

Р.О. Ткаченко, П.Р. Ткаченко, И.В. Изонин, Д.А. Батюк

Методы предварительной обработки изображений на основе нейропарадигмы Модель геометрических преобразований

Предложен метод изменения разрешения изображений на основе машинного обучения. Инструментом для обучения избраны нейроподобные структуры парадигмы Модель геометрических преобразований, поскольку они уменьшают вычислительные и временные ресурсы работы подобных методов и предоставляют возможность быстрого автоматического переобучения. Проведен ряд имитационных экспериментов на разных изображениях, а также сравнение эффективности работы разработанного метода с существующим.

Ключевые слова: разрешение изображения, машинное обучение, нейропарадигма, Модель геометрических преобразований.

Запропоновано метод зміни роздільної здатності зображень на основі машинного навчання. Інструментом для навчання обрано нейроподібні структури парадигми Модель геометричних перетворень, оскільки вони зменшують обчислювальні і часові ресурси роботи подібних методів і надають можливість швидкого автоматичного перенавчання. Проведено ряд імітаційних експериментів на різних зображеннях, а також порівняння ефективності роботи розробленого методу з ефективністю за існуючим.

Ключові слова: роздільна здатність зображення, машинне навчання, нейропарадигма, Модель геометричних перетворень.

Введение. Топологические подходы в задачах изменения разрешения изображений предусматривают использование различных конечных покрытий открытыми множествами, что дает возможность строить различные векторы признаков, характеризующие элемент определенной на изображении топологии [1, 2]. Существование в пространстве признаков значительного количества векторов, иногда также большой размерности, – весомый аргумент для использования или разработки методов машинного обучения в задачах предварительной обработки цифровых изображений [3, 4].

Постановка задачи

В общем случае каждое изображение C можно представить в виде результата действия некоторой непрерывной функции C (далее функция цвета):

$$C : \mathbf{N}^{2,+} \rightarrow Color, \quad (1)$$

$$C = C(\mathbf{N}^{2,+}). \quad (2)$$

Пусть задано изображение C (2) и имеет место:

$$C = \left\langle c_{(i,j)} \right\rangle_{\substack{i \in \overline{1,l} \\ j \in \overline{1,h}}}. \quad (3)$$

Тогда задачу изменения разрешения можно сформулировать так:

Задача увеличения разрешения заключается в том, чтобы сформировать новое изображение C' с C (3) такое, чтобы:

$$C' = \left\langle c_{(i,j)} \right\rangle_{\substack{i \in \overline{1,l'} \\ j \in \overline{1,h'}}}(l', h'), \quad (4)$$

где (l', h') – размерность матрицы, $l' > l \vee h' > h$ с минимальными потерями качества изображения. В случае уменьшения размерности – $l' < l \vee h' < h$.

Метод изменения разрешения изображений на основе нейропарадигмы Модель геометрических преобразований

Задача изменения разрешения изображений на основе машинного обучения состоит в передискретизации входного изображения до целевого коэффициента изменения с использованием инструментария машинного обучения. Для использования этого подхода необходимо применить ряд процедур: предварительная обработка изображений, обучение и применение. Основная идея – разделение пар изображений на фреймы для реализации обучения [3, 5]. В статье рассматривается нейросетевой аппарат для реализации процедуры обучения [6]. Основной недостаток существующих методов передискретизации изображений на основе машинного обучения это то, что они базируются на итерационных подходах [7], что и есть причиной очевидных недостатков, в частности:

- большие вычислительные затраты на реализацию процедуры обучения, существенно ограничивающие возможности решения задач большой размерности;

- зависимость решений от начальной случайной инициализации сети;

- отсутствие гарантии решения в случае вхождения функции активации сети в насыщение или неудовлетворительные решения при попадании в локальные оптимумы.

В статье рассматривается альтернатива существующим парадигмам нейронных сетей – Модель геометрических преобразований, которые базируются на принципиально отличных пространственно-геометрических принципах [4, 8].

Основными преимуществами этой нейропарадигмы, вытекающими из основных характеристик модели, есть неитерационность обучения, ортогональность шагов решения и сходство процедур обучения и функционирования [8–10]. К основным особенностям, имеющим практическую ценность для решения поставленной задачи, следует отнести:

- высокое быстродействие обучения, что создает предпосылки для решения задач большой размерности;
- повторяемость результатов и их математическая интерпретация;
- способность решать задачи в условиях как крупных, так и малых выборов;
- выделение экстраполяциянных точек;
- линейность в экстраполяциянных областях.

Допустим задана пара изображений низкого и высокого разрешения (рис. 1), на основе которых проводится обучение нейроподобной структуры Модели геометрических преобразований (НПС МГП) [6].



Рис. 1. Пара 8-битных изображений: a – 168×168 пикселей; b – 504×504 пикселей

Предварительная обработка изображений

Допустим, что изображение низкого разрешения есть матрицей C , размерности $l \times l$, $l \in \mathbf{N}$, $l > 0$, а изображение высокого разрешения – матрицей $C^{(m)}$, размерности $h \times h$, $h \in \mathbf{N}$, $h > 0$ из значений интенсивности пикселей [2]. Тогда:

$$C = [c_{i,j}]_{i,j=1..l}, C^{(m)} = [c_{i,j}^{(m)}]_{i,j=1..h}, \quad (5)$$

где $c_{i,j}$, $c_{i,j}^{(m)}$ – значение функции интенсивности в пикселях с координатами (i, j) изображений с низким C и высоким $C^{(m)}$ разрешением соответственно; $m \in \mathbf{N}$, $m > 0$ – коэффициент изменения разрешения; $h = l \cdot m$ – переменная, определяющая размерность матрицы изображения с высоким разрешением $C^{(m)}$.

Для реализации технологии обучения оба изображения делятся на одинаковое количество фреймов $FR_{i,j}$, $FR_{i,j}^{(m)}$ (квадратных плоских областей значений функции интенсивности изображения) [9]:

$$FR_{i,j} = \begin{pmatrix} c_{k(i-1)+1, k(j-1)+1} & \dots & c_{k(i-1)+1, kj} \\ \dots & \dots & \dots \\ c_{ki, k(j-1)+1} & \dots & c_{ki, kj} \end{pmatrix}; \quad (6)$$

$$FR_{i,j}^{(m)} = \begin{pmatrix} c_{mk(i-1)+1, mk(j-1)+1}^{(m)} & \dots & c_{mk(i-1)+1, mkj}^{(m)} \\ \dots & \dots & \dots \\ c_{mki, mk(j-1)+1}^{(m)} & \dots & c_{mki, mkj}^{(m)} \end{pmatrix}, i, j = \overline{1, n},$$

где $k \in \mathbf{N}$, $k > 0$ – переменная, определяющая размерность фрейма $FR_{i,j}$ изображения с низким разрешением, $\dim(FR_{i,j}) = k \times k$.

Переменная n , которая определяет количество фреймов $FR_{i,j}$ изображения низкого разрешения вычисляется так:

$$n = \frac{l}{k}, n \in \mathbf{N}, n > 0. \quad (7)$$

Отметим, что k кратно l . Если ввести обозначения:

$$k^{(m)} = mk, \quad (8)$$

то размерность фрейма $FR_{i,j}^{(m)}$ изображения с высоким разрешением будет равной $\dim(FR_{i,j}^{(m)}) =$

$= k^{(m)} \times k^{(m)}$. Согласно этому $k^{(m)} \in \mathbf{N}, k^{(m)} > 0$ – переменная, определяющая размерность фрейма $FR_{i,j}^{(m)}$.

Очевидно, что $\dim\{FR_{i,j}\} = \dim\{FR_{i,j}^{(m)}\} = n^2$.

Тогда в соответствии с (8) и определением значения h , значение $k^{(m)}$ кратно значению h .

Покрывание фреймами – дизъюнктивно. Таким образом, матрицы (5) можно представить в виде наборов соответствующих фреймов:

$$C = [FR_{i,j}]_{i,j=1..n}, C^{(m)} = [FR_{i,j}^{(m)}]_{i,j=1..n}. \quad (9)$$

Решение задачи увеличения разрешения изображения выражается равенством (8). В случае решения задачи уменьшения разрешения изображения должно выполняться следующее равенство:

$$k = k^{(m)} \% m, \quad (10)$$

где $\%$ – операция целочисленного деления.

Один из немногих недостатков НПС МГП – формат представления входных и выходных данных (в виде таблицы). Поэтому, дальнейшая подготовка пары изображений к обучению заключается в следующем.

Каждый полученный фрейм $FR_{i,j}$ из C представляем в виде вектора $A_{j+\frac{l(i-1)}{k}}$ (11), а каждый

фрейм $FR_{i,j}^{(m)}$ из $C^{(m)}$ – в виде вектора $A_{j+\frac{l(i-1)}{k}}^{(m)}$ (12):

$$A_{j+\frac{l(i-1)}{k}} = \quad (11)$$

$$= (c_{ki-k+1,kj-k+1}, \dots, c_{ki-k+1,kj}, \dots, c_{ki,kj-k+1}, \dots, c_{ki,kj}),$$

$$A_{j+\frac{l(i-1)}{k}}^{(m)} = \quad (12)$$

$$= (c_{ki-k+1,kj-k+1}^{(m)}, \dots, c_{ki-k+1,kj}^{(m)}, \dots, c_{ki,kj-k+1}^{(m)}, \dots, c_{ki,kj}^{(m)}).$$

Отметим, что множества $\left\{A_{j+\frac{l(i-1)}{k}}\right\}$ и

$\left\{A_{j+\frac{l(i-1)}{k}}^{(m)}\right\}$ одинаковы по размерности:

$$\dim\left\{A_{j+\frac{l(i-1)}{k}}\right\} = \dim\left\{A_{j+\frac{l(i-1)}{k}}^{(m)}\right\} = n^2. \quad (13)$$

Следующий шаг процедуры – формирование обучающей выборки из соответствующих

множеств $\left\{A_{j+\frac{l(i-1)}{k}}\right\}$ и $\left\{A_{j+\frac{l(i-1)}{k}}^{(m)}\right\}$.

Матрица учебного набора данных M для решения задачи увеличения разрешения изображения на основе НПС МГП при выполнении (8) формируется так:

$$M = \begin{pmatrix} A_1 & A_1^{(m)} \\ \dots & \dots \\ A_{n^2} & A_{n^2}^{(m)} \end{pmatrix}, \quad (14)$$

где размерность вектора $\dim(A_1)$ определяет количество входов НПС МГП, а размерность вектора $\dim(A_1^{(m)})$ – количество выходов.

Матрица учебного набора данных M для решения задачи уменьшения разрешения изображения на основе НПС МГП при выполнении (10) формируется так:

$$M = \begin{pmatrix} A_1^{(m)} & A_1 \\ \dots & \dots \\ A_{n^2}^{(m)} & A_{n^2} \end{pmatrix}, \quad (15)$$


где $\dim(A_1^{(m)})$ определяет количество входов, а $\dim(A_1)$ – количество выходов НПС МГП.

Обучение нейроразличных структур модели геометрических преобразований


Полученная матрица обучающей выборки согласно (14) или согласно (15) (в зависимости от поставленной задачи) подается на НПС МГП. Топология НПС МГП для задачи увеличения разрешения приведена на рис. 2. а; для задачи уменьшения разрешения – на рис. 2. б.

Для обобщения описания технологии обучения при решении обеих задач матрицу M , учитывая (14) или (15), представим в следующем виде:

$$M = \begin{pmatrix} x_{1,1} & \dots & x_{1,k^2+(mk)^2} \\ \dots & \dots & \dots \\ x_{n^2,1} & \dots & x_{n^2,k^2+(mk)^2} \end{pmatrix}. \quad (16)$$



а



б

Рис. 2. Топология НПС МГП для решения задачи изменения разрешения изображения: а – для увеличения разрешения; б – для уменьшения

Технология обучения НПС МГП для решения задачи изменения разрешения изображения предполагает выполнение следующих шагов [8, 9]. На первом этапе избирается базовая строка $x_b^{(1)}$, $x_b^{(1)} = (x_{b,1}^{(1)}, \dots, x_{b, k^2 + (mk)^2}^{(1)})$ из учебной матрицы M , сумма квадратов элементов которой максимальна $1 \leq b \leq n^2$. Каждая строка исходной матрицы превращается в $x_N^{(2)}$ как разница между каждым вектором–строкой $x_N^{(1)}$, $(x_N^{(1)} = (x_{N,r}^{(1)}, \dots, x_{n^2, k^2 + (mk)^2}^{(1)}))$ из матрицы M , и

произведением выбранной строки $x_b^{(1)}$ на коэффициент $K_N^{(1)}$:

$$x_N^{(2)} = x_N^{(1)} - K_N^{(1)} \cdot x_b^{(1)}, \quad (17)$$

где $1 \leq N \leq n^2$.

Величина $K_N^{(1)}$ для каждой строки определяется из условия минимума разницы в смысле критерия наименьших квадратов:

$$K_N^{(1)} = \frac{\sum_{r=1}^{k^2 + (km)^2} (x_{N,r}^{(1)} \cdot x_{b,r}^{(1)})}{\sum_{r=1}^{k^2 + (km)^2} (x_{b,r}^{(1)})^2}. \quad (18)$$

Для каждой строки $x_N^{(1)}$ учебной матрицы M вычисляем дополнительный параметр, являющийся, по сути, первой компонентой числовой характеристики первой реализации:

$$G_N^{(1)} = \frac{\sum_{r=1}^z (x_{N,r}^{(1)} \cdot x_{b,r}^{(1)})}{\sum_{r=1}^z (x_{b,r}^{(1)})^2}, \quad (19)$$

где $z = k^2$ – в случае (14) или $z = (mk)^2$ для случая (15).

Коэффициент $K_N^{(1)*}$ задаем как функцию $F^{(1)}$ от параметра $G_N^{(1)}$:

$$K_N^{(1)*} = F^{(1)}(G_N^{(1)}). \quad (20)$$

Интерполирующая зависимость (20) для строк учебной матрицы на дискретном множестве узловых значений воспроизводится с нулевой методической погрешностью [8]. Для всех строк из множества матрицы реализации – приближенно.

На следующем шаге выбирается строка $x_b^{(2)}$ из учебной матрицы M , сумма квадратов элементов которого максимальна. При этом значение элементов $x_b^{(2)}$ вычисляются так:

$$x_b^{(2)} = x_b^{(1)} - K_N^{(1)*} \cdot x_b^{(1)} \quad (21)$$

Для q -го шага вычислений, где $q = 1, k^2 + (km)^2$, имеем:

$$x_N^{(q+1)} = x_N^{(q)} - K_N^{(q)*} \cdot x_b^{(q)}; \quad (22)$$

$$K_N^{(q)*} = F^{(q)}(G_N^{(q)}); \quad (23)$$

$$G_N^{(q)} = \frac{\sum_{r=1}^z (x_{N,r}^{(q)} \cdot x_{b,r}^{(q)})}{\sum_{r=1}^z (x_{b,r}^{(q)})^2}; \quad (24)$$

$$x_b^{(q+1)} = x_b^{(q)} - K_N^{(q)*} \cdot x_b^{(q)}. \quad (25)$$

Выражения (23) – (25) для случая точного воспроизведения в узлах реализуют процедуру ортогонализации Грама–Шмидта [11]. На их основе строки исходной матрицы реализаций M из (16) можно представить конечной суммой вида:

$$x_N^{(1)} = \sum_{q=1}^{k^2+(mk)^2} K_N^{(q)*} \cdot x_N^{(q)}. \quad (26)$$

Результатами обучения на основе совокупности процедур (23) – (25) есть определенные векторы $x_N^{(q)}$ и набор функций $F^{(q)}$ – передаточные для НПС МГП.

Основное преимущество такого обучения – его неитерационность. Это обеспечивает скорость работы метода и как следствие – возможность его применения в современных интеллектуальных системах, основанных на *online* обработке изображений как программного, так и аппаратного типов [4, 12].

Процедура применения

В режиме применения на вход НПС МГП

подается матрица M_t , где $M_t = \begin{pmatrix} A_1 \\ \dots \\ A_{n^2} \end{pmatrix}$ при ре-

шении задачи увеличения разрешения изобра-

жения, или $M_t = \begin{pmatrix} A_1^{(m)} \\ \dots \\ A_{n^2}^{(m)} \end{pmatrix}$ при решении задачи

уменьшения разрешения изображения.

Для обобщения описания работы НПС МГП в режиме реализации для обеих задач, представим матрицу M_t в следующем виде:

$$M_t = \begin{pmatrix} x_{1,1} & \dots & x_{1,z} \\ \dots & \dots & \dots \\ x_{n^2,1} & \dots & x_{n^2,z} \end{pmatrix}, \quad (27)$$

где z определяется так же, как и для (15).

Процедура использования НПС МГП в режиме применения такова. Для заданных входных компонентов вектора $x_N^{(q)}$ из матрицы M_t (23) вычисляется $G_N^{(1)}$ согласно (20). Согласно (18) находятся значения коэффициентов $K_N^{(1)*}$. Для $q = 1$, в соответствии с (20), выполняется первый шаг преобразований входного вектора $x_N^{(q)}$.

На основе (22) – (24) выполняются последовательные преобразования для $q_{\max} = \overline{1, k^2}$. Основная цель преобразований – поиск величин: $K_N^{(1)*}, K_N^{(2)*}, \dots, K_N^{(q_{\max})*}$. На основе суммы (26) вычисляются искомые исходные компоненты каждого вектора из M_t .

Строки матрицы M_t – векторы (11) или (12) из полученных значений функции интенсивности уменьшенного или увеличенного изображения. Поэтому, последним шагом процедуры есть сбор матрицы в результирующее изображение C_r или $C_r^{(m)}$.

Эта процедура предусматривает обратное представление строк полученной матрицы из формы векторов (11) или (12) к форме соответствующих фреймов $FR_{i,j}$ или $FR_{i,j}^{(m)}$ из (6). Исходное изображение уменьшенного или увеличенного разрешения формируется путем сбора полученных фреймов соответственно $FR_{i,j}$ для C_r или $FR_{i,j}^{(m)}$ для $C_r^{(m)}$, подобно (9):

$$C_r = [FR_{i,j}]_{i,j=1..n} \quad \text{или} \quad C_r^{(m)} = [FR_{i,j}^{(m)}]_{i,j=1..n}, \quad (28)$$

где C_r – результирующее изображение уменьшенного разрешения, $C_r^{(m)}$ – результирующее изображение увеличенного разрешения.

Особенность описанного метода это то, что обученная на одних образцах НПС МГП может решать поставленную задачу совсем на других.

Эта возможность обеспечивается высокой способностью НПС МГП к обобщению. Значение целевого коэффициента изменения разрешения при этом определено на стадии обучения.

Еще одним преимуществом НПС МГП при обработке, например, набора изображений различных классов с флуктуациями функции интенсивности есть возможность быстрого переобучения НПС МГП. Его реализация возможна в автоматическом режиме, т.е. не требует дополнительной настройки параметров ее структуры.

Экспериментальное моделирование

Для реализации процедуры обучения в статье используется пара изображений из рис. 1. В режиме применения использовались изображения, приведенные в табл. 1. Следует отметить, что для представления в статье все изображения масштабированы. Тестовая выборка сформирована из самых известных изображений и взята из базы изображений Института обработки сигналов и изображений Университета Южной Калифорнии [13].

Практическая реализация метода увеличения разрешения изображений с использованием НПС МГП проводилась по следующим параметрам (рис. 1, а) [9]: количество входов $\dim(FR_{i,j})$, скрытых слоев – 1, количество нейронов в скрытом слое равно $\dim(FR_{i,j})$, коли-

чество выходов НПС МГП определяется из условия решения задачи увеличения разрешения изображений (4) и составляет $\dim(FR_{i,j}^{(m)})$, линейное значение синапсов. Коэффициент увеличения m принимает значение три.

Оценки качества полученных изображений на основе индекса структурного сходства (*SSIM*), соотношения пикового сигнала к шуму (*PSNR*), универсального индекса качества (*UIQ*) и среднеквадратичного отклонения (*MSE*) приведены в табл. 2.

Таблица 2. Оценка качества изображений, полученных методом на основе НПС МГП

№ изображения	Показатель качества			
	<i>MSE</i>	<i>PSNR</i>	<i>UIQ</i>	<i>SSIM</i>
1	32,1122	33,064	0,685	0,9629
2	50,3645	31,11	0,6108	0,9487
3	15,8538	36,13	0,7183	0,9762
4	361,861	22,545	0,6467	0,9397
5	306,362	23,268	0,5573	0,822
6	135,29	26,818	0,6183	0,9292
7	51,8225	30,986	0,5962	0,9387
8	29,5228	33,429	0,7733	0,9654
9	151,453	26,328	0,637	0,8896
10	102,57	28,021	0,6361	0,9306

Эффективность работы разработанного метода сравнивалась с эффективностью работы известного метода – на основе конволюцион-

Таблица 1. Изображения низкого разрешения (168 × 168 пикселей) тестовой выборки



ной нейронной сети [14]. Следует отметить, что этот метод (на основе конволюционной нейронной сети или *SRCNN*) показывает лучшие результаты по качеству исходных изображений повышенного разрешения в своем классе. Однако подход к решению задачи увеличения разрешения несколько отличается от разработанного. Известный метод на стадии обучения требует большую размерность обучающей выборки. Авторами метода установлено, что для качественных результатов работы метода она должна содержать не одно изображение [15].

Оценки качества изображений, полученных методом *SRCNN*, приведены в табл. 3.

Таблица 3. Оценка качества изображений, полученных методом *SRCNN*

№ изображения	Показатель качества			
	<i>MSE</i>	<i>PSNR</i>	<i>UIQ</i>	<i>SSIM</i>
1	25,0477	34,1431	0,7269	0,974
2	36,57	32,4996	0,6534	0,9648
3	6,6135	39,9265	0,8062	0,9884
4	44,8272	31,6154	0,7546	0,9748
5	264,1633	23,9121	0,6104	0,8582
6	82,8428	28,9483	0,6922	0,9606
7	31,9959	33,0799	0,6688	0,9734
8	17,2002	35,7755	0,8192	0,9806
9	109,6566	27,73	0,7057	0,9212
10	78,3252	29,1918	0,6925	0,9526

При рассмотрении двух таблиц видно, что по всем четырем показателям качества существующий метод показывает несколько лучшие результаты в сравнении с разработанным. Несмотря на это, разработанный метод имеет ряд существенных преимуществ, в частности [9]:

- процедура обучения по методу *SRCNN* требует наличия большого количества пар изображений, а учебная модель по предложенному методу содержит только одну пару изображений;

- *SRCNN* предусматривает использование итерационного алгоритма обратного распространения ошибки и при одинаковых настройках может давать разные результаты (т.е. существует проблема однозначности решения). Процедура обучения согласно разработанному

методу предусматривает выполнение лишь одной итерации и обеспечивает однозначность решения при прочих равных условиях;

- процедура обучения по методу *SRCNN* продолжается в течение трех суток [15], тогда как разработанный метод, благодаря неитерационности, обеспечивает высокое быстродействие в режиме обучения;

- *SRCNN* предназначен для реализации только процесса увеличения разрешения изображения. Разработанный метод позволяет осуществлять передискретизацию с коэффициентами (как увеличение, так и уменьшение).

Совокупность этих преимуществ делают возможным практическое использование разработанного метода в прикладных системах искусственного интеллекта, основанных на *online* обработке, особенно в случаях сценарных изображений.

Заключение. В статье приведен метод изменения разрешения изображений на основе машинного обучения. Подытоживая изложенный материал можно констатировать:

- благодаря реализации вышеуказанного подхода удалось расширить функциональные возможности методов на основе обучения, в частности: осуществлять процесс передискретизации с целевыми коэффициентами как увеличения, так и уменьшения, что обеспечивает высокое качество передискретизации при уменьшении времени обучения.

- разработанный нейросетевой метод изменения разрешения изображений обеспечивает высокую эффективность передискретизации по критериям на основе *PSNR* и *SSIM* и характеризуется уменьшением вычислительных ресурсов, необходимых для таких процедур.

1. *Analysis of invariant moments in tasks image processing* / D. Peleshko, M. Peleshko, N. Kustra et al. // The Experience of Designing and Application of CAD Systems in Microelectronics (CADSM): Proc. of XI int. conf., 23–25 Feb., 2011., Lviv, Polyana, Ukraine. – Lviv: Publ. House “Vezha&Co”, 2011. – P. 263–264. Aggarwal C.C. *Data Mining*. Cham: Springer, 2015. – 734 p.
2. *Ізонін І.В.* Дослідження методів обчислення експонент Гельдера в задачах реконструкції зображень //

- Сучасні проблеми математичного моделювання та обчислювальних методів: Мат. міжн. наук. конф.: тези доповіді. – Рівне, 19–22 лютого 2015. – Рівне: РВВ РДГУ, 2015. – С. 61–62.
3. Tkachenko O., Tkachenko R. Neural System Based on the Geometric Transformation Model // Proc. of the Second Int. Conf. on Automatic Control and Information Technology, 2013 (ICACIT 13). – Cracow, Poland, 2013. – P. 28–34.
 4. Tsmots I., Peleshko D., Izonin I. Parallel algorithms and VLSI structures for median filtering of images in real time // Int. J. of Advanced Research in Comp. Engin. & Technol. – 2014. – 3, N 8. – P. 2643–2649.
 5. До методу збільшення роздільної здатності зображень на основі ШНМ моделі геометричних перетворень / І.В. Ізонін, Р.О. Ткаченко, К.Ю. Грицик та ін. // Міжнар. наук.-практ. конф. «Комп'ютерні технології та інформаційна безпека»: Тези доп., 2–3 липня 2015 р., Кіровоградський нац. техн. ун-т. – Кіровоград. – 2015. – С. 54–55.
 6. Метод надвисокої роздільної здатності зображень на основі моделі геометричних перетворень / І.В. Ізонін, Р.О. Ткаченко, Д.Д. Пелешко та ін. // Інтелектуальні системи прийняття рішень і проблеми обчислювального інтелекту: Зб. міжнар. наук. конф. «Аналіз та моделювання складних систем і процесів. Теоретичні і прикладні аспекти систем прийняття рішень. Обчислювальний інтелект та індуктивне моделювання», 25–28 трав. 2015 р., Залізний порт. – Херсон: ХНТУ, 2015. – С. 284–286.
 7. Інваріантні моменти в прикладних задачах обробки та аналізу зображень / Д. Пелешко, А. Ковальчук, Н. Кустрта та ін. // Вісн. Нац. ун-ту «Львівська політехніка». Комп'ютерні науки та інформаційні технології. – 2011. – № 694. – С. 265–270.
 8. Пелешко Д.Д., Ізонін І.В., Пелех Ю.М. Аналіз основних методів збільшення роздільної здатності зображень на основі технології super-resolution // Зб. наук. праць Ін-ту проблем моделювання в енергетиці ім. Г.Є. Пухова НАНУ, 2013. – 67. – С. 162–169.
 9. Передискретизація зображень засобами машинного навчання / Р.О. Ткаченко, І.В. Ізонін, Д.А. Батюк та ін. // Математичне та комп'ютерне моделювання. Сер. Техн. науки. – 2016. – 13. – С. 176–183.
 10. Tkachenko R. Information Models of the Geometric Transformation // Proc. of the Second Int. Conf. on Automatic Control and Information Technol, 2013 (ICACIT 13). – Cracow, Poland. – 2013. – P. 48–53.
 11. Yang X., Hu X., Liu Y. Modified Gram–Schmidt orthogonalization of covariance matrix adaptive beamforming based on data preprocessing // IEEE 11th Int. Conf. on Signal Processing. – Beijing. – 2012. – P. 373–377.
 12. Цмоць І.Г., Шкодин А.В., Ізонін І.В. Передискретизація зображень в системах стереобачення на основі симетричної матриці відстаней // Інтелектуальні системи прийняття рішень і проблеми обчислювального інтелекту: Зб. наук. праць міжнар. наук. конф.: Аналіз та моделювання складних систем і процесів. Теоретичні і прикладні аспекти систем прийняття рішень. Обчислювальний інтелект та індуктивне моделювання, 28–31 трав. 2014 р., Залізний порт. – Херсон: Вид-во ХНТУ, 2014. – С. 343–344 с.
 13. Learning a Deep Convolutional Network for Image Super-Resolution / Dong Chao, Loy Chen Change, He Kaiming et al. // Computer Vision: Proc. of European conf. – Zurich, Switzerland, 6–12 Sept. 2014. – Springer, 2014. – P. 184–199.
 14. Image Super-Resolution Using Deep Convolutional Networks / Dong Chao, Loy Chen Change, He Kaiming et al. // IEEE Transactions on Pattern Analysis and Machine Intelligence. – Preprint. – 2015. – 14 p.
 15. The USC-SIPI Image Database of University of Southern California – <http://sipi.usc.edu/database/>

Поступила 09.04.2015

E-mail: ivanizonin@gmail.com

© Р.О. Ткаченко, П.Р. Ткаченко, І.В. Ізонін, Д.А. Батюк, 2017

UDC 004.89 + 004.932

R.O. Tkachenko, P.R. Tkachenko, I.V. Izonin, D.A. Batyuk

Methods of Image Pre-Processing Based on Neuro-Paradigm of Geometric Transformation Model

Keywords: image resolution, machine learning, neuro-paradigm, Geometric Transformation Model.

Introduction. The task of image preprocessing for the problems of the intellectual analysis become a significant spread in our time. It is explained by the increasing necessity to apply similar procedures in the areas such as medicine, criminology, video, and more. The realization of problem solution for improving the digital images quality sometimes of the large dimension in online mode and while minimizing the computing resources continues to be very relevant. Similar restrictions required the use of the effective methods and tools for its solution. One possible approach to solve this problem may be the use of the fast and effective machine learning procedures.

Purpose. There are many tools for the machine learning implementation. In this article the authors use the tools of computational intelligence – artificial neural networks. This apparatus allows the rapid and efficient learning. The use of such tools for solving the problem of improving the quality of digital images is not new. However, the existing methods are based on the classical neural networks have the significant drawbacks. It imposes a number of restrictions.

In the article the authors use a new paradigm of building artificial neural networks. It is based on the geometric transformation machine. Exactly this advantage is providing the possibility of solution the problem of improving the quality of digital images in online mode.

The authors describe the topology of the neural network of solution to the problem of improving the quality of digital images, the basic steps of the training algorithm. The proposed learning algorithm is different from the existing ones by speed and accuracy, It provides an effective solution of the problem of increasing the quality of the digital images. Also, the authors in detail describe the process of applying trained neural network to solve the problem.

Conclusions. Therefore, in this article a new method of image preprocessing to improve its quality for further intellectual analysis is described. The method is simulated in different images. The estimation of the images quality, using four indicators, is carried out. It is established that the efficiency of the method is the best on one class of images. A comparison of the proposed method with existing ones is conducted. The basic advantages of the developed method for its application in real-time vision systems are described.

1. Peleshko D., Peleshko M., Kustra N. and Izonin I. Analysis of invariant moments in tasks image processing. 11th International Conference the Experience of Designing and Application of CAD Systems in Microelectronics (CADSM-2011), Polyana-Svalyava, 2011, P. 263–264.

2. Tkachenko O., Tkachenko R. Neural System Based on the Geometric Transformation Model. Proceeding of the Second International Conference on Automatic Control and Information Technology 2013 (ICACIT'13), Cracow, Poland, 2013, P.28–34.

3. Peleshko D., Kovalchuk A., Kustra N., Izonin I. Invariantni momenty v prykladnykh zadachakh obrobky ta analizu zobrazen. Visnyk Natsionalnoho universytetu "Lvivska politehnika": Komp'uterni nauky ta informatsiini tekhnolohii, 2011, N 694, P. 265–270 (In Ukrainian).

4. Tkachenko R.O., Izonin I.V., Batiuk D.A., Sydorenko R.V., Prostrelchuk V.I. Peredyskretyzatsiia zobrazen zasobamy mashynnoho navchannia. Matematychni ta kompiuterni modeliuvannia. Ser. : Tekhnichni nauky, 2016, Vyp.13, P. 176–183 (In Ukrainian).

5. Peleshko D.D., Izonin I.V., Pelekh Iu. M. Analiz osnovnykh metodiv zbilshennia rozdilnoi zdutnosti zobrazen na osnovi tekhnolohii super-resolution. Zbirnyk naukovykh prats Instytutu problem modeliuvannia v enerhetytsi im. H.Ye. Pukhova. Nats. akad. nauk Ukrainy, In-t probl. modeliuvannia v enerhetytsi im. H.Ye. Pukhova, Kyiv, 2013, Vyp. 67, P. 162–169 (In Ukrainian).

6. Tkachenko R. Information Models of the Geometric Transformation. In: proceeding of the Second International Conference on Automatic Control and Information Technology 2013 (ICACIT'13), Cracow, Poland, 2013, P.48–53 (In Ukrainian).

7. Tsmots I.H., Shkodyn A.V., Izonin I.V. Peredyskretyzatsiia zobrazen v systemakh stereobachennia na osnovi symetrychnoi matrytsi vidstanei. Intelktualni systemy pryiniattia rishen i problemy obchysluvalnoho intelektu: zb. nauk. pr. mizhnar. nauk. konf., 28–31 travnia 2014, Zaliznyi port, Kherson, Vyd-vo KhNTU, 2014, P.343–344 (In Ukrainian).

8. Izonin I.V. Doslidzhennia metodiv obchyslennia eksponent Helderera v zadachakh rekonstruktsii zobrazen. Suchasni problemy matematychnoho modeliuvannia ta obchysluvalnykh metodiv: materialy mizhn. nauk. konf.: tezy dopovidi, Rivne, 19–22 liutoho 2015, Rivne: RVV RDHU, 2015, P.61–62 (In Ukrainian).

9. Tsmots Ivan, Peleshko Dmytro, Izonin Ivan. Parallel algorithms and VLSI structures for median filtering of images in real time. International Journal of Advanced Research in Computer Engineering & Technology, 2014, Vol. 3, N 8, P. 2643–2649.

10. Izonin I.V., Tkachenko R.O., Peleshko D.D., Batiuk D.A. Metod nadvysokoi rozdilnoi zdutnosti zobrazen na osnovi modeli heometrychnykh peretvoren. Intelktualni systemy pryiniattia rishen i problemy obchysluvalnoho intelektu: zb. mizhnar. nauk. konf., 25–28 travnia 2015, Zaliznyi port, Kherson: KhNTU, 2015, P. 284–286 (In Ukrainian).

11. Yang X., Hu X., Liu Y.: Modified Gram-Schmidt orthogonalization of covariance matrix adaptive beamforming based on data pre-processing. IEEE 11th International Conference on Signal Processing, Beijing, 2012, P.373–377.

12. Izonin I.V., Tkachenko R.O., Hrytsyk K.Iu., Tytyk R.O. Do metodu zbilshennia rozdilnoi zdutnosti zobrazen na osnovi ShNM modeli heometrychnykh peretvoren. Kompiuterni tekhnolohii ta informatsiina bezpeka: mizhn. nauk.-prakt. konf., 2–3 lypnia 2015, Kirovohradskiy natsionalnyi tekhnichnyi universytet, Kirovohrad, 2015, P.54–55 (In Ukrainian).

13. Dong Chao, Loy Chen Change, He Kaiming, Tang Xiaou. Image Super-Resolution Using Deep Convolutional Networks. IEEE Transactions on Pattern Analysis and Machine Intelligence, Preprint, 2015, P.14.

14. Dong Chao, Loy Chen Change, He Kaiming, Tang Xiaou. Learning a Deep Convolutional Network for Image Super-Resolution. Computer Vision. Proc. of European conf., Zurich, Switzerland, 6–12 September 2014, Springer, 2014, P.184–199.

15. The USC-SIPI Image Database of University of Southern California. <http://sipi.usc.edu/database/>

