

Применение нейронных сетей для диагностики вида и параметров искажений изображения

Я. К. Соломенцев*, П. А. Чочиа**

* Московский физико-технический институт, Москва, Россия
solomencev-yaroslav@mail.ru

** Институт проблем передачи информации им. А. А. Харкевича РАН, Москва, Россия
chochia@iitp.ru

Поступила в редколлегию 01.06.2020

Аннотация—Регистрация изображений во многих случаях сопровождается искажениями, вызываемыми неточностями фокусировки, смещениями сцены или устройства регистрации, рассеянием излучения в среде прохождения сигнала и аналогичными. Решение задачи восстановления сигнала требует знания искажающего оператора, который, как правило, неизвестен. Поэтому вопрос определения вида и параметров искажения по наблюдаемому сигналу является актуальным. В работе предложен новый подход к решению задачи диагностики искажений видеоинформации на основе использования глубоких нейронных сетей. Решается задача определения типа и параметров линейных однородных искажающих операторов основных видов: круговой формы прямоугольного профиля, круговой формы Гауссова профиля и линейной формы прямоугольного профиля. Исследуется возможность применения нейронных сетей с архитектурами ResNet50, ResNet29 и ResNet18 для идентификации вида и определения параметров искажений. Показано, что качество работы нейронной сети не уступает методам, основанным на спектральном анализе.

КЛЮЧЕВЫЕ СЛОВА: Искажения изображений, нейронные сети, диагностика искажений.

1. ВВЕДЕНИЕ

Параметры оптических систем и условия съемки являются основными факторами, влияющими на качество регистрируемых изображений. Особенно существенны подобные искажения при дистанционном зондировании. Искажения чаще всего вызываются неточностями фокусировки, взаимными смещениями наблюдаемой сцены и устройства регистрации, рассеянием излучения в среде прохождения сигнала. Для решения задачи восстановления сигнала требуется знать искажающий оператор. Если известны характеристики, положение и движение камеры, а также оптические свойства среды, то можно вычислить функцию рассеяния точки и решить задачу восстановления сигнала. Иногда можно предполагать класс и основные свойства возможных искажений, например: линейность, конечность, неотрицательность, однородность. Конкретные же параметры остаются, как правило, неизвестными. Поэтому диагностика искажений по наблюдаемому изображению является актуальной.

Задача оценивания параметров искажения изучается во многих работах. Большинство посвящено линейному смещению [1–3], заметно меньшее количество — круговому рассеянию [4–6], Гауссову рассеянию [7], сложному относительному движению камеры, как то: отдалению, приближению и вращению [8]; иногда рассматривается сочетание нескольких вариантов искажений. Несмотря на это проблема определения типа и параметров искажения остается еще не решенной.

Большинство известных методов идентификации искажающего оператора основано на анализе Фурье-спектров сигналов, что вполне оправданно, однако диагностика каждого из видов

искажений требует разработки индивидуального алгоритма анализа [9]. В настоящей работе мы предлагаем решать эту задачу при помощи единого нейросетевого подхода.

2. МОДЕЛИ ИСКАЖЕНИЙ ИЗОБРАЖЕНИЯ

В рамках класса искажений, описываемых линейными однородными операторами рассеяния, получаемое изображение $f(x, y)$ может быть представлено в виде свертки исходного сигнала $g(u, v)$ с искажающей функцией $h(x - u, y - v)$, и последующего суммирования с независимым некоррелированным аддитивным шумом ξ :

$$f(x, y) = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} g(u, v)h(x - u, y - v)dudv + \xi(x, y), \quad -\infty < (x, y) < \infty. \quad (1)$$

Так же, как и в [9], ограничимся вопросами диагностики типа и параметров линейных однородных операторов рассеяния, задаваемых следующими операторами.

Линейный смаз обычно возникает при равномерном прямолинейном движении устройства регистрации относительно наблюдаемой сцены. Параметрами искажения являются направление α ($0 \leq \alpha < \pi$) и величина смещения r . Централно-симметричный оператор линейного смаза описывается формулой

$$h_S(x, y) = \begin{cases} 1/r & y = x \tan \alpha, \quad x^2 + y^2 \leq r^2/4; \\ 0 & \text{в остальных точках.} \end{cases} \quad (2)$$

Круговое размытие описывает эффект нарушения фокусировки оптического устройства. Центрированный оператор кругового размытия прямоугольного профиля радиуса r имеет вид:

$$h_C(x, y) = \begin{cases} 1/(\pi r^2) & x^2 + y^2 \leq r^2; \\ 0 & \text{в остальных точках.} \end{cases} \quad (3)$$

Гауссово размытие чаще всего используют как функцию рассеяния точки при описании турбулентности атмосферы [8, 10] с параметром σ , характеризующим силу рассеяния:

$$h_G(x, y) = (1/2\pi\sigma^2) \exp\{-(x^2 + y^2)/2\sigma^2\}. \quad (4)$$

3. НЕКОТОРЫЕ ПОДХОДЫ К ДИАГНОСТИКЕ ИСКАЖАЮЩЕГО ОПЕРАТОРА

Анализ спектра является наиболее часто используемым вариантом трансформационного анализа. Он основан на том, что согласно теореме о свертке, спектр получаемого сигнала $F(\omega)$ ($\omega = \{\omega_x, \omega_y\}$), описываемого уравнением (1) можно записать как произведение спектров исходного сигнала $G(\omega)$ и функции искажения $H(\omega)$ в сумме со спектром шума $\Xi(\omega)$, вычисляемых при помощи преобразования Фурье:

$$F(\omega) = H(\omega)G(\omega) + \Xi(\omega). \quad (5)$$

Как известно, по амплитудным характеристикам спектров $G(\omega)$ удается сделать лишь общие заключения об особенностях изображений [10, 11], а амплитуду спектра шума $\Xi(\omega)$ можно считать постоянной. Спектры же искажающих операторов $H(\omega)$ уникальны и существенно отличаются от спектров реальных изображений. Согласно (5) отличительные черты $H(\omega)$ переносятся в спектры искаженных изображений, а значит особенности $H(\omega)$ могут быть обнаружены в спектре $F(\omega)$ и использованы для анализа.

Такие искажающие операторы как линейный смаз или круговое размытие приводят к появлению в Фурье-спектре сигнала множества нулей, имеющих определенное пространственное

расположение; Гауссово размытие также приводит к значительному ослаблению амплитуды спектра. Обнаружение особенностей спектра и их интерпретация позволяют сделать вывод о виде и параметрах искажения. Проблемы в данном подходе появляются из-за влияния шума, неоднородностей искажающего оператора, отличия его формы от идеальной. Если указанные помехи не превосходят определенного уровня, то применением специфических методов распознавания удастся с определенной точностью решить задачу диагностики [9].

Локально-однородная деконволюция [12, 13] использует пространственную однородность и ограниченность искажающего оператора $h(x, y)$. При этом предполагается, что локальные характеристики изображения, связанные с его сюжетом, меняются в каждом участке сцены.

Разобьем получаемое изображение на K непересекающихся фрагментов. С точностью до влияния шума, спектр каждого фрагмента можно представить в виде

$$F_k(\omega) = H_k(\omega)G_k(\omega) + \Xi(\omega), \quad (6)$$

где H , ξ , G и F суть амплитудные спектры искажающего оператора, шума, исходного и результирующего сигналов соответственно. Считая шум малым, и пренебрегая составляющей ξ , перепишем уравнение (6) для логарифмов:

$$\log |F_k(\omega)| = \log |H_k(\omega)| + \log |G_k(\omega)|. \quad (7)$$

Усреднив (7) по K фрагментам и учитывая однородность искажения $H_k = H$, получим:

$$\log |H(\omega)| = \frac{1}{K} \sum_k \log |F_k(\omega)| - \frac{1}{K} \sum_k \log |G_k(\omega)|. \quad (8)$$

Потенцированием найденных значений $\log |H(\omega)|$ получим оценку амплитуды спектра искажающего оператора $|H(\omega)|$.

Первое слагаемое в правой части выражения (8) представляет собой выборочное среднее значений логарифмов частот искаженного изображения и может быть легко вычислено. Вторая компонента — аналогичная оценка для исходного неискаженного изображения — является неизвестной. В [13] показано, что она мало меняется для изображений хорошего качества, и, следовательно, может быть получена как среднее по достаточному набору типичных образцов. Аналогичное предположение было также сделано в работе [9].

Данный подход имеет несколько очевидных проблем. Во-первых, должен быть низок уровень шума ξ в (6). Во-вторых, пространственные размеры искажающего оператора $H(\omega)$ должны быть малы, чтобы можно было сформировать достаточно представительное число K фрагментов. В-третьих, выражения (7) и (8) справедливы для амплитуд спектров, что означает потерю фазы; следовательно, либо оператор $H(\omega)$ должен иметь соответствующие симметрии, либо фаза должна определяться из каких-то дополнительных соображений.

Дуальный подход к диагностике предполагает, что искаженному изображению можно поставить в соответствие множество возможных пар {искажающий оператор — соотносящееся изображение}. В этом множестве будет содержаться как пара {истинный искажающий оператор — неискаженное изображение}, так и пары с более “гладкими” искажающими операторами и более “резкими” изображениями, причем уровни гладкости искажающего оператора и соотносящегося изображения оказываются обратно зависимыми [10]. Какая именно пара из указанного допустимого множества является правильной, нам неизвестно. Поэтому задачей является выбор в нем той пары, которая наилучшим образом соответствует некоторым задаваемым критериям, например, критериям гладкости.

Выбранная нами задача нахождения вида и параметров искажающего оператора при помощи нейронных сетей (НС) в некотором смысле близка именно такому подходу.

4. КОМПОНЕНТЫ ДИАГНОСТИКИ ИСКАЖЕНИЙ ПРИ ПОМОЩИ НС

В качестве возможного подхода к оцениванию параметров искажающих операторов был выбран анализ на основе использования нейронных сетей. В последние годы НС получили большую популярность в задачах классификации данных, поскольку дают возможность использовать неявные и трудно формализуемые признаки. Во многих случаях такой вариант анализа оказывается лучше классических подходов.

Диагностика искажений при помощи НС включает решение нескольких задач, среди которых: выбор способа предварительного преобразования данных, формирование набора данных для настройки и тестирования алгоритма НС, выбор структуры НС, настройка (обучение) НС. В настоящей работе использовались некоторые известные архитектуры НС, опробованные в задачах классификации изображений.

4.1. Предварительное преобразование данных

Распознавание вида и параметров искажения может осуществляться как путем непосредственного анализа наблюдаемого изображения, так и путем анализа данных, получаемых с помощью какого-то предварительного преобразования. Проведенные эксперименты по сравнению различных видов диагностики искажений, а также ранее полученные результаты исследований, касающиеся идентификации искажений на основе анализа спектров [9], показали преимущество последнего способа.

На основании этого для диагностики искажений был выбран трансформационный подход, основанный на предварительном преобразовании изображений в частотную область и последующем анализе спектров $F(\omega)$ в (5). Кроме того, поскольку спектры реальных изображений характеризуются быстрым спаданием амплитуды с ростом частоты, то анализировались не сами амплитуды, а значения их логарифмов: $\log |F(\omega)|$.

4.2. Формирование набора данных для настройки НС и тестирования алгоритма

Исходными изображениями являлись фотоснимки высокого разрешения, не подвергавшиеся сжатию с потерями. С помощью операций масштабирования и вырезания непересекающихся участков был составлен набор неискаженных изображений, каждое размерами 512×512 пикселей. Некоторые из первоначальных изображений показаны на Рис.1.




Рис. 1. Примеры изображений, использованных в экспериментах.

Параллельно генерировалось множество операторов искажения следующих видов и параметров: кругового размытия с диапазоном радиусов от 3 до 50 пикселей; Гауссова размытия с величиной среднеквадратического отклонения от 2 до 10 пикселей; линейного смаза размерами от 5 до 70 пикселей и углами поворота от 0 до π . По каждому из диапазонов параметры искажающих операторов распределялись приблизительно равномерно, чтобы набор данных

был сбалансированным, и не возникало переобучения нейронной сети на каких-то отдельных видах искажений.

Ансамбль искаженных изображений формировался операциями свертки неискаженных изображений из указанного набора с тем или иным искажающим оператором. Затем вся совокупность была разделена на множество обучающей выборки и множество тестовой выборки (в соотношении 4:1) так, что пропорции между количеством изображений в тестовых и обучающих выборках для каждого класса были приблизительно одинаковыми. Итоговый набор данных составлял около 1500 изображений по каждому из видов искажений.

5. СТРУКТУРА И ОБУЧЕНИЕ НС

Для решения задачи был выбран вид глубоких “остаточных” сверточных нейронных сетей (*residual neural networks, ResNet*) [14, 15]. Реализация осуществлялась на основе нейросетевой библиотеки “Keras” [16]. Процедуры обучения НС, а равно и распознавания строились по двухэтапному сценарию: на первом этапе происходило распознавание вида искажения из четырех классов: исходное неискаженное изображение, линейный смаз, круговое размытие, Гауссово размытие. На втором этапе производилось определение параметров искажения для уже выбранного класса, т.е. определение параметров осуществлялось уже для каждого из трех классов искажений по отдельности.

Для минимизации функции ошибки применялся метод стохастической оптимизации Adam [17], а в качестве функции потерь использовалась бинарная кросс энтропия $H(p, q)$:

$$H(p, q) = -\frac{1}{N} \sum_{n=1}^N \sum_{m=1}^M p_n^m \log(q_n^m), \quad (9)$$

где $p_n^m \in \{0, 1\}$ — индикаторная функция принадлежности объекта n классу m , q_n^m — вероятность, с которой алгоритм предсказывает принадлежность объекта под номером n классу m , N — количество наблюдаемых объектов, M — количество классов. В качестве метрики качества классификации НС использовалась доля верных ответов (точность) A :

$$A = (T_P + T_N)/N, \quad (10)$$

где T_P — количество верных ответов для объектов с $p_n^m = 1$, а T_N — количество верных ответов для объектов с $p_n^m = 0$.

Определение угла линейного смаза выполнялось с помощью НС классификации. В качестве функции потерь использовалась кросс-энтропия (9), а в качестве значения ошибки углового отклонения величина

$$\delta = \min(|\alpha_t - \alpha_p|, \pi - |\alpha_t - \alpha_p|),$$

где α_t — истинное значение угла, α_p — угол, предсказываемый НС.

Определение величины линейного смаза, кругового размытия и Гауссова размытия осуществлялось при помощи НС как регрессия к одному выходному сигналу. Функцией активации последнего нейрона являлась

$$\phi(x) = |x|.$$

Функцией ошибки и метрикой для оценки результата регрессии была средняя относительная ошибка E , вычисляемая по формуле:

$$E = \frac{1}{N} \sum_{n=1}^N \frac{|b_t(n) - b_p(n)|}{b_t(n)}, \quad (11)$$

где $b_t(n)$ и $b_p(n)$ — фактическое и предсказываемое с помощью НС значения величины размытия n -го изображения, N — количество изображений в анализе.

6. ЭКСПЕРИМЕНТЫ

Процессы обучения НС и распознавания осуществлялись на базе изображений, искусственно искаженных по формулам (2)–(4). Сравнения результатов распознавания вида и параметров искажения при помощи НС с архитектурами ResNet50, ResNet29 и ResNet18 [16] проводились как путем непосредственного анализа искаженных изображений, так и путем анализа спектров изображений. Сравнительные показатели точности идентификации вида искажения в результате обучения НС по самому изображению или по амплитуде его спектра при помощи различных архитектур сети, усредненные по ансамблю имеющихся наборов данных, приводятся в Табл. 1. Значения отражают долю верных ответов на тестовой выборке по эпохам, когда показатели ответов на обучающей выборке стабилизировались.

Табл. 1. Точность классификации вида искажения.

Архитектура НС	Вид оценки	Способ идентификации искажения	
		По изображениям	По амплитудам спектров
ResNet50	Среднее значение	0,9376	0,9788
	СКО	0,038	0,0196
ResNet29	Среднее значение	0,875	0,9698
	СКО	0,052	0,033
ResNet18	Среднее значение	0,9271	0,986
	СКО	0,048	0,0077

Сравнение приведенных данных показывает, что при обучении НС непосредственно на искаженных изображениях лучшие результаты у ResNet50. Однако при обучении НС на спектрах искаженных изображений лучшее качество имеет ResNet18. Также видно, что для всех видов архитектур точность идентификации по спектрам изображений существенно выше точности идентификации непосредственно по искаженным изображениям. Таким образом, эксперименты подтвердили, что НС дает лучше результаты при обучении на спектрах, чем на самих искаженных изображениях, а наилучшей по метрике точности (10) оказалась сеть с архитектурой ResNet18.

Как уже говорилось выше, распознавание состояло из двух этапов: распознавание вида искажения, а затем определение параметров для уже выбранного класса. Приведенные ниже графики (Рис. 2–4) иллюстрируют изменение точности диагностики НС ResNet18 вида искажения и параметров размытия в зависимости от номера эпохи (N); под *эпохой* здесь подразумевается “прогон” НС на всем множестве данных. Черные линии, обозначенные ‘1’, соответствуют классификации по обучающей выборке, а серые ‘2’ — по тестовой выборке.

На первом этапе осуществлялась *классификация вида искажения*.

Точность (Accuracy) НС ResNet18 выходит на плато после 20-й эпохи: на обучающей выборке вблизи среднего значения 0,995 при СКО $\sigma \approx 0,0013$, а на тестовой выборке — вблизи среднего значения 0,986 при СКО $\sigma \approx 0,0077$. На Рис. 2 представлена зависимость доли верных ответов (A) от номера эпохи (N).

На втором этапе производилось *определение параметров размытия*.

Ниже на графиках иллюстрируется изменение средней относительной ошибки E (11) в зависимости от номера эпохи (N).

Для кругового размытия (Рис. 3а) средняя относительная ошибка после 20-ой эпохи на обучающей выборке составила 0,043, а на тестовой выборке — 0,051. Для Гауссового размытия (Рис. 3б) средний уровень ошибки перестал снижаться после 30-ой эпохи и составил на обучающей выборке 0,0347, а на тестовой выборке — 0,0363.




Рис. 2. Зависимости доли верных ответов (A) от номера эпохи (N) при идентификации вида искажения.




Рис. 3. Изменение средней относительной ошибки (E) от номера эпохи (N) при определении величины: а) радиуса кругового размытия; б) СКО Гауссова размытия.




Рис. 4. Изменение средней относительной ошибки (E) от номера эпохи (N) при: а) классификации угла линейного смаза; б) регрессии к значению линейного смаза.

В случае линейного смаза (Рис. 4а) ошибки определения угла стабилизировались после 13-ой эпохи и в дальнейшем среднее значение составило $0,0096 \cdot \pi$ на обучающей выборке и $0,014 \cdot \pi$ на тестовой выборке. Ошибка величины линейного смаза (Рис. 4б) начала стабилизироваться после 30-й эпохи и составила на обучающей выборке $0,061$, а на тестовой выборке — $0,078$.

Также проводилось сравнение результатов распознавания, получаемых при помощи НС, и метода диагностики, основанного на спектральном анализе [9]. Средние значения ошибок идентификации вида и определения параметров искажения, посчитанные по представительному подмножеству данных, приведены в Табл. 2. Оба подхода демонстрируют сопоставимые результаты.

Табл. 2. Точность классификации вида и определения параметров искажения.

Вид искажения	Ошибки идентификации и определения параметров				
	Нейронная сеть		Спектральный анализ		
	Средняя ошибка	Неверная идентификация	Средняя ошибка	Отказ от идентификации	Двойная идентификация
Круговое	0,0429	0,15	0,0162	0	0,15
Гауссово	0,0363	0,10	0,0113	0,20	0
Линейное (угол)	0,0141	0	0,0088	0	0,08
Линейное (размер)	0,0776	0	0,0868	0	0,08

7. ЗАКЛЮЧЕНИЕ

В работе предложен новый подход к решению задачи диагностики искажений видеoinформации, сочетающий трансформационный анализ и нейросетевую диагностику. Проведены исследования по распознаванию вида и параметров распространенных линейных однородных искажающих операторов при помощи глубоких нейронных сетей. Сравнение результатов распознавания НС с архитектурами ResNet50, ResNet29 и ResNet18 показало, что наилучшие результаты достигаются при использовании архитектуры ResNet18.

Сопоставление методов диагностики искажений на основе НС и на основе спектрального анализа показало, что по распознаваемым параметрам они близки по точности.

СПИСОК ЛИТЕРАТУРЫ

1. Tiwari S., Shukla V. P., Singh A.K. Review of Motion Blur Estimation Techniques // Journal of Image and Graphics, 2013, vol. 1, no. 4, pp. 176–184.
2. Dash R., Majhi B. Motion Blur Parameters Estimation for Image Restoration // Optik, 2014, vol. 125, pp. 1634–1640.
3. Song Y. X., Zhang Y. M. Parameter Estimation and Restoration of Motion Blurred Image // Applied Mechanics and Materials, 2014, vols. 608–609, pp. 855–859.
4. Oliveira J. P. A., Figueiredo M. A. T., Bioucas-Dias J. M. Blind Estimation of Motion Blur Parameters for Image Deconvolution // Proc. 3rd Iberian Conf. IbPRIA 2007, vol. 4478, pp. 604–611.
5. Liang M. Parameter Estimation for Defocus Blurred Image Based on Polar Transformation // Rev. Tec. Ing. Univ. Zulia, 2016 vol. 39, no. 1, pp. 333–338.
6. Zhu X., Cohen S., Schiller S., Milanfar P. Estimating Spatially Varying Defocus Blur From a Single Image // IEEE Trans. Image Processing, 2013, vol. 22, no. 12, pp. 4879–4891.
7. Gajjar R., Pathak A., Zaveri T. Defocus Blur Parameter Estimation Technique // Int. Journal of Electronics and Communication Engineering & Technology (IJECET), 2016, vol. 7, no. 4, pp. 85–90.
8. Milukova O. P., Chochia P. A. Application of Metrical and Topological Image Characteristics for Distortion Diagnostics in the Signal Restoration Problem // Journal of Communications Technology and Electronics, 2018, vol. 63, no. 6, pp. 637–642.

9. Чочиа П. А. Диагностика линейного однородного искажающего оператора по спектру наблюдаемого изображения // Информационные процессы, 2019, Т. 19, № 3, С. 313–326.
10. Прэтт У. Цифровая обработка изображений. Т.1 и 2. М.: Мир. 1982. 790 с.
11. Гонсалес Р., Вудс Р. *Цифровая обработка изображений*. М.: Техносфера, 2012. 1104 с.
12. Reeves S. J. Image Restoration: Fundamentals of Image Restoration // Academic Press Library in Signal Processing, ed. S. Theodoridis and R. Chellappa; vol. 4, ch. 6: *Image, Video Processing and Analysis, Hardware, Audio, Acoustic and Speech Processing*. Elsevier, 2014. pp. 164–192.
13. Cannon M. Blind Deconvolution of Spatially Invariant Image Blurs with Phase // IEEE Trans. ASSP, 1976, vol. 24, no. 1, pp. 58–63.
14. He K., Zhang X., Ren Sh., Sun J. Deep Residual Learning for Image Recognition // Proc. IEEE Conf. on Computer Vision and Pattern Recognition (CVPR), 2016, Stanford: CA, pp. 770–778.
15. Huang G., Liu Z., Weinberger K. Q., Van der Maaten L. Densely Connected Convolutional Networks // IEEE Proc. Computer Vision and Pattern Recognition (CVPR), 2017, Honolulu: HI, pp. 2261–2269.
16. Джулли А., Пал С. *Библиотека Keras — инструмент глубокого обучения: реализация нейронных сетей с помощью библиотек Theano и TensorFlow*. Пер. с англ. М.: ДМК Пресс, 2018. 293 с.
17. Kingma D.P., Ba J. Adam: A Method for Stochastic Optimization // 3rd Int. Conf. on Learning Representations (ICLR), San Diego: CA, 2015, pp. 1–15. (arXiv preprint arXiv:1412.6980)

The use of neural networks to diagnose the type and parameters of image distortion

Solomentsev Ia. K., Chochia P. A.

The registration of images in many cases is accompanied by distortions caused by inaccuracies in focusing, displacements of the scene or recording device, radiation scattering in the signal transmission medium, and similar aberrations. Solving the signal recovery problem requires knowledge of a distorting operator, which is usually unknown. Therefore, the question of determining the type and parameters of distortion of the observed signal is relevant. The paper proposes a new approach to solving the problem of diagnosing distortion of video information based on the use of deep neural networks. The problem of determining the type and parameters of linear homogeneous distorting operators of following types is discussed: a circular shape of a rectangular profile, a circular shape of a Gaussian profile and a linear shape of a rectangular profile. The possibility of using neural networks with architectures ResNet50, ResNet29 and ResNet18 to identify the type and determine the parameters of distortion is investigated. It is shown that the quality of the neural network is not inferior to the methods based on spectral analysis.

KEYWORDS: Image distortions, neural networks, distortion diagnostics.