

Использование глубоких гауссовых моделей при совмещении изображений

В.Е. Дементьев¹, А.Г. Ташлинский¹

¹Ульяновский государственный технический университет, Северный Венец 32, Ульяновск, Россия, 432027

Аннотация

В работе рассмотрены возможности повышения точности совмещения изображений на основе использования глубоких гауссовых моделей. Рассмотрены возможности идентификации параметров таких моделей на основе модификации вариационного автокодировщика. Показано, что результаты такой идентификации возможно использовать для повышения точности совмещения пар изображений. Приводятся количественные характеристики такого выигрыша

Ключевые слова

Глубокие гауссовы модели, идентификация параметров, нейронные сети, псевдоградиентные алгоритмы, совмещение изображений

1. Введение

Одной из важных задач обработки временных последовательностей изображений является качественное пространственное совмещение этих изображений. Опыт нашей научной школы [1,2] показывает, что в большом количестве реальных практических ситуаций хорошие результаты при совмещении изображений показывают безидентификационные псевдоградиентные (ПГ) процедуры. Недостатком этих процедур является малая рабочая зона и требования к яркостно-корреляционным свойствам совмещаемых изображений. В настоящей работе представлен один из вариантов повышения качества работы ПГ процедур при совмещении изображений на основе выявления их скрытых свойств, определяемых через глубокие гауссовы модели (ГГМ).

2. Глубокие гауссовы модели

В случае использования ГГМ [3,4] многомерное изображение может быть описано с помощью многомерного случайного поля X , заданного на дискретной прямоугольной сетке Ω , а распределение X определяется выражением:

$$w(X|M^{(0)}, D^{(0)}, \rho^{(0)}) = \mathcal{N}(M^{(0)}, D^{(0)}B^{(0)}(\rho^{(0)}),$$

где $M^{(0)}$, $D^{(0)}$ – поля параметров, заданные на Ω , определяющие математическое ожидание и дисперсию X соответственно; $\rho^{(0)}$ – случайное поле, заданное на Ω , определяющее изменения корреляционной функции. При этом возможно аналогично через семейство вложенных гауссовых процессов определить семейство случайных полей $\rho^{(i)}$, $i = 1, \dots, N$; N – глубина ГСМ; параметризующих соответствующие корреляционные функции.

Одним из вариантов такого описания может быть глубокая марковская модель (ГММ), например, на основе марковских полей с кратными корнями характеристических уравнений [4,5]. Можно показать [5], что подобные ГММ можно обучать на основании модификаций вариационного автокодировщика [4]. В этом случае, зная веса α и β нейронных сетей, соответствующих кодирующей и декодирующей компоненте автокодировщика, возможно для любого конкретного изображения X получить множество параметров Θ , с помощью которых возможно выполнить соответствующую оценку скрытых слоев ГММ.

ГММ позволяет формировать на своей основе эффективные классификаторы многомерных изображений X , позволяя выявлять объекты, содержащиеся на этих изображениях [5]. Таким образом, каждому X может быть поставлен в соответствие вектор вероятностей $S_X = \{p(z_s = 1|X, \varpi), s = 1, \dots, S\}$ принадлежности X к одному из S классов. Такие классификаторы могут лежать в основе соответствующих алгоритмов сегментации изображений.

3. Совмещение изображений с использованием ГММ

Несмотря на существенные вычислительные сложности, сопутствующие обучению ГММ, применение уже обученных ГММ для обработки многомерных изображений не приводит к каким либо принципиальным сложностям, особенно при применении параллельных вычислительных архитектур (например, CUDA). Это дает возможность в режимах близких к реальному времени ставить каждому X в соответствие наборы параметров $\bar{\Theta}$, определяющий в том числе внутренние корреляционные характеристики изображения, а также результаты классификации $\{S_i\}$. Эти результаты возможно использовать совместно с X в ПГ алгоритмах совмещения. При этом совмещаются не отдельные опорные точки в X , а вектора, составленные из соответствующих отсчетов $X, \bar{\Theta}, S$. На рисунке 1 приведены фрагменты двух исходных совмещаемых изображений, поле оценок параметров ГММ, и результаты сегментации.




Рисунок 1: Исходные изображения и результаты обработки

В результате проведенных экспериментов, состоящих в последовательном совмещении искусственно искаженных фрагментов спутниковых изображений, установлено, что подобный подход позволяет уменьшить погрешность совмещения до 80% в сравнении с обработкой только наблюдаемых изображений. При этом выигрыши растут с увеличением разницы между изображениями.

4. Благодарности

Работа поддержана грантами РФФИ № 19-47-730011 и № 19-29-09048.

5. Литература

- [1] Magdeev, R. Efficiency of object identification for binary images / R. Magdeev, A. Tashlinskii // *Computer Optics*. – 2019. – № 2. – P. 277-281.
- [2] Tashlinskii, A. Probability prediction of estimations improvement at image parameters stochastic estimation / A. Tashlinskii, D. Kraus, R. Kovalenko // *Journal of Physics: Conference Series*. – 2019. – Vol. 1096(1). – P. 012033
- [3] Dai, Z. Variational Auto-encoded Deep Gaussian Processes / Z. Dai, A. Damianou, J. González, N. Lawrence // *Conference on Learning Representations*. – 2016. – P. 1-8.
- [4] Dementev, V.E. Computer Vision in Advanced Control Systems. Advanced Decisions in Technical and Medical Applications / M.N. Favorskaya, L.C. Jain, V.E. Dementev, K.K. Vasiliev // *KES International, Shoreham-by-Sea, UK, 2020*. – 321 p.
- [5] Andriyanov, N. Deep Markov models of multidimensional random fields / N. Andriyanov, V. Dementiev, A. Tashlinskii // *Procedia Computer Science*. – 2020. – 176. – P. 1289-1298.