

Распознавание растровых текстурных изображений на основе параметрических ациклических марковских моделей

Сергей Двоенко, Шанг Динь

Кафедра автоматки и телемеханики

Тулский Государственный Университет, Тула, Россия

dsd@tsu.tula.ru, dvietsang@gmail.com

Аннотация

В задаче распознавания растровых текстурных изображений часто требуется выполнить сегментацию поля изображения на области однородных в некотором смысле текстур.

Предполагается, что массив данных представлен в виде двухкомпонентного марковского случайного поля скрытых классов текстур и наблюдаемых признаков. Требуется восстановить неизвестные маргинальные распределения вероятностей скрытых классов.

Взаимосвязи между точками растра, образующие исходный циклический граф соседства элементов массива в виде решетки, аппроксимируются набором ациклических графов соседства.

Предлагается маргинальные распределения скрытых классов относительно исходной решетки заменить линейной комбинацией маргинальных распределений относительно заданных ациклических графов соседства.

Марковские матрицы переходов между классами также являются параметрами ациклических моделей и могут быть определены только одним диагональным элементом, который требуется определить.

Ключевые слова: графические модели, марковские поля, текстурные изображения, машинное обучение, распознавание, сегментация, интеллектуальный анализ данных.

1. ВВЕДЕНИЕ

В интеллектуальном анализе данных и машинном обучении в настоящее время интенсивно развивается направление, получившее название графических моделей, опирающееся на графы соседства элементов множества для построения эффективных алгоритмов распознавания и обработки, в том числе и изображений [9].

Пусть массив данных представлен в виде двухкомпонентного марковского случайного поля скрытых классов элементов массива и их наблюдаемых признаков. Исходные взаимосвязи между элементами массива в реальных данных аппроксимированы набором ациклических графов соседства элементов массива.

Требуется по предъявленным наблюдениям восстановить скрытую компоненту случайного поля.

Известно, что для графов общего вида с циклами задача распознавания марковских случайных полей обладает свойствами задачи класса NP [4, 6, 7]. Как правило, стандартным способом является решение данной задачи в терминах гиббсовских энергий, где минимизация гиббсовской энергии скрытых состояний марковского случайного поля доставляет максимум их неизвестному совместному апостериорному распределению на основе теоремы Хаммерсли-Клиффорда [6].

В данной статье развивается подход, основанный на численной оценке маргинальных распределений вероятностей скрытых классов, где неизвестные маргинальные распределения вероятностей скрытых классов относительно исходного графа соседства заменяются линейной комбинацией маргинальных распределений относительно заданных ациклических графов соседства [1–3].

Марковские матрицы переходов между скрытыми классами являются параметрами таких ациклических моделей и, как показано в данной статье, могут быть определены только одним диагональным элементом, который ранее [1–3] обычно задавался эвристически.

В данной статье построены алгоритмы поиска марковских параметров одновременно с поиском весов ациклических графов соседства в их линейной комбинации с целью эффективного улучшения качества распознавания.

Приведены результаты сравнительных экспериментов в задаче сегментации растровых текстурных изображений.

2. АЦИКЛИЧЕСКИЕ МОДЕЛИ МАРКОВСКОГО ПОЛЯ И АЛГОРИТМЫ РАСПОЗНАВАНИЯ

Пусть массив T взаимосвязанных объектов $t \in T$ представлен как двухкомпонентное случайное поле (X, Y) .

Наблюдаемая компонента $Y = (y_t, t \in T)$ принимает значения из множества $y_t \in \Theta$, определенного природой источника данных. Скрытая компонента $X = (x_t, t \in T)$ подлежит восстановлению и в задаче распознавания принимает значения номеров классов объектов $\Omega = \{1, \dots, m\}$. Наблюдения условно независимы относительно реализации скрытого случайного поля классов объектов $\psi_t(y_t | X) = \psi_t(y_t | x_t)$.

На множестве элементов $t \in T$ массива данных определено симметричное антирефлексивное бинарное отношение, представленное в виде неориентированного графа G без петель, ребра которого $(s, t) \in T$ соединяют соседние элементы массива данных $s \in T$ и $t \in T$. Граф G является деревом или цепью, т.е. не содержит циклов.

Скрытое поле X является марковским, если для всех $t \in T$ выполнено $q_t(x_t | X_{(t)}) = q_t(x_t | X_{(t)}^0)$, где приняты обозначения $X_{(t)} = (x_s, s \in T \setminus t)$, $X_{(t)}^0 = (x_s, s \in T \setminus t, (s, t) \in G)$.

Древоидный граф G разбивает окрестность нетерминального элемента x_t на две произвольные части $X_{(t)}^0 = X_{(t)}^- \cup X_{(t)}^+$. Вершина $t^* \in T$ в качестве корня задает естественный нисходящий и восходящий порядок просмотра, определяя окрестность $X_{(t)}^- = x_t$ из одного элемента, предшествующего x_t , и окрестность $X_{(t)}^+$ непосредственных потомков x_t .

Можно доказать [1–3], что такое априорное поле является односторонним марковским $q_t(x_t | X_{(t)}^0) = q_t(x_t | x_r)$.

Можно также доказать [1–3], что апостериорное скрытое поле относительно того же графа G остается односторонним марковским $p_t(x_t | X_{(t)}, Y) = p_t(x_t | x_r, Y_t^+)$, где Y_t^+ – поддерево с корнем в y_t , включая его.

Для решений о поле X можно использовать, например, байесовское правило $\hat{x}_t(Y) = \arg \max_{x_t \in \Omega} p_t(x_t | Y)$, $t \in T$, где

$p_t(x_t | Y)$ – локальные апостериорные маргинальные распределения вероятностей скрытых классов в элементах массива $t \in T$.

Восстановленная компонента X формирует связные области одинаковых номеров классов, образуя сегментацию поля наблюдений, например, растрового изображения на области с разными типами текстур.

Базовый алгоритм. Процедура восстановления скрытой компоненты названа базовым алгоритмом распознавания. Скрытое поле X распознается в общем случае за три прохода по дереву G [2, 3].

1. Задается начало обработки в корне t^* и априорное распределение $q_{t^*}(x_{t^*})$, $x_{t^*} \in \Omega$. Нисходящим просмотром для всех $t \in T$ вычисляются априорные распределения классов

$$q_s(x_s) = \sum_{x_t \in \Omega} q_s(x_s | x_t) q_t(x_t), \quad x_s \in \Omega, \quad s \in T_{(t)}^{+0}.$$

2. Восходящим просмотром от терминалов к корню вычисляются «фильтрационные» апостериорные маргинальные распределения классов

$$p_t(x_t | Y_t^+) \propto p_t(x_t | Y_{(t)}^+) p_t(x_t | y_t), \quad x_t \in \Omega, \quad t \in T,$$

$$p_t(x_t | Y_{(t)}^+) \propto \prod_s \sum_{x_s \in \Omega} p_s(x_s | Y_s^+) \frac{q_s(x_s | x_t)}{q_s(x_s)}, \quad s \in T_{(t)}^{+0},$$

где Y_t^+ – поддерево с корнем в y_t , включая его. Апостериорные маргинальные распределения $p_t(x_t | y_t)$ получены на этапе независимого обучения. В терминальных вершинах принимается $p_t(x_t | Y_t^+) = p_t(x_t | y_t)$.

3. На последнем восходящем шаге распределение в корне опирается на все наблюдения $p_{t^*}(x_{t^*} | Y_{t^*}^+) = p_{t^*}(x_{t^*} | Y)$, $x_{t^*} \in \Omega$. Такое «интерполяционное» апостериорное маргинальное распределение значений корневой переменной позволяет принять решение о классе

$$\hat{x}_{t^*}(Y) = \arg \max_{x_{t^*} \in \Omega} p_{t^*}(x_{t^*} | Y).$$

4. Нисходящим просмотром от корня для всех $t \in T$ вычисляются интерполяционные апостериорные маргинальные распределения

$$p_s(x_s | Y) \propto \sum_{x_t \in \Omega} p_s(x_s | x_t, Y) p_t(x_t | Y), \quad x_s \in \Omega, \quad s \in T_{(t)}^{+0},$$

$$p_s(x_s | x_t, Y) \propto p_s(x_s | Y_s^+) q_t(x_t) \frac{q_s(x_s | x_t)}{q_s(x_s)}$$

и принимаются решения о классах

$$\hat{x}_s(Y) = \arg \max_{x_s \in \Omega} p_s(x_s | Y).$$

Итерационный алгоритм. Для заданного набора ациклических графов соседства G_k , $k = 1, \dots, K$, аппроксимирующий исходный граф соседства элементов реального массива данных, итерационный алгоритм распознавания построен на основе базового алгоритма и имеет следующий вид [3].

1. Для каждого ациклического графа G_k базовым алгоритмом формируются апостериорные распределения $p_t^k(x_t | Y)$, $k = 1, \dots, K$, $t \in T$, и на их основе формируются апостериорные распределения $p_t(x_t | Y) = \sum_{k=1}^K w_k p_t^k(x_t | Y)$, $t \in T$ для заданных весов $w_k \geq 0$, $\sum_{k=1}^K w_k = 1$.

2. Только что найденные распределения $p_t(x_t | Y)$ принимаются за исходные вместо распределений $p_t(x_t | y_t)$ и для каждого ациклического графа соседства в отдельности базовый алгоритм применяется вновь.

3. Итерационный алгоритм останавливается, когда распределения перестают изменяться, позволяя принять решения о классах $\hat{x}_t(Y)$, $t \in T$.

Схема Гаусса-Зайделя. Веса графов соседства в линейной комбинации определяются по схеме Гаусса-Зайделя, где изменение веса графа G_k в диапазоне от 0 до 1 считаем аналогом покоординатного варьирования [3].

1. На начальном шаге распределение весов всех графов изменяется от $1/(K-1), \dots, 0, \dots, 1/(K-1)$, когда граф G_k полностью исключен, до $0, \dots, 1, \dots, 0$, когда есть только граф G_k . Шаг заканчивается после варьирования всех весов и выбора того графа, чей вес обеспечил минимальное число ошибок распознавания на обучающем множестве изображений.

2. На очередном шаге варьируется вес $0 \leq p \leq 1$ графа G_k . Нормированный вес графа G_k в линейной комбинации имеет значение $w_k = p$. Остальные графы имеют к данному шагу постоянные веса l_i , $i = 1, \dots, K$, $i \neq k$, где их сумма также постоянна $L = \sum_{i=1}^K l_i$, $i \neq k$. Их нормированные веса $w_i = l_i(1-p)/L$ изменяются от $w_i = l_i/L$ до $w_i = 0$.

Каждое пробное варьирование проверяется однократным комбинированием уже вычисленных маргинальных распределений $p_t^k(x_t | Y)$, $t \in T$, $k = 1, \dots, K$ и распознаванием с подсчетом числа ошибок для решений \hat{x}_t , $t \in T$.

Шаг заканчивается после варьирования всех весов и выбора нового веса того графа, для которого получено минимальное число ошибок.

3. ЧАСТНАЯ МОДЕЛЬ МАРКОВСКОГО ПОЛЯ

Марковское априорное случайное поле классов X определяет его одностороннее свойство в виде условных распределений вероятностей на множестве значений переменной $x_t \in \Omega$ относительно любой переменной $x_r \in X_{(t)}^0$ из марковской окрестности x_t .

Для каждой пары вершин $(r, t) \in G$, соединенных ребром, определена пара условных распределений $q_t(x_t | x_r)$ и $q_r(x_r | x_t)$. Выбор некоторой вершины в качестве корня $t^* \in T$ задает нисходящее и восходящее направления просмотра.

Односторонняя марковская модель поля X является однородной конечной марковской цепью с неизменными условными распределениями в восходящем и нисходящем направлениях, где $q_r(x_r | x_t) = q(x_r | x_t)$, $q_t(x_t | x_r) = \bar{q}(x_t | x_r)$, и определена двумя матрицами $Q(m \times m)$ и $\bar{Q}(m \times m)$ ус-

ловных вероятностей переходов. Односторонняя марковская модель поля X является эргодической неразложимой марковской цепью и имеет финальное распределение $p(x), x \in \Omega$ в корне t^* . Для неразложимой марковской цепи матрицы Q и \bar{Q} связаны через финальное распределение вероятностей $\bar{q}(x_i | x_r) = q(x_r | x_i) p(x_i) / p(x_r)$. В такой модели начальное априорное маргинальное распределение вероятностей $q_i(x_i)$ можно задать в любой вершине $t \in T$, тогда соответствующие маргинальные распределения оказываются известными во всех остальных вершинах дерева G , в том числе и в его корне. Корень t^* естественно связать с началом обработки, а начальное распределение сделать корневым $q_{t^*}(x_{t^*}), x_{t^*} \in \Omega$.

Если предположить, что априорное распределение классов в корне t^* является равномерным финальным распределением $q_{t^*}(x_{t^*}) = p(x_{t^*}) = 1/m$, то маргинальные априорные распределения вероятностей скрытых классов во всех остальных элементах также равномерны. В этом случае $\bar{q}(x_i | x_r) = q(x_r | x_i)$.

Это, в частности, позволяет выполнить приведенный выше базовый алгоритм всего за два просмотра, исключив первый просмотр.

В итоге, остается только одна симметричная и дважды стохастичная матрица переходов Q . Предполагается, что такая матрица Q имеет одинаковые диагональные элементы и одинаковые недиагональные элементы. Тогда в такой частной модели матрица Q задается только одним значением ее диагонального элемента q , который оказывается единственным марковским параметром, требующим настройки.

Заметим, что теоретически для улучшения качества распознавания по сравнению с результатом независимого распознавания необходимо обеспечить $q > 1/m$. Ранее эвристически предполагалось, что для распознавания протяженных областей одного типа текстуры достаточно, например, обеспечить $0,95 \leq q < 1$, получив относительно редко переключающуюся марковскую цепь [1–3].

4. АЛГОРИТМЫ ПОИСКА МАРКОВСКИХ ПАРАМЕТРОВ

Расширим схему Гаусса-Зайделя поиска весов графов для одновременного поиска оптимального значения диагонального элемента матрицы переходов. Заметим, что при однократном распознавании шаг варьирования диагонального элемента в диапазоне $1/m \leq q < 1$ оказывается вырожденным, т.к. при любом наборе весов ациклических графов увеличение диагонального элемента при условии $q < 1$ монотонно уменьшает число ошибок распознавания. Чтобы задача поиска не оказалась вырожденной, в новых алгоритмах поиска будем применять многократное распознавание при оценке числа ошибок.

Алгоритм 1. Поиск единственного диагонального элемента и весов. Все ациклические марковские модели, соответствующие графам $G_k, k = 1, \dots, K$, определяются одним общим диагональным элементом q . Сначала все веса одинаковы $\mathbf{w}^* = \{w_i = 1/K, i = 1, \dots, K\}$.

1. Проварьируем q и найдем его значение при минимальном числе ошибок $E: q^* = \arg \min_{1/m \leq q < 1} E(\mathbf{w}^*, q)$.

2. Шаг варьирования весов по всем графам. Варьируется вес w_k очередного графа G_k в диапазоне $0 \leq w_k \leq 1$ при масштабировании весов остальных графов. Каждое пробное варьирование проверяется многократным распознаванием с подсчетом числа ошибок $E(\mathbf{w}, q^*)$. Для каждого графа G_k определим число ошибок и оптимальный вектор весов $\mathbf{w}_k^* = (w_1, \dots, w_k^*, \dots, w_K)$:

$$E_k^* = \min_{0 \leq w_k \leq 1} E(\mathbf{w}, q^*), \quad \mathbf{w}_k^* = \arg \min_{0 \leq w_k \leq 1} E(\mathbf{w}, q^*).$$

3. Среди всех наборов $\mathbf{w}_k^*, k = 1, \dots, K$ найдем набор $\mathbf{w}^* = \mathbf{w}_{k^*}^*, k^* = \arg \min_{1 \leq k \leq K} E_k^*$, обеспечивший наименьшее число ошибок.

4. Повторим шаги 1–3 до тех пор, пока число ошибок распознавания не перестанет изменяться.

Алгоритм 2. Первая схема последовательного поиска диагональных элементов и весов. Каждому графу $G_k, k = 1, \dots, K$ соответствует ациклическая марковская модель со своим диагональным элементом $q_k, k = 1, \dots, K$. Сначала все веса одинаковы $\mathbf{w}^* = \{w_i = 1/K, i = 1, \dots, K\}$.

1. Проварьируем одновременно все диагональные элементы $q_k = q, k = 1, \dots, K$ и найдем значение q^* при минимальном числе ошибок $E: \mathbf{q}^* = (q^*, \dots, q^*) = \arg \min_{1/m \leq q < 1} E(\mathbf{w}^*, \mathbf{q})$.

2. Шаг варьирования весов по всем графам. Варьируется вес w_k очередного графа G_k в диапазоне $0 \leq w_k \leq 1$ при масштабировании весов остальных графов. Каждое пробное варьирование проверяется многократным распознаванием с подсчетом числа ошибок $E(\mathbf{w}, \mathbf{q}^*)$. Для каждого графа G_k определим число ошибок и вектор весов $\mathbf{w}_k^* = (w_1, \dots, w_k^*, \dots, w_K)$:

$$E_k^* = \min_{0 \leq w_k \leq 1} E(\mathbf{w}, \mathbf{q}^*), \quad \mathbf{w}_k^* = \arg \min_{0 \leq w_k \leq 1} E(\mathbf{w}, \mathbf{q}^*).$$

3. Среди всех наборов $\mathbf{w}_k^*, k = 1, \dots, K$ найдем набор $\mathbf{w}^* = \mathbf{w}_{k^*}^*, k^* = \arg \min_{1 \leq k \leq K} E_k^*$, обеспечивший наименьшее число ошибок.

4. Шаг варьирования всех диагональных элементов. В диапазоне $1/m \leq q_k < 1$ варьируется диагональный элемент q_k , соответствующий графу G_k . Остальным графам соответствуют элементы $q_i, i = 1, \dots, K, i \neq k$, найденные до варьирования q_k , которые остаются постоянными. Найдем значение q_k при минимальном числе ошибок:

$$q_k^* = \arg \min_{1/m \leq q_k < 1} E(\mathbf{w}^*, \mathbf{q}).$$

Новое значение q_k^* применяется при варьировании остальных диагональных элементов q_{k+1}, \dots, q_K . В итоге, получим оптимальный вектор \mathbf{q}^* .

5. Повторим шаги 2–4 до тех пор, пока число ошибок распознавания не перестанет изменяться.

Алгоритм 3. Вторая схема параллельного поиска диагональных элементов и весов.

Каждому графу $G_k, k=1, \dots, K$ соответствует отдельная ациклическая марковская модель со своим диагональным элементом $q_k, k=1, \dots, K$. Сначала все веса одинаковы $\mathbf{w}^* = \{w_i = 1/K, i=1, \dots, K\}$.

1. Проварьируем одновременно все диагональные элементы $q_k = q, k=1, \dots, K$ и найдем значение q^* при минимальном числе ошибок $E: \mathbf{q}^* = (q_1^*, \dots, q_K^*) = \arg \min_{1/m \leq q < 1} E(\mathbf{w}^*, \mathbf{q})$.

2. Шаг варьирования весов и диагональных элементов по всем графам. Варьируется вес w_k очередного графа G_k в диапазоне $0 \leq w_k \leq 1$ при масштабировании весов остальных графов. Каждое пробное варьирование проверяется многократным распознаванием с подсчетом числа ошибок $E(\mathbf{w}, \mathbf{q}^*)$. Определим число ошибок и вектор весов $\mathbf{w}_k^* = (w_1, \dots, w_k^*, \dots, w_K)$:

$$E_k^* = \min_{0 \leq w_k \leq 1} E(\mathbf{w}, \mathbf{q}^*), \quad \mathbf{w}_k^* = \arg \min_{0 \leq w_k \leq 1} E(\mathbf{w}, \mathbf{q}^*)$$

Далее варьируется элемент q_k , соответствующий графу G_k , в диапазоне $1/m \leq q_k < 1$. Остальным графам соответствуют элементы $q_i, i=1, \dots, K, i \neq k$, найденные до варьирования q_k , которые остаются постоянными. Найдем значение q_k при минимальном числе ошибок:

$$q_k^* = \arg \min_{1/m \leq q_k < 1} E(\mathbf{w}_k^*, \mathbf{q})$$

Значение q_k^* определяет вектор $\mathbf{q}^* = (q_1^*, \dots, q_k^*, \dots, q_K^*)$.

3. Среди всех пар $(\mathbf{w}_k^*, \mathbf{q}_k^*), k=1, \dots, K$ найдем пару $(\mathbf{w}^*, \mathbf{q}^*) = (\mathbf{w}_{k^*}^*, \mathbf{q}_{k^*}^*), k^* = \arg \min_{1 \leq k \leq K} E(\mathbf{w}_k^*, \mathbf{q}_k^*)$, обеспечившую наименьшее число ошибок.

4. Повторим шаги 2–3 до тех пор, пока число ошибок распознавания не перестанет изменяться.

5. СРАВНЕНИЕ АЛГОРИТМОВ

Решалась задача сегментации 100 модельных растровых изображений (рис. 1) размером 201×201 пикселей.

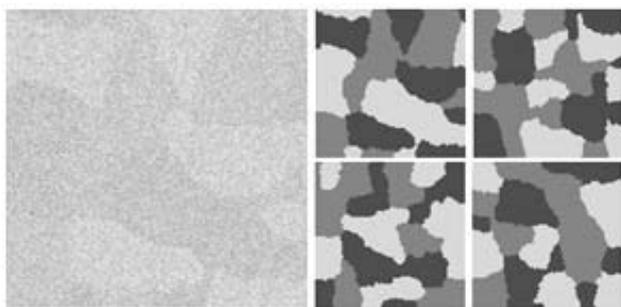


Рис 1: Пример текстуры и заданных сегментаций.

Текстуры трех классов были представлены реализациями трех нормально распределенных случайных величин с немного отличающимися средними в пространстве красной и зеленой компонент (на рис. 1 в градациях серого представлены: слева – пример первого изображения, справа – заданная сегментация текстур на первых четырех из 100 тестовых изображений).

Таким образом, множества точек растра трех классов очень сильно пересекались в пространстве цветных RG-компонент.

Результаты независимого распознавания дают не менее 30% ошибок сегментирования поля растра.

На рис. 2 показаны ациклические графы соседства, которые удобно использовать для замены решеток растровых текстурных изображений.



Рис 2: Ациклические графы соседства.

Сравнивались четыре алгоритма поиска параметров ациклических марковских моделей (Г-3 – схема Гаусса-Зайделя поиска весов без поиска диагонального элемента, А1 – поиск единственного диагонального элемента и весов, А2 – первая схема поиска диагональных элементов и весов, А3 – вторая схема поиска диагональных элементов и весов) и алгоритм TRWS [5, 8, 10].

Изображения просматривались в случайном порядке, и средняя ошибка распознавания вычислялась каждый раз после добавления очередного изображения к просмотренному множеству. На рис. 3 показаны кумулятивные линии средних ошибок для одной из случайных последовательностей заданных изображений. На рис. 4 показаны линии отклонения доли средних ошибок разработанных алгоритмов относительно линии доли средних ошибок TRWS, показанной как горизонтальная координатная ось.

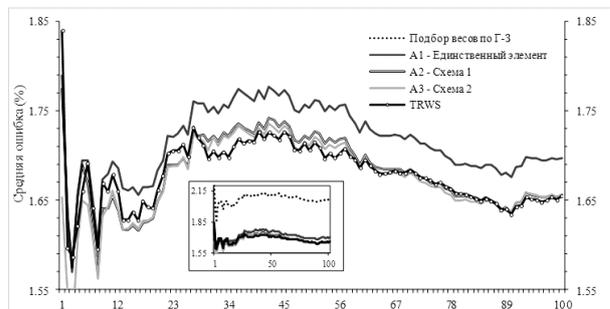


Рис 3: Среднее число ошибок (%).

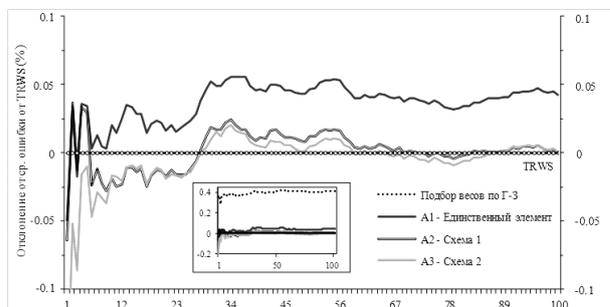


Рис 4: Отклонения линий ошибок.

Легко увидеть одинаковый характер кумулятивных линий средних ошибок для всех алгоритмов. Алгоритмы с поиском марковских параметров (А1–А3) резко улучшают качество распознавания по сравнению с алгоритмом по схеме

Гаусса-Зайделя (Г-З) без такого поиска (показан на врезке). Например, алгоритм TRWS не является однозначно лучшим, т.к. на части изображений он уступает по качеству распознавания.

Очевидно, что характер поведения таких кумулятивных характеристик изменяется с увеличением размера выборки, становясь более плавным. На рис. 3 видно, что алгоритм A1 систематически проигрывает по средней ошибке остальным алгоритмам. Тем не менее, на начальном участке видно, что на каждом отдельном изображении он может выигрывать в качестве, давая меньшее число ошибок. Так и происходит: все сравниваемые алгоритмы (A1–A3, TRWS) достаточно часто уступали друг другу в качестве на различных отдельных изображениях.

В частности, при сравнении с алгоритмом TRWS оказалось, что алгоритм A1 был лучше только в 35 случаях из 100, сделав суммарно на 1721 ошибку больше; алгоритм A2 был лучше уже в 55 случаях из 100, сделав суммарно на 17 ошибок больше; алгоритм A3 был лучше в 50 случаях из 100, сделав суммарно на 43 ошибки больше.

В итоге, оказалось, что алгоритмы с поиском марковских параметров сравнимы по качеству между собой и с алгоритмом TRWS, который сегодня считается одним из эффективных алгоритмов обработки изображений. Например, при уровнях значимости $\alpha = 0,001; 0,01; 0,05$ и, вообще, при $\alpha < 0,3788$ (т.е. для всех значений правой границы $Z_{кр} > 0,88$ двухсторонней критической области функции Лапласа, где $|Z_{набл}| = 0,88$ соответствует максимальному из значений критерия, полученному для алгоритма A1) гипотеза о равенстве среднего уровня ошибок алгоритмов с поиском марковских параметров (A1 – A3) и TRWS не отвергается.

Визуально результаты сегментаций разными алгоритмами отличаются лишь мелкими деталями и выглядят практически как заданные сегментации, например, на рис. 1.

Ниже в таблице показаны параметры настройки алгоритмов на примере некоторых изображений из 100.

Параметры настройки алгоритмов						
Изображение	A1		A2		A3	
	Весы	q	Весы	q	Весы	q
1	0,04282	0,86	0,03947	0,90	0,02000	0,75
	0,20338		0,23684	0,89	0,09287	0,93
	0,24000		0,25000	0,91	0,36836	0,92
	0,25690		0,23684	0,90	0,25939	0,89
	0,25690		0,23684	0,89	0,25939	0,89
2	0,16894	0,89	0,17000	0,89	0,16000	0,89
	0,09034		0,17000	0,80	0,12643	0,89
	0,18863		0,17000	0,90	0,20205	0,87
	0,36209		0,32000	0,90	0,33540	0,88
	0,19000		0,17000	0,91	0,17612	0,90
3	0,06643	0,89	0,17408	0,70	0,09000	0,82
	0,19373		0,15105	0,88	0,19376	0,92
	0,30135		0,27079	0,91	0,19376	0,92
	0,23849		0,23000	0,89	0,32872	0,79
	0,20000		0,17408	0,91	0,19376	0,92
4	0,17953	0,90	0,21000	0,89	0,17225	0,90
	0,09995		0,08208	0,73	0,16000	0,88
	0,30963		0,23597	0,93	0,22966	0,91
	0,23089		0,23597	0,90	0,29854	0,90
	0,18000		0,23597	0,81	0,13955	0,89
52	0,16486	0,89	0,46511	0,37	0,15000	0,36
	0,23356		0,13000	0,61	0,21329	0,89
	0,23356		0,14111	0,90	0,21329	0,89
	0,25000		0,14111	0,92	0,21329	0,89
	0,11803		0,12267	0,82	0,21012	0,94

Легко увидеть, что марковские параметры настройки отличаются от предполагаемых по умолчанию эвристических значений. При поиске единственного диагонального элемента его значение оказывается достаточно большим, но меньше, чем обычно предполагалось эвристически.

При поиске диагональных элементов, соответствующих каждому из ациклических графов соседства, их значения, например, на первых четырех изображениях также достаточно велики, но снова меньше, чем предполагалось эвристически. Особенно это заметно, например, на изображении 52, для которого диагональный элемент, соответствующий первому графу соседства (ступенчатое дерево), оказался относительно небольшим.

6. ЗАКЛЮЧЕНИЕ

В данной статье для распознавания взаимосвязанных объектов, организованных в единый массив данных, применяется аппарат скрытых марковских моделей. Показано, что модель марковской цепи удается непосредственно применить для описания класса зависимых объектов с гораздо более широким разнообразием свойств, представленных марковскими полями, например, для растровых текстурных изображений.

Введение односторонней марковской модели для ациклических графов соседства взаимосвязанных элементов в массиве данных позволяет построить эффективный базовый итерационный алгоритм распознавания.

Тем не менее, в реальных данных графы соседства обычно содержат циклы, как, например, решетки соседства на изображениях. Ациклическая аппроксимация исходных графов соседства неизбежно искажает характер взаимосвязей между элементами массива данных.

В данной статье предложено редуцированное множество взаимосвязей скомпенсировать расширением самого множества ациклических графов соседства. Разработаны соответствующие итерационные алгоритмы распознавания и приведены результаты экспериментов.

Следует отметить, что алгоритм TRWS решает глобальную задачу восстановления скрытого марковского поля в терминах гиббсовских энергий взаимодействия на кликах графа соседства общего вида. В случае растровых изображений это – только парные клики.

Алгоритмы A1 – A3 решают, вообще говоря, другую задачу восстановления скрытого марковского апостериорного поля в виде совокупности непосредственных численных оценок локальных апостериорных маргинальных распределений вероятностей скрытых классов. Тем не менее, показано, что, несмотря на ограниченность частной постановки такой задачи, также достигается высокое качество результатов распознавания.

7. БЛАГОДАРНОСТИ

Работа была выполнена при частичной поддержке грантов РФФИ №04–01–08038, 05–01–00679, 08–01–99003, 08–01–12023, 09–07–00394, 10–07–00489, гранта INTAS №04–77–7347.

8. ССЫЛКИ

[1] Двоенко С.Д., Копылов А.В., Моттль В.В. Задача распознавания образов в массивах взаимосвязанных объектов. Постановка задачи и основные предположения// Автоматика и телемеханика. - 2004. - № 1. - С. 143-158.

- [2] Двоенко С.Д., Копылов А.В., Моттль В.В. Задача распознавания образов в массивах взаимосвязанных объектов. Алгоритм распознавания// Автоматика и телемеханика. - 2005. № 12. - С. 162-176.
- [3] Dvoenko S.D. Recognition of dependent objects based on acyclic Markov models// Pattern Recognition and Image Analysis. - 2012. - V. 22. № 1. Pp. 28-38. DOI: 10.1134/S1054661812010130.
- [4] Geman S., and Geman D., Stochastic Relaxation, Gibbs Distributions, and the Bayesian Restoration of Images. IEEE Trans. on PAMI. **6**: 721–741 (1984).
- [5] Kolmogorov V., Convergent Tree-Reweighted Message Passing for Energy Minimization. IEEE Trans. on PAMI. **10**: 1568–1583 (2006).
- [6] Li S.Z. Markov Random Field Modeling in Image Analysis. London: Springer-Verlag, 2009.
- [7] Schlesinger M.I., and Flach B., Some Solvable Subclasses of Structural Recognition Problems. Proc. of Czech Pattern Recognition Workshop: 55–62 (2000).
- [8] Szeliski R., Zabih R., Scharstein D., Veksler O., Kolmogorov V., Agarwala A., Tappen M., and Rother C., A Comparative Study of Energy Minimization Methods for Markov Random Fields with Smoothness-Based Priors. IEEE Trans. on PAMI. **6**: 1068–1080 (2007).
- [9] Wainwright M.J., and Jordan M.I., Graphical Models, Exponential Families, and Variational Inference. Foundations and Trends in Machine Learning. **1**: 1–305 (2008).
- [10] vision.middlebury.edu/MRF/code/MRF2.1.zip

Об авторах

Сергей Д. Двоенко – профессор Тульского государственного университета. Его адрес: dsd@tsu.tula.ru.
 Шанг Динь Вьет – аспирант Тульского государственного университета. Его адрес: dvietsang@gmail.com.