

привлечения ресурсов и, как результат, снижается эффективность управленческих процессов на предприятии.

Внедрение систем документооборота позволяет:

1. автоматизировать бизнес-процессы;
2. сократить цикл прохождения информации;
3. обеспечить прозрачность процессов;
4. наладить контроль над исполнением распоряжений;
5. повысить оперативность доставки управленческих документов;
6. снизить затраты времени;
7. организационно выстроить поиск информации;
8. упорядочить документооборот;
9. снизить затраты на управление компанией.

Таким образом, можно сделать вывод: автоматизация управления предприятием просто необходима для преодоления этих негативных явлений. Для автоматизации управления разрабатываются комплексные системы электронного документооборота. Они облегчают построение инфраструктуры для утверждения, использования и контроля исполнения всех документов на предприятии. Создание такой единой системы управления информацией обеспечивает высокую эффективность управления даже крупной организацией.

*Список использованной литературы*

1. Басв И. А. Экономика предприятия: Учебник для вузов.-М: 1-е изд. Литер 2006.-268 с.
2. Гольдштейн Г.Я. Основы менеджмента.- Таганрог: ТРТУ, 2003.-198 с.
3. Попов Г.Х. Эффективное управление. М.: Экономика, 2002.-236 с.

## ОЦЕНКА КАЧЕСТВА ИЗОБРАЖЕНИЙ С ПОМОЩЬЮ НЕЙРОННЫХ СЕТЕЙ ВЫСОКОГО ПОРЯДКА

Муравьев А.С.

E-mail: an.muravyov@gmail.com

*Научный руководитель: к. т. н., доцент Белоусов А.А., каф. ВТ, ИК, НИ ТПУ*

### Введение и постановка задачи

Одной из важных задач в области компьютерной обработки изображений является *оценка их качества* (IQA, Image Quality Assessment). В данном контексте под качеством подразумевается наличие одного или нескольких объективных искажений, таких, как шум, артефакты сжатия, размытие и пр. Распознавание присутствия данных негативных факторов остается затруднительным для систем без участия человека, несмотря на многочисленные исследования в этом направлении [1]. Поскольку эталонным может считаться только человеческое восприятие, в качестве критерия результативности предлагаемых методов IQA традиционно используются показатели корреляции, связывающие результаты их работы с оценками пользователей.

Чаще всего в данной области рассматриваются и анализируются т. н. *парные* (full-reference) метрики, самой известной из которых является SSIM [2] и ее многочисленные модификации. Эти метрики оценивают качество изображения при непосредственном наличии эталона – аналогичного изображения, не имеющего искажений. Несмотря на очень высокую точность парных метрик, их очевидная непрактичность в использовании стимулирует работы в других направлениях – развитие частично парных (reduced-reference) и непарных (no-reference) оценок. Обычно это подразумевает применение в том или ином виде методов машинного обучения – выделение общих признаков, несущих информацию об искажениях, на некотором обучающем множестве, с их последующим использованием для оценки вновь поступающих изображений.

В работе [3] для решения данной задачи рассматривалось применение нейронной сети с эволюционной настройкой весов. В качестве входных переменных использовались простейшие яркостные и цветковые параметры, а также расстояние между статистическими моделями NSS, построенными соответственно для данного изображения и для некоторого эталонного множества (подход, подобный описанному в [4]). Достигнутые результаты оказались сопоставимы с MS-SSIM, однако был обнаружен ряд недостатков такого подхода.

1. Необходимость двухэтапного обучения с использованием различных обучающих выборок – сначала синтез модели NSS с помощью набора эталонных изображений, затем собственно обучение ИНС на искаженных изображениях с пользовательскими оценками.

2. Высокая нелинейность данных приводит к необходимости использования ИНС с несколькими скрытыми слоями, что значительно увеличивает количество настраиваемых параметров и потому усложняет обучение (как с точки зрения алгоритмической реализации, так и с точки зрения устойчивости и эффективности).

3. Следствием вышеупомянутого недостатка является сильное непостоянство качества системы – для получения удовлетворительной точности может понадобиться достаточно много перезапусков обучения.

В данной работе описываются возможные пути решения перечисленных проблем. Для устранения первой из них предлагается введение новых признаков, которые могут быть независимо вычислены для каждого изображения, что, в свою очередь, позволяет избавиться от первого обучающего этапа. Для устранения второй и третьей проблем стандартная ИНС прямого распространения, используемая в [3], заменяется на нейронную сеть с умножающими узлами, веса связей которой настраиваются посредством эволюционного алгоритма.

### Независимые признаки качества изображений

Как было показано в [3], даже такие тривиальные признаки, как средняя яркость, средняя контрастность, тоновая насыщенность и другие, несут информацию о наличии искажений в изображении, которая может быть извлечена с помощью нейронной сети. По данной причине отказываться от их использования нет смысла, особенно с учетом малых вычислительных затрат на их получение.

Необходимость двухэтапного обучения системы обусловлена, как уже было сказано выше, потребностью в получении одного из входных параметров сети – расстояния между эталонной и фактической моделями NSS. Данная величина весьма эффективна в роли показателя качества [4], однако стремление к упрощению системы и снижению временных затрат заставляет обратиться к возможным альтернативам. Так, в работе [5] предлагается несколько признаков, которые могут быть использованы для оценки непосредственно. Каждый из них оценивался по степени корреляции с пользовательскими оценками на различных типах искажений.

Для более точного описания локального контраста предлагается использовать *градиент яркости изображения*. Приближенное значение его компонентов (вертикального и горизонтального) может быть легко получено с помощью распространенного оператора Собеля стандартной размерности 3x3. По величинам этих компонентов в каждой точке рассчитывается длина вектора градиента, которая затем усредняется по всему изображению и используется в качестве параметра. Согласно [5], данная величина эффективна при обнаружении белого шума (корреляция ~0.87), менее эффективна при обнаружении размытия (корреляция ~0.64).

Другая величина – *энтропия изображения*. Она уже задействована в первоначальном варианте ИНС в качестве входного параметра и потому не нуждается в дополнительном рассмотрении. Тем не менее, можно отметить, что данный параметр сам по себе довольно эффективен при обнаружении артефактов сжатия JPEG (корреляция ~0.84).

Наиболее точные оценки могут быть получены при использовании *средней фазовой конгруэнтности* (СФК). Ее физический смысл – степень когерентности локальных частот компонентов Фурье. Одна из формул, по которым может быть рассчитана фазовая конгруэнтность, имеет следующий вид [6]:

$$PC(x) = \frac{\sum_n W(x) \left[ A_n(x) [\cos(\Delta\varphi(x)) - |\sin(\Delta\varphi(x))|] - T \right]}{\sum_n A_n(x) + \varepsilon},$$

где  $A(x)$  – амплитуда  $n$ -го компонента разложения Фурье исходного изображения,  $\Delta\varphi(x) = \varphi_n(x) - \bar{\varphi}(x)$  – разность между фазой  $n$ -го компонента Фурье и средней фазой по всем компонентам,  $W(x)$  – весовая функция окна (авторами рекомендуется использование окна Гаусса),  $T$  – оценка уровня шума (детали расчета приведены в [6]),  $\lfloor \cdot \rfloor$  – функция, обращающая числитель дроби в ноль, если его значение отрицательно,  $\varepsilon$  – малая константа для предотвращения деления на ноль. Данная величина сама по себе имеет корреляцию более 0.75 для всех рассмотренных типов

искажений – сжатие JPEG, сжатие JPEG2000, белый шум, размытие по Гауссу, потеря информации при передаче по быстрозатухающему рэлеевскому каналу.

Достаточно высокая эффективность вышеперечисленных параметров позволяет рассчитывать на повышение точности оценки при их внедрении, при этом дополнительного обучающего этапа не требуется – связывающие эти параметры зависимости будут обнаружены с помощью нейронной сети.

### Нейронная сеть с умножающими узлами

В работе [3] использовалась стандартная нейронная сеть прямого распространения, в которой структура задавалась вручную, а подбор весов осуществлялся с помощью эволюционного алгоритма с целью максимизации корреляции выхода с пользовательскими оценками. При этом было обнаружено, что сети с одним скрытым слоем недостаточно эффективно аппроксимируют функциональную зависимость, существующую между входными параметрами и искомым выходным значением. Из этого можно сделать вывод, что данная зависимость имеет нелинейность высокого порядка. В таком случае достаточно логичным решением представляется использование т. н. *нейронных сетей высокого порядка* (higher order neural network). Существует целый ряд моделей таких сетей, в их числе  $\Sigma\Pi$ -сети,  $\Pi\Sigma$ -сети, сети функциональных связей и нейронные сети с умножающими узлами [7]. Общей чертой таких сетей является непосредственное применение ими нелинейных комбинаций входных параметров (в то время как в стандартной модели используется только взвешенное суммирование). Общим недостатком такого подхода является неприменимость для таких сетей градиентных методов обучения из-за очень сложного рельефа поверхности ошибки. Необходимость применения методов глобальной оптимизации для подстройки весов мешает сетям высокого порядка получить широкое распространение, однако в рамках данной работы обучение изначально осуществляется с помощью эволюционного алгоритма, что позволяет внедрить одну из вышеперечисленных моделей ИНС без серьезного изменения «инфраструктуры».

В рамках данной работы выбор был произведен в пользу *нейронной сети с умножающими узлами* (product unit neural network, PUNN). Причин тому несколько – во-первых, в сетях высокого порядка других типов нелинейности между входными параметрами «зашиты» в структуру, в то время как в PUNN они создаются автоматически, повышая гибкость системы; во-вторых, сети других типов обладают очень большим количеством настраиваемых параметров, повышая размерность пространства поиска при обучении.

Стандартная структура PUNN приведена на рис. 1. В сетях такого типа существует три разновидности нейронов – входные, суммирующие и умножающие (давшие название всей модели в целом). Умножающие нейроны находятся, как правило, в скрытом слое, однако существуют и прямые связи между входными и выходными узлами. Функции активации нейронов PUNN обычно линейные (выходной сигнал равен входному). Отличие от стандартной архитектуры заключается в умножающих узлах, значение в которых вычисляется в виде

$$y_i = \prod_{j=1}^N z_j^{w_{ji}} - \theta_i,$$

где  $i$  – номер умножающего узла,  $N$  – количество входов сети,  $z_j$  –  $j$ -й входной сигнал сети,  $w_{ji}$  – вес связи между  $j$ -м входным узлом и  $i$ -м умножающим узлом,  $\theta_i$  – значение внутреннего сдвига  $i$ -го умножающего узла.




Рис. 1. Пример структуры нейронной сети с умножающими узлами

Таким образом, приведенная на рис. 1 структура позволяет сети выучить произвольное полиномиальное представление входных сигналов, например:

$$f(z) = a_0 + a_1 \cdot z + a_2 z^2 + \dots + a_n z^n$$

Обучение PUNN можно осуществлять с помощью эволюционного алгоритма, описанного в [3], без значительных изменений. При этом число настраиваемых параметров за счет упрощения структуры заметно сократится, что положительно скажется на временных и мощностных затратах. Следует, впрочем, отметить, что существуют достаточно успешные нейроэволюционные подходы к настройке структуры PUNN [8], которые могут быть применены в случае необходимости.

#### Заключение

Следует ожидать, что внесение описанных выше изменений в первоначальный алгоритм позволит значительно повысить его ресурсоэффективность за счет сокращения подготовительного этапа. Логично предположить, что коэффициенты корреляции результата с пользовательскими оценками также увеличатся, однако выводы по этому аспекту могут быть сделаны только после дополнительных исследований.

#### СПИСОК ИСПОЛЬЗОВАННОЙ ЛИТЕРАТУРЫ

1. Lin W., Jay Kuo C. C. Perceptual visual quality metrics: A survey //Journal of Visual Communication and Image Representation. – 2011. – Т. 22. – №. 4. – С. 297-312.
2. Wang Z., Simoncelli E. P., Bovik A. C. Multiscale structural similarity for image quality assessment //Signals, Systems and Computers, 2004. Conference Record of the Thirty-Seventh Asilomar Conference on. – IEEE, 2003. – Т. 2. – С. 1398-1402.
3. Муравьев А. С. , Белоусов А. А. Нейросетевая оценка качества естественных изображений на основе статической модели NSS // Нейроинформатика – 2014: сборник научных трудов XVI Всероссийской научно-технической конференции. В 3-х частях. Часть 2, Москва, 27-31 Января 2014. - Москва: НИЯУ МИФИ, 2014 - С. 233-242.
4. Mittal A., Soundararajan R., Bovik A. C. Making a “completely blind” image quality analyzer //Signal Processing Letters, IEEE. – 2013. – Т. 20. – №. 3. – С. 209-212.
5. Li C. et al. No-training, no-reference image quality index using perceptual features //Optical Engineering. – 2013. – Т. 52. – №. 5. – С. 7003.
6. Kovese P. Image features from phase congruency //Videre: Journal of computer vision research. – 1999. – Т. 1. – №. 3. – С. 1-26.
7. Ismail A. Training and Optimization of Product Unit Neural Networks : дис. – University of Pretoria, 2001.
8. Martínez-Estudillo A. et al. Evolutionary product unit based neural networks for regression //Neural Networks. – 2006. – Т. 19. – №. 4. – С. 477-486.