

Краткий обзор приложения метода условных случайных полей в области распознавания речи

Леднов Д.А., кандидат технических наук

Цель этой работы — обзор математических основ модели условных случайных полей, а также идеологическое сравнение этой модели с другими известными направлениями обработки речи.

- условные случайные поля
- скрытые модели Маркова
- модель Байеса
- модель максимума энтропии

This paper is aimed to survey conditional random fields mathematical bases and to compare them with other direction of speech processing.

- conditional random fields
- hidden Markov's models
- Byres' model
- model maximum entropy

Введение

Последние десять лет в области распознавания речи развивается направление, которое может стать, с одной стороны, достойной альтернативой скрытым марковским моделям (СММ), а с другой стороны, включить в себя все преимущества СММ. Это направление известно как модель условных случайных полей. Цель этой работы состоит в том, чтобы показать математические основы этого направления и идеологически сравнить его с другими направлениями обработки речи. Здесь приводится сравнение метода условных случайных полей с методом Байеса, скрытыми марковскими моделями и методом максимальной энтропии. В качестве базовых работ этого обзора выбраны работы [6,7].




Рис. 1. Классификация статистических моделей в области классификации паттернов. На рисунке использованы английские аббревиатуры — NB — Nave Bayes, HMM — hidden Markov's Models, ME — Maximum Entropy Model, CRF — Conditional Random Field

Модель Байеса

Модель Байеса связана с тем, что в процессе моделирования необходимо построить представление условной вероятности $p(Y|X)$ с входным вектором наблюдений $X = (x_1, x_2, \dots, x_m)$ и условно зависимой Y переменной класса, подлежащей определению. Эта условная вероятность может быть представлена с помощью правила Байеса:

$$p(Y|X) = \frac{p(X|Y)p(Y)}{p(X)}.$$

Делитель $p(X)$ не важен для классификации и может быть интерпретирован как нормализационная константа. Числитель – это совместная вероятность $p(X|Y)p(Y) = p(Y, X)$.

Общая декомпозиция этой вероятности может быть выполнена с помощью формулы полной вероятности:

$$p(Y, X) = p(Y) p(Y | x_1) \prod_{i=2}^m p(x_i | x_{i-1}, \dots, x_1, Y)$$

На практике часто допускается, что входные переменные условно независимы. Это допущение известно, как предположение Байеса. На основе этого предположения получим:

$$p(Y, X) = p(Y) \prod_{i=1}^m p(x_i | Y).$$

Последнее выражение равносильно высказыванию, что совместная вероятность появления вектора наблюдения и класса пропорциональна произведению вероятностей того, что определённое значение каждой компоненты вектора наблюдений порождается переменной класса.

Скрытая модель Маркова

Модель Байеса допускает, что весь вектор наблюдения принадлежит единственному классу. В модели Маркова, в отличие от модели Байеса, дана последовательность наблюдений, и поэтому необходимо идентифицировать последовательность классов:

$$p(Y, X) = \prod_{i=1}^m p(y_i) p(x_i | y_i)$$

$$p(Y, X) = p(y_1) p(x_1 | y_1) \prod_{i=2}^m p(y_i | y_{i-1}) p(x_i | y_i).$$

По сравнению с моделью Байеса вводится условная зависимость между классами — переходная вероятность, которая определяет зависимость между классами в цепи. Как и в случае модели Байеса, в качестве характеристики модели выступает совместная вероятность (см. рис. 1).

Модель максимума энтропии

В работе [1] было введено понятие условной энтропии:

$$H(Y|X) = - \sum_{(X,Y) \in Z} p(Y,X) \log p(Y|X),$$

где множество $Z = X \times Y$, которое нашло практическое приложение в работах [2,3] для задач идентификации классов.

Базовая идея максимальной энтропии — найти такую модель $p^*(X|Y)$, которая делает энтропию максимальной на обучающих данных, т.е.

$$p^*(Y|X) = \operatorname{argmax}_{p(Y|X) \in P} H(Y|X),$$

где P — множество всех моделей, содержащихся в обучающих данных.

Введём некоторые функции случайных переменных $f_i(X,Y)$. По сути, функции $f_i(X,Y)$ определяют некоторые известные нам связи между случайными величинами. Математические ожидания этих функций можно рассчитать двумя способами: с одной стороны, можно предположить, что известна эмпирическая оценка совместной вероятности $\hat{p}(Y, X)$, и тогда справедливо:

$$\tilde{E}(f_i) = \sum_{(X,Y) \in Z} \hat{p}(Y, X) f_i(Y, X), \quad (1)$$

а с другой стороны, можно предположить, что известна сама совместная вероятность, и тогда справедливо:

$$E(f_i) = \sum_{(X,Y) \in Z} p(Y, X) f_i(Y, X) = \sum_{(X,Y) \in Z} \hat{p}(X) p(Y|X) f_i(Y, X), \quad (2)$$

где $\hat{p}(X)$ — эмпирическая оценка случайной величины X . Очевидно, что в лучшем случае эти два математических ожидания должны быть равны друг другу.

Ещё надо отметить, что выполняется нормальное статистическое условие $\sum_Y p(Y|X) = 1$, где суммирование ведётся по всему пространству переменных Y .

Всё сказанное выше означает, что для поиска модели $p^*(Y|X)$ мы можем поставить задачу

$$\Lambda(p, \lambda) = H(Y|X) + \sum_{i=1}^m \lambda_i (\tilde{E}(f_i) - E(f_i)) + \lambda_{m+1} \left(\sum_Y p(Y|X) - 1 \right). \quad (3)$$

оптимизации с неопределёнными коэффициентами Лагранжа:

$$H(Y|X) = - \sum_{(X,Y) \in Z} \hat{p}(X) p(Y|X) \log p(Y|X),$$

Аппроксимируем выражение для энтропии:

$$\frac{\partial}{\partial p(Y|X)} H(Y|X) = -\hat{p}(X)(1 + \log p(Y|X)),$$

$$\frac{\partial}{\partial p(Y|X)} \sum_{i=1}^m \lambda_i (\tilde{E}(f_i) - E(f_i)) = \sum_{i=1}^m \lambda_i \hat{p}(X) f_i(Y, X)$$



и проведём дифференцирование всех членов функционала (3):

$$\frac{\partial}{\partial p(Y|X)} \Lambda(p, \lambda) = -\hat{p}(X)(1 + \log p(Y|X)) + \sum_{i=1}^m \lambda_i \hat{p}(X) f_i(Y, X) + \lambda_{m+1} = 0.$$

Тогда

$$p(Y|X) = \exp\left(\sum_{i=1}^m \lambda_i f_i(Y, X)\right) \exp\left(\frac{\lambda_{m+1}}{\hat{p}(X)} - 1\right),$$

Если провести экспоненцирование последнего выражения, то получим:

$$p(Y|X) = \frac{\exp(\sum_{i=1}^m \lambda_i f_i(Y, X))}{\sum_Y \exp(\sum_{i=1}^m \lambda_i f_i(Y, X))} \quad (4)$$

и, учитывая нормальное статистическое условие, окончательно найдём оптимальную модель, максимизирующую условную энтропию:

Модель максимума энтропии, как и модель Байеса, предназначена для идентификации одного класса и для этой идентификации используется условная вероятность (см. рис. 1). Модель условных случайных полей является расширением модели максимума энтропии в условиях описания последовательности наблюдений, как последовательности классов.

Графическое представление

Отвлечёмся от изложения статистических моделей идентификации классов и их последовательностей и рассмотрим графическое представление совместной вероятности, которое предложил Бишоп в работе [3].

$$p(\vartheta) = \prod \Psi_s(\vartheta_s),$$

Допустим, что совместную плотность распределения вероятностей множества случайных величин можно факторизовать, т.е. представить в виде: где $\Psi_s(\vartheta_s)$ — факторы. Пусть, например совместную вероятность $p(x, y, z)$ можно представить в виде $p(x, y, z) = p(x)p(y)p(z|x, y)$, тогда все вероятности в правой части формулы есть факторы. На рис. 2 показано графическое представление этой факторизации $\psi_1 = p(x)$, $\psi_2 = p(y)$, $\psi_3 = p(z|x, y)$.

В таком графическом представлении можно представить скрытую модель Маркова (см. рис. 3).




Рис.2.Графическое представление факторизации совместной вероятности $p(x,y,z)=p(x)p(y)p(z|x,y)$




Рис. 3. Графическое представление факторизации модели Маркова

Условные случайные поля

Понятие условного случайного поля введено Лафферти в работе [4].

$$p(Y|X) = \frac{p(Y, X)}{P(X)} = \frac{p(Y, X)}{\sum_{Y'} p(Y', X)} = \frac{\prod_c \psi_c(Y, X)}{\sum_{Y'} \prod_c \psi_c(Y', X)}$$

где $\psi(Y, X)$ — некоторая возможная факторизация условной вероятности $p(Y, X)$. Таким образом, удалось выразить условную вероятность через факторизацию совместной вероятности:

$$p(Y|X) = \frac{1}{Z} \prod_c \psi_c(Y, X), \quad Z = \sum_Y \prod_c \psi_c(Y, X).$$

Рассмотрим важное понятие в области условных случайных полей — это линейная цепь, структура которой показана на *рис. 4*.




Рис. 4. Графическое представление факторизации линейной цепи условного случайного поля

Условное случайное поле линейной цепи можно записать в виде:

$$p(Y|X) = \frac{1}{Z(X)} \prod_{j=1}^n \psi_j(Y, X), \quad \text{где } Z(X) = \sum_Y \prod_{j=1}^n \psi_j(Y, X)$$

и на основании (4) факторы имеет форму:

$$\psi_j(Y, X) = \exp\left(\sum_{i=1}^m \lambda_i f_i(y_{j-1}, y_j, X, j)\right)$$

Предполагая, что длина последовательности наблюдения равна $n+1$, то для условной вероятности справедливо:

$$p(Y|X) = \frac{1}{Z(X)} \exp\left(\sum_{j=1}^n \sum_{i=1}^m \lambda_i f_i(y_{j-1}, y_j, X, j)\right),$$

где

$$Z(X) = \sum_Y \exp\left(\sum_{j=1}^n \sum_{i=1}^m \lambda_i f_i(y_{j-1}, y_j, X, j)\right).$$

В последнем выражении суммирование по Y означает суммирование по всевозможным последовательностям Y .



Процесс обучения линейной цепи состоит в максимизации логарифмического правдоподобия по всем путям, наблюдающимся в обучающих данных.

$$L = \sum_{(X,Y) \in Tr} \log p(Y|X) = \sum_{(X,Y) \in Tr} \log \left(\frac{\exp(\sum_{j=1}^n \sum_{i=1}^m \lambda_i f_i(y_{j-1}, y_j, X, j))}{\sum_Y \exp(\sum_{j=1}^n \sum_{i=1}^m \lambda_i f_i(y_{j-1}, y_j, X, j))} \right) - \sum_{i=1}^m \frac{\lambda_i^2}{2\sigma^2}$$

Последний член функционала позволяет ограничить решения лишь теми, которые находятся на гиперсфере радиусом $\sqrt{2\sigma^2}$.

Продифференцируем последний функционал по λ_k :

$$\frac{\partial}{\partial \lambda_k} L = \sum_{(X,Y) \in Tr} \sum_{j=1}^n f_k(y_{j-1}, y_j, X, j) - \sum_{(X,Y) \in Tr} \sum_Y p(Y|X) \sum_{j=1}^n f_k(y_{j-1}, y_j, X, j) - \frac{\lambda_k}{\sigma^2} = 0$$

В предпоследнем слагаемом сначала проводится суммирование по всевозможным последовательностям Y , это означает, что второе суммирование проводится только по последовательностям X , которые входят в обучающую базу.

Последнее выражение равносильно:

$$\frac{\partial}{\partial \lambda_k} L = \hat{E}(f_k) - E(f_k) - \frac{\lambda_k}{\sigma^2} = 0 \quad (5)$$

Вычисление параметра λ_k , как уже было сказано выше, связано с интегрированием значений функций f_k и экспериментально полученных оценок распределений (1). Для вычисления λ_k используется известный алгоритм прямого и обратного хода [8], где прямую переменную можно записать в форме:

$$\alpha_j(s|X) = \sum_{s1 \in T_j^{-1}(s)} \alpha_{j-1}(s1|X) \psi_j(X, s1, s),$$

и обратную переменную в форме:

$$\beta_j(s|X) = \sum_{s1 \in T_j(s)} \beta_{j+1}(s1|X) \psi_j(X, s1, s),$$

где

$$\psi_j(X, s1, s) = \exp \left(\sum_{j=1}^n \sum_{i=1}^m \lambda_i f_i(s, s1, X, j) \right),$$

приведут к новой форме записи:

$$E(f_k) = \sum_{(X,Y) \in Tr} \frac{1}{Z(X)} \sum_{j=1}^n \sum_{s \in S} \sum_{s1 \in T_j(s)} f_k(s, s1, X, j) \alpha_j(s|X) \psi_j(X, s, s1) \beta_{j+1}(s1|X),$$

где $Z(X) = \sum_{s \in S} \beta_0(s|X)$ — нормализующий фактор.

Таким образом, подставляя последнее выражение в (5), мы получим окончательную формулу для неизвестных коэффициентов λ_k :

Заключительная важная часть построения модели условного случайного поля состоит в том, чтобы найти наилучшую последовательность Y при заданной последовательности наблюдений X . Для решения этой проблемы используется известный алгоритм Витерби [8], который состоит в поиске максимума условной вероятности:

$$\delta_j(s|X) = \max_{y_1, y_2, \dots, y_j = s|X} p(y_1, y_2, \dots, y_j = s|X),$$

по различным последовательностям имён классов.

Эту процедуру можно представить итеративно для значения текущей вероятности

$$\delta_{j+1}(s|X) = \max_{s1 \in S} \delta_j(s1|X) \psi_{j+1}(X, s, s1),$$

максимум которой в последний момент времени определит искомую условную вероятность наиболее вероятной последовательности классов:

$$p^* = \max_{s \in S} \delta_n(s|X)$$

и индекс класса, в котором заканчивается наиболее вероятная траектория:

$$y^* = \operatorname{argmax}_{s \in S} \delta_n(s|X).$$

В заключение приведём пример [5], который покажет соответствие между параметрами скрытой модели Маркова и модели условных случайных полей.

Наша цель состоит в том, чтобы конвертировать параметры выражений стоящих в правой и левой части равенства:

$$\prod_{t=1}^T p(y_t|y_{t-1})p(x_t|y_t) = \prod_{t=1}^T \exp(w_t f(t, y_t, y_{t-1}, X) + v_t g(t, y_t, x_t, X)) \quad (6)$$

Представим себе, что первая часть суммы в степени экспоненты соответствует переходной вероятности $p(y_t|y_{t-1})$. Введём функции индикаторы, с помощью которых функцию $f(t, y_t, y_{t-1}, X)$ запишем в форме:

$$f_{ij}(t, y_t, y_{t-1}, X) = I(y_t = i)I(y_{t-1} = j).$$

Индикаторная функция такова, что если условие внутри скобок — истинно, то она равна единице, и нулю в — противном случае.

Это представление позволяет соотнести переходную вероятность в левой части уравнения (6) и экспоненту в правой части уравнения (6) в каждый момент времени, в которые процесс переходит из состояния j в состояние i :

$$\exp(w_{ij} f_{ij}) = p(y_t = i|y_{t-1} = j),$$

откуда следует:

$$w_{ij} = \log(p(y_t = i|y_{t-1} = j)).$$



Аналогично можно представить с помощью коэффициентов экспонент параметра распределения вероятностей $p(x_t|y_t)$, если допустить, что оно является нормальным:

$$\exp(v_t g(t, y_t = i, x_t, X)) = \frac{1}{\sqrt{2\pi\sigma}} \exp\left\{-\frac{(x - \mu)^2}{2\sigma^2}\right\},$$

тогда

$$v_t g(t, y_t = i, x_t, X) = -\frac{1}{2\sigma^2} x^2 + \frac{\mu}{\sigma} x - \left(\frac{\mu^2}{2\sigma^2} + \log(\sqrt{\pi\sigma^2})\right),$$

и функции можно представить в виде:

$$\begin{aligned} g_{0i} &= I(y_t = i), \\ g_{1i} &= I(y_t = i) x_t, \\ g_{2i} &= I(y_t = i) x_t^2. \end{aligned}$$

Как видно из приведённого примера, в простейших случаях весьма просто сопоставить параметры различных вероятностных моделей, но уже небольшое усложнение приводит к значительным вычислительным трудностям.

Мы можем это наблюдать уже в том случае, когда попытаемся представить распределение вероятностей $p(x_t|y_t)$, как смесь нормальных распределений.

Литература

1. Jaynes E.T.: Information Theory and Statistical Mechanics. In: Physical Review 106 (1957), May, No. 4, P. 620-630.
2. Korn G.A., Korn T.M. Mathematical Handbook for Scientists and Engineers: Definitions, Theorems, and Formulas for Reference and Review. 2 Revised. New York: Dover Publications Inc., 2000.
3. Bishop C.M. Pattern Recognition and Machine Learning. Springer, 2006.
4. Lafferty J.D.; McCallum A.; Pereira F. C. N. Conditional Random Fields: Probabilistic Models for Segmenting and Labeling Sequence Data. In: Proceedings of the Eighteenth International Conference on Machine Learning (ICML 2001), Morgan Kaufmann Publishers, 2001, P. 282–289.
5. Douglas L. V., C. Guestrin. Conditional random fields for activity recognition // In Proceedings of the Sixth International Joint Conference on Autonomous Agents and Multiagent Systems (AAMAS 2007).
6. Klinger R., Tomanek K. Classical Probabilistic Models and Conditional Random Fields// Algorithm Engineering Report TR07–2-013 December, 2007.
7. C. Sutton and A. McCallum. An introduction to conditional random fields for relational learning. In L. Getoor and B. Taskar, editors, Introduction to Statistical Relational Learning. MIT Press, 2006.
8. Jeff A. Bilmes A. Gentle Tutorial of the EM algorithm and its Application to Parameter Estimation for Gaussian Mixture and Hidden Markov Models// ICSI-TR-97–021, April 1998.

Сведения об авторе

Леднов Дмитрий Анатольевич,

кандидат технических наук, старший научный сотрудник, научный консультант научно-технического департамента ООО «Стэл — Компьютерные Системы», основные научные интересы лежат в областях: моделей обработки данных, случайных процессов, распознавания речи и идентификации дикторов.