

М. Ф. БОНДАРЕНКО, канд. техн. наук, В. М. БОНДАРЕВ

О МАТЕМАТИЧЕСКОМ ОПИСАНИИ СЛОВОИЗМЕНЕНИЯ
СУЩЕСТВИТЕЛЬНЫХ. СООБЩЕНИЕ 2

Необходимой частью математического описания словоизменения существительных являются предикаты, связывающие словоформу с морфологическими характеристиками. Представляется полезным уметь выделить буквы основы словоформы и указать ее окончание.

Рассмотрим следующее высказывание. Если окончание словоформы $-я$, то существует такой номер переменной k , что $y_i = \eta_i$ ($i < k$), $y_k = я$, $\eta_k = \sqcup$, а все переменные y_i и η_i ($i > k$) равны пробелу,

$$L_{4,я} = \omega^я \supset (\exists k \in \{1, 2, \dots, n-1\}) \left[\bigwedge_{i=1}^{k-1} (y_i = \eta_i) \overline{\eta_{k-1}^{\sqcup}} \wedge \right. \\ \left. \wedge y_k^я \eta_k^{\sqcup} \bigwedge_{i=k+1}^n y_i^{\sqcup} \eta_i^{\sqcup} \right]. \quad (29)$$

Запись $(\exists k \in \{1, 2, \dots, n\}) P(k)$ означает $P(1) \vee P(2) \vee \dots \vee P(n)$.

Трехбуквенному окончанию $-ями$ соответствует предикат:

$$L_{4,ями} = \omega^{ями} \supset (\exists k \in \{1, 2, \dots, n-3\}) \left[\bigwedge_{i=1}^{k-1} (y_i = \eta_i) \overline{\eta_{k-1}^{\sqcup}} \wedge \right. \\ \left. \wedge y_k^я y_{k+1}^м y_{k+2}^н \eta_k^{\sqcup} \eta_{k+1}^{\sqcup} \eta_{k+2}^{\sqcup} \bigwedge_{i=k+3}^n y_i^{\sqcup} \eta_i^{\sqcup} \right]. \quad (30)$$

Обобщим выражения типа (29) и (30):

$$L_{4,i} = \omega^i \supset (\exists k \in \{1, 2, \dots, n-3\}) \left[\bigwedge_{i=1}^{k-1} (y_i = \eta_i) \overline{\eta_{k-1}^{\sqcup}} \wedge \right. \\ \left. \wedge y_k^{a_1} y_{k+1}^{a_2} y_{k+2}^{a_3} \eta_k^{\sqcup} \eta_{k+1}^{\sqcup} \eta_{k+2}^{\sqcup} \bigwedge_{i=k+3}^n y_i^{\sqcup} \eta_i^{\sqcup} \right]. \quad (31)$$

Каждому значению переменной i соответствует один столбец табл. 1.

Таблица 1

ω	е	я	а	ю	у	и	й	ь	ем	ей	ев	ям	ам	ях	ах	ями	ами	$\sqcup$
a_1	е	я	а	ю	у	и	й	ь	е	е	е	я	а	я	а	я	а	$\sqcup$
a_2	$\sqcup$	$\sqcup$	$\sqcup$	$\sqcup$	$\sqcup$	$\sqcup$	$\sqcup$	$\sqcup$	м	й	в	м	м	х	х	м	м	$\sqcup$
a_3	$\sqcup$	$\sqcup$	$\sqcup$	$\sqcup$	$\sqcup$	$\sqcup$	$\sqcup$	$\sqcup$	$\sqcup$	$\sqcup$	$\sqcup$	$\sqcup$	$\sqcup$	$\sqcup$	$\sqcup$	и	и	$\sqcup$

Если окончание словоформы пустое, выражение (31) можно упростить:

$$L_{4, \square} = \omega \supset \bigwedge_{i=1}^n (y_i = \eta_i). \quad (32)$$

Общий предикат, учитывающий связь переменных y , ω и η будет логическим произведением всевозможных предикатов $L_{4,i}$:

$$L_4(y, \omega, \eta) = \bigwedge_{i=1}^{18} L_{4,i}. \quad (33)$$

Изучим предикаты, описывающие чередование в основах словоформ. Рассмотрим связь между словом X , основой словоформы η , типом склонения γ и степенью чередования β . Если в словоформе имеет место первая степень чередования, то все буквы слова X и основы η , совпадают, начиная с 1-й и кончая некоторой k -й буквой, причем эта буква — последняя в основе, не являющаяся пробелом. Если тип склонения нулевой, то $(k+1)$ -я буква слова — $\square$, если не нулевой, то $(k+1)$ -я буква слова — e . Все остальные буквы основы и слова — пробелы:

$$L_{5,1} = \beta^1 \supset (\exists k \in \{1, 2, \dots, n-2\}) \left[\bigwedge_{i=1}^k (\eta_i = x_i) \overline{\eta_k} \square \wedge \right. \\ \left. \wedge \eta_{k+1} \square (\gamma^0 x_{k+1} \square \vee \gamma^0 x_{k+1}^e) \bigwedge_{i=k+2}^n x_i \square \eta_i \square \right]. \quad (34)$$

Таблица 2

x_k	x_{k+1}	x_{k+2}	η_k	η_{k+1}	η_{k+2}
ь	е	$\square$	и	$\square$	$\square$
в	ц	е	в	е	ц
д	ц	е	д	е	ц
н	ц	е	н	е	ц
р	ц	е	р	е	ц
т	ц	е	т	е	ц
ь	ц	е	е	ц	$\square$

Если степень чередования вторая, то соответствие между буквами слова и основы нагляднее всего выразится табл. 2.

Все буквы слова и основы словоформы с 1-й по $(k-1)$ -ю попарно одинаковы, а все символы, следующие за $(k+2)$ -м, являются пробелами. После вынесения за скобки общих элементов предикат, описывающий таблицу и замечания к ней, будет следующим:

$$L_{5,2} = \beta^2 \supset (\exists k \in \{1, 2, \dots, n-3\}) \left[\left(\bigwedge_{i=1}^{k-1} x_i = \eta_i \bigwedge_{i=k+3}^n x_i \square \eta_i \square \right) \wedge \right. \\ \left. \wedge (x_k^b x_{k+1}^e x_{k+2} \square \eta_k^b \eta_{k+1} \square \eta_{k+2} \square \vee x_{k+1}^e x_{k+2} (\eta_{k+1}^e \eta_{k+2}^b (x_k^b \eta_k^b \vee x_k^b \eta_k^b \vee \right. \\ \left. \vee x_k^b \eta_k^b \vee x_k^p \eta_k^p \vee x_k^r \eta_k^r)) \vee x_k^b \eta_k^e \eta_{k+1} \square \eta_{k+2} \square) \right]. \quad (35)$$

Произведение $L_{5,1} \wedge L_{5,2}$ даст предикат $L_5(\beta, X, \eta, \gamma)$:

$$L_5(\beta, X, \eta, \gamma) = L_{5,1} \wedge L_{5,2}. \quad (36)$$

Последним звеном нашей модели будет описание зависимости между типом склонения γ , окончанием словоформы ω , чередованием β , основой α и словом X . Если тип склонения 6-й, а окончание словоформы -й или же тип склонения 5-й, окончание пус-

тое, а третьей от конца буквой слова X является n , p , t или b (слово *солнце* — исключение), то в словоформе должна иметь место вторая ступень чередования (в противном случае ступень чередования первая):

$$L_6(\alpha, X, \omega, \gamma, \beta) = L_{6,1} L_{6,2} \sim \beta^2; \quad (37)$$

$$L_{6,1} = \gamma^6 \omega^a \vee \gamma^5 \omega^c (\mu_1^a \vee \mu_1^d \vee \mu_1^e \vee \mu_1^p \vee \mu_1^t \vee \mu_1^b) \bar{\alpha}^c. \quad (38)$$

Здесь показатель c в выражении $\bar{\alpha}^c$ означает номер основы слова *солнце*, μ_1 — третья от конца буква слова X :

$$L_{6,2} = (\forall i \in \{4, 5, \dots, n\}) [x_{i-1}^e x_i^c \supset (\mu_1 = x_{i-3})]. \quad (39)$$

Построенную модель фрагмента морфологии русского языка укрупненно можно представить в виде системы предикатов

$$L_0(X, Y, Z, \Gamma; L_1(Z, \gamma, \omega); L_2(X, \alpha); L_3(X, \alpha, \gamma); L_4(\eta, \omega, Y); \\ L_5(X, \beta, \eta); L_6(\gamma, \omega, \alpha, X, \beta).$$

Под предикатом $L_0(X, Y, Z, \Gamma)$ подразумевается конъюнкция предикатов (1—9).

При решении задач морфологической обработки не обязательно представлять систему (40) в виде единого уравнения $L_0 \wedge L_1 \wedge \dots \wedge L_6 = 1$. Можно отдельно искать корни каждого из уравнений $L_i = 1$ ($i = 0, 1, \dots, 6$) и в качестве ответа задачи брать те из них, которые удовлетворяют всем уравнениям системы. При этом, решая очередное уравнение, целесообразно опираться на сведения о корнях уравнений, решенных ранее.

Усилия, затраченные на отыскание корней системы существенно зависят от того, в каком порядке решаются уравнения $L_i = 1$. По-видимому, для каждого типа морфологических задач существует некоторый оптимальный порядок. На наш взгляд, для задачи синтеза он таков: $L_0, L_2, L_3, L_1, L_6, L_5, L_4$.

Приведем пример морфологического синтеза. Заданы словарная форма *поле* ($x_1 = n, x_2 = o, x_3 = l, x_4 = e, x_5 = x_6 = x_7 = \square$), число искомой словоформы — единственное ($z_1 = e$), падеж — творительный ($z_2 = t$). Требуется определить словоформу, т. е. найти значение переменной Y . В разбираемых примерах ограничимся величиной $n = 7$. Разделим весь процесс отыскания переменной Y на этапы, каждый из которых будем связывать с решением одного из уравнений $L_i = 1$. Для ясности начало описания очередного этапа обозначим символом соответствующего предиката.

L_0 . В результате «решения» уравнения $L_0 = 1$ убеждаемся, что исходные значения X и Z не выходят за пределы их областей определения.

L_2 . Значение $X = \langle n, o, l, e, \square, \square, \square \rangle$ обращает в 0 все конъюнкции $x_1^{a_{11}} x_2^{a_{12}}, \dots, x_n^{a_{in}}$, кроме одной — $x_1^n x_2^o x_3^l x_4^e \times x_5^\square x_6^\square x_7^\square$. Поэтому существует лишь одно значение α , которое

удовлетворяет уравнению $L_2(X, \alpha) = 1$, а именно то, которое обращает в 1 эквивалентность $\alpha^m \sim x_1^n x_2^o x_3^a x_4^e x_5^{\sqcup} x_6^{\sqcup} x_7^{\sqcup}$. Поскольку предикат (23) записан в общем виде, будем считать, что $\alpha = m$, где m — условный номер основы слова *поле*.

L_3 . Так как слово *поле* не относится к числу несклоняемых, M_0 не может содержать элемент m (из-за того, что M_0 не задано явно, мы лишены возможности проверить это непосредственно). Значит, справедливо утверждение $\alpha \in \overline{M_0}$, что влечет истинность всех сомножителей произведения $L_{31}L_{32}L_{33}$. Определим значение переменной μ из (26); $x_{i+1}^e x_{i+2}^{\sqcup} = 1$ только, если $i = 3$, значит, $\mu = x_3 = l$. Это согласуется с (25) и в силу (24) дает единственное возможное значение для типа склонения: $\gamma = 2$.

L_1 . Так как $\gamma = 2$, из (10) заключаем, что $L(2, z_1, z_2, \omega) = 1$. Из условия $z_1 = m$ и (11) получаем, что $L(2, m, z_2, \omega) = 1$. Наконец, из выражения для $L(2, m, z_2, \omega)$ (13) и условия $z_2 = t$ имеем $\omega = -ям$.

L_6 . Значение переменной $\gamma = 2$ обращает в 0 предикат (38). Следовательно, из (37) имеем $0 \sim \beta^2$, что в сочетании с (7) дает $\beta = 1$.

L_5 . Выражение (36) говорит о том, что корни системы должны обратить в 1 предикаты $L_{5,1}$ и $L_{5,2}$. Из того, что $\beta = 1$ и $L_{5,1} = 1$, однозначно следуют равенства $\eta_1 = x_1 = n$; $\eta_2 = x_2 = o$; $\eta_3 = x_3 = l$; $\eta_4 = \eta_5 = \eta_6 = \eta_7 = \sqcup$.

L_4 . Из (33) и (30) получаем искомое значение переменной $Y = \langle y_1, y_2, \dots, y_n \rangle$: $y_1 = \eta_1 = n$; $y_2 = \eta_2 = o$; $y_3 = \eta_3 = l$; $y_4 = \eta_4 = \eta_5 = m$; $y_6 = \eta_6 = u$; $y_7 = \eta_7 = \sqcup$.

Рассмотрим пример морфологического анализа. Дана словоформа *донец* ($y_1 = d, y_2 = o, y_3 = n, y_4 = e, y_5 = u, y_6 = \sqcup, y_7 = \sqcup$). Требуется отыскать значение числа и падежа, соответствующие заданной словоформе. Порядок решения уравнений в задаче анализа выберем следующим: $L_0, L_4, L_5, L_2, L_3, L_6, L_1$.

L_0 . Согласно (2), заданные значения переменных $y_i (i = 1, 2, \dots, 7)$ содержатся в их области определения.

L_4 . Словоформа *донец* такова, что обращает в 0 выражения, стоящие в предикатах $L_{4,i}$ после знака импликации. Лишь в предикате $L_{4,\sqcup}$ (32) при условии $\eta_i = y_i (i = 1, 2, \dots, 7)$ это выражение может быть равным 1, что допускает значение $\omega = \sqcup$. Это единственно возможное решение, при котором истинны все предикаты $L_{4,i} (i = 1, 2, \dots, 18)$, а вместе с ними и L_4 (33).

L_5 . Анализируя предикаты, составляющие L_5 (34)–(36), убеждаемся, что уравнению $L_5 = 1$ удовлетворяют два набора значений неизвестных X и β : $\langle \langle d, o, n, e, u, \sqcup \rangle, 1 \rangle$ и $\langle \langle d, o, n, u, e, \sqcup \rangle, 2 \rangle$.

L_2 . Решая уравнение $L_2 = 1$ (23), приходим к выводу, что $X = \langle d, o, n, e, u, e, \sqcup \rangle$ не является его корнем, так как наборы $\langle a_{i1}, a_{i2}, \dots, a_{in} \rangle$ представляют собой русские слова,

дополненные пробелами до стандартной длины, и среди них не может быть слова *донец*. Определяем номер основы слова *донец* (условно принимаем $\alpha = d$).

L_3 . Сопоставляя d и M_0 , видим, что $d \in M_0$, значит, истинен предикат $\alpha \in M_0$, поскольку $\alpha = d$. Из (28) заключаем, что $L_{3,1}L_{3,2}L_{3,3} = 1$, далее, согласно (26) $\mu = \psi$. Это удовлетворяет (25) и в соответствии с (24) дает $\gamma = 5$.

L_6 . Подстановка ранее найденных значений $\alpha = d$, $X = \langle d, o, n, \psi, e, \square, \square \rangle$, $\omega = \square$, $\gamma = 5$, $\beta = 2$ в уравнения $L_{6,1} = 1$; $L_{6,2} = 1$; $L_6 = 1$ (37)–(39) не приводит к противоречию, что позволяет нам перейти к следующему этапу анализа.

L_1 . Из (10) и $\gamma = 5$ делаем заключение об истинности предиката $L_1(5, z_1, z_2, \omega)$. Анализируя (17) и (18), замечаем, что $L_1(5, e, z_2, \omega)$ ложен при имеющемся значении $\omega = \square$, а $L_1(5, m, z_2, \omega) = 1$ в случае $z_2 = p$ или $z_2 = v$. Из (11) в этих же случаях получаем: $z_1 = m$.

Итак, решив задачу морфологического анализа, мы установили, что число словоформы *донец* — множественное, падеж — родительный или винительный. Это не должно вызывать удивления, если вспомнить, что построенная модель не учитывает категории одушевленности. Полученный ответ допускает оба возможных значения этой категории. Попутно выяснили, что $X = \langle d, o, n, \psi, e, \square, \square \rangle$, т. е. решили задачу нормализации.

Может показаться, что решение некоторых уравнений, например $L_2 = 1$, излишне при морфологическом анализе. Следующий пример доказывает обратное. Пусть требуется произвести морфологический анализ ошибочно заданной словоформы *маре*.

L_4 . Уравнению $L_4 = 1$ удовлетворяют две пары значений: $\omega = \square$, $\eta = \langle m, a, p, e, \square, \square, \square \rangle$ и $\omega = e$, $\eta = \langle m, a, p, \square, \square, \square, \square \rangle$.

L_5 . Возможными корнями уравнения $L_5 = 1$ будут: $X = \langle m, a, p, e, \square, \square, \square \rangle$, $X = \langle m, a, p, e, e, \square, \square \rangle$, $X = \langle m; a, p, \square, \square, \square, \square \rangle$.

L_2 . Ни одно из буквосочетаний *маре*, *марее*, *мар* не является словом русского языка, поэтому ни одно из соответствующих значений переменной X не обратит в тождества одновременно уравнения $L_2 = 1$ (23) и (5). Следовательно, не существует решения системы L' в целом, что свидетельствует о противоречивости исходных данных.

Если требуется по заданной словоформе найти ее словарную форму, т. е. произвести нормализацию, необходимо последовательно решить уравнения: $L_0 = 1$; $L_4 = 1$; $L_5 = 1$; $L_2 = 1$. Например, задана словоформа *чудищ* ($y_1 = \psi$, $y_2 = y$, $y_3 = d$, $y_4 = = u$, $y_5 = \psi$, $y_6 = y_7 = \square$).

L_0 . С помощью (2) проверяем, принадлежат ли значения переменных y_i ($i = 1, 2, \dots, 7$) их области определения.

L_4 . Из (33), (32) и (6) заключаем, что $\omega = \square$, $\eta = \langle \psi, y, d, u, \psi, \square, \square \rangle$.

L_5 . Уравнение $L_5 = 1$ дает два допустимых значения переменной X : $\langle u, y, d, u, u, e, \square \rangle$ и $\langle u, y, d, u, u, \square, \square \rangle$.

L_2 . Из этих значений уравнению $L_2 = 1$ удовлетворяет лишь первое, т. е. искомая словарная форма — *чудище*.

В заключение отметим, что построенная нами модель данного фрагмента морфологии не является единственно возможной. Состав предикатов этой модели может быть другим, или же они могут выражаться иными формулами.