

## ОПРЕДЕЛЕНИЕ ХАРАКТЕРИСТИК КОРРЕКТОРА ДЛЯ ОБЕСПЕЧЕНИЯ ЗАДАННОГО КАЧЕСТВА КОНЕЧНОГО ПРОДУКТА

In paper the idea of a determination of a matrix of passage for operations of a proofreading of the text is considered, radiating from given vectors of states of the text before operation of a proofreading. For this purpose the method of discrete Markovian processes is used. In outcome the algorithm of a determination of a matrix of passage for any size  $n$  of vectors of a state of the text is offered.

Одной из важнейших характеристик продукции является ее качество. В случае рассмотрения текста книги, статьи, да и любого издания основной характеристикой текста является количество ошибок, которые рассматриваемый текст содержит. Для анализа качества текста целесообразно применять метод дискретных марковских процессов. В этом случае вектор состояния текста определяется в виде матрицы-строки:

$$\bar{P} = [P_0 \ P_1 \ P_2 \ \dots \ P_n], \quad (1)$$

где  $P_i$  — вероятность того, что количество ошибок в тексте равно  $i$ .

Элементы вектора состояния удовлетворяют следующему очевидному условию:

$$\sum_{i=0}^n P_i = 1. \quad (2)$$

Преобразование текста после каждого этапа технологического процесса описывается матрицей перехода:

$$P = \begin{bmatrix} P_{00} & P_{01} & P_{02} & \dots & P_{0n} \\ P_{10} & P_{11} & P_{12} & \dots & P_{1n} \\ P_{20} & P_{21} & P_{22} & \dots & P_{2n} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ P_{n0} & P_{n1} & P_{n2} & \dots & P_{nn} \end{bmatrix}. \quad (3)$$

Элементы матрицы  $P_{ij}$  означают вероятность перехода текста из состояния  $i$  в состояние  $j$ , т. е. вероятность того, что число ошибок изменится от  $i$  до  $j$ . Состояние  $n$  будем считать таким, когда число ошибок в тексте  $i \geq n$ .

Сумма элементов матрицы в каждой строке равна единице:

$$\sum_{j=0}^n P_{ij} = 1. \quad (4)$$

Для нахождения вектора состояния текста после его преобразования необходимо воспользоваться матричным произведением

$$\overline{P(1)} = \overline{P(0)} \cdot P, \quad (5)$$

где  $P(0)$  и  $P(1)$  — строки, соответствующие векторам состояния текста до и после его преобразования.

При вводе текстовой информации в ЭВМ с помощью клавиатуры матрица кодирования приобретает треугольную форму:

$$P_{код} = \begin{bmatrix} P_{00} & P_{01} & P_{02} & \dots & P_{0n} \\ 0 & P_{11} & P_{12} & \dots & P_{1n} \\ 0 & 0 & P_{22} & \dots & P_{2n} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & 0 & \dots & 1 \end{bmatrix} \quad (6)$$

Тогда уравнение (5) может быть записано в развернутом виде:

$$[PP_0 \quad PP_1 \quad PP_2 \quad \dots \quad PP_n] = [PD_0 \quad PD_1 \quad PD_2 \quad \dots \quad PD_n] \cdot \begin{bmatrix} P_0 & P_1 & P_2 & \dots & P_n \\ 0 & P_0 & P_1 & \dots & P_{n-1} + P_n \\ 0 & 0 & P_0 & \dots & P_{n-2} + P_{n-1} + P_n \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & 0 & \dots & 1 \end{bmatrix} \quad (7)$$

Данное матричное уравнение может быть записано в виде системы линейных уравнений:

$$\left\{ \begin{array}{l} PD_0 \cdot P_0 = PP_0 ; \\ PD_0 \cdot P_1 + PD_1 \cdot P_0 = PP_1 ; \\ PD_0 \cdot P_2 + PD_1 \cdot P_1 + PD_2 \cdot P_0 = PP_2 ; \\ \vdots \\ PD_0 \cdot P_n + PD_1 \cdot P_{n-1} + \dots + PD_{n-1} \cdot P_1 + PD_n \cdot P_0 = PP_n . \end{array} \right. \quad (8)$$

Для проверки можно воспользоваться уравнением  $\sum_{j=0}^n P_j = 1$ .

Для устранения ошибок в набранном тексте используются операции корректуры. Матрица корректуры в общем случае имеет вид, описываемый выражением (6). Если же корректор абсолютно грамотен, т. е. не вносит дополнительных ошибок в текст, то матрица корректуры имеет вид

$$P_{кор} = \begin{bmatrix} 1 & 0 & 0 & \dots & 0 \\ P_{10} & P_{11} & 0 & \dots & 0 \\ P_{20} & P_{21} & P_{22} & \dots & 0 \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ P_{n0} & P_{n1} & P_{n2} & \dots & P_m \end{bmatrix} \quad (9)$$

Рассмотрим идею определения коэффициентов в матрице корректуры для получения текста с заданным количеством ошибок  $PP$  при условии, что характеристики исходного текста  $PD$  также известны. Решение такой задачи «в лоб» не представляется возможным, так как в этом случае мы будем иметь дело с системой из  $2n$  уравнений и оперировать при этом  $n(n-1)/2+n$  неизвестными. Для нахождения искомых коэффициентов предлагается следующий алгоритм нахождения коэффициентов матрицы перехода для корректуры.

1. Рассмотрим матрицу размера  $3 \times 3$ . Тогда уравнение (5) примет вид

$$[PP_0 \quad PP_1 \quad PP_2] = [PD_0 \quad PD_1 \quad PD_2] \cdot \begin{bmatrix} P_{00} & 0 & 0 \\ P_{10} & P_{11} & 0 \\ P_{20} & P_{21} & P_{22} \end{bmatrix}$$

$$\begin{cases} PD_0 \cdot P_{00} + PD_1 \cdot P_{10} + PD_2 \cdot P_{20} = PP_0 ; \\ PD_0 \cdot 0 + PD_1 \cdot P_{11} + PD_2 \cdot P_{21} = PP_1 ; \\ PD_0 \cdot 0 + PD_1 \cdot 0 + PD_2 \cdot P_{22} = PP_2 ; \end{cases} \quad (10)$$

$$\begin{cases} P_{00} = 1 ; \\ P_{10} + P_{11} = 1 ; \\ P_{20} + P_{21} + P_{22} = 1 . \end{cases} \quad (11)$$

Таким образом, имеем систему из шести уравнений с шестью неизвестными, которые можно найти численными или аналитическими методами. Найденные коэффициенты матрицы  $P$  в дальнейшем обозначим с индексом  $n$ .

2. Рассмотрим матрицу размера  $4 \times 4$ . Тогда уравнение (5) примет вид

$$[PP_0 \quad PP_1 \quad PP_2 \quad PP_3] = [PD_0 \quad PD_1 \quad PD_2 \quad PD_3] \cdot \begin{bmatrix} P_{00n} & 0 & 0 & 0 \\ P_{10n} & P_{11n} & 0 & 0 \\ P_{20} & P_{21} & P_{22} & 0 \\ P_{30} & P_{31} & P_{32} & P_{33} \end{bmatrix}$$

$$\begin{cases} PD_0 \cdot P_{00n} + PD_1 \cdot P_{10n} + PD_2 \cdot P_{20} + PD_3 \cdot P_{30} = PP_0 ; \\ PD_0 \cdot 0 + PD_1 \cdot P_{11n} + PD_2 \cdot P_{21} + PD_3 \cdot P_{31} = PP_1 ; \\ PD_0 \cdot 0 + PD_1 \cdot 0 + PD_2 \cdot P_{22} + PD_3 \cdot P_{32} = PP_2 ; \\ PD_3 \cdot P_{33} = PP_3 ; \end{cases} \quad (12)$$

$$\begin{cases} P_{20} + P_{21} + P_{22} = 1 ; \\ P_{30} + P_{31} + P_{32} + P_{33} = 1 . \end{cases} \quad (13)$$

Таким образом, имеем систему 6 уравнений с 7 неизвестными. Для нахождения воспользуемся уравнением

$$\frac{P_{20i} - P_{21i}}{P_{21i} - P_{22i}} = \frac{P_{20} - P_{21}}{P_{21} - P_{22}}$$

Данное соотношение имеет следующий физический смысл: в новой матрице  $P$  размера  $4 \times 4$  числа в третьей строке должны находиться в той же пропорции, что и числа в третьей строке матрицы  $P$  размера  $3 \times 3$ .

Аналогичным образом рассматриваются матрицы с размером на одну строку и один столбец большие по сравнению с рассмотренными ранее матрицами, дополняя при этом систему уравнений соотношениями, аналогичными (14) до тех пор, пока размер не достигнет заданной величины  $n$ .

#### ЛИТЕРАТУРА

1. Ефимов М.В. Автоматизированное управление полиграфическим производством. — М.: Мир книги, 1998.
2. Технические средства переработки текста и иллюстраций / Под ред. М.В. Ефимова. — М.: Мир книги, 1994.
3. Берлин А.С., Воскресенский М.И., Ефимов М.В. и др. Автоматизированные системы переработки текстовой информации. — М.: Книга, 1991.