

УДК 004.932

*А.А. Степаненко*Запорожский национальный технический университет, Украина  
ул. Жуковского, 64, г. Запорожье, 69063**АНАЛИЗ И ВОССТАНОВЛЕНИЕ СЛАБОКОНТРАСТНЫХ  
ИЗОБРАЖЕНИЙ МЕТОДОМ НЕЙРОСЕТЕВОГО СИНТЕЗА В  
СРАВНЕНИИ С МЕТОДОМ ЛИНЕЙНОГО ПРЕДСКАЗАНИЯ***A. Stepanenko*Zaporizhzhya National Technical University, Ukraine  
60, Zhukovsky str., Zaporozhye, 69063**ANALYSIS AND RECOVERY OF LOW-CONTRAST IMAGES  
BY NEURAL NETWORK SYNTHESIS IN COMPARISON WITH THE  
LINEAR PREDICTION**

Статья демонстрирует сравнительный анализ эффективности восстановления слабоконтрастных изображений, основанный на использовании методов самоорганизующегося нейросетевого синтеза и линейного предсказания. Оба метода позволяют повысить чувствительность и пространственное разрешение визуального анализа низкоконтрастных яркостных (одномерных) и мультиспектральных изображений. Приведены практические примеры со сравнением эффективности для различных технологий (радиология, геоинформационные системы).

**Ключевые слова:** слабоконтрастные изображения, пространственное разрешение, параметрическая модель, нелинейный спектральный анализ, нейронная сеть Кохонена, нейросетевой синтез, визуальный анализ.

Article shows a comparative analysis of the efficiency of the recovery of low-contrast images, based on the use of self-organizing neural network methods of synthesis and linear prediction. Both methods allow to increase the sensitivity and spatial resolution of the visual analysis of low contrast luminance (one-dimensional) and multispectral images. The practical examples for comparing the effectiveness of different technologies (radiology, geographic information systems).

**Keywords:** low contrast image gradation, parametric model, nonlinear spectral analysis, neural network Kohonen vector of synaptic weights, the objective function, visual analysis.

**Введение**

Что именно отличает «хорошее» изображение от «плохого»? Как можно оценить качество изображения и какие критерии используются для его оценки? В общей иерархии задач обработки и анализа изображений, особую сложность представляет проблема анализа слабоконтрастных изображений, характеризующихся узким диапазоном градации яркостей, наличием сглаженных (размытых) участков, обнаружение и анализ которых, зачастую, и представляет основной интерес (онкология, аномальные участки изображений геофизических полей и данных дистанционного зондирования) [1, 2]. Основной подход к решению подобных задач – расширение информационной базы, основанной на сопоставлении каждому пикселю анализируемого изображения ряда новых характеристик [3], что, однако, приводит к возникновению новой проблемы, связанной с необходимостью синтеза одного результирующего изображения из многомерного массива [4].

Данное обстоятельство диктует необходимость разработки новых подходов к анализу слабоконтрастных изображений различной физической сущности и повышения эффективности уже существующих. Возможны различные подходы к решению этой проблемы, однако все они связаны с необходимостью расширения информационной базы на основе синтеза новых, более широкополосных характеристик [4,5].

**Постановка задачи**

Демонстрация возможностей современных технологий анализа слабоконтрастных изображений, основанных на сочетании вейвлет-декомпозиции исходного изображения и самоорганизующийся нейросетевой синтез одного

результатирующего изображения из многомерного массива в сравнении с методом линейного предсказания высшего порядка, а также произвести визуальную оценку различных изображений и их характеристик, раскрыть возможность повышения эффективности их анализа.

#### **Анализ последних исследований и публикаций**

При всем многообразии новых методов обработки и анализа изображений возникает проблема выбора решения для конкретной задачи, так как, в большинстве случаев, алгоритмы моделируются на совершенно разных технологиях получения исходных изображений, а оценка их проводится визуально.

В [1,2] описываются виды и типы изображений, методика их получения, представление цифровых изображений, дается общее описание проблемы анализа и обработки низкоконтрастных изображений: восстановление, сегментация или сжатие; в [3] – приводится способ сегментации слабоконтрастных изображений как основной метод выделения информативных признаков разложения с возможностью применения к ним вейвлет-преобразования: при синтезе нового изображения используется метод нуль-пространственного отображения; в [4] – возможность представления слабоконтрастного изображения как совокупности суперпозиций неизвестных импульсных сигналов: выделяются основы метода линейного предсказания, показывается применение этого метода на примере эхо-импульсных сейсмических изображений; [5] – обосновываются предпосылки параметрического спектрального анализа второго порядка и его применение для увеличения разрешающей способности ультразвуковых медицинских изображений; в [6] – показан один из способов вейвлет-разложения слабоконтрастного медицинского радиологического изображения, обосновывается структура алгоритма нейросетевого синтеза, как одного из способов повышения чувствительности получаемых изображений; в [7] – даются математические выкладки основ вейвлет-анализа, описываются различные типы вейвлет-функций, возможности их применения для различных видов задач, в том числе и при обработке сигналов; в [8] – показаны основы вейвлет-анализа, их применение, например, для распознавания образов, показаны нюансы при использовании Фурье- и вейвлет-преобразования, обосновывается выбор вейвлет-функции Добеши при разложении низкоконтрастных изображений; в [9] – приведен модифицированный алгоритм синтеза нового изображения на основе самоорганизующейся нейронной сети Кохонена.

При анализе публикаций возникли некоторые замечания. Например, в [5] представлены результаты модифицированной медианной фильтрации на примере тестовых прямоугольников и треугольников, пятен произвольной формы, а также карт облачности, но нет строгой количественной оценки полученных результатов. В работе [6] приведены результаты моделирования пространственной фильтрации-сегментации без их математической оценки. В [7] также графически приведены результаты фильтрации-сегментации простейших тестовых изображений однослойной нейронной сетью без численного анализа. Строгая математическая оценка результатов обработки по предлагаемым алгоритмам отсутствует и в [8-10]. Наиболее общими способами описания являются векторно-матричное представление и представление с использованием детерминированных или стохастических функций, а также на их основе структурное, признаковое и множественное представления [11].

#### **Метод линейного предсказания высокого порядка**

Модель суперпозиции сигналов, которые перекрываются, при условии, что зависимость эквивалентного шумового спектрального компонента близка к белому шуму, целесообразно подать в виде:

$$\hat{S}(f_k) = \sum_{m=1}^{M=2N} p(m)S(f_{k-m}), k=1,2,\dots,K, \quad (1)$$

где  $p(m)$  – коэффициенты линейного прогнозирования;  $M$  – порядок фильтра линейного прогнозирования;  $K$  – число частот, на которых измеряется спектральная характеристика  $S(f)$  (оно, как правило, совпадает с числом временных отсчетов сигнальной последовательности  $s(t)$ ) [4].

Задача повышения разделяющей способности визуального анализа суперпозиций сигналов, которые перекрываются, решается на основе использования модели синтезированного «отфильтрованного» эхо-импульсного изображения:

$$\hat{s}(t) = \frac{\sigma^2}{\left[1 - \sum_{i=1}^M p_i e^{-j2\pi i \Delta f t}\right]^2}, \quad (2)$$

где  $\sigma^2$  рассматривается как дисперсия ошибки линейного прогнозирования для заданного порядка модели  $M$ ;  $\Delta f = f_k - f_{k-1}$  – величина, которая характеризует дискретность спектральной характеристики  $S(f)$ , которая возникает через конечное значение временного интервала регистрации суперпозиции  $s(t)$ .

### Эксперимент 1

На входе системы присутствует исходная импульсная последовательность (суперпозиция зашумленных сигналов, которые перекрываются) т.е. текущий столбец обрабатываемого изображения, на выходе – «синтезированная» времязависимая последовательность, которая измеряется в отношениях амплитуд. Основным объектом исследований (исходная информация) было изображение соответствующего формата (GIF, BMP, JPEG), которое считывалось в компьютер в виде числовой матрицы (например, 400x400 пикселей) [5].

На рис. 1 показано изображение мозга в разрезе, полученное с помощью магнито-резонансной томографии.




Рис. 1. Исходное изображение мозга в разрезе: (а) – оригинал; б – применение преобразования Гильберта; в – применение метода линейного предсказания (порядок модели  $M=60$ ); г – полюсо-частотный срез 113-го столбца исходного изображения; д – тот же срез синтезированного; ж – его спектр.

Из анализа рисунка 1 следует, что исходное изображение слабоконтрастно и нет возможности выделить аномальные структуры.

Использование преобразования Гильберта для удаления низкочастотной компоненты (тренда) с целью нейтрализации влияния системы автоматического регулирования уровня (АРУ) тоже не дало положительных результатов (рис. 1б). И только применение метода линейного предсказания при достаточно высоком порядке модели ( $M=60$ ) позволило четко выделить скрытые структуры (рис. 1в).

Это же показывает и срез 113-го столбца синтезированного изображения, пики импульсов последовательности (высокочастотная составляющая, отвечающая за резкость изображения) намного острее.

**Метод разложения исходного изображения с помощью вейвлет-преобразования и синтез результирующего изображения на основе нейронной сети**

Расширение информационной базы анализа открывается на основе использования двумерного вейвлет-преобразования, в рамках которого используется двумерная масштабирующая функция

$$\varphi(x, y) = \varphi(x)\varphi(y) \quad (3)$$

и три разделимые «направленные» вейвлет-функции:

$$\psi^H(x, y) = \psi(x)\varphi(y), \quad (4)$$

$$\psi^V(x, y) = \varphi(x)\psi(y), \quad (5)$$

$$\psi^D(x, y) = \psi(x)\psi(y). \quad (6)$$

Таким образом, одному исходному изображению  $I(x, y)$  можно сопоставить четыре новых, причем  $\varphi(x, y)$  будет представлять собой вдвое уменьшенную копию изображения  $I(x, y)$ .

На рис. 2 даны характеристики вейвлет-разложения радиологического изображения.

Анализ рис. 2 показывает, что три «направленные» вейвлет-характеристики  $\psi^H(x, y)$ ,  $\psi^V(x, y)$  и  $\psi^D(x, y)$  позволяют выделить ряд информативных признаков, неразличимых на исходных изображениях ( $\varphi(x, y)$ ), которые фактически представляют собой лишь уменьшенную копию исходного изображения), что и открывает потенциальную возможность повышения чувствительности и разрешающей способности визуального анализа слабоконтрастных изображений [6].




Рис. 2. Характеристики вейвлет-разложения радиологического изображения

Существует большое количество различных типов вейвлет-функций [7]. Применительно к визуальному анализу слабоконтрастных изображений, они дают одинаковый результат: в экспериментах были использованы вейвлет-функции Добеши [8]. Таким образом, на основании использования метода вейвлет-декомпозиции из одного исходного изображения синтезируется четыре новых, но при этом возникает проблема синтеза одного результирующего изображения. Эта задача решалась на основе использования самоорганизующейся нейронной сети Кохонена. Кратко структура работы алгоритма дана в [9].

### Эксперимент 2

На рис. 3 представлены результаты нейросетевого синтеза, а на рис. 4 также яркостно-контрастные и пространственные срезы средних строк исходного и синтезированного радиологического изображений.



Рис. 3. Результаты нейросетевого синтеза и синтеза на основе модели линейного предсказания: а – исходное изображение; б – синтезированное изображение на основе использования модели линейного предсказания ( $M=50$ ); в – изображение, полученное на основе нейросетевого синтеза.





Рис. 4. Результаты нейросетевого синтеза и синтеза на основе модели линейного предсказания радиологического изображения: а – яркостно-контрастный и пространственный срез 32-го столбца исходного изображения, синтезированный способом нейросетевого синтеза (б) и синтеза на основе модели линейного предсказания (в), соответственно

Представленные на рис. 3 и рис. 4 данные свидетельствуют о том, что для некоторых типов изображений, синтезированное изображение на основе использования модели линейного предсказания при порядке модели  $M=50$  позволяет повысить чувствительность и пространственную разрешающую способность визуального анализа слабоконтрастных изображений, тогда когда метод нейросетевого синтеза не дает желаемого результата. Похожая тенденция наблюдается и для некоторых других типов изображений.


Так, в сфере геоинформационных систем большинство изображений дистанционного зондирования земной поверхности являются мультиспектральными и анализируются как цветные RGB изображения [10, 11]. На рис. 5 представлено изображение участка акватории Черного моря (цветное изображение конвертировано к градациям серого).



Рис. 5. Изображение – оригинал участка акватории Черного моря



а



б

Рис. 6. Анализ мультиспектрального изображения: а – результат нейросетевого синтеза; б – синтезирование на основе метода линейного предсказания для порядка модели  $M=50$ .  
Интерес представляет именно акватория с точки зрения обнаружения участков

потенциальных залежей углеводов. Однако на исходном изображении не удастся осуществить процедуру сегментации из-за очень низких перепадов значений яркости и цвета.

В данном случае необходимо осуществлять вейвлет-декомпозицию для трех спектральных каналов по отдельности, что приводит к синтезу 12-мерного ансамбля новых изображений. Нейронная сеть формирует единое результирующее изображение (рис. 6а), из которого видно, что предлагаемый подход к анализу мультиспектральных слабоконтрастных изображений позволил выделить множество участков акватории морской поверхности.

Метод линейного предсказания вообще не позволил обнаружить участки акватории и создал ложные переотражения (рис. 6б).

### Результаты

Экспериментально продемонстрированы возможности современных технологий анализа слабоконтрастных изображений, основанные на сочетании вейвлет-декомпозиции исходного изображения, и самоорганизующийся нейросетевой синтез одного результирующего изображения из многомерного массива, в сравнении с методом линейного предсказания высшего порядка, а также произведена визуальная оценка различных типов изображений и их характеристик, раскрыты возможности повышения эффективности их анализа. Это позволит в дальнейшем выявить новые возможности для повышения эффективности обработки и анализа различных типов изображений.




Рис. 7. Выделение максимально однородной области изображения.

При поверхностном рассмотрении более высокие порядки фильтров модели линейного предсказания (М) или N-мерного ансамбля новых изображений нейросетевого синтеза, по большей части, кажутся более

качественными, чем низкие. Однако, с высокими порядками обеих моделей неразрывно связан уровень шума. Чем они больше, тем больше возрастает уровень шума. Это происходит потому, что при увеличении порядков моделей посредством цифрового усиления соотношение «сигнал-шум» остается неизменным, то есть, изменить собственные характеристики изображения невозможно.

Существует достаточно много методов как абсолютной, так и относительной оценки качества изображений. На практике можно использовать инструментальные средства для анализа изображений, как, например, ImageJ – свободно распространяемое инструментальное средство, с помощью которого можно просматривать, редактировать и анализировать изображения [12]. После загрузки изображений в ImageJ на них необходимо выделить прямоугольную, максимально однородную область для светлых участков (рис. 7) и для темных. После этого, для выделенного участка изображения, комбинацией клавиш Ctrl + H, генерируем гистограмму для светлых и темных участков. (рис. 8 а и б).

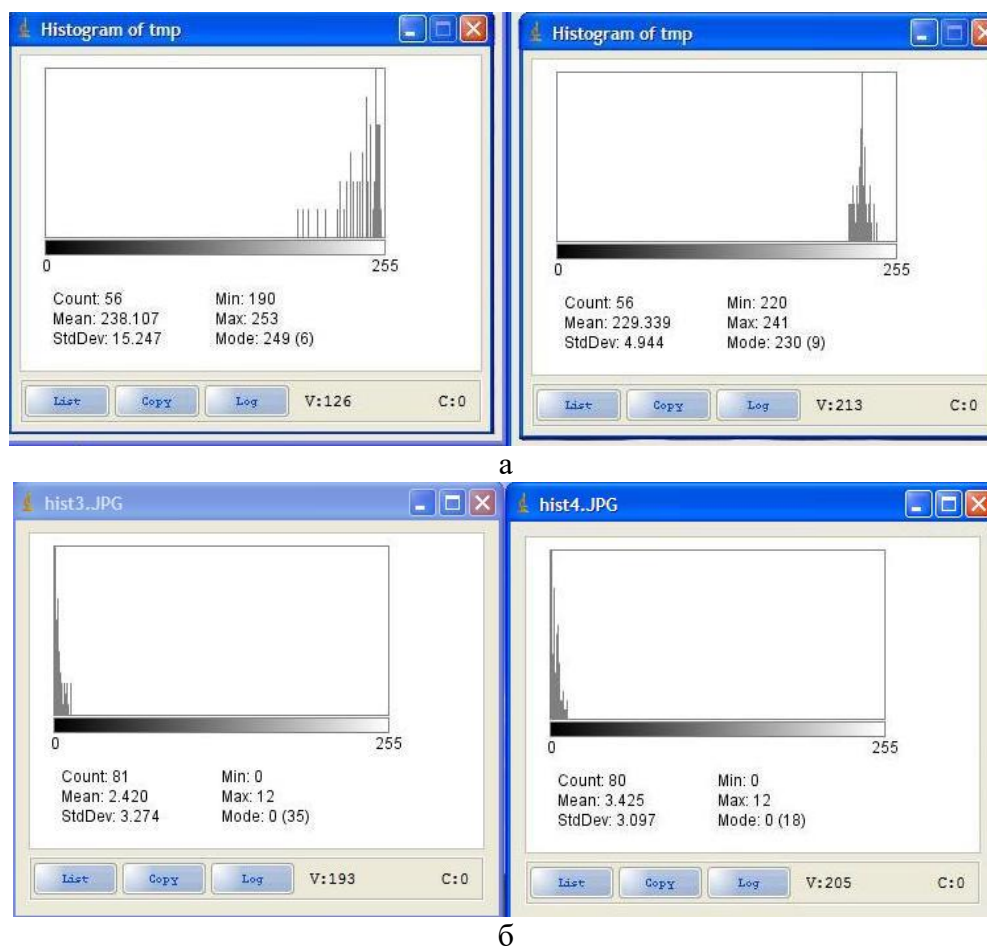


Рис. 8. Гистограмма: а – светлых участков, б – темных участков

Соотношение «сигнал-шум» (SNR) изображения слева составит:

$$SNR = \frac{\text{mean} [_{(\text{светлое})} - \text{mean} ]_{(\text{темное})}}{\text{StdDev}_{(\text{светлое})}} = \frac{238,1 - 2,4}{15,2} = 15,35$$

где:  $\text{mean}_{(\text{светлое})}$  – среднее значение светлого на выделенном участке;  $\text{mean}_{(\text{темное})}$  – среднее значение темного;  $\text{StdDev}$  – среднеквадратичное отклонение на



светлом участке.

Аналогично для изображения справа:

$$SNR = \frac{\text{mean} [I_{(\text{свет.лосе})} - \text{mean}]_{(\text{темное})}}{\text{StdDev}_{(\text{свет.лосе})}} = \frac{229,3 - 3,4}{4,9} = 46,1$$

Таким образом, соотношение «сигнал-шум» изображения справа выше, чем изображения слева в 3 раза. Следовательно, меньше помех и искажений и выше качество.

### Выводы

1. При всем многообразии новых методов фильтрации и сегментации изображений отсутствует строгий математический аппарат оценки их качества.

2. Рассмотренные методы позволяют повысить чувствительность и пространственную разрешающую способность визуального анализа слабоконтрастных изображений.

3. Впервые продемонстрировано, что метод линейного предсказания лучше зарекомендовал себя для анализа радиологических и магнито-резонансных слабоконтрастных изображений, при этом порядок модели предсказания должен быть достаточно высоким (40 и более).

4. Вейвлет-декомпозиция обеспечивает увеличение пространства информативных признаков, а нейросетевой синтез обеспечивает синтез одного результирующего изображения из многомерного ансамбля вейвлет-декомпозиции как яркостных (одномерных), так и мультиспектральных изображений.

5. Впервые показано, что, при визуальном сравнении, анализ мультиспектральных изображений с помощью метода вейвлет-декомпозиции и нейросетевого синтеза показал наилучшие результаты.

6. Практически продемонстрирована возможность оценки качества изображений с помощью простых инструментальных средств (ImageJ2x).

### Литература

1. Гонсалес Р. Цифровая обработка изображений. / Р. Гонсалес, З. Вудс. – М.: Техносфера, 2006. – 1070 с.
2. Яне Б. Цифровая обработка изображений. / Б. Яне – М.: Техносфера, 2007. – 583 с.
3. Ахметшин О.М. Нейромережева сегментація низькоконтрастних зображень геофізичних полів на основі багатопараметрового методу нуль-просторового відображення. / О.М. Ахметшин, Л.Г. Ахметшина. – Геоінформатика, Київ, 2003, №2. – С. 65-73.
4. Степаненко А.А. Разложение суперпозиций неизвестных импульсных сигналов адаптивным спектральным методом линейного предсказания / А.А. Степаненко, А.М. Ахметшин // Вестник информационных и компьютерных технологий, – М.: Машиностроение. – 2006. – №10. – С. 2 – 12.
5. Степаненко А.А. Повышение чувствительности ультразвуковой диагностики на основе метода параметрического спектрального анализа второго порядка / А.А. Степаненко, А.М. Ахметшин // Клиническая информатика и телемедицина. – 2005. – Т.2. – №1. С. 98 – 100.
6. Слюняева В.А. Повышение чувствительности анализа слабоконтрастных изображений на основе сочетания методов вейвлет-преобразования и самоорганизующегося нейросетевого синтеза. / В.А. Слюняева, А.М. Ахметшин. Матеріали VI Міжнародної наук.-практ. конф. молодих учених і студентів, «Інформаційні процеси і технології «Інформатика – 2013»»: Севастополь, 22-26 квіт. 2013 р. / СНТУ – Севастополь : Вебер, 2013. – С. 66-67.
7. Мала С. Вейвлеты в обработке сигналов / С. Мала. – М., Мир, 2005, – 672 с.
8. Добеши И. Десять лекций по вейвлетам / И. Добеши. – Ижевск, РХД, 2001. – 464 с.
9. Кохонен Т. Самоорганизующиеся карты / Т. Кохонен. – М.: Бином, 2008. – 655 с.
10. Злобин В.К., Еремеев В.В., Васильев В.М. Стохастическая модель спутниковых изображений и ее использование для сегментации природных объектов. / В.К. Злобин, В.В. Еремеев, В.М. Васильев // Автометрия. – 2002. – № 2. – С. 41-50.
11. Соломатин И.И. Обзор методов предварительной обработки тоновых изображений для

- распознавания искусственных объектов. / И.И. Соломатин // Изв. вузов. Приборостроение. – 1996. – Т. 39. – № 7. – С. 5-12.
12. Черановски К., Швер М. Как оценить качество изображения? // Электронный журнал «Мост безопасности», № 1, 2016. Режим доступа: [http://www.security-bridge.com/biblioteka/stati\\_po\\_bezопасnosti/kak\\_ocenit\\_kachestvo\\_izobrazheniya/](http://www.security-bridge.com/biblioteka/stati_po_bezопасnosti/kak_ocenit_kachestvo_izobrazheniya/)

### Literatura

1. Gonsales R. Tsifrovaya obrabotka izobrazheniy. / R. Gonsales, Z. Vuds. – М.: Tehnosfera, 2006. – 1070 s.
2. Yane B. Tsifrovaya obrabotka izobrazheniy / B. Yane – М.: Tehnosfera, 2007. – 583 s.
3. Ahmetshin O.M. Neyromerezheva segmentatsiya nizko kontrastnih zobrazhen' geofizichnih poliv na osnovi bagatoparametrovogo metodu nul-prostorovogo vidobrazhennya. / O.M. Ahmetshin, L.G. Ahmetshina. – GeoInformatika, Kiyv, 2003, #2, S. 65-73.
4. Stepanenko A.A. Razlozhenie superpozitsiy neizvestnykh impul'snykh signalov adaptivnym spektral'nym mehtodom lineynogo predskazaniya / A.A. Stepanenko, A.M. Ahmetshin // Vestnik informacionnyh i komp'uternykh tekhnologiy, - М: Mashinostroenie. - 2006. №10. – S. 2-12.
5. Stepanenko A.A. Povishenie chuvstvitel'nosti ul'trazvukovoi diagnostiki na osnove metoda parametricheskogo spektral'nogo analiza vtorigo poryadka / A.A. Stepanenko, A.M. Ahmetshin // Klinicheskaya informatika i telemedicina. – 2005. – Т.2. – №1. S. 98-100.
6. Slyunyaeva V.A. Povishenie chuvstvitel'nosti analiza slabo-kontrastnykh izobrazheniy na osnove sochetaniya metodov veyvlet preobrazovaniya I samoorganizuyuschegosya neyrosetevogo sinteza. / V.A. Slyunyaeva, A.M. Ahmetshyn. Materialy VI Mezhdunarodnoy nauchno-prakticheskoy konferentsiy molodykh uchenykh I studentov "Informacionnye processy i tekhnologiy «Informatika-2013»": Sevastopol' 22-26 kvitnya 2013 r. / SNTU – Sevastopol': Veber, 2013. – S. 66-67.
7. Mala S. Veyvletyi v obrabotke signalov / S. Mala. – М., Mir, 2005. – 672 s.
8. Dobeshi I. Desyat' lektsiy po veyvletam / I. Dobeshi. – Izhevsk, RHD, 2001. – 464 s.
9. Kohonen T. Samoorganizuyuschiesya kartyi / T. Kohonen. – М.: Binom, 2008. – 655 s.
10. Zlobin V.K., Ereemeev V.V., Vasilev V.M. Stohasticheskaya model sputnikovyykh izobrazheniy i ee ispolzovanie dlya segmentatsii prirodnykh ob'ektov. / V.K. Zlobin, V.V. Ereemeev, V.M. Vasilev // Avtometriya. - 2002. - # 2. - S. 41-50.
11. Solomatin I.I. Obzor metodov predvaritel'noy obrabotki tonovykh izobrazheniy dlya raspoznavaniya iskusstvennykh ob'ektov. / I.I. Solomatin // Izv. vuzov. Priborostroenie. - 1996. - Т. 39. - # 7. - S. 5-12.
12. Cheranovski K., Shver M. Kak otsenit kachestvo izobrazheniya? // Elektronnyy zhurnal «Most bezопасnosti», # 1, 2016. Rezhim dostupa: [http://www.security-bridge.com/biblioteka/stati\\_po\\_bezопасnosti/kak\\_ocenit\\_kachestvo\\_izobrazheniya/](http://www.security-bridge.com/biblioteka/stati_po_bezопасnosti/kak_ocenit_kachestvo_izobrazheniya/)

## RESUME

### A. Stepanenko

#### **Analysis and recovery of low-contrast images by neural network synthesis in comparison with the linear prediction**

Article shows a comparative analysis of the efficiency of the recovery of low-contrast images, based on the use of self-organizing neural network methods of synthesis and linear prediction, which allow to increase the sensitivity and spatial resolution of the visual analysis of low contrast luminance and multispectral images.

With all the variety of new methods of image processing and analysis, filtering and image segmentation, there is no rigorous mathematical apparatus for evaluating their quality, the problem of choosing a solution for a particular problem arises, since in most cases the algorithms are modeled on completely different technologies for obtaining original images, and their evaluation is performed visually.

In the general hierarchy of image processing and analysis problems, the problem of analyzing low-contrast images characterized by a narrow range of gradation of brightness, the presence of smoothed (fuzzy) areas, is of particular complexity, detection and analysis of which are often of primary interest (oncology, anomalous sections of images of geophysical fields and Remote sensing data).

The methods considered allow to increase the sensitivity and spatial resolution of visual analysis of low-contrast images. For the first time it was shown that the method of linear prediction proved to be better for the analysis of radiological and magneto-resonant low-contrast images, and the order of the prediction model should be sufficiently high (40 or more). Wavelet decomposition provides an increase in the space of informative features, and neural network synthesis provides the synthesis of a single resulting image from a multidimensional wavelet decomposition ensemble of both luminance (one-dimensional) and multispectral images.

At the input of the system, there is an initial pulse sequence (superposition of noisy signals that overlap). The current column of the processed image, the output is a "synthesized" time-dependent sequence, which is measured in the ratio of the amplitudes. The main object of the research (initial information) was the image of the corresponding format (GIF, BMP, JPEG), which was read into the computer in the form of a numerical matrix (for example 400x400 pixels). Color image requires preliminary conversion to grayscale.

It was shown for the first time that in a visual comparison, the analysis of multispectral images using the wavelet decomposition method and neural network synthesis showed the best results. Practically demonstrated the possibility of assessing the quality of images using simple tools (ImageJ2x).

*Надійшла до редакції 24.03.2017*