

ГЕОЭКОЛОГИЯ

Е.А. Чернецова

АВТОМАТИЗАЦИЯ ПРОЦЕССА РАСПОЗНАВАНИЯ НЕФТЯНЫХ ПЯТЕН НА РАДИОЛОКАЦИОННОМ ИЗОБРАЖЕНИИ МОРСКОЙ ПОВЕРХНОСТИ

Е.А. Chernetsova

AUTOMATION OF THE OIL SPILL IDENTIFICATION PROCESS ON THE MARINE SURFACE RADAR IMAGE

Обсуждается метод обработки изображений, представленных в виде массива величин интенсивности пикселей с помощью нейронных сетей (НС), в котором в качестве входных параметров НС используются физические и геометрические характеристики объекта, а выходной параметр представляет собой вероятность принадлежности темного объекта к заданному классу изображений..

A method of imagery processing is discussed, when imagery is represented in the form of an array of intensity of pixels, with the help of neural networks (NN), where the physical and geometrical properties of an object are taken as input parameters of NN, and the output parameter is the affiliation of the dark object with the preset class of imagery.

Присутствие нефтяной пленки на поверхности моря уменьшает малые волны из-за возрастающей вязкости верхнего слоя и заметно уменьшает энергию обратного рассеивания сигнала, поэтому на радиолокационном изображении возникают темные области. Однако на изображении, полученном с помощью радиолокатора, могут возникнуть также затемнения, вызванные наличием локальных ветров низкой скорости над морской поверхностью или присутствием натуральных морских сликов.

Нефтяные пятна проявляют на радиолокационном изображении большую прерывистость по сравнению с цветом фона, в основном, за счет своей вязкости. Основываясь на этом, можно предложить следующий алгоритм обработки радиолокационных изображений:

- выделение области изображения, содержащей темный объект
- вычисление физических и геометрических характеристик объекта
- классификация объекта как нефтяного пятна или ветрового слика

Алгоритмы классификации базируются в основном на байесовских или статистических решениях. Недостатком этих методов является сложность вы-

работки классификационных правил из-за вовлеченности в этот процесс многих нелинейных и плохо изученных факторов. Эти сложности можно преодолеть при использовании алгоритмов нейронных сетей. Использование инструментария нейронных сетей в дистанционном зондировании часто бывает эффективным благодаря тому, что он позволяет одновременно управлять преобразованием многомерного пространства входов в определенный выход и справиться со сложным статистическим поведением. Нейронные сети, в отличие от статистических классификаторов, не требуют точно определенного отношения между входным и выходным векторами, так как формируют свои собственные отношения вход-выход из набора данных, используя построение границ решений. Вход нейронной сети состоит из набора данных, содержащих информацию об области, кажущейся нефтяным пятном, а выход дает вероятность, с которой этот объект может быть реальным нефтяным пятном.

Для обнаружения нефтяных пятен достаточным является разрешение $100 \text{ м} \times 100 \text{ м}$. Пример обрабатываемых радиолокационных изображений приведен на рис. 1, *а*, *б*.




Рис. 1. *а* – изображение нефтяного пятна; *б* – изображение природного сика

Анализ радиолокационного изображения начинается с определения границ темного объекта. Анализируется его общая поверхность и строится гистограмма, в которой по оси абсцисс откладывается уровень интенсивности серого цвета на изображении, а на оси ординат – количество пикселей. Типичная форма такой гистограммы приведена на рис. 2, *а*, *б*. Гистограмма изображения нефтяного пятна имеет два пика, меньший из которых сосредоточен в районе среднего значения рассеяния темного объекта, больший сосредоточен в районе среднего значения фона. Локальный минимум между пиками используется для фрагментации изображения. Для этой цели выбирается самый темный пиксель области в качестве точки старта и затем наращивается область вокруг

него, определяя границы пятна, пока соседние пиксели не имеют значения оттенка серого, больше порога, который вычислен из локального минимума, полученного на предыдущем шаге.

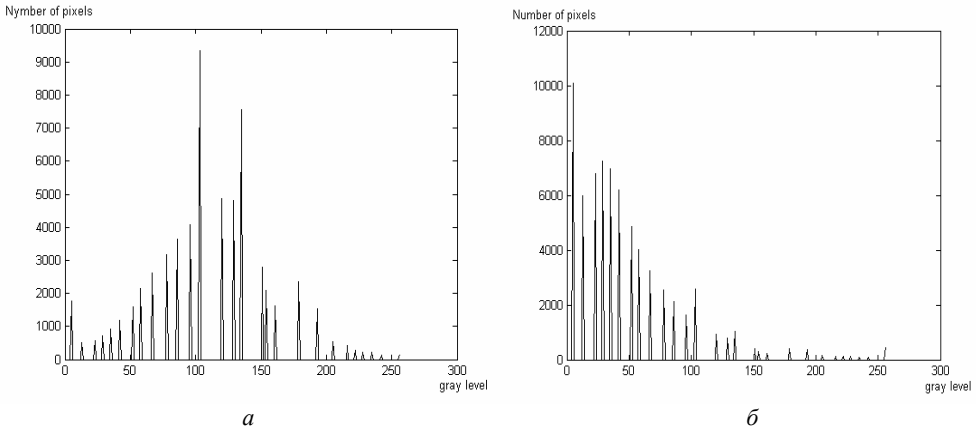


Рис. 2. *a* – гистограмма нефтяного пятна; *б* – гистограмма природного сика

Параметры, вычисляемые для темного объекта, которые затем используются для классификации, касаются геометрии объекта (протяженности и формы) и его физического поведения (интенсивности обратного рассеяния пикселей, принадлежащих объекту по отношению к фону и по отношению к области, которая окружает объект).

Такими параметрами являются:

1. Размер области, на которой наблюдается объект (m^2) A ;
2. Периметр P – длина границ объекта, км;
3. Сложность, определяемая как

$$C = \frac{P}{2\sqrt{\pi A}} . \tag{1}$$

Этот параметр обычно принимает малые численные значения для районов с простой геометрией и большие значения для сложных геометрических районов.

4. Протяженность S . Этот параметр получен с помощью метода главных компонент [Глинский, 2002] векторов, составляющими которых являются координаты пикселей, принадлежащих объекту. Если λ_1 и λ_2 являются двумя собственными числами, связанными с вычисляемой матрицей ковариации и $\lambda_1 > \lambda_2$, значение протяженности

$$S = \frac{100\lambda_2}{\lambda_1 + \lambda_2} . \tag{2}$$

Численное значение S мало для протяженных и тонких объектов и велико для объектов, чья форма близка к окружности.

5. Стандартное отклонение объекта (**OSd**) – стандартное отклонение (в дБ) значений интенсивности пикселей, принадлежащих темному объекту.

6. Стандартное отклонение фона (**BSd**) – стандартное отклонение (в дБ) значений интенсивности пикселей, принадлежащих интересующему району, окружающему темный объект.

7. Максимальная контрастность (**ConMax**) – отличие (дБ) между средним значением фона и самым малым значением вне темного объекта.

8. Средняя контрастность (**ConMe**) – отличие (дБ) между средним значением фона и средним значением интенсивности пикселей темного объекта.

9. Максимальный градиент (**GMax**). – максимальный граничный градиент (дБ).

10. Средний градиент (**GMe**) – средний граничный градиент (дБ)

11. Стандартное отклонение градиента (**GSd**) – стандартное отклонение в дБ значений граничного градиента.

Нефтяные пятна имеют меньшую сложность и более тонкую форму, чем ветровые слики. Средние значения градиента вдоль границ у нефтяного пятна выше, чем у ветровых сликов, которые обычно протяженнее, чем нефтяные пятна.



Рис. 3. Основное окно программы

Для обнаружения нефтяных пятен в пакете Matlab [Дьяков, 2004] была разработана программа, основное окно которой представлено на рис. 3. Интерфейс программы предусматривает возможность ввода пользователем разрешения снимка (чаще всего это 100×100 м). Для вывода на экран гистограммы используется отдельная кнопка.

Алгоритм обработки изображения заключается в следующем:

1. По гистограмме находится порог обнаружения (интенсивность пиксе-

лей) для выделения области-кандидата на признание пятном.

2. Производится выделение скоплений пикселей со значением, меньшим или равным пороговому. При этом необходимым условием является наличие минимум 40 точек в одной области. Для подсчёта количества пикселей используется следующий алгоритм: вокруг одной точки (с интенсивностью меньше порогового значения) производится поиск по соседним точкам. Если находится хотя бы одна точка, удовлетворяющая пороговому значению, область поиска увеличивается на один пиксель во все стороны. Это продолжается до тех пор, пока не обнаружится так называемая “мёртвая зона” (по периметру не содержится пикселей, подходящих по пороговому значению, либо произошёл выход за границы файла-изображения). При ее обнаружении программа перемещается на следующую точку.

3. Производительность программы обеспечивается тем, что в уже проверенных областях значения интенсивности пикселей принудительно изменяются (делаются больше порогового). Это исключает повторное сканирование и намного сокращает время обработки изображения.

4. Используется фильтрация изображения перед обработкой (убираются заведомо не подходящие для поиска точки – отдельные малые скопления).

5. Применяется сглаживание изображения после первичной обработки (“закрашиваются одиночные и двойные “внутренние” пиксели”).

Поясним алгоритм вычисления протяженности S темного объекта. Для этого рассмотрим изображение пятна на поверхности в терминах координат пикселей (рис. 4).

	координата x								
ко-	1,1	1,2	1,3	1,4	1,5	1,6	1,7	1,8	1,9
ор-	2,1	2,2	2,3	2,4	2,5	2,6	2,7	2,8	2,9
ди-	3,1	3,2	3,3	3,4	3,5	3,6	3,7	3,8	3,9
на-	4,1	4,2	4,3	4,4	4,5	4,6	4,7	4,8	4,9
та	5,1	5,2	5,3	5,4	5,5	5,6	5,7	5,8	5,9
	6,1	6,2	6,3	6,4	6,5	6,6	6,7	6,8	6,9
у	7,1	7,2	7,3	7,4	7,5	7,6	7,7	7,8	7,9
	8,1	8,2	8,3	8,4	8,5	8,6	8,7	8,8	8,9
	9,1	9,2	9,3	9,4	9,5	9,6	9,7	9,8	9,9

Рис. 4. Протяженное и тонкое пятно на поверхности в терминах координат пикселей

Координаты пикселей, принадлежащих пятну представляют собой двумерный вектор \mathbf{a} :

$$\mathbf{a} = [2\ 2;3\ 3;4\ 3;4\ 4;5\ 4;5\ 5;6\ 5;6\ 6;7\ 6;7\ 7].$$

Рассчитываем матрицу ковариации \mathbf{b} вектора \mathbf{a} :

$$\mathbf{b} = \text{cov}(\mathbf{a}).$$

Рассчитываем вектор с собственных чисел матрицы ковариации \mathbf{b} :

$$\mathbf{c} = \text{eig}(\mathbf{b}).$$

Получаем следующие значения собственных чисел:

$$c = 0,1298 - \text{это величина собственного числа } \lambda_2;$$

$$5,1369 - \text{это величина собственного числа } \lambda_1.$$

Рассчитываем протяженность по формуле (2):

$$S = 100 \Delta 0,1298 / (0,1298 + 5,1369) = 2,4645.$$

На рис. 5 изображен темный объект, который по форме больше стремится к окружности.

Координаты пикселей, принадлежащих пятну, представляют собой двумерный вектор **a1**:

$$\mathbf{a1} = [2 \ 2; 2 \ 3; 2 \ 4; 2 \ 5; 3 \ 2; 3 \ 3; 3 \ 4; 3 \ 5; 4 \ 2; 4 \ 3; 4 \ 4; 4 \ 5; 4 \ 6; 4 \ 7; 4 \ 8; 5 \ 2; 5 \ 3; 5 \ 4; 5 \ 5; 5 \ 6; 5 \ 7; 5 \ 8; 6 \ 4; 6 \ 5; 6 \ 6; 6 \ 7; 6 \ 8; 7 \ 6; 7 \ 7; 7 \ 8].$$

Вычисляем ковариационную матрицу двумерного вектора **a1**:

$$\mathbf{b1} = \text{cov}(\mathbf{a1}).$$

Вычисляем собственные числа ковариационной матрицы **b1**:

$$c1 = 1,3269 - \text{это величина собственного числа } \lambda_2$$

$$4,8950 - \text{это величина собственного числа } \lambda_1$$

	координата x								
ко-	1,1	1,2	1,3	1,4	1,5	1,6	1,7	1,8	1,9
ор-	2,1	2,2	2,3	2,4	2,5	2,6	2,7	2,8	2,9
ди-	3,1	3,2	3,3	3,4	3,5	3,6	3,7	3,8	3,9
на-	4,1	4,2	4,3	4,4	4,5	4,6	4,7	4,8	4,9
та	5,1	5,2	5,3	5,4	5,5	5,6	5,7	5,8	5,9
	6,1	6,2	6,3	6,4	6,5	6,6	6,7	6,8	6,9
y	7,1	7,2	7,3	7,4	7,5	7,6	7,7	7,8	7,9
	8,1	8,2	8,3	8,4	8,5	8,6	8,7	8,8	8,9
	9,1	9,2	9,3	9,4	9,5	9,6	9,7	9,8	9,9

Рис. 5. Темный объект, по форме стремящийся к окружности в терминах пикселей

Рассчитываем протяженность второго темного объекта на плоскости:

$$S1 = 100 \cdot 1,3269 / (1,3269 + 4,895) = 21,3263.$$

Сравнивая $S = 2,4645$ и $S1 = 21,3263$ видим, что выполняется утверждение о том, что численное значение S мало для протяженных и тонких объектов и велико для объектов, чья форма близка к окружности.

При обработке значений интенсивности объекта значения большие порогового, заменялись на пороговые, так как они появлялись вследствие “осреднения” изображения.

Расчёт площади заключается в умножении количества пикселей, принадлежащих темному объекту, на площадь одного пикселя, при этом разрешение изображения задаётся пользователем. Периметр изображения также напрямую связан с размером одного пикселя изображения.

Автоматизировав решение задачи вычисления параметров темного объекта на радиолокационном изображении морской поверхности, перейдем к решению задачи классификации темного объекта как нефтяного пятна или ветрового сликa. Для этого воспользуемся теорией нейронных сетей. Искусственную нейронную сеть (NN) можно рассматривать как математическую модель, состоящую из многих нелинейных вычислительных элементов, называемых нейронами, в которых операции выполняются параллельно и которые массово соединены связями, характеризующимися различными весами. Нейрон вычисляет сумму своих входов, добавляет основные условия и выводит результирующую нелинейную функцию активации для формирования единственного выхода, называемого уровнем активации нейрона [Оссовский, 2004]. В данном случае рассматривался многослойный персептрон и сеть с прямой связью, в которой вход связан с выходом в одном направлении, а каждый нейрон слоя связан со всеми нейронами следующего слоя, но не имеет обратной связи с нейронами предыдущих слоев. В данном случае использовалась топология 11-8-8-1 и два слоя весов, так как эта структура показала лучшие характеристики как по точности классификации, так и по времени обучения (около 15 000 обучающих циклов) [Медведев, 2002]. Тип входных сигналов сети – целые или действительные. Тип выходных сигналов – действительные из интервала, заданного передаточной функцией нейронов. Был выбран сигмоидальный тип передаточной функции сети, так как сигмоидальные функции являются монотонно возрастающими и имеют отличные от нуля производные на всей области определения. Эти характеристики обеспечивают правильное функционирование и обучение сети.

Для аппроксимации неизвестного отношения вход-выход определялись веса (или сила) связи посредством обучающих правил. Эти правила показывают, как получить минимум функции ошибки аппроксимации в области, покрываемом тренировочным набором данных (примеры вход-выход). Входной вектор тренировочного набора данных состоит из значений измеряемых параметров, выходной вектор содержит соответствующую классификацию.

Была поведена тренировка сети с использованием алгоритма обратного распространения, который использует технику поиска градиента и итерационно подбирает весовые коэффициенты в сети для минимизации функции ошибки по среднему квадрату между желаемым и действительным значением выхода. Процедура итерации прекращалась, когда не наблюдалось значительных изменений в значении общей ошибки. Таким образом, обучение сети сводится к решению задачи оптимизации функционала ошибки градиентным методом. Вся “соль” обратного распространения ошибки состоит в том, что

в качестве ее оценки для нейронов скрытых слоев можно принять взвешенную сумму ошибок последующего слоя.

Окно программы, создающей и тренирующей нейронную сеть по методу градиентного спуска, изображена на рис. 6, а.

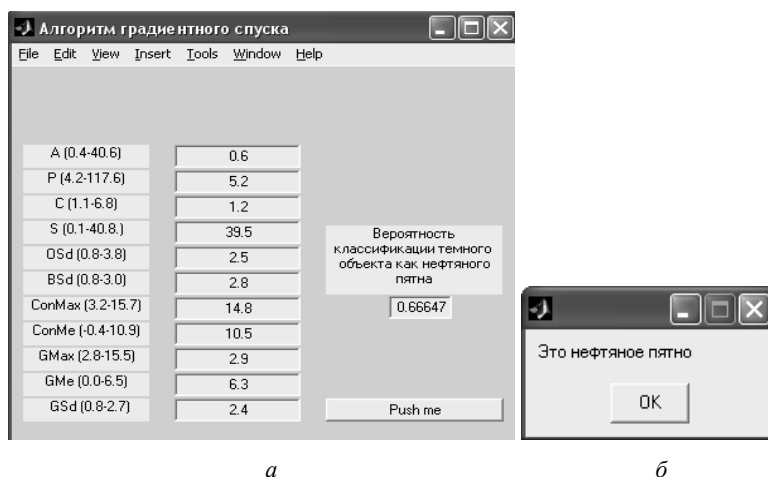


Рис. 6. Интерфейс программы, реализующей нейронную сеть:
а – ввод параметров изображения; б – результат классификации

Входные данные, получаемые на этапе нахождения параметров темного объекта, вводятся вручную в соответствующие ячейки, рядом с которыми написан диапазон изменения параметров, соответствующий изображению нефтяного пятна. Для тренировки сети используются значения параметров, выбираемых случайным образом из банка данных изображений нефтяного пятна и банка данных ветровых снимков. Результатом работы программы является вероятность принадлежности темного объекта на радиолокационном изображении к нефтяным пятнам (рис. 6, б).

Литература

1. Глинский В.В., Ионин В.Г. Статистический анализ. – М.: Инфра-М, 2002. – 323 с.
2. Дьяконов В.П. Matlab 6.0/6.1/6.5/6.5 + SP1 + Simulink 4/5. Обработка сигналов и изображений. – М.: Солон-Пресс, 2004. – 592с.
3. Оссовский С. Нейронные сети для обработки информации. Пер. с польск.– М.: Финансы и статистика, 2004. –4 96 с.
4. Медведев В., Потемкин В. Нейронные сети. MATLAB 6 Нейронные сети. MATLAB 6.– М: Диалог-МИФИ, 2002.– 496 с.