_i (l -ый спектральный канал), z_i^l – l -я компонента вектора \mathbf{z}_i , x_{\max}^l , x_{\min}^l – максимальное и минимальное значение l -го спектрального канала по всему обучающему набору $\{\mathbf{x}_i\}$. Для удобства работы в качестве **n+1** компоненты в векторе \mathbf{z}_i всегда добавляется единичный элемент

$$z_i^{n+1} = 1.$$

После указанных процедур выражение (1) оказалось возможным заменить на

$$y = C_0 + \sum_{j=1}^n C_j \sigma(\mathbf{a}_j \cdot \mathbf{z}),$$

где вектора \mathbf{a}_j имеют ту же размерность, что и вектор \mathbf{z} . Обучение перцептрона производится хорошо известным методом обратного распространения ошибки.

Способ оценки количественной характеристики зондируемой поверхности на основании спектральных данных был апробирована на примере решения задач оценки характеристик лесов Московской области по данным многоспектральной и радиолокационной съемок.

На рис. 1 показан многоспектральный снимок высокого разрешения участка Московской области, взятый из интернет-системы Google Earth. Информация с этого снимка использовалась для выбора обучающих участков для определения проективного покрытия леса по многоспектральным и радиолокационным данным радара Spaceborne Imaging Radar (SIR-C) (<http://southport.jpl.nasa.gov/sir-c/>)



Рис. 1. Участок Московской области, использованный для определения проективного покрытия леса

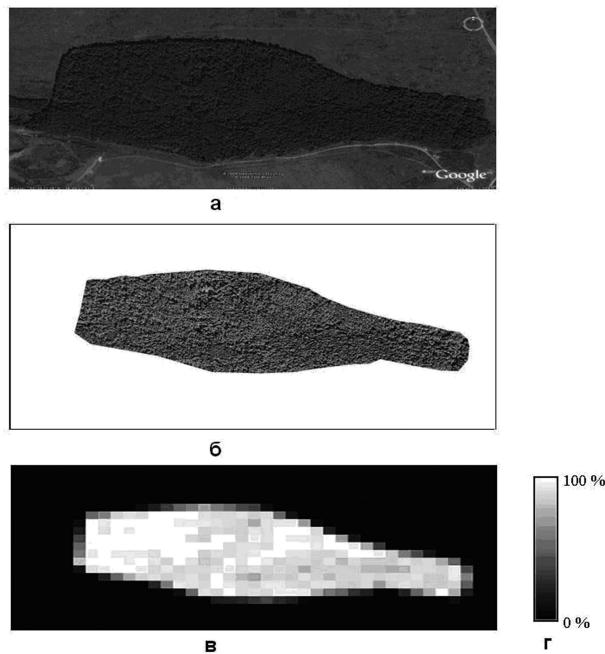


Рис. 2. Пример получения карты проективного покрытия на одном из обучающих участков: а – исходный фрагмент снимка, полученного с ИСЗ; б – выделенный участок фрагмента, использованный для обработки; в – результат определения проективного покрытия; г – шкала соответствия градаций серого цвета числовым значениям интенсивности проективного покрытия

На рис. 2 показано последовательность выделения одного из обучающих участков и формирования на нем карты проективного покрытия леса по RGB-изображениям высокого разрешения данных ИСЗ QuickBird: а – исходный фрагмент снимка; б – выделенный участок, занятый лесным массивом и использованный для обработки; в – карта проективного покрытия леса обучающего участка. Формирование карты проективного покрытия леса (рис. 2в) проводилось посредством выделения на изображении обучающего участка (рис. 2б) крон деревьев, подсчета их площадей на каждом из локальных (состоящим из нескольких пикселов) фрагментов обучающего участка, и отнесения результата к площади этого фрагмента. Величина проективного покрытия показана на рис. 2в с помощью оттен-

ков серого цвета. Шкала соответствия градаций серого цвета числовым значениям проектного покрытия приведена на рис. 2г. На рис. 3 слева показаны все сформированные обучающие участки для определения проектного покрытия леса. Справа на рисунке показано расположение обучающих участков (выделено черным кружком) на многоспектральном изображении с ИСЗ QuickBird.

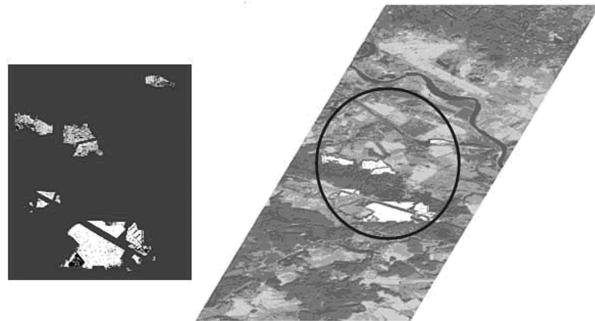


Рис. 3. а- сформированные обучающие участки для определения проектного покрытия леса и б – расположение обучающих участков на RGB снимке мультиспектральных спутниковых данных высокого разрешения с Quickbird

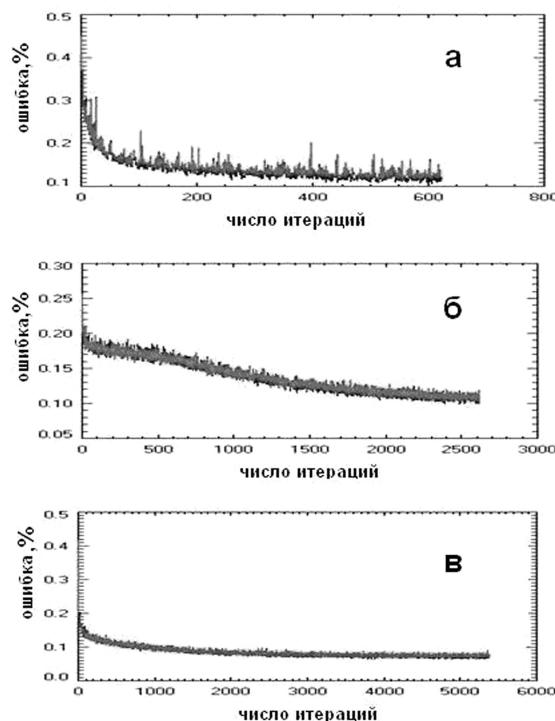


Рис. 4. Процесс обучения нейросетевого алгоритма для определения проектного покрытия леса:
 (а) – только по гиперспектральным данным; (б) – только по радиолокационным данным;
 (с) – совместная обработка гиперспектральных и радиолокационных данных

Для оценки эффективности процесса обучения нейросетевого алгоритма определения проектного покрытия лесов были вычислены кривые ошибок в зависимости от числа итераций, выполняемых перцептроном.

На рис. 4 показаны кривые ошибок определения проектного покрытия леса: а – только по гиперспектральным данным; б – только по радиолокационным данным; в – при совместной обработке гиперспектральных и радиолокационных данных. Черные кривые это кривые ошибок при определении проектного покрытия перцептроном на обучающих участках, красные кривые – это ошибки при определении проектного покрытия на тестовых участках.

На основе полученных в работе результатов можно констатировать следующее:

- все кривые ошибок монотонно спадают, что свидетельствует о хорошей обучаемости перцептрона;
- величины ошибки оценки проективного покрытия леса по многоспектральным данным от числа итераций спадают несколько быстрее чем аналогичные ошибки оценки по данным радиолокатора SIR-C;
- совместное использование многозональных и радиолокационных данных приводит к снижению ошибки по сравнению с многозональными данными.

Литература

1. Галушкин А.И. Нейрокомпьютеры и их применение. Сб. докладов Пятой всерос. конф.// М.: Радио и связь. 1999, 484 с.
2. Morton J. Canty. Image analysis, classification and change detection in remote sensing: with algorithms for ENVI/IDL // CRC Press Tailor & Francis group. 2007. P. 143-202
3. Saich P., Lewis P., Disney M., Thackrah, G. Comparison of HyMap/E-SAR data with models for optical reflectance and microwave scattering from vegetation canopies // Proc. Int. Symp. Retrieval of Bio- and Geophysical parameters from SAR data for Land Applications. Sheffield Sept. 2001 (ESA SP-475, Jan. 2000).
4. Lewis P. Three-dimensional plant modelling for remote sensing simulation studies using the Botanical Plant Modelling System // Agronomie: Agriculture and Environment.1999. V.19. No.3-4. P.185-210.
5. Нильсон Т, Кууск А. Приближенные аналитические формулы для расчета коэффициентов спектральной яркости сельскохозяйственной растительности // Исслед. Земли из космоса. 1984. № 5. С. 76-83.
6. Oh Yisok, Hong Jin-Young, Lee Sung-Hwa. A simple microwave backscattering model for vegetation canopies // J. of the Korea electromagnetic engineering soc. 2005. V. 5. № 4. P. 183-188.

Using the neural network algorithm for determination of qualitative features of remote sensed Earth surface on the base of multispectral and radar data

A.A. Ilyin¹, V.V. Egorov², A.P. Kalinin³, I.D. Rodionov⁴

¹Joint Stock Company, Research and Development Center "Reagent",
119991 Moscow, 4 Kosygina str.;

²Space Research Institute RAS,

117997 Moscow, 84/32 Profsoyuznaya str.,
E-mails: victor_egorov@mail.ru;

³A.Ishlinsky Institute for Problems in Mechanics RAS,
Russia 119526 Moscow, bld. 1, 101 Vernadskogo avenue;

⁴N.N.Semenov Institute of Chemical Physics,
119991 Moscow, 4 Kosygina str.

It is proposed to use neural networks for definition of qualitative features of remote sensed Earth surface on the base of multispectral and radar data. The received *in situ* data were divided on the train and test one. These data were used for the neural networks training and following inverse problem solution. The verification of neural network algorithms demonstrated rather high quality – clustering analysis accuracy was equal 0.98 and root-mean-square error of the cannabis biometric parameters determination was in the range of 3-6%.

Key words: multispectral survey, remote sensing, neural network, training, verification, accuracy, *in situ* data.