

УДК 621.3:681.34

А.В. НАУМЕНКО, В.В. ЛУКИН

Национальный аэрокосмический университет им. Н.Е.Жуковского «ХАИ», Украина

ДЕТЕКТИРОВАНИЕ ГРАНИЦ НА ИЗОБРАЖЕНИЯХ С ПОМОЩЬЮ ИСКУССТВЕННОЙ НЕЙРОННОЙ СЕТИ

Предложен метод совместного анализа выходных значений нескольких локальных детекторов границ на основе применения искусственной нейронной сети. Рассмотрена эффективность использования различных детекторов границ в нейросетевом обнаружителе. Установлено, что для улучшения характеристик нейросетевого детектора границ необходимо применение только наиболее информативных локальных параметров. Описана процедура обучения нейросети и проведено сравнение эффективности нейросетевого детектора с рядом известных. Сформулированы задачи и тематика дальнейших исследований.

Ключевые слова: детектирование границ, нейронные сети, совместный анализ локальных параметров

Введение

Задача обнаружения границ является одной из основных при обработке изображений [1]. Надежное и точное обнаружение границ особенно актуально при обработке изображений, которые искажены помехами высокой интенсивности. Таковыми являются, в частности, изображения, формируемые радиолокаторами с синтезированной апертуры (РСА) авиационного и комического базирования, которые в настоящее время используются для широкого круга приложений благодаря их всепогодности и высокому разрешению [2], достигаемому при работе в одновзглядовом режиме.

Однако именно одновзглядные РСА-изображения искажены наиболее интенсивными помехами. Кроме того, шум на РСА-изображениях имеет негауссово распределение (например, распределение Рэлея для амплитудных одновзглядовых изображений) и мультипликативный характер, что дополнительно усложняет задачу обнаружения границ [2]. Напомним, что спекл-шум на РСА-изображениях связан со случайной интерференцией отражений от элементарных отражателей в элементе разрешения РСА, которые имеют случайные амплитуды и начальные фазы, обусловленные неоднородностью снимаемой поверхности. На самих изображениях этот эффект проявляется в виде произведения искаженного изображения со стационарным шумоподобным процессом (спеклом) [2], присутствие которого затрудняет решение большинства задач обработки РСА-изображений.

Существующие популярные детекторы границ, такие как, например, детекторы Собеля или Кенни, в основном, предназначены для случаев воздействия аддитивной помехи. Поэтому они практически не-

применимы для обработки рассматриваемого типа изображений.

Существуют также детекторы границ для случаев мультипликативных помех. Большинство таких детекторов представляют собой некоторые оценки статистических параметров изображения, полученные в скользящем окне [3]. При этом часто используется нормировка рассчитываемого в скользящем окне локального параметра на локальное среднее или его квадрат для учета мультипликативного характера помех. Размер скользящего окна обычно выбирается равным нечетному числу: 3x3, 5x5, реже 7x7; при этом выходное значение получают для центрального элемента (пикселя).

Однако практически все известные детекторы границ имеют как достоинства, так и недостатки [1]. Так, например, такой параметр как относительная локальная дисперсия [4] достаточно чувствителен к малым контрастам, однако получаемый в результате контурный препарат имеет достаточно широкие линии, что затрудняет локализацию границ объектов. Другой локальный параметр – квазиразмах [3] – дает более тонкие контурные препараты, однако обладает более слабой чувствительностью к границам с малыми контрастами. В работах [5, 6] показано, что для устранения указанных недостатков и более эффективного использования достоинств перечисленных выше детекторов целесообразно использовать их совместную обработку с помощью нейросети. Однако разработанная в [5, 6] нейросеть применима при гауссовом распределении помех и ее тестирование выполнялось лишь для мультипликативных помех невысокой интенсивности. Отметим, что имеется и ряд других публикаций, в которых анализируются возможности применения нейросетей для решения аналогичных задач [7, 8].

Поэтому целью данной статьи является разработка методов обнаружения границ на одновзглядных РСА-изображениях с использованием искусственной нейронной сети.

1. Анализ локальных параметров

При разработке метода совместной обработки нескольких локальных параметров необходимо решить вопросы об их количестве, полезных свойствах локальных параметров, а также о характеристиках самого метода, в данном случае – структуре нейросети, ее параметрах и способе обучения.

Все используемые ниже локальные параметры вычислялись в прямоугольном скользящем окне, размером 5x5 пикселей. Для анализа работы детекторов границ, а также для формирования наборов обучающей выборки для обучения нейросети использовалось тестовое изображение со смоделированным шумом. Шум на тестовом изображении является пространственно-некоррелированным и имеет распределение Рэлея с относительной дисперсией $\sigma_{\mu}^2 \approx 0,273$. Само изображение имеет размер 256x256 пикселей и представляет собой 8 вертикальных полос различных интенсивностей. В результате имеются границы с различными контрастами.




Рис. 1. Незашумленное (а) и зашумленное (б) тестовое изображение

Для первичного анализа нами были выбраны следующие детекторы границ.

Относительная локальная дисперсия:

$$\delta_{ij} = \frac{\sigma_{ij}^2}{(\sigma_{\mu}^2 \bar{I}_{ij}^2)}, \quad (1)$$

где σ_{ij}^2 - локальная дисперсия в окне 5x5 пикселей с центром в ij -м отсчете, \bar{I}_{ij} - среднее в окне, σ_{μ}^2 дисперсия мультипликативной помехи.

Принцип работы данного детектора основан на предположении о том, что дисперсия в скользящем

окне, попавшем на границу, значительно больше, чем в окне, попавшем на однородный участок.

Квазиразмах:

$$QR_{ij} = \frac{(I_{ij}^{(q)} - I_{ij}^{(p)})}{I_{ij}^{(q)} + I_{ij}^{(p)}}, \quad (2)$$

где $I_{ij}^{(q)}$ и $I_{ij}^{(p)}$ - соответственно q -й и p -й элемент (порядковая статистика) ранжированной выборки. В соответствии с рекомендациями [4, 9] $q=20$ и $p=6$ для окна размером 5x5 пикселей.

Квазиразмах (2) представляет собой нормированную разность значений порядковых статистик в скользящем окне, где вместо нормировки на локальное среднее используется нормировка на $I_{ij}^{(q)} + I_{ij}^{(p)} \approx 2\bar{I}_{ij}$. При попадании окна на границу разность $I_{ij}^{(q)} - I_{ij}^{(p)}$ существенно возрастает по сравнению с ее значениями на однородном участке.

Робастная оценка коэффициента асимметрии (РОКА) [10]:

$$SK_{ij} = \frac{Q_3 + Q_1 - 2Q_2}{Q_3 - Q_1}, \quad (3)$$

где Q_1 - 1-й квартиль ранжированной выборки. Фактически для скользящего окна размером 5x5 пикселей Q_1, Q_2, Q_3 совпадают с порядковыми статистиками. $I_{ij}^{(3)}, I_{ij}^{(13)}, I_{ij}^{(20)}$

РОКА (3) является еще одним статистическим параметром, который потенциально может использоваться для обнаружения границ. Ее значения для выборок данных с распределением Рэлея (то есть на однородных участках) имеют значения в пределах 0,1..0,19, а в окрестностях границ (особенно контрастных) заметно отличаются от этого значения.

Две робастные оценки коэффициента эксцесса (РОКЭ) [10]:

$$KR_{ij} = \frac{(E_7 - E_5) + (E_3 - E_1)}{E_6 - E_2}, \quad (4)$$

$$PCK_{ij} = \frac{2 \cdot (E_7 - E_1)}{E_6 - E_2}, \quad (5)$$


где E_1 - 1-й октиль ранжированной выборки. Октили от 1-го до 7-го для выборки размером 25 элементов (в окне 5x5 пикселей) – это порядковые статистики, $I_{ij}^{(3)}, I_{ij}^{(6)}, I_{ij}^{(10)}, I_{ij}^{(13)}, I_{ij}^{(16)}, I_{ij}^{(20)}, I_{ij}^{(23)}$.

Эти статистические параметры также учитывают особенности выборок данных в скользящем окне для однородных и неоднородных участков. Их средние значения на однородных участках равны соответственно 0,44 и 3,32 для KR и PCK. Значения


же этих параметров при попадании скользящего окна на границы существенно отличаются от значений, которые имеют место на однородных участках.

Отметим, что обычные оценки асимметрии и эксцесса являются достаточно неустойчивыми и реагируют на присутствие в выборке даже одного «аномального» значения, которое может быть обусловлено присутствием в скользящем окне малоразмерного объекта. Именно этими причинами обусловлено использование в данной работе устойчивых оценок этих статистических параметров.

Результаты работы рассмотренных детекторов границ для тестового изображения на рис. 1,б представлены на рис. 2 и 3 в виде контурных препаратов. Пиксели, для которых значение на выходе детектора превосходит заданный порог, показаны белым цветом.




а




б


Рис. 2. Контурные препараты для детекторов границ: относительная локальная дисперсия (а), квазиразмах (б)



а



б



в

Рис. 3. Контурные препараты для робастных оценок коэффициента асимметрии (а) и коэффициентов эксцесса KR (б) и PCK (в)

Основным критерием эффективности работы обнаружителей границ является зависимость вероятности правильного обнаружения от вероятности ложной тревоги. В этом плане важен выбор порога для любого детектора. Для приведенных на рис. 2 и 3 контурных препаратов эти значения порогов соответственно равны 1,7, 1,9, 2,0, 0,5, 6,0 для детекторов (1)...(5). Характерным свойством является то, что уменьшение порога приводит к возрастанию вероятности правильного обнаружения и увеличению вероятности ложной тревоги. Поэтому на рис. 2 и 3 приведены данные, которые примерно соответствуют приемлемому на практике компромиссу.

Анализ контурных препаратов показывает следующее:

1) границы с малыми контрастами (например, граница между 7-й и 8-й полосами) обнаруживаются гораздо хуже, чем границы с большими контрастами (например, между первой и второй полосой);

2) для разных детекторов имеют место разные ширины линий контурных препаратов; в частности, хорошо видно указанное выше свойство относительной локальной дисперсии (1), (см. рис. 2,а), особенно по сравнению с контурными препаратами для КР и РСК (рис. 3,б,в);

3) для КР и РСК наблюдаются разрывы линий контурных препаратов даже для границ с большими контрастами, что нежелательно.

С учетом вышесказанного детекторы границ обычно характеризуют зависимостями правильного обнаружения от вероятности ложной тревоги, которые получают для тестовых данных путем варьирования порога. Для получения оценки вероятности правильного обнаружения рассчитывают количество правильно детектированных пикселей N_c для границ всех контрастов на тестовом изображении. При этом правильно обнаруженными пикселями в наших экспериментах считались только по одному пикселю слева и справа от вертикальных границ. Полученное значение N_c нормируют на общее число пикселей на границах. Оценку вероятности ложной тревоги производят на однородных участках, где рассчитывают количество срабатываний детектора N_f и нормируют его на общее число пикселей на рассматриваемых участках изображения.

Для приведенных выше локальных параметров эти зависимости имеют вид, показанный на рис. 5, б.

Эти зависимости отображают, фактически, чувствительность детектора к шумам и его способность обнаруживать границы при фиксированной вероятности ложной тревоги. Чем выше проходит кривая, тем детектор эффективнее, т.е. он менее чувствителен к помехам и более эффективно распознает границы.

Анализ этих зависимостей показывает, что наиболее эффективным локальным параметром среди рассмотренных является относительная локальная дисперсия, близкие по эффективности результаты обеспечивает квазиразмах. Детекторы (3)..(5) в большей степени чувствительны к помехам и их эффективность существенно ниже.

2. Структура и параметры обучения нейронной сети

Как уже было сказано выше, в качестве метода совместной обработки нескольких локальных параметров нами предлагается использовать нейронную сеть, а именно – ее способность к распознаванию образов на основе совместной обработки разноплановых входных параметров. Образом в данном случае является вектор из рассчитанных в скользящем окне параметров, а распознавать нейросети предстоит два класса: «граница» и «неграница».

Для рассматриваемой задачи принято решение использовать персептрон. Это связано с тем, что для этого типа сети существуют хорошо апробированные методики и алгоритмы их обучения с учителем. Кроме того, учтен опыт решения аналогичных задач. Разработанная нейронная сеть представляет собой сеть прямого распространения и состоит из трех слоев: 5 нейронов во входном слое (что соответствует числу детекторов), 7 нейронов в скрытом (это число определено эмпирическими правилами обучения нейронных сетей) и двух нейронов в выходном слое (соответствующих определяемым классам). Обучение выполнялось «с учителем» на тестовых изображениях методом обратного распространения ошибки. При таком способе обучения ошибка текущей эпохи обучения передается на вход, модифицируя веса матрицы связей перед следующей эпохой, с некоторым коэффициентом, определяющим скорость и точность обучения [11]:

$$w_t^m = w_t^{m-1} + \alpha(Y_g - f(X_g)), \quad (6)$$

где w_t^m, w_t^{m-1} - веса предыдущей и следующей эпохи соответственно;

α - коэффициент, определяющий скорость обучения;

$(Y_g - f(X_g))$ - ошибка на текущей эпохе обучения, определяемая как разность между текущим результатом и ожидаемым значением из обучающей выборки.

Обучение, таким образом, сводится к минимизации функции ошибки $(Y_g - f(X_g))$ и считается завершенным, когда она достигнет значения менее 1%.

Выход нейронной сети определяется следующим соотношением [11]:

$$X_n = f \left(\sum_{n=1}^N w_{nt}^{(2)} f \left(\sum_{t=1}^T x_t w_{nt}^{(1)} \right) \right). \quad (7)$$

В качестве функции активации нейрона использовалась сигмоидальная функция (вид функции активации обычно мало влияет на результат обучения) [11]:

$$f(x) = \frac{1}{1 + e^{-x}}. \quad (8)$$

Структура нейронной сети представлена на рис. 4.

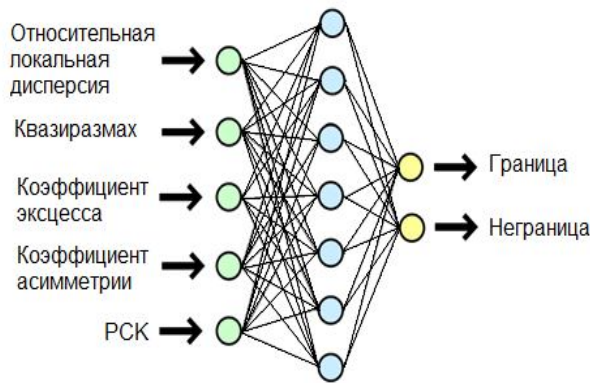


Рис. 4. Структура нейронной сети

В обучающую выборку входили не сами элементы изображения, ее составляли векторы значений локальных параметров в скользящих окнах. Это делает нейросетевой детектор инвариантным по отношению к направлению обрабатываемой границы (ни один из параметров (1)...(5) не учитывает геометрию данных в скользящем окне). Именно поэтому тестовое изображение на рис. 1 содержит только вертикальные границы – значение имеет только различие в контрастах.


Все входные параметры были приведены к диапазону [0;1] при помощи «нормировки» (путем деления на число, заведомо большее максимального для данного параметра), так как это желательно для их «восприятия» нейросетью и ускорения обучения. Обучающая выборка включала векторы локальных параметров (после нормировки) для всех возможных положений скользящего окна на границах и такого же числа выборок на однородных участках из всех полос.

В результате обучения нейросети ожидалось, что при ее применении уменьшится вероятность ложной тревоги (при фиксированной вероятности правильного обнаружения) или увеличится вероятность правильного обнаружения (при фиксированной вероятности ложной тревоги).

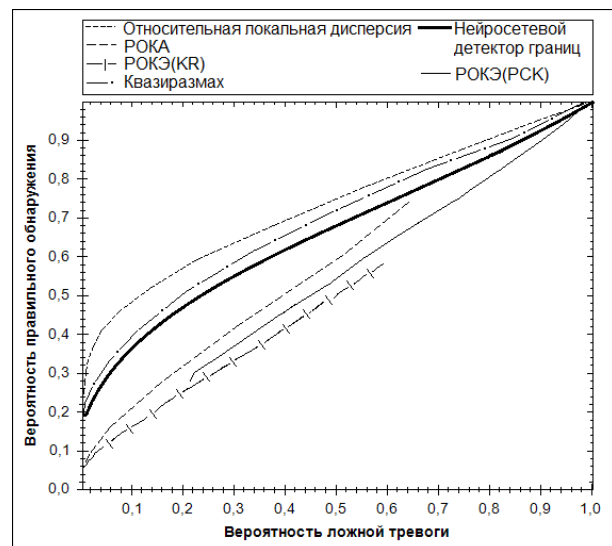
3. Анализ полученных результатов

Отметим, что результаты обучения зависят от выбранного метода обучения, размера обучающей выборки и установленного порога. Поскольку сеть после обучения имеет некоторую ошибку определения, которая должна быть менее 1%, то для нейросети так же, как и для других детекторов можно определить порог, при превышении которого принимается решение о наличии границы.

В данном случае совместная обработка указанных пяти параметров при помощи нейросети не принесла ожидаемого эффекта. Результат применения обученной нейросети для обработки тестового изображения на рис. 1,б представлены на рис. 5,а.



а



б

Рис. 5. Результат работы нейросетевого детектора границ на тестовом изображении (а); зависимость вероятности правильных срабатываний от вероятности ложной тревоги (б)

Линии остались достаточно широкими, достаточно высока вероятность ложной тревоги. Кривые обнаружения приведены на рис. 5,б. Нейросеть работает лучше, чем детекторы (3)...(5), но хуже, чем детекторы (1) и (2).

На наш взгляд, причина заключается в следующем. Некоторые используемые нейросетью локальные параметры оказались «малоинформативными», поэтому для нейронной сети их присутствие во входном векторе только ухудшает конечный результат. Как видно из графика, кривые для робастных оценок коэффициентов асимметрии и эксцесса (обоих) проходят существенно ниже остальных. То есть, они являются более чувствительными к помехам, чем остальные детекторы границ. В связи с этим, присутствие таких параметров в векторе входных данных представляется нецелесообразным.

Исходя из этих предположений, нами было принято решение пересмотреть состав вектора входных параметров. Очевидно, что необходимо использовать только наиболее эффективные локальные параметры, слабо чувствительные к помехам.

4. Определение состава входного вектора

С учетом проведенного анализа было принято решение оставить в векторе входных данных относительную локальную дисперсию как параметр, который обеспечивает наилучшие результаты среди ранее рассмотренных.

Также были проанализированы свойства еще двух детекторов границ.

Детектор Харриса на основе отношения средних [12]. В скользящем окне размером 5×5 пикселей оценивается отношение средних в четырех направлениях (рис.6).

$$M_1 = \begin{bmatrix} I_h^2 & I_h I_v \\ I_h I_v & I_v^2 \end{bmatrix}, \quad (9)$$

$$M_2 = \begin{bmatrix} I_{md}^2 & I_{md} I_{ad} \\ I_{md} I_{ad} & I_{ad}^2 \end{bmatrix}, \quad (10)$$

где I_h - отношение средних левой и правой половины скользящего окна;

I_v - отношение средних верхней и нижней половины скользящего окна;

I_{md} - отношение средних в частях скользящего окна, взятые над его главной диагональю и под его главной диагональю;

I_{ad} - отношение средних в частях скользящего окна, взятые над его побочной диагональю и под его побочной диагональю;

M_1, M_2 - матрицы, составленные из отношений средних в скользящем окне.




Рис. 6. Направления расчета отношений средних в скользящем окне

Эти параметры используются для получения одного выходного значения:

$$\begin{aligned} R_1 &= \text{Det}(M_1) - k \cdot \text{Tr}^2(M_1) \\ R_2 &= \text{Det}(M_2) - k \cdot \text{Tr}^2(M_2) \\ R_{ij} &= \min(R_1, R_2), \end{aligned} \quad (11)$$

где R_1, R_2 - промежуточные параметры, необходимые для определения итогового выходного значения детектора;


k - эмпирическая константа, которая в данных опытах принята равной 0,04 согласно [12];

R_{ij} - выходное значение для данного скользящего окна.


По утверждению авторов [12] этот детектор является оптимальным и, в отличие от относительной локальной дисперсии, он учитывает пространственные признаки.

Детектор на основе дискретного косинусного преобразования (ДКП). Принцип его работы состоит в следующем. В ДКП-спектре, вычисленном для скользящего окна, попавшего на границу, количество превысивших некоторый порог коэффициентов ДКП больше, чем на однородном участке [13]. С учетом данного свойства представляется возможным обнаруживать неоднородные участки изображения. В наших экспериментах ДКП вычисляется в окне 5×5 , а порог при данном типе помех был выбран равным $1,35 \bar{I}_{ij} \approx 2,7 \sigma_{\mu} \bar{I}_{ij}$ с учетом мультипликативного характера помех.

Контурные препараты для этих локальных параметров представлены на рис. 7.



а



б

Рис. 7. Контурные препараты для детектора Харриса (а) и детектора границ на основе ДКП (б)

В данном опыте из обучающей выборки исключены наиболее чувствительные к помехам параметры. Вошедшие в нее детекторы имеют наивысшую эффективность среди всех рассмотренных. Поэтому, после обучения ожидалось получить улучшение характеристик нейросетевого детектора по сравнению с наилучшими из обычных детекторов.

5. Анализ результатов, полученных с новой обучающей выборкой

Структура нейронной сети была изменена в соответствии с новым вектором входных параметров. Теперь во входном слое содержится 3 нейрона и 5 - в скрытом слое. Определяемые классы остались прежними, соответственно число нейронов в выходном слое также осталось равным двум. Не изменился и метод обучения. Структура нейросети отображена на рис. 8.




Рис. 8. Структура нейронной сети

В данном случае, совместная обработка нескольких наиболее информативных локальных параметров привела к улучшению результата, что подтверждается анализом кривых обнаружения (рис. 9).

Кривая для предложенного метода проходит выше остальных на всем промежутке значений. Это означает, что разработанный метод совместной обработки детекторов границ обеспечивает более эффективное обнаружение границ, чем каждый из этих методов по отдельности.





Рис. 9. Зависимости вероятности правильного обнаружения от вероятности ложной тревоги


Отметим также, что все три детектора (Харриса, на основе ДКП и относительной локальной дисперсии) имеют примерно одинаковую эффективность (см. зависимости на рис. 9), но при этом каждый из них основан на разных принципах обнаружения границ: относительная локальная дисперсия учитывает статистические признаки в пространственной области, детектор Харриса учитывает геометрические признаки, а детектор на основе ДКП – статистику в спектральной области

Результат также подтверждается визуально. На рис. 10 представлены контурные препараты для де-

тектора Харриса (а) и предлагаемого нами метода (б). Видно, что с помощью нейросетевого детектора удается лучше обнаружить малоcontrastные границы между 5-й и 6-й, а также между 6-й и 7-й полосами. Границы между 5-й и 6-й полосами, а также между 4-й и 5-й полосами практически не содержат разрывов.




а




б

Рис. 10. Контурные препараты для детектора Харриса на основе отношения средних (а) и для нейросетевого детектора границ (б)


Результаты работы предложенного метода детектирования границ на реальных РСА-изображениях в сравнении с картой границ, полученных с помощью относительной локальной дисперсией представлены на рис. 11 и 12. Поскольку спекл-шум на используемых ниже реальных изображениях системы TerraSAR-X [14, 15] является пространственно-коррелированным, то нами было проведено предварительное прореживание исходных изображений с уменьшением их размеров вдвое по каждой из осей.



а



б




в

Рис. 11. Реальное РСА- изображение (а), контурный препарат для детектора на основе относительной локальной дисперсии (б), контурный препарат для предложенного нейросетевого детектора границ (в)



а



б



в

Рис. 12. Реальное РСА- изображение (а), контурный препарат для детектора на основе относительной локальной дисперсии (б), контурный препарат для предложенного нейросетевого детектора границ (в)

Сравнительный анализ приведенных результатов показывает, что предложенный нейросетевой детектор границ позволяет лучше обнаруживать малококонтрастные границы.

Заключение

Рассмотрены проблемы обнаружения границ существующими детекторами при обработке одно-взглядовых РСА-изображений.

Предложен метод совместной обработки нескольких локальных параметров с использованием нейросети для устранения некоторых недостатков известных детекторов границ. Рассмотрена целесообразность использования в нейросетевом обнаружителе различных детекторов границ. Показано, что улучшение характеристик нейросетевого детектора по сравнению с другими может быть достигнуто путем совместной обработки только наиболее информативных локальных параметров (выходов обычных обнаружителей).

В дальнейшем предполагается разработать обнаружитель границ, применяемый к изображению на выходе предварительного фильтра. Кроме того, будут рассмотрены пути учета пространственной коррелированности помех.

Литература

1. Шовенгердт, Р.А. Дистанционное зондирование. Методы и модели обработки изображений [Текст] / Р.А. Шовенгердт. – Техносфера, 2010. – 560 с.
2. Oliver, C. Understanding Synthetic Aperture Radar Images [Текст] / C. Oliver, S. Quegan. – Sci-Tech Publishing, 2004. – 486 p.
3. Роечко, А.А. Применение устойчивых оценок параметров выборок данных при обработке изображений [Текст] / А.А. Роечко, Д.В. Февралев, Н.Н. Пономаренко, В.В. Лукин // Восточноевропейский журнал передовых технологий. - 2007. - N3/2 (27). - С. 21 – 31.
4. Local activity indicators: analysis and application to hard-switching adaptive filtering of images [Текст] / V.P. Melnik, V.V. Lukin, A.A. Zelensky, J.T. Astola, P Kuosmanen. // Optical Engineering Journal. - 2001. - Vol. 40, No 8. - P. 1441-1445.
5. Лукин, В.В. Методы детектирования границ на изображениях на основе совместного анализа нескольких локальных параметров [Текст] / В.В. Лукин, А.В. Соколов. // Технология приборостроения. - Харьков: ГП НИТИП. - 2001. - Вып. 1-2. - С. 83-90.
6. Sokolov, A.V. Local Recognition of Radar Images by Three-Layer Neural Network Using Spatial Features [Текст] / A.V. Sokolov, V.V. Lukin // Telecommunications and Radioengineering. - Begell House. - 2003. – Vol. 60, No 1&2. – P. 141 – 150.

7. Frate, F. *Neural networks for oil spill detection using ERS-SAR data [Текст] / F. Del Frate, A. Petrocchi, J. Lichtenegger, G. Calabresi // IEEE Transactions on geoscience and remote sensing. - September 2000. - Vol. 38, No. 5. - P. 2282 – 2287.*
8. Perlovsky, L. *Model-based neural network for target detection in SAR images [Текст] / L.I. Perlovsky, W.H. Schoendorf, B.J. Burdick, D.M. Tye // IEEE Transactions on image processing. - Vol. 6, No. 1. - January 1997. - P. 203 – 216.*
9. *Digital adaptive robust algorithms for radar image filtering [Текст] / V.V. Lukin, V.P. Melnik, A.B. Pogrebniak, A.A. Zelensky, J.T. Astola, K.P. Saarinen // Journal of Electronic Imaging. - Vol.5, No.3. - July 1996. - P. 410-421.*
10. White, H. *On more robust estimation of skewness and kurtosis [Текст] / H. White, T.-H. Kim - Finance Research // Letters. - Vol.1, No.1. - March, 2004. - P. 56-73.*
11. Bishop, C. *Pattern Recognition and Machine Learning [Текст] / C. Bishop. - Springer Science+Business Media, LLC, 2006. - 738 p.*
12. Kang, X. *SAR image edge detection by ratio-based Harris Method [Текст] / X. Kang, C. Han, Y. Yang, T. Tao // ICASSP 2006 Proceedings. - Vol. 2. - May 2006. - P. 837 -840.*
13. *Edge Detection and Filtering of Images Corrupted by Nonstationary Noise Using Robust Statistics [Текст] / N. Ponomarenko, D. Fevralev, A. Roenko, S. Krivenko, V. Lukin, I. Djurovič // Proceedings of CADSM2009. - Svalyava, February 2009. - P. 129-136.*
14. *Материалы сайта ASTRION AN EADS COMPANY [Электронный ресурс]. – Режим доступа: <http://www.astrion-geo.com/en/23-sample-imagery>. – 07.02.2012 г.*
15. *Performance evaluation for Blind Methods of Noise Characteristics Estimation for TerraSAR-X Images [Текст] / V.V. Lukin, S.K. Abramov, D.V. Fevralev, N.N. Ponomarenko, K.O. Egiazarian, J.T. Astola, B. Vozel, K. Chehdi // Proceedings of SPIE/EUROPTO on Satellite Remote Sensing. - Vol. 8180. - Prague, September 2011. - 12 p.*

Поступила в редакцию 7.02.2012

Рецензент: д-р техн. наук, проф., проф. каф. «Проектирование радиоэлектронных систем летательных аппаратов» В.К. Волосяк, Национальный аэрокосмический университет им. Н.Е. Жуковского "ХАИ", Харьков.

ДЕТЕКТУВАННЯ МЕЖ НА ЗОБРАЖЕННЯХ ЗА ДОПОМОГОЮ ШТУЧНОЇ НЕЙРОННОЇ МЕРЕЖІ

О.В. Науменко, В.В. Лукін

Запропоновано метод спільного аналізу вихідних значень декількох локальних детекторів меж на основі застосування штучної нейронної мережі. Розглянута ефективність використання різних детекторів меж у нейромережевому детекторі. Встановлено, що для покращення характеристик нейромережевого детектора необхідно застосування тільки найбільш інформативні локальні параметри. Описана процедура навчання нейромережі і проведено порівняння ефективності нейромережевого детектора з низкою відомих. Сформульовані задачі подальших досліджень.

Ключові слова: детектування меж, нейронні мережі, спільний аналіз локальних параметрів

IMAGE EDGE DETECTION USING ARTIFICIAL NEURAL NETWORK

A.V. Naumenko, V.V. Lukin

A method of joint analysis of several local edge detector outputs using an artificial neural network is proposed. The efficiency of applying different edge detectors in the neural network edge detector is considered. It is established that the usage of only the most informative local parameters can improve characteristics of the neural network edge detector. A procedure of neural network learning is described and comparison of neural network detector efficiency to several known detectors is carried out. The tasks of further research are formulated.

Keywords: edge detection, neural networks, joint analysis of local parameters

Науменко Алексей Васильевич – студент каф. «Прием, передача и обработка сигналов», Национальный аэрокосмический университет им. Н.Е. Жуковского «ХАИ», Харьков, Украина, e-mail: phist@mail.ru.

Лукін Владимир Васильевич – д-р техн. наук, проф., проф. каф. «Прием, передача и обработка сигналов», Национальный аэрокосмический университет им. Н.Е. Жуковского «ХАИ», Харьков, Украина, e-mail: lukin@xai.kharkov.ua.