Math-Net.Ru

Общероссийский математический портал

М. И. Бояркин, И. А. Данилушкин, С. А. Колпащиков, А. А. Миронов, А. С. Рязанов, Возможности кластеризации сложной графической информации в соответствии с топологическими свойствами фазового пространства динамической системы распознавания образов, *Вестн. Сам. гос. техн. ун-та. Сер. Физ.-мат. науки*, 2007, выпуск 2(), 202–204

DOI: <https://doi.org/10.14498/vsgtu563>

Использование Общероссийского математического портала Math-Net.Ru подразумевает, что вы прочитали и согласны с пользовательским соглашением
<http://www.mathnet.ru/rus/agreement>

Параметры загрузки:

IP: 34.229.108.108

26 апреля 2023 г., 17:06:33

УДК 004.93'14

**М. И. Бояркин, И. А. Данилушкин, С. А. Колпащиков, А. А. Миронов, А. С. Рязанов,
А. А. Юдашкин**

ВОЗМОЖНОСТИ КЛАСТЕРИЗАЦИИ СЛОЖНОЙ ГРАФИЧЕСКОЙ ИНФОРМАЦИИ В СООТВЕТСТВИИ С ТОПОЛОГИЧЕСКИМИ СВОЙСТВАМИ ФАЗОВОГО ПРОСТРАНСТВА ДИНАМИЧЕСКОЙ СИСТЕМЫ РАСПОЗНАВАНИЯ ОБРАЗОВ

Описываются практические возможности группировки многомерных данных, используемых в задачах динамического распознавания образов, по признаку их контекстной принадлежности областям притяжения аттракторов системы. Критерии принадлежности вводятся на базе евклидова определения расстояния в подпространстве с неортонормированным базисом.

Задачи кластеризации данных являются достаточно распространёнными в прикладной математике и обработке информации. Кластеризация позволяет осуществить классификацию данных в соответствии с их сущностью, то есть предоставить полный анализ информации вне зависимости от субъективно вводимых критериев. Как известно, кластеризация является достаточно сложной задачей даже для данных небольшой размерности. В задачах распознавания образов размерность данных чрезвычайно высока, в частности, вследствие необходимости работы с растровыми изображениями. В настоящее время существует ряд методик, наиболее популярных в качестве основы распознавания образов. К ним относятся искусственные нейронные сети, SVM и байесовские алгоритмы. Несмотря на относительно успешные применения указанных методик для решения частных задач, до сих пор не удавалось создать эффективной модели, позволяющей накапливать и классифицировать информацию о распознаваемых изображениях аналогично тому, как это делает человек, самостоятельно обучаясь на примерах из окружающей среды и не смешивая их. Основной проблемой здесь является необходимость либо мириться с существенной неопределённостью схем «без учителя», либо пытаться обойти ограничения субъективно вводимых критериев в схемах обучения «с учителем». В данном сообщении рассматривается новая возможность инкрементального накопления необходимой информации для формирования отдельных кластеров, отражающих различный смысл входных данных, для распознавания лиц людей в рассматриваемом случае.

В работе в качестве базовой схемы распознавания используется самоорганизующаяся нейронная сеть Хакена, предложенная в работе [1] и в дальнейшем развитая в [2, 3]. Одно из приложений данной модели рассмотрено в работе [4].

Предъявляемый к распознаванию образ $\mathbf{q}(0)$ является вектором, состоящим из N вещественных чисел. В модели имеется M образов-прототипов $\mathbf{v}_i$ ($i = 1, 2, \dots, M$), имеющих такую же структуру. В процессе распознавания образ может быть представлен в виде линейной комбинации запомненных образов $\mathbf{v}_i$ с коэффициентами мод d_i и некоторого остатка

$$\mathbf{q}(t) = \sum_{i=1}^M d_i(t) \mathbf{v}_i + \boldsymbol{\xi}(t).$$

Данное представление распознаваемого образа позволяет свести распознавание к конкуренции мод, значения которых изменяются во времени, и рассматривать задачу не в фазовом пространстве размерности N , а в пространстве мод размерности M .

После предъявления системе образа, она со временем эволюционирует в одно из устойчивых состояний — узлов в фазовом пространстве мод, соответствующее одному из запомненных образов системы в соответствии с динамикой системы дифференциальных уравнений

$$\dot{\mathbf{d}}_i = \lambda_i \mathbf{d}_i - B \sum_{j \neq i}^M \mathbf{d}_j \mathbf{d}_i \left(\sum_{k=1}^M g_{jk} \mathbf{d}_k \right) - C \sum_{j=1}^M \mathbf{d}_i \mathbf{d}_j \left(\sum_{k=i}^M g_{jk} \mathbf{d}_k \right), \quad (1)$$

где B , C , λ_i — в общем случае неотрицательные настраиваемые параметры; начальные условия определяются следующим образом:

$$\mathbf{d}(0) = \mathbf{A}' \mathbf{q}(0). \quad (2)$$

Здесь $\mathbf{A} = \mathbf{G}^{-1}$, $\mathbf{G} = \mathbf{V}' \mathbf{V}$; $\mathbf{V}$ — матрица $N \times M$, составленная из набора векторов-столбцов $\{\mathbf{v}_1, \mathbf{v}_2, \dots, \mathbf{v}_n\}$.

К сожалению, на практике приходится иметь дело с наборами изображений, представляющих один и тот же объект, но отличающихся друг от друга достаточно существенно для того, чтобы система (1) допустила ошибку. Ликвидация этого недостатка в приложениях, связанных с обработкой больших объёмов информации и их индексации, основана на формировании кластеров [5] из изображений одного и того же объекта и конкуренции между кластерами. Отнесение объекта к кластеру должно происходить с помощью естественного механизма, связанного с топологией пространства, натянутого на векторы образов в ситуации, когда эти векторы не образуют базиса и при этом число их растёт.

В данной работе кластер — это совокупность образов $S = \{c_1, c_2, \dots, c_n\}$, объединённая по субъективному признаку их визуального сходства. Образы, как и выше, представлены вещественнозначными векторами из N компонент. Учитывая свойства евклидовой метрики, считаем, что чем дальше образы друг от друга в пространстве $\mathbb{R}$, тем они менее похожи визуально. Аналогично методу модифицированного правила Хебба, ранее применявшемуся для повышения качества запоминания образов в модели Хопфилда [6], используем разложение некоторого образа $\mathbf{q}$ на уже известную системе часть (образ «Да») и новую составляющую (образ «Нет») в виде $\mathbf{q} = \mathbf{q}_Y + \mathbf{q}_N$. Образ «Да» вектора $\mathbf{q}$ по отношению к набору векторов $\{\mathbf{v}_1, \mathbf{v}_2, \dots, \mathbf{v}_n\}$ — это результат разложения вектора $\mathbf{q}$ по набору векторов $\{\mathbf{v}_1, \mathbf{v}_2, \dots, \mathbf{v}_n\}$, как по базису, вычисляемый по формуле

$$\mathbf{q}_V(\mathbf{q}, V) = V\mathbf{G}^{-1}V'\mathbf{q}.$$

Так как набор векторов $\{\mathbf{v}_1, \mathbf{v}_2, \dots, \mathbf{v}_n\}$ в общем случае не является базисом в пространстве векторного представления образов, то $\mathbf{q}$ не совпадает с образом «Да».

Образ «Нет» вектора $\mathbf{q}$ по отношению к набору векторов $\{\mathbf{v}_1, \mathbf{v}_2, \dots, \mathbf{v}_n\}$ — это вектор, равный разности между $\mathbf{q}$ и «Да», то есть степень «новизны» $\mathbf{q}$ по отношению к введённому набору, и определяемый из формулы

$$\mathbf{q}_N(\mathbf{q}, V) = \mathbf{q} - \mathbf{q}_V(\mathbf{q}, V) = \mathbf{q} - V\mathbf{G}^{-1}V'\mathbf{q}.$$

В зависимости от образов «Да» и «Нет», получившихся в результате такого разложения вектора, представляющего $\mathbf{q}$, принимается решение о включении образа $\mathbf{q}$ в тот или иной кластер C_i . Данная процедура является одним из этапов работы описываемой модели кластеризации и называется первичной кластеризацией. Подгруппа образов, наиболее хорошо линейно аппроксимирующая свойства кластера, в большинстве случаев достаточна для описанной выше процедуры в качестве набора $\{\mathbf{v}_1, \mathbf{v}_2, \dots, \mathbf{v}_n\}$. Данная подгруппа называется ядром кластера. Формирование ядра кластера и последующая корректировка его формы называется рекластеризацией.

Для упрощения работы модели кластеризации матрица $\mathbf{G}$ может быть сформирована на основе инкрементально вычисленных образов V_{ink} при помощи процедуры ортогонализации Грамма—Шмидта для исходной упорядоченной последовательности векторов $\{\mathbf{v}_1, \mathbf{v}_2, \dots, \mathbf{v}_n\}$:

$$\mathbf{V}_{\text{ink}}(\mathbf{V}) = \left\| \mathbf{v}_1 \mathbf{q}_N(\mathbf{v}_2, \mathbf{v}_1) \mathbf{q}_N(\mathbf{v}_3, \left\| \mathbf{v}_1 \mathbf{q}_N(\mathbf{v}_2, \mathbf{v}_1) \right\|) \dots \mathbf{q}_N(\mathbf{v}_n, \left\| \mathbf{v}_1 \mathbf{q}_N(\mathbf{v}_2, \mathbf{v}_1) \dots \mathbf{q}_N(\mathbf{v}_{n-1}, \dots) \right\|) \right\|.$$

Легко убедиться в том, что получающаяся матрица $\mathbf{G}$ становится диагональной, что существенно облегчает вычисление обратной матрицы.

Описанные принципы кластеризации основаны на внутренних топологических свойствах пространства обрабатываемых данных, связаны с их природой и не содержат формально введённых логических критериев.

Модель практически реализована в виде программного обеспечения, реализующего индексацию и распознавание произвольных фотографий людей. Проведены работы по оптимизации модели, уменьшению вычислительной стоимости её работы, улучшению эффективности критериев, применяемых на различных этапах процедуры кластеризации.

Работа выполнена в рамках гранта Президента РФ для государственной поддержки молодых российских учёных МД-9422.2006.9 и гранта РФФИ по проекту 07-08-00401-а.

БИБЛИОГРАФИЧЕСКИЙ СПИСОК

1. *Haken, H.* Synergetic computers and cognition: A top-down approach to neural nets [Text]/ H. Haken. — Springer-Verlag New York, Inc., 1991. — 225 p. — ISBN 0-387-53030-4.
2. *Yudashkin, A.* A topological approach to the pattern classification in neural networks [Text] / A. Yudashkin // Proc. of 1996 IEEE Int. Conf. on Neural Networks (Washington, DC, USA, 3-6 June 1996). — Washington, 1996. — Vol. 3. — P. 1484-1487.

3. Юдашкин, А. А. Бифуркации стационарных решений в синергетической нейронной сети и управление распознаванием образов [Текст] / А. А. Юдашкин // Автоматика и телемеханика. — 1996. — № 11. — С. 139–147.
4. Mobile Biometric Person Identification System on the Basis of Pattern Recognition Software and GSM Cellular Networks [Text] / A. Yudashkin, I. Danilushkin, S. Kolpaschikov and other / eAdoption and the Knowledge Economy: Issues, Applications, Case Studies (Proc. of eChallenges-2004, Vienna, Austria, 2004). — Amsterdam, Berlin, Oxford, Tokyo, Washington: IOS Press, 2004. — Part 1. — P. 102–108.
5. Frigui, H. Clustering and aggregation of relational data with applications to image database categorization [Text] / H. Frigui, C. Hwang, F. Chung—Hoon Rhee // Pattern Recognition. — 2007. — Vol. 40, Issue 11. — P. 3053–3068.
6. Лоскутов, А. Ю. Введение в синергетику [Текст]: Учеб. рук. / А. Ю. Лоскутов, А. С. Михайлов. — М.: Наука, 1990. — 272 с. — ISBN 5–02–014475–4.