

Л.Г. Ахметшина, А.А. Егоров

ПОВЫШЕНИЕ ЧУВСТВИТЕЛЬНОСТИ СЕГМЕНТАЦИИ ИЗОБРАЖЕНИЙ СЕТЬЮ КОХОНЕНА НА ОСНОВЕ МОДУЛЯЦИОННЫХ ПРЕОБРАЗОВАНИЙ

Аннотация. Рассмотрены возможности повышения чувствительности визуальной сегментации слабоконтрастных изображений с использованием самоорганизующихся карт Кохонена в зависимости от способа формирования многомерного входного вектора на основе модуляционных преобразований исходных яркостей.

Ключевые слова: сегментация, карта Кохонена, слабоконтрастные изображения, модуляционные преобразования, предобработка.

Введение. Постоянно возрастает количество практических задач, решаемых на основе цифровой обработки изображений, являющихся результатом применения стандартных методов исследования в различных областях деятельности человека, например, в медицине, геофизике, экологии и пр. Сегментация изображений является одной из важнейших и, при этом, неоднозначных процедур, относящихся к методам высокого уровня обработки [1], которая должна обеспечить разделение исходных данных на составные части с однородными свойствами с целью выделения объектов интереса для дальнейшего визуального анализа. Степень требуемой детализации при сегментации определяется как качеством изображения, так и решаемой задачей, а от точности проведения этого этапа зависит успех анализа в целом.

Возможность повышения чувствительности и достоверности сегментации изображения заключается в решении задачи расширения пространства входных признаков за счет преобразования исходных данных, например, путем анализа локального контраста отдельных элементов, что требует использование методов обработки в многомерном пространстве. Выбор различных типов преобразований и методов сегментации, приводит к различным результатам [2].

Отсутствие четких критериев оптимальности получаемых результатов (часто применяется субъективная визуальная оценка) при-

водит к необходимости сравнения различных методов обработки, в частности, вариантов формирования входного набора данных, используемых при анализе. Для зашумленных слабоконтрастных изображений необходимо выполнение дополнительных предварительных процедур нацеленных на улучшение их качества.

Актуальность исследований. Люди имеют исключительную способность идентифицировать образы трехмерного пространства, однако, не могут выделять простейшие образы в многомерном пространстве. Современный подход решения задачи анализа многомерных данных в условиях неоднозначности, и, зачастую, их неопределенности базируется на использовании нейросетевого [3] и нечеткого [2] подходов. Достоинство подхода на основе самоорганизующихся карт Кохонена (СКК) [3] заключается, прежде всего, в его в адаптивности, возможности обработки набора информативных признаков большой размерности при минимуме априорных знаний и обеспечения гарантированного двумерного отображения многомерной информации.

Поскольку заранее обычно неизвестно насколько полезны те или иные входные переменные для «предсказания» значений выходов, то возникает соблазн увеличения пространства входных параметров, однако, при этом страдает точность и интерпретируемость результатов. Таким образом, количество входов приходится довольно жестко лимитировать, и выбор наиболее информативных входных переменных представляет важный этап подготовки данных для анализа. Сложность заключается в том, что, с одной стороны, неизвестно какие данные необходимо использовать дополнительно для повышения чувствительности, с точки зрения решаемой задачи, а с другой следует учитывать, что отрицательным фактором при увеличении размерности входного вектора может стать:

- наличие корреляции между входными признаками;
- увеличение времени обработки;
- появление артефактов.

Постановка задачи. Целью данной статьи является исследование информационных возможностей повышения визуальной чувствительности сегментации слабоконтрастных изображений с использованием самоорганизующихся карт Кохонена (СКК) в зависимости от способа формирования многомерного входного вектора на основе модуляционных преобразований исходных яркостей.

Результаты исследований. На рис. 1 показана архитектура сети, называемая дискретной картой Кохонена, нейроны которой образуют двумерную решетку, все нейроны которой связаны со всеми узлами входного слоя. С прикладной точки зрения СКК это самодостаточный метод анализа, формирующий правила обучения нейросети исходя из топологии распределения исходных данных и естественным образом квантующий входное пространство анализируемых признаков, с возможностью представления их в виде, эффективном для визуального анализа имеющихся особенностей [3].




Рисунок 1 – Архитектура карты Кохонена:

$(n_x \times n_y)$ – общее число узлов в карте; (x_1, x_2, \dots, x_n) – входы;

$W_i = [w_{i1}, w_{i2}, \dots, w_{in}]^T$ – вектор весов для узла i

При использовании алгоритма СКК для сегментации изображений мы выделяем следующие этапы:

1. определение методов предобработки анализируемых изображений и вычисление релевантного набора входных векторов с учетом пространственного распределения значений исходных яркостей и в соответствии с поставленной задачей анализа;

2. выбор размерности сети и параметров обучения;

3. обучение сети;

4. сегментация – определение метода отображения результатов кластеризации многомерных данных на двумерную плоскость.

Эксперименты показали, что при обработке изображений на ошибку кластеризации существенное влияние оказывает как общее число нейронов в сети, которое ограничивает максимально возможное значение кластеров, так и число нейронов n_x , n_y по осям x и y , соответственно, что связано с топологическими свойствами анализируемых данных. Выбор значений n_x , n_y должны быть обусловлены ко-

личеством уровней серого, используемого при отображении изображений (максимум для стандартных мониторов составляет 256) и их геометрическими размерами. Использование лишних нейронов приводит к формированию артефактов. Карты небольшого размера способствуют формированию более крупных кластеров, т.е. обеспечивают некоторую универсальность, что может оказаться полезным в ряде случаев, например, если в данных присутствует много помех.

Квадрат ошибки e_k^2 для кластера k представляет собой сумму квадратов евклидовых расстояний между признаками в кластере k и его центроидом v_k

$$e_k^2 = \sum_{i=1}^N z_{ik} (x_i - v_k)^T (x_i - v_k) \quad (1)$$

Общий квадрат ошибки кластеризации есть сумма квадратов ошибок всех кластеров K

$$E_K^2 = \sum_{k=1}^K e_k^2 \quad (2)$$

На рис. 2 приведен типичный вид значений ошибки кластеризации в зависимости от размеров сети, который позволяет определить ее оптимальный размер при выполнении условия $n_x \times n_y \leq 256$. (область возможных параметров сети выделена на рисунке белым прямоугольником в котором выполняется также соотношение $n_x > n_y$).




Рисунок 2 – Зависимость ошибки кластеризации от количества нейронов в сети Кохонена

При выполнении эксперимента использовались две фазы обучения (грубая и точная), с гауссовой функцией модификации сосед-

них нейронов. Оптимальный диапазон изменения радиуса влияния нейрона для грубой фазы определяется как целая часть от значения $r_1 = \sqrt{(n_x^2 + n_y^2)}$, а для точной фазы как $r_2 \approx r_1 / 5$.

Визуализация результатов кластеризации формировалась двумя способами: на основе значений центроидов класса принадлежности пикселя и на основе среднеквадратичного отклонения пикселей в пределах каждого класса. В дальнейшем использовался тот метод представления, который наиболее соответствовал поставленной задаче.

Влияние процедуры декорреляции оценивалось с использованием метода сингулярного разложения (SVD) который широко используется при обработке многомерной информации, в частности, применительно к задачам сжатия.

Анализ матрицы собственных чисел в наших экспериментах показал, что устранение постоянной составляющей из всех анализируемых исходных изображений существенно влияет на ее значения и приводит к изменению результатов кластеризации, повышая чувствительность. Без использования процедуры декорреляции, устранение постоянной составляющей абсолютно не влияет на конечный результат нейросетевой сегментации на основе СКК.

Набор входных векторов для выполнения процедуры кластеризации формировался на основе оригинальных методов преобразования изображений разработанных автором.

В работах [5] для этой цели нами было предложено модуляционное преобразование вида

$$R(x, y) = I(x, y)e^{j\pi \frac{I(x, y)}{\lambda}} = \text{Re}\{R(x, y)\} + j \text{Im}\{R(x, y)\} = |R(x, y)|e^{j\Phi(x, y)}, \quad (3)$$

где $I(x, y)$ – исходное изображение, а λ – модуляционный параметр.

С математической точки зрения это преобразование означает переход из пространства действительных яркостей в пространство комплексных значений с возможностью использования математического аппарата теории функций комплексной переменной. Отличительной особенностью получаемой функции $R(x, y)$ является то, что ее амплитудно-пространственная характеристика (модуль $|R(x, y)|$) соответствует исходному изображению $I(x, y)$, тогда как фазо-пространственная характеристика (аргумент $\Phi(x, y)$ - угол поворота

вектора в комплексной плоскости) зависит от соотношения $I(x, y) / \lambda$. Вариация параметра λ влияет на изменчивость фазовой характеристики $\Phi(x, y)$ и позволяет получать виртуальные изображения, характеризующиеся различной чувствительностью к изменению значений яркости пикселей.

Другой подход – формирование нового входного вектора осуществляется на основе использования выражения [6]

$$\bar{A}(x, y) = \exp[j\pi I(x, y) / \lambda(x, y)] = \operatorname{Re}\{\bar{A}(x, y)\} + j \operatorname{Im}\{\bar{A}(x, y)\}, \quad (4)$$

где λ является константой преобразования и зависит от координаты текущего пикселя.

Алгоритм преобразования предполагает выполнение следующих этапов.

1. В окрестности каждого пикселя формируется скользящая рамка размером $(L \times L)$, позволяющая учитывать влияние ближайших соседей (во многих приложениях достаточен выбор значения $L = 3$).

2. Для каждого пикселя анализируемого изображения $I(x, y)$ в пределах размерности используемой скользящей рамки вычисляется значение параметра модуляции в виде

$$\lambda(x, y) = I_{L, \max} - I_{L, \min} + k, \quad (5)$$

где k – стабилизирующий коэффициент, определяемый эмпирически. Выбор его значения зависит от исходного динамического диапазона изменения яркостей. Эксперименты показали, что для большинства типов изображений для рамки размера 3×3 оптимальным является значение $k = 0.2 \div 0.4$.

Экспериментальные результаты возможности повышения чувствительности сегментации слабоконтрастных изображений с СКК в зависимости от способа формирования многомерного входного вектора на основе модуляционных преобразований были исследованы на примерах обработки одномерных и мультиспектральных изображений различной физической сущности.

На рис. 3,а представлено изображение рентгеновской компьютерной томограммы головы, анализируемое с целью выявления области влияния гематомы (помечена стрелкой). Для улучшения качества томограммы традиционно используется рентгеноконтрастная жидкость вводимая в вену – дорогая и вредная для здоровья процедура,

которая в данном случае имеет невысокую эффективность (рис. 3,б). На рис. 3,в,е представлен результат сегментации СКК непосредственно по исходным данным и на основе амплитудно-пространственной и фазовой характеристик выражения (3). Из рассмотрения рис. 3,г,д следует, что реальная и мнимая части модуляционного преобразования сами по себе не решают задачи выявления области влияния гематомы. Однако, использование их при кластеризации СКК (рис. 3,е) существенно повышают чувствительность сегментации (в частности, выявилась неоднородность пленки) и позволяет решить поставленную задачу.

Дополнительные простые возможности повышения чувствительности СКК обеспечивает использование выражения (4), причем в данном случае возможно использование четырех характеристик: модулей и аргументов суммы и разности виртуальных векторных полей с последующим синтезом результирующего изображения на основе использования СКК.




Рисунок 3 – Обработка изображения томограммы СКК:

а – исходное изображение; б – с рентгеноконтрастным веществом; в – сегментация рис. 3,а; г,д – реальная и мнимая части модуляционного преобразования, соответственно; е – сегментация по характеристикам модуляционного преобразования

То, что использование такого подхода позволяет повысить чувствительность СКК, демонстрирует пример анализа изображения гравитационного поля, представленного на рис. 4, которое соответствует участку земной поверхности с соляными выработками (рис. 4,б). В результате построения геофизической модели была получена карта изолиний, изображенная на рис. 4,в. Рис. 4,г отображает сегментацию СКК непосредственно по исходному изображению.

Анализ показывает, что в этом случае выявляются лишь те аномальные участки геофизического поля, которые и так различимы на исходном изображении (рис. 4,а). Для данного примера хорошие результаты были достигнуты при применении СКК к синтезированным характеристикам адаптивного интерференционного метода ($\lambda = 0.05$) (рис. 4,д) и фазовой характеристики голографического преобразования ($\lambda = 0.17$) примененного к градиентам, на которых выявлены практически все аномалии поля, соответствующие реальной структуре.




Рисунок 4 – Сегментация СКК гравитационного поля (а); б – карта соляных выработок; в – геофизическая модель; г – по исходным данным; д – характеристики преобразования (4); е – на основе фазовой характеристики выражения (3)

Выводы. Сеть Кохонена является эффективным средством сегментации изображений и формирования композитного изображения на основе многомерных данных. Способ формирования пространства информативных признаков определяется физической природой, яркими характеристиками исходного изображения и задачей анализа. Использование характеристик модуляционных преобразований входных векторов позволяет существенно повысить чувствительность процедуры СКК сегментации.

ЛИТЕРАТУРА

1. Р. Цифровая обработка изображений / Гонсалес Р., Вудс Р.; [пер. с англ. под ред. П.А.Чочиа]. – М.: Техносфера, 2006. – 1070 с.
2. Chi Z. Fuzzy algorithms: With Applications to Image Processing and Pattern Recognition / Chi Z., Yan H., Pham T. – Singapore; – New Jersey; – London; – Hong Kong: Word Scientific, 1998. – 225 p.
3. Каллан Р. Основные концепции нейронных сетей / Каллан Р. – М.: Вильямс, 2001. – 287 с.
4. Дебок Г. Анализ финансовых данных с помощью самоорганизующихся карт / Дебок Г., Кохонен Т.; [пер. с англ. А.И. Горбунова]. – М.: Альпина, 2001. – 316 с.
5. Ахметшина Л.Г. Информационные возможности модуляционного преобразования при сегментации мультиспектральных изображений / Ахметшина Л.Г. // Системні технології. – 2004. – № 6. – С. 122-127.
6. Ахметшина Л.Г. Геометрические методы повышения качества низкоконтрастных изображений в плоскости комплексных яркостей / Ахметшина Л.Г., Ахметшин А.М., Мацюк И.М. // Геометричне та комп'ютерне моделювання. – 2007. – Вип. 18. – С. 41-46.