

Частотные регулярные языки

Д. Н. Бабин

Естественные языки обладают свойством постоянной частоты встречаемости букв и пар букв. В статье изучены регулярные языки с этим свойством.

Ключевые слова: естественный язык, регулярный язык, цепь Маркова, марковский язык.

Введение

Обработка текстов на естественном языке, распознавание образов заданных последовательностями букв, распознавание речи, оптическое распознавание печатных и рукописных символов, создание человеко-машинных интерфейсов и так далее требуют специализированных лингвистических и математических моделей, простейшими из которых являются специальные регулярные языки.

Еще в начале 20 века выдающимся русским ученым А. А. Марковым был создан аппарат цепей, впоследствии названных цепями Маркова, и опробован [1] на вычислении переходных вероятностей между соседними буквами (биграммami) в поэме А. С. Пушкина «Евгений Онегин». В дальнейшем этот аппарат получил широкое применение для распознавания и статистического моделирования естественных языков. Обобщением открытых Марковым зависимостей является n -граммная модель [2], которая до настоящего времени используется в большинстве современных коммерческих систем распознавания речи. Модель позволяет вычислить вероятность того, что слово $\alpha = a_{i_1} a_{i_2} \dots a_{i_s}$ является допустимым словом языка. В модели делается допущение о том, что лишь ограниченной длины n предистория влияет на следующую букву, а именно

$$P(a_{i_j} | a_{i_1} a_{i_2} \dots a_{i_{j-1}}) \approx P(a_{i_j} | a_{i_{j-n+1}} a_{i_{j-n+2}} \dots a_{i_{j-1}}).$$

Это приводит к тому, что вероятность, расписанная в виде произведения условных вероятностей

$$P(a_{i_1} a_{i_2} \dots a_{i_s}) = P(a_{i_1}) \times P(a_{i_2} | a_{i_1}) \times \dots \times P(a_{i_s} | a_{i_1} a_{i_2} \dots a_{i_{s-1}}),$$

выражается через произведение вероятностей вида

$$P(a_{i_j} | a_{i_{j-n+1}} a_{i_{j-n+2}} \dots a_{i_{j-1}}).$$

Очевидно, что в таком случае модель сводится к конечному множеству вероятностей, каждую из которых можно оценить на этапе обучения системы, вычислив частоту встречаемости соответствующих слов в обучающей выборке. Это свойство естественных языков иметь в пределе фиксированные вероятности вида $P(a_{i_j} | a_{i_{j-n+1}} a_{i_{j-n+2}} \dots a_{i_{j-1}})$ может быть обобщено на регулярные языки. Получается описанный ниже класс регулярных языков с предельными частотными свойствами. Другим подходом в анализе языков является вложение изучаемого множества слов в язык с фиксированными частотами биграмм (2-грамм). Этот приём используется для проверки текстового множества на принадлежность естественному языку: а именно, частота пар букв (или ключевых слов) в естественном языке является фиксированной. Изучаемое множество слов может быть вложено в *биграммный язык* — множество *всех* слов с фиксированными частотами пар соседних букв. Оказывается, биграммные языки обладают уникальными свойствами. По матрице частот можно явно определить непустоту, мощность, конечность или бесконечность биграммного языка. Свойства биграммных языков связаны с эйлеровыми свойствами ориентированных гиперграфов, порожденными матрицами биграмм.

1. Регулярные языки с предельными частотными свойствами

Какие же свойства имеют регулярные языки, имеющие частотные свойства естественных языков. Перенесем понятия n -граммной модели на регулярные языки. Для этого определим частоту встречаемости слова w на s -ом месте, а затем рассмотрим предел этой частоты при s стремящемся к бесконечности.

Пусть $M = (A, Q, \varphi, Q_F, q_0)$ — конечный детерминированный автомат [3], A — входной алфавит, Q — множество состояний, $Q_F \subseteq Q$ — множество финальных состояний, $\varphi : A \times Q \rightarrow Q$ — функция переходов, q_0 — начальное состояние автомата. Через $L_M = \{\alpha \in A^* \mid \varphi(q_0, \alpha) \in Q_F\}$ обозначим язык, порождаемый автоматом M . Для натурального числа $s \in \mathbb{N}$ обозначим через $L(s)$ множество слов языка L длины s :

$$L(s) = \{\alpha \in L : |\alpha| = s\}.$$

Через PL обозначим множество префиксов слов языка L , включая сами слова:

$$PL = \{\alpha \in A^* \mid \exists \beta \in A^*, \alpha\beta \in L\}, L \subseteq PL.$$

Через L_γ обозначим множество слов языка L , оканчивающихся на γ , то есть

$$L_\gamma = \{\alpha \in A^* \in L \mid \exists \beta \in A^*, \alpha = \beta\gamma\}.$$

Пусть $|w| = n$. Обозначим через $l_w(s)$ число слов языка L , имеющих с $(s - n + 1)$ -ой по s -ую букву подслово w , то есть

$$l_w(s) = |PL_w(s)|.$$

Введём $G_w(s)$ — частоту встречаемости слова w на s -ом месте как

$$G_w(s) = \frac{l_w(s)}{\sum_{|w'|=|w|} l_{w'}(s)}.$$

Через $G_w = \lim_{s \rightarrow \infty} G_w(s)$ обозначим предельную частоту встречаемости слова w среди слов той же длины.

Пусть $w \in A^*$ — слово и $a \in A$ — буква, $|wa| = n$.

Введём величину $\Gamma_{w,a}(s)$ как

$$\Gamma_{w,a}(s) = \frac{l_{wa}(s)}{\sum_{|w'|=|w|} l_{w'a}(s)}.$$

Величину

$$\Gamma_{w,a} = \lim_{s \rightarrow \infty} \Gamma_{w,a}(s),$$

если она существует, назовём n -граммой языка L для пары (w, a) .

Язык L назовём марковским языком порядка n , если существуют все n -граммы $\Gamma_{w,a}$, где $|wa| = n$ и существуют все частоты G_v , где $|v| = n$.

Множество марковских языков порядка n обозначим через $ML(n)$. Через ML обозначим класс марковских языков, то есть языков, являющихся марковскими при любом порядке n :

$$ML = \bigcap_{n=1}^{\infty} ML(n).$$

Нетрудно показать, что в классе регулярных языков существуют языки, не являющиеся марковскими, и число марковских регулярных языков достаточно велико. Обозначим через ML_N класс марковских языков, задаваемых автоматами с не более чем N состояниями; через R_N обозначим класс всех регулярных языков, задаваемых автоматами с не более чем N состояниями. Справедливы теоремы 1–4 [4].

Теорема 1. *Для достаточно больших N*

$$\frac{ML_N}{R_N} > \left(1 - \frac{1}{e}\right).$$

Оказывается, что классы марковских языков строго вкладываются друг в друга. Это показывают теоремы 2 и 3.

Теорема 2. *Если язык является марковским порядка n , то он также является марковским порядка $k < n$.*

Теорема 3. *Для любого $n \in \mathbb{N}$ существует язык L , такой, что $L \in ML_{n-1}$, но при этом $L \notin ML_n$.*

Таким образом, марковские языки образуют строго сужающуюся последовательность:

$$ML(1) \supset ML(2) \supset ML(3) \supset \dots \supset ML(n) \supset \dots$$

С другой стороны, если язык L фиксирован, то ситуация становится обратной. А именно, справедлива

Теорема 4. *Пусть язык $L = L_M$ задан автоматом $M = \{A, Q, \varphi, Q_F, q_0\}$. Тогда из $L \in ML(2^{|Q|})$ следует, что $L \in ML$.*

2. Биграммные языки

Биграммой в алфавите A называется двухбуквенное слово $ab \in A^*$, $a, b \in A$. Обозначим через $\theta_\beta(\alpha)$ количество подслов β в слове α . Значение $\theta_\beta(\alpha)$ при данных β и α назовем кратностью β в слове α . По слову $\alpha \in A^*$ можно построить квадратную матрицу биграмм $(\Theta(\alpha))_{i,j=1}^{|A|}$ размера $|A| \times |A|$ такую, что на месте (i, j) матрицы будет стоять значение $\theta_{a_i a_j}(\alpha)$.

Обозначим через Ξ множество квадратных матриц размера $|A| \times |A|$, каждый элемент которых является целым неотрицательным числом.

Назовем языком $L(\Theta)$, порожденным матрицей $\Theta \in \Xi$, множество всех слов, имеющих одну и ту же матрицу биграмм Θ , то есть $L(\Theta) = \{\beta | \Theta(\beta) = \Theta\}$. Построим по матрице $\Theta \in \Xi$ ориентированный гиперграф G_Θ , вершинами которого будут буквы из алфавита A , при этом ребра будут соответствовать биграммам с учетом их кратностей, то есть θ_{ab} будет порождать θ_{ab} ориентированных ребер $a \rightarrow b$, а θ_{cc} будет порождать θ_{cc} петель $c \rightarrow c$.

Связный ориентированный гиперграф называется эйлеровым [5], если у всех вершин количество входящих ребер равно количеству исходящих ребер. Граф называется почти эйлеровым, если у всех вершин, кроме двух, количество входящих ребер равно количеству исходящих ребер, а у оставшихся двух вершин разность количества входящих ребер и количества исходящих ребер равна $+1$ и -1 соответственно.

Мы можем рассматривать матрицу биграмм как матрицу пропорций. Получается язык, F_Θ , в котором сохраняются отношения $\theta_{ab}(\alpha)/\theta_{cd}(\alpha) \forall a, b, c, d \in A$, $\theta_{cd}(\alpha) > 0$ для любого слова α из этого языка.

$$F_\Theta = \bigcup_{k=1}^{\infty} L(k\Theta),$$

Имеют место теоремы 5–6 [6].

Теорема 5. Для алфавита $A = \{0, 1\}$ и матрицы биграмм $\Theta \in \Xi$, задающей эйлеров или полуэйлеров граф число слов N_Θ с матрицей биграмм Θ равно

1. $C_{\theta_{11}+\theta_{10}}^{\theta_{11}} C_{\theta_{00}+\theta_{10}}^{\theta_{00}}$; при $\theta_{01} > \theta_{10}$

$$2. C_{\theta_{11}+\theta_{01}}^{\theta_{11}} C_{\theta_{00}+\theta_{01}}^{\theta_{00}}; \text{ при } \theta_{01} < \theta_{10}$$

$$3. C_{\theta_{00}+\theta_{01}}^{\theta_{00}} C_{\theta_{11}+\theta_{01}}^{\theta_{11}} \left(\frac{\theta_{01}}{\theta_{00}+\theta_{01}} + \frac{\theta_{01}}{\theta_{11}+\theta_{01}} \right); \text{ при } \theta_{01} = \theta_{10}$$

(здесь под C_n^k понимается число сочетаний из n по k , то есть $C_n^k = \frac{n!}{k!(n-k)!}$).

Теорема 6. Если G_Θ эйлеровый граф, то F_Θ счетно, если G_Θ полуэйлеровый граф, то F_Θ конечно, в остальных случаях F_Θ пусто.

Список литературы

- [1] Марков А. А. Исчисление вероятностей. — СПб.: Типография Императорской Академии Наук, 1913.
- [2] Bahl L. R., Baker J. K., Jelinek F., Mercer R. L. Perplexity a measure of the difficulty of speech recognition tasks. / Program of the 94th Meeting of the Acoustical Society of America // J. Acoust. Soc. Am. — 1977. Suppl. no. 1. Vol. 62. — P. S63.
- [3] Кудрявцев В. Б., Алёшин С. В., Подколзин А. С. Введение в теорию автоматов. — М.: Наука, 1985.
- [4] Бабин Д. Н., Холоденко А. Б. Об автоматной аппроксимации естественных языков // Интеллектуальные системы. — Т. 12, вып. 3–4. 2008. — С. 125–136.
- [5] Оре О. Теория графов. — М.: Наука, 1980.
- [6] Петюшко А. А. Частотные языки // Интеллектуальные системы в производстве. — 2012. № 1. — С. 192–201.