

Международная конференция ИОИ-10

Графическая вероятностная модель со скрытыми состояниями на основе главных многообразий

Юлин Сергей Сергеевич

Рыбинский государственный авиационный технический
университет имени П. А. Соловьева

Научный руководитель: канд. тех. наук, профессор Паламарь И. Н.

Греция, о. Крит
2014 г.

Применение графических вероятностных моделей

Классификация временных последовательностей используется при решении задач распознавания:


- речи;
- траекторий рукописного текста (online handwriting);
- движений глаз, жестов рук, движений головы.

Объект классификации:


$$\bar{x} = \{x_1, x_2, \dots, x_t, \dots, x_T\}, x_t \in \mathcal{R}^d,$$

где T – длина последовательности,


d – размерность пространства признаков.



a)



b)



c)


a) <http://www.wagner.com/technologies/voice-speech/noisyvoice2.gif>, b) <https://kaggle2.blob.core.windows.net/competitions/kaggle/3385/media/stroke.png>, c) <http://www.hci.iis.u-tokyo.ac.jp/assets/images/research/tracking-fingertips1.jpg>

Скрытая Марковская Модель

Для моделирования временных последовательностей вводят дополнительную случайную дискретную величину h (скрытое состояние), которая позволяет учитывать в модели изменение анализируемой последовательности во времени.


Совместное распределение случайных величин модели:

$$p(\bar{h}, \bar{x}) = \prod_{t=1}^T p(h_t | h_{t-1}) p(x_t | h_t)$$



Графическое представление Скрытой Марковской Модели (C – количество классов)

Недостатки Скрытой Марковской Модели



Недостатки Скрытой Марковской Модели (*Hidden Markov Model* - HMM):

- необходимость выбора формы плотности вероятности $f_h(x)$;
- необходимость отсутствия зависимостей в компонентах вектора признаков (в случае гауссовской плотности вероятности **наличие линейной зависимости между компонентами приводит к вырожденности матрицы ковариации** $|\Sigma| = 0$). Плотность гауссовского многомерного распределения:

$$f_h(x) = \frac{1}{(2\pi)^{d/2} |\Sigma|^{1/2}} e^{-\frac{1}{2}(x-\mu)^\top \Sigma^{-1}(x-\mu)}, \quad x, \mu \in \mathcal{R}^d$$

Недостатки Скрытой Марковской Модели были устранены в дискриминантной модели "Условные случайные поля со скрытыми состояниями" (*Hidden Conditional Random Fields - HCRF*), предложенной *A. Gunawardana et al.* в 2005 году в работе "*Hidden conditional random fields for phone classification*"

Недостатки HCRF:

- целевая функция оптимизации не является выпуклой;
- дискриминантной модели необходимо больше обучающих данных чем порождающей модели для достижения своей асимптотически минимальной ошибки классификации (*Andrew Ng, Michael Jordan "On Discriminative vs. Generative Classifiers: A comparison of logistic regression and Naive Bayes"*, 2002)

Цель: разработать порождающую графическую модель дающую хорошее качество классификации при малом количестве обучающих данных и не требующую оценки параметров плотности вероятности.

Связь минимизации эмпирического риска и максимизации правдоподобия

Максимизация правдоподобия (MLE):

$$L(X | \Sigma, \mu) = \sum_{i=1}^n \ln f(x_i | \Sigma, \mu) \rightarrow \max_{\Sigma, \mu}$$

где n – размер обучающей выборки;

X – обучающая выборка;

Σ, μ – параметры модели.

Минимизация эмпирического риска (ERM):

$$Q(X, W) = \sum_{i=1}^n E(x_i, W) \rightarrow \min_W$$

где W – параметры модели.

Эквивалентность MLE и ERM

$$-\ln f(x_i | \Sigma, \mu) = E(x_i, W)$$


Для каждого $k = 0, 1, \dots, d - 1$ среди всех k -мерных нелинейных многообразий в \mathcal{R}^d найти такое $M_k \subset \mathcal{R}^d$, что сумма квадратов уклонений $x_i, i = 1 \dots n$ от M_k минимальна:

$$Q(X, M_k) = \sum_{i=1}^n \text{dist}^2(x_i, M_k) \rightarrow \min_{M_k}.$$


Задача построения такого многообразия трудоемка, поэтому строят его точечную аппроксимацию такими алгоритмами как **самоорганизующиеся карты Кохонена**, **упругие карты**, **алгоритм растущего "нейронного газа"** и другими:

$$Q(X, W) = \sum_{i=1}^n \sum_{j=1}^k \|x_i - w_j\|_2^2 \rightarrow \min_W,$$

где w_j — значение j -ого узла сетки в \mathcal{R}^d , $w_j \in M_k$; k — количество узлов в сетке.



Аппроксимация нелинейным многообразием^{a)}



Аппроксимация нелинейным многообразием в виде сетки узлов
a) <http://wissrech.ins.uni-bonn.de/research/pub/feuersaenger/mani.pdf>

Предлагаемая модель (NPM-PGM): описание


Основываясь на том, что:

- MLE эквивалентно ERM: $-\ln f(x_i | \Sigma, \mu) = E(x_i, W)$;
- номер узла аппроксимирующей сетки соответствует номеру скрытого состояния, т.е. $h = \{1, \dots, k\}$

получим, что совместное распределение случайных величин модели NPM-PGM:

$$p(\bar{h}, \bar{x}) = \prod_{t=1}^T p(h_t | h_{t-1}) \Psi(x_t, h_t)$$

$$\Psi(x_t, h_t) = \frac{\exp(-\|x_t - w_{h_t}\|_2^2)}{\sum_{j=1}^k \exp(-\|x_t - w_j\|_2^2)}, \quad p(h_t | h_{t-1}) = \frac{a_{h_t, h_{t-1}}}{\sum_{j=1}^k a_{h_t, j}}$$



Графическое представление модели NPM-PGM (C – количество классов)

Оптимизация функции:

$$L(\bar{h}, \bar{x} \mid W, A) = \sum_{l=1}^n \ln \prod_{t=1}^T p(h_t \mid h_{t-1}) \Psi(x_t^{(l)}, h_t) \rightarrow \max_{W, A},$$

где W – множество значений узлов сетки,

A – матрица вероятностей переходов между узлами сетки,

сводится к оптимизации:

$$\sum_{l=1}^n \sum_{j=1}^k \|x^{(l)} - w_j\|_2^2 \rightarrow \min_W,$$

и вычислению:

$$a_{i,j} = \begin{cases} a_{i,j} + 1, & \text{если } i = h_t = \arg \min \|x_t - w_i\|_2^2 \text{ и} \\ & j = h_{t-1} = \arg \min \|x_{t-1} - w_j\|_2^2 \\ 0, & \text{в противном случае} \end{cases}$$

Вычисление правдоподобия выполняется **алгоритмом ”прямого-обратного”** хода (Р. Л. Стратонович, 1960), также как в моделях НММ и HCRF). Временная сложность алгоритма – $O(k^2T)$.

Так как количество узлов аппроксимирующей сетки k может быть довольно велико, то для ускорения процесса вычисления можно воспользоваться алгоритмами сэмплирования:

- алгоритм Метрополиса-Гастингса;
- сэмплирование по Гиббсу.

UCI: Spoken Arabic Digit Data Set

- *Описание*: слова, произнесенные на арабском языке
- *Количество классов*: 10
- *Размерность пространства признаков*: 13
- *Количество экземпляров каждого класса*: 880
- *Источник*: <http://archive.ics.uci.edu/ml/datasets/Spoken+Arabic+Digit>

UCI: Character Trajectories Data Set

- *Описание*: траектории рукописных букв английского алфавита
- *Количество классов*: 20
- *Размерность пространства признаков*: 3
- *Количество экземпляров каждого класса*: 100
- *Источник*: <http://archive.ics.uci.edu/ml/datasets/Character+Trajectories>

Размер обучающей выборки: 90 экземпляров каждого класса

- UCI: Spoken Arabic Digit Data Set

Model	HMM(1 mix)	HMM(16 mix)	HCRF(BFGS)	HCRF(CG)	NPM-PGM
States	5	5	5	5	1024
F-score	0.6018	0.5374	0.6420	0,6274	0.8043

- UCI: Character Trajectories Data Set

Model	HMM(1 mix)	HMM(16 mix)	HCRF(BFGS)	HCRF(CG)	NPM-PGM
States	7	7	7	7	256
F-score	0.9329	0.9288	0.9651	0.9516	0.9809

Размер обучающей выборки: 800 экземпляров каждого класса

- UCI: Spoken Arabic Digit Data Set

Model	HMM(1 mix)	HMM(16 mix)	HCRF(BFGS)	HCRF(CG)	NPM-PGM
States	5	5	5	5	1024
F-score	0.8778	0.8368	0.9525	0.9344	0.9349

Достоинства предлагаемой модели NPM-PGM:

- лучший показатель F-score чем у HMM на всех тестах;
- лучший показатель F-score чем у HCRF при малом количестве обучающих данных.

Недостатки предлагаемой модели NPM-PGM:

- сложность выбора оптимального количества узлов аппроксимирующей сетки k , дающего наилучшее качество классификации;
- большое количество скрытых состояний k , что сказывается на времени выполнения классификации (временная сложность алгоритма ”прямого-обратного”хода – $O(k^2 T)$).