

## МЕТОДЫ ПОСТРОЕНИЯ БАЙЕСОВСКИХ СЕТЕЙ НА ОСНОВЕ ОЦЕНОЧНЫХ ФУНКЦИЙ

**Ключевые слова:** байесовская сеть, оценочные методы поиска, вычислительные характеристики, минимальная длина описания.

### ВВЕДЕНИЕ

Во всех странах мира накапливаются большие объемы информации, требующие надлежащей обработки и принятия решений на основе результатов этой обработки. Методы интеллектуального анализа данных (ИАД), к которым принадлежат и байесовские сети (БС), предоставляют возможность автоматического поиска закономерностей, характерных для многомерных данных. В основе большинства инструментов интеллектуального анализа данных лежат две технологии: машинное обучение и визуализация информации. Байесовские сети объединяют в себе эти две технологии.

Широкое применение БС нашли в медицинской и технической диагностике в условиях неполной и неточной информации, в системах классификации данных различной природы, системах автоматического распознавания речевых сигналов, маркетинге, бизнесе и во многих других сферах деятельности. В общем случае БС дает возможность воспроизвести причинно-следственные связи между событиями и определить вероятность наступления той или иной ситуации при получении новой информации относительно изменения состояния любого узла (переменной) сети. Степень целесообразности применения данного метода моделирования и формирования вероятностного вывода зависит от умения корректно осуществить постановку задачи, выбрать переменные процесса, которые в достаточной мере характеризуют его динамику или статику, найти необходимые данные и использовать их для обучения сети, а также корректно сформулировать результат-вывод с помощью построенной сети.

В англоязычной литературе термин «построение БС» означает реализацию следующих процессов: 1) поиск оптимальной структуры БС, т.е. направленного ациклического графа, наиболее адекватно соответствующего обучающим данным или исследуемому процессу; 2) вычисление значений таблиц условных вероятностей БС для соответствующих узлов этого графа.

Цель настоящей статьи — анализ существующих методов решения задачи выбора оптимальной структуры байесовской сети, описание заложенных в них принципов и практического использования.

### ФОРМАЛЬНАЯ МАТЕМАТИЧЕСКАЯ ЗАПИСЬ БС

Байесовская сеть — это графическая модель процесса или объекта произвольной природы, представленная парой  $\langle G, B \rangle$ . Первой компонентой  $G$  является направленный ациклический граф, соответствующий случайным переменным объекта или процесса. Он записывается как набор условий независимости: каждая переменная не зависит от ее родителей в  $G$ . Вторая компонента пары  $B$  представляет множество параметров, определяющих сеть. Эта компонента содержит параметры  $\Theta_{x^{(i)} | pa(X^i)} = P(X^{(i)} | pa(X^{(i)}))$  для каждого возможного

значения  $x^{(i)} \in X^{(i)}$  и  $pa(X^{(i)}) \in Pa(X^{(i)})$ , где  $Pa(X^{(i)})$  означает набор родителей переменной  $X^{(i)} \in G$ . Каждая переменная  $X^{(i)} \in G$  представляется в виде вершины. Если рассматривают более одного графа, то для определения родителей переменной  $X^{(i)}$  в графе  $G$  используют обозначение  $Pa^G(X^{(i)})$ . Полная совместная вероятность БС вычисляется по формуле

$$P_B(X^{(1)}, \dots, X^{(N)}) = \prod_{i=1}^N P_B(X^{(i)} | Pa(X^{(i)})).$$

Множество обучающих данных записывается следующим образом:  $D = \{d_1, \dots, d_n\}$ ,  $d_i = \{x_i^{(1)}, x_i^{(2)}, \dots, x_i^{(N)}\}$ . Здесь нижний индекс — это номер наблюдения, а верхний — номер переменной;  $n$  — количество наблюдений, каждое из которых состоит из  $N$  ( $N \geq 2$ ) переменных  $X^{(1)}, X^{(2)}, \dots, X^{(N)}$ . Каждая  $j$ -я переменная ( $j=1, \dots, N$ ) имеет  $A^{(j)} = \{0, 1, \dots, \alpha^{(j)} - 1\}$  ( $\alpha^{(j)} \geq 2$ ) состояний, а каждая структура  $g \in G$  БС представляется  $N$  множествами предков ( $\Pi^{(1)}, \dots, \Pi^{(N)}$ ). Иными словами, для каждой вершины  $j=1, \dots, N$  множество  $\Pi^{(j)}$  — набор родительских вершин таких, что  $\Pi^{(j)} \subseteq \{X^{(1)}, \dots, X^{(N)}\} \setminus \{X^j\}$  (вершина не может быть предком самой себе, т. е. петли в графе отсутствуют).

#### ГРАФИЧЕСКОЕ ОТОБРАЖЕНИЕ СТРУКТУРЫ БС

Дерево — такая структура БС, в которой любая вершина может иметь не более одной вершины-предка (рис. 1).

Поли-дерево — такая структура БС, в которой любая вершина может иметь более одной вершины-предка, но при этом между любыми двумя вершинами должно быть не более одного связывающего их пути (рис. 2).

Сети — сетевая структура, в которой любая вершина может иметь более чем одну вершину-предка; при этом между любыми двумя вершинами может быть более одного связывающего их пути (рис. 3).




Рис. 1. Структура БС в виде дерева




Рис. 2. Структура БС в виде поли-дерева




Рис. 3. Структура БС в виде сети

Деревья и поли-деревья называют также односвязными сетями, а сети — многосвязными сетями.

#### АЛГОРИТМЫ ПОСТРОЕНИЯ СТРУКТУРЫ СЕТЕЙ БАЙЕСА

Чу и Лиу (Chow and Liu) в 1968 г. предложили алгоритм для построения БС в виде дерева [1], основанный на использовании значений обоюдной информации между вершинами. В качестве решения метод выдает структуру БС со значением совместного распределения вероятности, наиболее соответствующе-

го обучающим данным. Построение структуры БС осуществляется за  $O(N^2)$  шагов, где  $N$  — число вершин сети, однако этот алгоритм не применим для многосвязных БС.

В 1988 г. Рибан и Перл (Rebane and Pearl) предложили усовершенствованный измененный алгоритм Чу и Лиу для построения БС в виде поли-дерева [2]. Купер и Гершкович (Cooper and Herskovits) в 1990 г. разработали алгоритм Кутато (Kutato) [3]. На этапе инициализации алгоритма с учетом, что все вершины БС независимы, вычисляется энтропия этой сети. Затем происходит добавление дуг между вершинами в сети таким образом, чтобы минимизировать энтропию БС. Для работы алгоритма требуется наличие упорядоченного множества вершин.

Алгоритм SGS [4], предложенный в 1991 г., при построении структуры обходится без упорядоченного множества вершин, но вместо этого ему приходится выполнять экспоненциальное количество тестов на условную независимость между вершинами. Купер и Гершкович в 1992 г. предложили широко известный алгоритм K2 [5], который выполняет поиск структуры с максимальным значением функции Купера–Гершковича (КГ). Для работы алгоритма требуется наличие упорядоченного множества вершин.

Алгоритм Лема–Бахуса (Lam–Bacchus) [6], предложенный в 1996 г., выполняет эвристическое построение структуры сети, используя обоюдную информацию между вершинами, а в качестве оценочной функции применяется описание минимальной длины (ОМД).

Алгоритм Бенедикта (Benedict) [7], предложенный в 1996 г., выполняет эвристический поиск на основе упорядоченного множества вершин, анализируя условные независимости в структуре сети на основе  $d$ -разделения, а в качестве оценочной функции используется энтропия.

Алгоритм СВ [8] предложен в 1995 г. Он использует тест на условную независимость между вершинами сети для построения упорядоченного множества вершин. При построении структуры сети используется функция КГ.

Алгоритм Фридмана–Голдшмидта (Friedman–Goldszmidt) [9] предложен в 1996 г. При построении сети применяется анализ ее локальных подструктур, а в качестве оценочных функций используются ОМД и оценка Байеса.

В алгоритме WKD [10], предложенном в 1996 г., в качестве оценочной функции при построении сети используется функция сообщения минимальной длины, которая имеет сходство с ОМД.

Алгоритм Сузуки (Suzuki) [11], предложенный в 1999 г., основан на методе ветвей и границ для задания последовательности построения структуры сети, а в качестве оценочной функции используется ОМД.

#### ФУНКЦИЯ КУПЕР–ГЕРШКОВИЧА

В работе [5] Купер и Гершкович предложили метод КГ для обучения БС, который основан на поиске структуры БС с максимальным значением функции КГ. Функция КГ структуры  $g \in G$  при заданной последовательности из  $n$  наблюдений  $x^n = d_1 d_2 \dots d_n$  записывается уравнением

$$P(g, x^n) = P(g) \cdot \prod_{j \in J} \left( \prod_{s \in S(j, g)} \frac{(\alpha^{(j)} - 1)! \cdot \prod_{q \in A^{(j)}} (n[q, s, j, g]!)!}{(n[s, j, g] + \alpha^{(j)} - 1)!} \right).$$

Здесь  $P(g)$  — априорная вероятность структуры  $g \in G$ , которую часто опуска-

ют при вычислениях; запись  $j \in J = \{1, \dots, N\}$  означает перебор всех вершин структуры сети  $g$ , а  $s \in S(j, g)$  — перебор множества всех наборов значений, принимаемых предками  $j$ -й вершины;

$$n(s, j, g) = \sum_{i=1}^n I(\pi_i^{(j)} = s); \quad n[q, s, j, g] = \sum_{i=1}^n I(x_i = q, \pi_i^{(j)} = s),$$

где  $\pi^{(j)} = \Pi^{(j)}$ , функция  $I(E) = 1$ , когда предикат  $E = \text{true}$ , в противном случае  $I(E) = 0$ .

Алгоритм обучения БС с использованием функции КГ основан на циклическом переборе всех возможных ациклических сетевых структур. В  $g^*$  сохраняется оптимальная сетевая структура. Оптимальной структурой будет та, которая имеет наибольшее значение функции  $P(g, x^n)$ :

- 1)  $g^* \leftarrow g_0 (\in G)$ ;
- 2)  $\forall g \in G - \{g_0\}$ : если  $P(g, x^n) > P(g^*, x^n)$ , то  $g^* \leftarrow g$ ;
- 3) на выходе имеем  $g^*$  в качестве решения.

Однако при использовании функции КГ необходимо учитывать вычислительные ограничения моделирующих систем, связанные с конечной длиной разрядной сетки. Приведем тривиальный пример, когда в структуре имеются две вершины:  $X^{(1)}$  и  $X^{(2)}$ , а множество обучающих примеров включает миллион записей  $D = \{d^{(1)}, \dots, d^{(1.000.000)}\}$ . В таком случае при нахождении  $P(g, x^n)$  потребуется вычислить факториал вида  $(n[s, j, g] + \alpha^{(j)} - 1)! = (1.000.000 + \alpha^{(j)} - 1)!$ , в то время как такие 32-разрядные программы как MatLab и MathCAD способны вычислить факториалы не более 170!.

### МОДИФИЦИРОВАННАЯ ЛОГАРИФМИЧЕСКАЯ ФУНКЦИЯ КУПЕРА И ГЕРШКОВИЧА

Для более широкого использования функции КГ следует избавиться от факториала. Для этого прологарифмируем уравнение, описывающее функцию КГ:

$$\begin{aligned} \log(P(g, x^n)) &= \log \left( P(g) \cdot \prod_{j \in J} \left( \prod_{s \in S(j, g)} \frac{(\alpha^{(j)} - 1)! \prod_{q \in A^{(j)}} (n[q, s, j, g]!) }{(n[s, j, g] + \alpha^{(j)} - 1)!} \right) \right) = \\ &= \log(P(g)) + \sum_{j \in J} \left( \sum_{s \in S(j, g)} \left( \sum_{i=1}^{\alpha^{(j)}-1} i + \sum_{q \in A^{(j)}} \left( \sum_{i=1}^{n[q, s, j, g]} i \right) - \sum_{i=1}^{n[s, j, g] + \alpha^{(j)} - 1} i \right) \right) = \\ &= \log(P(g)) + \sum_{j \in J} \left( \sum_{s \in S(j, g)} \left( \sum_{q \in A^{(j)}} \left( \sum_{i=1}^{n[q, s, j, g]} i \right) - \sum_{i=\alpha^{(j)}}^{n[s, j, g] + \alpha^{(j)} - 1} i \right) \right). \end{aligned}$$

Полученное выражение умножим на  $-1$  и для экономии вычислительных ресурсов исключим из него  $\log(P(g))$ . Как и в [5] предполагаем, что априорные вероятности  $P(g)$  всех структур равны. Теперь вместо поиска структуры с максимальным значением функции КГ следует осуществлять поиск структуры с минимальным значением модифицированной логарифмической функции Купера и

Гершковича (МЛКГ):

$$F(g, x^n) = \sum_{j \in J} \left( \sum_{s \in S(j, g)} \left( \sum_{i=\alpha^{(j)}}^{n[s, j, g] + \alpha^{(j)} - 1} i \right) \right) - \\ - \sum_{j \in J} \left( \sum_{s \in S(j, g)} \left( \sum_{q \in A^{(j)}} \left( \sum_{i=1}^{n[q, s, j, g]} i \right) \right) \right).$$

Как показали вычислительные эксперименты, функции КГ и МЛКГ выдают на одних и тех же обучающих данных абсолютно одинаковые решения. Однако на маленьких сетях (до 10 вершин) алгоритм с использованием функции КГ работает быстрее, чем МЛКГ, а на сетях с большим количеством вершин ситуация противоположна.

#### **ФУНКЦИЯ ОПИСАНИЯ МИНИМАЛЬНОЙ ДЛИНЫ**

При построении БС в качестве оценочной часто используют функцию ОМД [6, 9, 11, 12] или ее модификации. Для заданной последовательности  $x^n = d_1, d_2, \dots, d_n$  из  $n$  наблюдений ОМД структуры  $g \in G$  вычисляется по формуле

$$L(g, x^n) = H(g, x^n) + \frac{k(g)}{2} \cdot \log(n),$$

где  $k(g)$  — количество независимых условных вероятностей в сетевой структуре  $g$ ;  $H(g, x^n)$  — эмпирическая энтропия:

$$H(g, x^n) = \sum_{j \in J} H(j, g, x^n), k(g) = \sum_{j \in J} k(j, g).$$

ОМД  $j$ -й вершины вычисляется по формуле

$$L(j, g, x^n) = H(j, g, x^n) + \frac{k(j, g)}{2} \cdot \log(n),$$

где  $k(j, g)$  — количество независимых условных вероятностей  $j$ -й вершины:

$$k(j, g) = (\alpha^{(j)} - 1) \cdot \prod_{k \in \varphi(j)} \alpha^k,$$

$\varphi(j) \subseteq \{1, \dots, j-1, j+1, \dots, N\}$  — это такое множество, при котором  $\Pi^{(j)} = \{X^{(k)} : k \in \varphi(j)\}$ .

Эмпирическая энтропия  $j$ -й вершины вычисляется согласно выражению

$$H(j, g, x^n) = \sum_{s \in S(j, g)} \sum_{q \in A^{(j)}} -n[q, s, j, g] \cdot \log \frac{n[q, s, j, g]}{n[s, j, g]},$$

$$n(s, j, g) = \sum_{i=1}^n I(\pi_i^{(j)} = s); n[q, s, j, g] = \sum_{i=1}^n I(x_i = q, \pi_i^{(j)} = s),$$

где  $\pi^{(j)} = \Pi^{(j)}$  означает, что  $X^{(k)} = x^{(k)} \forall k \in \varphi(j)$ ; функция  $I(E) = 1$ , когда предикат  $E = \text{true}$ , в противном случае  $I(E) = 0$ .

## ЭВРИСТИЧЕСКИЙ ПОИСК С ИСПОЛЬЗОВАНИЕМ УПОРЯДОЧЕННОГО МНОЖЕСТВА ВЕРШИН

Купер и Гершкович [5], а также Дехтер [13] и многие другие исследователи [8] для уменьшения пространства структур сети предлагают считать множество вершин упорядоченным. Иными словами, имеется упорядоченное множество вершин вида  $\{X^{(1)}, X^{(2)}, \dots, X^{(N)}\}$ , где вершина  $X^{(1)}$  — главная корневая вершина, у которой нет предков;  $X^{(2)}$  — дочерняя вершина по отношению к  $X^{(1)}$ ;  $X^{(3)}$  — дочерняя вершина по отношению к какой-то предыдущей вершине или ко всем предыдущим вершинам одновременно и т.д.

В статье [5] предлагается эвристический метод, известный в литературе как алгоритм К2. К вершине  $X^{(N)}$  по очереди добавляются предки от  $X^{(1)}$  до  $X^{(N-1)}$ . С помощью функции КГ вычисляются  $P(g, x^{(n)})$  для каждой комбинации. В качестве предка для вершины  $X^{(N)}$  оставляют вершину  $X^{(i)}$ , при которой  $P(g, x^{(n)})$  принимает максимальное значение. После этого к вершинам  $X^{(N)}$  и  $X^{(N-1)}$  по очереди добавляются предки от  $X^{(1)}$  до  $X^{(N-2)}$  и вычисляются  $P(g, x^{(n)})$ . На выходе метод выдает структуру сети  $g$ , для которой  $P(g, x^{(n)})$  принимает максимальное значение.

Наличие упорядоченного множества вершин существенно сокращает пространство всех возможных нециклических структур. Но в этом случае появляется новая нетривиальная задача — как по множеству обучающих данных получить упорядоченное множество вершин сети. Наиболее очевидный способ — привлечь экспертов. Однако может возникнуть потребность моделирования данных в такой предметной области, где квалифицированных экспертов нет.

## ЗНАЧЕНИЕ ОБОЮДНОЙ ИНФОРМАЦИИ МЕЖДУ ВЕРШИНАМИ

Для оценки степени зависимости двух произвольных переменных  $x^i$  и  $x^j$  в работе [1] Шоу и Лиу предложили в 1968 г. использовать значение обоюдной информации (mutual information)  $MI(x^i, x^j)$ . Для расчета предложено следующее выражение:

$$MI(x^i, x^j) = \sum_{x^i, x^j} P(x^i, x^j) \cdot \log \left( \frac{P(x^i, x^j)}{P(x^i) \cdot P(x^j)} \right).$$

По своей сути значение обоюдной информации является аналогом корреляции, но по своему содержанию — это оценка количества информации о переменной  $x^j$ , содержащейся в переменной  $x^i$ . Значение обоюдной информации принимает неотрицательные значения  $MI(x^i, x^j) \geq 0$ , а в случае, если вершины  $x^i$  и  $x^j$  полностью независимы одна от другой, то  $MI(x^i, x^j) = 0$ , так как  $P(x^i, x^j) = P(x^i) \cdot P(x^j)$ ; следовательно,

$$\log \left( \frac{P(x^i, x^j)}{P(x^i) \cdot P(x^j)} \right) = \log \left( \frac{P(x^i) \cdot P(x^j)}{P(x^i) \cdot P(x^j)} \right) = \log(1) = 0.$$

Значение обоюдной информации используется вместо упорядоченного множества вершин при построении БС [1, 2, 6, 12].

## РЕЗУЛЬТАТЫ ВЫЧИСЛИТЕЛЬНЫХ ЭКСПЕРИМЕНТОВ

Наиболее распространенными оценочными функциями при построении структур БС являются функции КГ и ОМД, а также их модификации. Поэтому в настоящей статье выполнено сравнение алгоритмов, использующих МЛКГ и ОМД относительного времени, затраченного на построение БС. Для определения порядка добавления дуг в БС использовалось значение обоюдной информации [12], а для построения — выборка генетических данных, состоящая из 600 обучающих записей. На рис. 4 и 5 показаны графики временных затрат вычисления алгоритмов. Как видно, для построения БС, состоящих из более чем 30 вершин, алгоритм с использованием ОМД работает быстрее, чем с МЛКГ.

## ЗАКЛЮЧЕНИЕ

Использование БС является востребованым современным подходом в области обработки информации при моделировании процессов различной природы и сложности. В статье выполнен анализ десяти методов построения БС, использующих оценочные функции. Наиболее распространенными оценочными функциями являются функции КГ и ОМД, а также их модификации. Результаты вычислительных экспериментов показали, что на коротких обучающих выборках (до 170 записей) и сетях, состоящих не более чем из 10 вершин, алгоритм с использованием функции КГ работает быстрее по сравнению с МЛКГ и ОМД. Однако алгоритмы, использующие МЛКГ и ОМД, в отличие от КГ, работают с обучающими выборками любого размера. Вычислительные эксперименты показали, что методы построения БС с применением функций КГ и ее модификаций, выполняют переобучение БС, т. е. такие сети содержат лишние дуги.

При сравнении функций МЛКГ и ОМД на выборках генетических данных, состоящих из 600 обучающих записей, функция МЛКГ показала лучшее время вычисления на сетях, состоящих не более чем из 30 вершин. Но алгоритм с использованием ОМД по сравнению с МЛКГ работает в несколько раз быстрее на больших сетях, состоящих из более чем 30 вершин.

## СПИСОК ЛИТЕРАТУРЫ

1. Chow C. K., Liu C. N. Approximating discrete probability distributions with dependence trees // IEEE Transactions on information theory. — 1968. — 4, N 3. — P. 462–467.
2. Rebane G., Pearl J. The recovery of causal poly-trees from statistical data // Intern. Jour. of Approx. Reas. — 1988. — 2, N 3. — P. 175–182.
3. Herskovits E., Cooper G. Kutato: an entropy-driven system for construction of probabilistic expert systems from databases // Proc. of the Sixth Intern. Conf. on Uncertainty in Arti-




Рис. 4. Диаграмма времени вычисления алгоритмов с использованием МЛКГ и ОМД




Рис. 5. График временных затрат алгоритма с использованием ОМД

- ficial Intelligence (UAI'90), Cambridge, MA, USA. — New York: Elsevier science, 1991. — P. 54–62.
4. Spirtes P., Glymour C., Scheines R. From probability to causality // *Philosophical Studies*. — Amsterdam: Springer Netherlands. — 1991. — **64**, N 1. — P. 1–36.
  5. Cooper G., Herskovits E. A Bayesian method for the induction of probabilistic networks from data // *Machine Learning*. — 1992. — **9**. — P. 309–347.
  6. Lam W., Bachus F. Learning Bayesian belief networks: an approach based on the MDL principle // *Computational Intelligence*. — 1994. — **10**, N 4. — P. 269–293.
  7. Acid S., Campos L. Benedict: an algorithm for learning probabilistic belief networks // Proc. of the Sixth International Conf. on Information Processing and Management of Uncertainty in Knowledge-Based Systems (IPMU'96), Granada, Spain. — New York: Springer, 1997. — P. 979–984.
  8. Singh M., Valtorta M. Construction of Bayesian network structures from data: a brief survey and an efficient algorithm // *Intern. Jour. of Approx. Rea.* — 1995. — **12**. — P. 111–131.
  9. Friedman N., Goldszmidt M. Learning Bayesian networks with local structure // Proc. of the Twelfth International Conf. on Uncertainty in Artificial Intelligence (UAI'96), Portland, Oregon, USA. — SF.: Morgan Kaufmann, 1996. — P. 252–262.
  10. Wallace C., Korb K., Dai H. Causal discovery via MML / Proc. of the Thirteenth Intern. Conf. on Machine Learning (ICML'96), Bari, Italy. — SF.: Morgan Kaufmann, 1996. — P. 516–524.
  11. Suzuki J. Learning Bayesian belief networks based on the MDL principle: an efficient algorithm using the branch and bound technique // *IEICE Trans. on Inform. and Systems*. — 1999. — P. 356–367.
  12. Терентьев А.Н., Бидюк П.И. Эвристический метод построения байесовских сетей // *Мат. машины и системы*. — 2006. — **3**. — С. 12–23.
  13. Dechter R. Bucket elimination: a unifying framework for reasoning // ACM Press. — 1996. — **28**, N 61. — P. 1–51.

*Поступила 27.06.2007*