

Математические модели в лингвистике

Исправление опечаток

Мати Пентус, Александр Пиперски, Алексей Сорокин

МГУ им. М. В. Ломоносова, межфакультетский курс,
осенний семестр 2015–2016 учебного года

Определение задачи

Исправление опечаток

Исправление опечаток (в широком смысле) — выявление ошибок правописания и поиск возможных вариантов их исправления.

Определение задачи

Исправление опечаток

Исправление опечаток (в широком смысле) — выявление ошибок правописания и поиск возможных вариантов их исправления.

- Опечатки и орфографические ошибки содержатся в любом достаточно длинном тексте.

Определение задачи

Исправление опечаток

Исправление опечаток (в широком смысле) — выявление ошибок правописания и поиск возможных вариантов их исправления.

- Опечатки и орфографические ошибки содержатся в любом достаточно длинном тексте.

Решено было не допустить ни одной ошибки. Держали двадцать корректур. И все равно на титульном листе было напечатано: Британская энциклопудия.

Илья Ильф, «Записные книжки»

Определение задачи

Исправление опечаток

Исправление опечаток (в широком смысле) — выявление ошибок правописания и поиск возможных вариантов их исправления.

- Опечатки и орфографические ошибки содержатся в любом достаточно длинном тексте.

Решено было не допустить ни одной ошибки. Держали двадцать корректур. И все равно на титульном листе было напечатано: Британская энциклопудия.

Илья Ильф, «Записные книжки»

- По запросу “сваего мнения” [google.ru](https://www.google.ru) находит 689 результатов.

Применения исправления опечаток

- Информационный поиск (коррекция запросов)

Применения исправления опечаток

- Информационный поиск (коррекция запросов)
- Программы проверки правописания в текстовых редакторах

Применения исправления опечаток

- Информационный поиск (коррекция запросов)
- Программы проверки правописания в текстовых редакторах
- Нормализация текста (коррекция стилистических вариантов, актуальна для социальных медиа)

Применения исправления опечаток

- Информационный поиск (коррекция запросов)
- Программы проверки правописания в текстовых редакторах
- Нормализация текста (коррекция стилистических вариантов, актуальна для социальных медиа)

Применения исправления опечаток

- Информационный поиск (коррекция запросов)
- Программы проверки правописания в текстовых редакторах
- Нормализация текста (коррекция стилистических вариантов, актуальна для социальных медиа)
- Распознавание звучащей речи, изображений...

Применения исправления опечаток

- Информационный поиск (коррекция запросов)
- Программы проверки правописания в текстовых редакторах
- Нормализация текста (коррекция стилистических вариантов, актуальна для социальных медиа)
- Распознавание звучащей речи, изображений...
- Компаративистика («опечатки» — эволюционные изменения в словах языка или различия между родственными языками)

Причины опечаток

- Разновидности опечаток (в широком смысле):
 - Орфографические ошибки

Причины опечаток

- Разновидности опечаток (в широком смысле):
 - Орфографические ошибки
 - Типографские ошибки (опечатки в узком смысле/описки)

Причины опечаток

- Разновидности опечаток (в широком смысле):
 - Орфографические ошибки
 - Типографские ошибки (опечатки в узком смысле/описки)
 - Когнитивные ошибки (смещение понятий, “предать” $\leftrightarrow$ “придать”)

Причины опечаток

- Разновидности опечаток (в широком смысле):
 - Орфографические ошибки
 - Типографские ошибки (опечатки в узком смысле/описки)
 - Когнитивные ошибки (смещение понятий, “предать” $\leftrightarrow$ “придать”)
 - Ошибки при записи речи “на слух”.

Причины опечаток

- Разновидности опечаток (в широком смысле):
 - Орфографические ошибки
 - Типографские ошибки (опечатки в узком смысле/описки)
 - Когнитивные ошибки (смещение понятий, “предать” $\leftrightarrow$ “придать”)
 - Ошибки при записи речи “на слух”.
 - Транслитерационные ошибки (в иноязычных словах/именах собственных).

Причины опечаток

- Разновидности опечаток (в широком смысле):
 - Орфографические ошибки
 - Типографские ошибки (опечатки в узком смысле/описки)
 - Когнитивные ошибки (смещение понятий, “предать” ↔ “придать”)
 - Ошибки при записи речи “на слух”.
 - Транслитерационные ошибки (в иноязычных словах/именах собственных).
 - Региональная/стилистическая вариативность (“colour” ↔ “color”, “dialogue” ↔ “dialog”).

Причины опечаток

- Разновидности опечаток (в широком смысле):
 - Орфографические ошибки
 - Типографские ошибки (опечатки в узком смысле/описки)
 - Когнитивные ошибки (смещение понятий, “предать” ↔ “придать”)
 - Ошибки при записи речи “на слух”.
 - Транслитерационные ошибки (в иноязычных словах/именах собственных).
 - Региональная/стилистическая вариативность (“colour” ↔ “color”, “dialogue” ↔ “dialog”).
- Чаще всего ошибки локальны (затрагивают один-два символа)

Причины опечаток

- Разновидности опечаток (в широком смысле):
 - Орфографические ошибки
 - Типографские ошибки (опечатки в узком смысле/описки)
 - Когнитивные ошибки (смещение понятий, “предать” ↔ “придать”)
 - Ошибки при записи речи “на слух”.
 - Транслитерационные ошибки (в иноязычных словах/именах собственных).
 - Региональная/стилистическая вариативность (“colour” ↔ “color”, “dialogue” ↔ “dialog”).
- Чаще всего ошибки локальны (затрагивают один-два символа)
- Однако может влиять и более широкий контекст (“ться” → *’цца”, “ян” → “яnn/енн” в суффиксе прилагательного)

Пример

The screenshot shows a Google search results page for the query "князь серебряный". The browser's address bar shows the URL: <https://www.google.ru/search?num=100&newwindow=1&safe=off&espv=2&biw=1024&bih=499&q=князь+серебря>. The search bar contains the text "князь серебряный". Below the search bar, the results are displayed. The first result is "Князь Серебряный - Онлайн книги" from loveread.ws/view_global.php?id=268, dated 12 мая 2012 г. The second result is "Князь Серебрянный. Повесть времен Иоанна ... - LiveLib" from www.livelib.ru/book/1000366772, with a rating of 4.3 - 737 голосов. The third result is "Диссертация на тему «Принципы характерологии в ...»" from www.dissercat.com. On the right side of the page, there is a knowledge panel for "Князь Серебряный" by Алексей Константинович Толстой, published in 1862. The panel includes a description: "«Князь Серебряный. Повесть времён Иоанна Грозного» — исторический роман А. К. Толстого о временах oprичнины, который увидел свет в 1863 году. Википедия".

Методы исправления опечаток

- Как исправлять опечатки?

Методы исправления опечаток

- Как исправлять опечатки?
- Можно искать близкие слова в словаре.

Методы исправления опечаток

- Как исправлять опечатки?
- Можно искать близкие слова в словаре.
- Что значит “близкие”?
- Требуется задать функцию расстояния на множестве слов.

Методы исправления опечаток

- Как исправлять опечатки?
- Можно искать близкие слова в словаре.
- Что значит “близкие”?
- Требуется задать функцию расстояния на множестве слов.
- Кроме того хочется, чтобы эту функцию было легко вычислять или хотя бы оценивать.

Модель близости слов

Расстояние Левенштейна

Расстояние Левенштейна $\rho_L(u, v)$ между словами u и v — минимальное число замен, вставок и удалений, необходимых, чтобы получить v из u .

Модель близости слов

Расстояние Левенштейна

Расстояние Левенштейна $\rho_L(u, v)$ между словами u и v — минимальное число замен, вставок и удалений, необходимых, чтобы получить v из u .

Появилась в работах В. И. Левенштейна (1965) и F. Damerau (1964).

Модель близости слов

Расстояние Левенштейна

Расстояние Левенштейна $\rho_L(u, v)$ между словами u и v — минимальное число замен, вставок и удалений, необходимых, чтобы получить v из u .

Появилась в работах В. И. Левенштейна (1965) и F. Damerau (1964).


m	o		n	t	a	g	n	e
						↑		↑
m	o	u	n	t	a	i	n	

Модель близости слов

Расстояние Левенштейна

Расстояние Левенштейна $\rho_L(u, v)$ между словами u и v — минимальное число замен, вставок и удалений, необходимых, чтобы получить v из u .

Появилась в работах В. И. Левенштейна (1965) и F. Damerau (1964).




$$d(\text{montagne}, \text{mountain}) = 3$$

Модель близости слов

Расстояние Левенштейна

Расстояние Левенштейна $\rho_L(u, v)$ между словами u и v — минимальное число замен, вставок и удалений, необходимых, чтобы получить v из u .

Появилась в работах В. И. Левенштейна (1965) и F. Damerau (1964).



$$d(\text{montagne}, \text{mountain}) = 3$$


- Можно добавить перестановку соседних символов (с некоторыми ограничениями).

Модель близости слов

Расстояние Левенштейна

Расстояние Левенштейна $\rho_L(u, v)$ между словами u и v — минимальное число замен, вставок и удалений, необходимых, чтобы получить v из u .

Появилась в работах В. И. Левенштейна (1965) и F. Damerau (1964).



$$d(\text{montagne}, \text{mountain}) = 3$$

- Можно добавить перестановку соседних символов (с некоторыми ограничениями).
- Можно по-разному “штрафовать” за разные изменения.

Вычисление расстояния Левенштейна

Обозначения:

- $w = w_0 \dots w_{n-1}$ — слово, $|w| = n$ — длина слова.

Вычисление расстояния Левенштейна

Обозначения:

- $w = w_0 \dots w_{n-1}$ — слово, $|w| = n$ — длина слова.
- $w[i]$ — i -ый символ слова, $w[i, j]$ — подслово с i -ой по j -ую позицию (не включая j).

Вычисление расстояния Левенштейна

Обозначения:

- $w = w_0 \dots w_{n-1}$ — слово, $|w| = n$ — длина слова.
- $w[i]$ — i -ый символ слова, $w[i, j]$ — подслово с i -ой по j -ую позицию (не включая j).
- $w[, j]$ — префикс по j -ую позицию (не включая j).
- $w[i,]$ — суффикс с i -ой позиции (включая i).

Вычисление расстояния Левенштейна

Обозначения:

- $w = w_0 \dots w_{n-1}$ — слово, $|w| = n$ — длина слова.
- $w[i]$ — i -ый символ слова, $w[i, j]$ — подслово с i -ой по j -ую позицию (не включая j).
- $w[, j]$ — префикс по j -ую позицию (не включая j).
- $w[i,]$ — суффикс с i -ой позиции (включая i).

Идея алгоритма: будем вычислять $d_{ij} = \rho(u[, i], v[, j])$ рекурсивно через значения для меньших i, j . Если $|u| = m, |v| = n$, то ответом будет d_{mn} .

Рекурсивная формула

$$\rho(u[i], v[0]) = i,$$

$$\rho(u[0], v[j]) = j,$$

$$\rho(u[i], v[j]) = \min \begin{aligned} &(\rho(u[i-1], v[j-1]) + \llbracket u[i-1] \neq v[j-1] \rrbracket, \\ &\rho(u[i], v[j-1]) + 1, \\ &\rho(u[i-1], v[j]) + 1 \end{aligned}$$

Рекурсивная формула

$$\rho(u[i], v[0]) = i,$$

$$\rho(u[0], v[j]) = j,$$

$$\rho(u[i], v[j]) = \min(\rho(u[i-1], v[j-1]) + \llbracket u[i-1] \neq v[j-1] \rrbracket, \\ \rho(u[i], v[j-1]) + 1, \\ \rho(u[i-1], v[j]) + 1)$$

Возможные случаи:

- $\rho(u[i], v[j]) = \rho(u[i-1], v[j-1])$:
 $d(bad, bold) = d(ba, bol) = 2$.

b	a		d
b	o	l	d

Рекурсивная формула

$$\rho(u[i], v[0]) = i,$$

$$\rho(u[0], v[j]) = j,$$

$$\rho(u[i], v[j]) = \min(\rho(u[i-1], v[j-1]) + \llbracket u[i-1] \neq v[j-1] \rrbracket, \\ \rho(u[i], v[j-1]) + 1, \\ \rho(u[i-1], v[j]) + 1)$$

Возможные случаи:

- $\rho(u[i], v[j]) = \rho(u[i-1], v[j-1])$:
 $d(\text{bad}, \text{bold}) = d(\text{ba}, \text{bol}) = 2.$
- $\rho(u[i], v[j]) = \rho(u[i-1], v[j-1]) + 1$:
 $\rho(\text{feel}, \text{feed}) = \rho(\text{fee}, \text{fee}) + 1 = 1.$

f	e	e	l
f	e	e	d

Рекурсивная формула

$$\rho(u[i], v[0]) = i,$$

$$\rho(u[0], v[j]) = j,$$

$$\rho(u[i], v[j]) = \min(\rho(u[i-1], v[j-1]) + \llbracket u[i-1] \neq v[j-1] \rrbracket, \\ \rho(u[i], v[j-1]) + 1, \\ \rho(u[i-1], v[j]) + 1)$$

Возможные случаи:

- $\rho(u[i], v[j]) = \rho(u[i-1], v[j-1])$:
 $d(bad, bold) = d(ba, bol) = 2$.
- $\rho(u[i], v[j]) = \rho(u[i-1], v[j-1]) + 1$:
 $\rho(feel, feed) = \rho(fee, fee) + 1 = 1$.
- $\rho(u[i], v[j]) = \rho(u[i-1], v[j]) + 1$:
 $\rho(slide, solid) = \rho(slid, solid) + 1 = 2$.

s	∅		i	d	e
s	o		i	d	∅

Рекурсивная формула

$$\begin{aligned}
 \rho(u[i], v[0]) &= i, \\
 \rho(u[0], v[j]) &= j, \\
 \rho(u[i], v[j]) &= \min(\rho(u[i-1], v[j-1]) + \llbracket u[i-1] \neq v[j-1] \rrbracket, \\
 &\quad \rho(u[i], v[j-1]) + 1, \\
 &\quad \rho(u[i-1], v[j]) + 1)
 \end{aligned}$$

Возможные случаи:

- $\rho(u[i], v[j]) = \rho(u[i-1], v[j-1])$:
 $d(\text{bad}, \text{bold}) = d(\text{ba}, \text{bol}) = 2$.
- $\rho(u[i], v[j]) = \rho(u[i-1], v[j-1]) + 1$:
 $\rho(\text{feel}, \text{feed}) = \rho(\text{fee}, \text{fee}) + 1 = 1$.
- $\rho(u[i], v[j]) = \rho(u[i-1], v[j]) + 1$:
 $\rho(\text{slide}, \text{solid}) = \rho(\text{slid}, \text{solid}) + 1 = 2$.
- $\rho(u[i], v[j]) = \rho(u[i], v[j-1]) + 1$:
 $\rho(\text{site}, \text{step}) = \rho(\text{site}, \text{ste}) + 1 = 2$.

Окончательная рекуррентная формула

Лемма

$$\rho(ux, vx) = \rho(u, v)$$

Окончательная рекуррентная формула

Окончательная формула для расстояния Левенштейна:

$$\begin{aligned}
 \rho(u[i], v[0]) &= i, \\
 \rho(u[0], v[j]) &= j, \\
 \rho(u[i], v[j]) &= \rho(u[i-1], v[j-1]), \text{ если } u[i-1] = v[j-1] \\
 \rho(u[i], v[j]) &= \min(\rho(u[i-1], v[j-1]), \\
 &\quad \rho(u[i], v[j-1]), \\
 &\quad \rho(u[i-1], v[j])) + 1, \text{ если } u[i-1] \neq v[j-1]
 \end{aligned}$$

Окончательная рекуррентная формула

Окончательная формула для расстояния Левенштейна:

$$\rho(u[i], v[0]) = i,$$

$$\rho(u[0], v[j]) = j,$$

$$\rho(u[i], v[j]) = \rho(u[i-1], v[j-1]), \text{ если } u[i-1] = v[j-1]$$

$$\rho(u[i], v[j]) = \min(\rho(u[i-1], v[j-1]), \\ \rho(u[i], v[j-1]), \\ \rho(u[i-1], v[j])) + 1, \text{ если } u[i-1] \neq v[j-1]$$

Идея алгоритма: будем заполнять двумерную таблицу D размера $(m+1) \times (n+1)$, где в ячейке с номером (i, j) будет храниться $\rho(u[i], v[j])$. Заполняем рекурсивно по возрастанию i и j .

Псевдокод

Вход: Слова u, v длины m, n соответственно.

Выход: $d(u, v)$ — расстояние Левенштейна между u и v .

▷ D — таблица размера $(m + 1) \times (n + 1)$

$D[0, 0] = 0$

for $i = 1, \dots, m$ **do**

$D[i, 0] = i$

end for

for $j = 1, \dots, n$ **do**

$D[0, j] = j$

end for

for $i = 1, \dots, m$ **do**

for $j = 1, \dots, n$ **do**

if $u[i - 1] == v[j - 1]$ **then**

$D[i, j] = D[i - 1, j - 1] + 1$

else

$d = \min(D[i - 1, j - 1], D[i, j - 1], D[i - 1, j])$

$D[i, j] = d + 1$

end if

end for

end for

return $D[m, n]$

Пример вычисления расстояния Левенштейна

$$d(\text{штора}, \text{строка}) = ?$$

Пример вычисления расстояния Левенштейна

$$d(\text{штора}, \text{строка}) = ?$$

			с	т	р	о	к	а
		0	1	2	3	4	5	6
ш т о р а	0	0	1	2	3	4	5	6
	1	1						
	2	2						
	3	3						
	4	4						
	5	5						

Пример вычисления расстояния Левенштейна

$$d(\text{штора}, \text{строка}) = ?$$

			с	т	р	о	к	а
		0	1	2	3	4	5	6
ш т о р а	0	0	1	2	3	4	5	6
	1	1						
	2	2						
	3	3						
	4	4						
	5	5						

$$T_{11} = \min(T_{00}, T_{01}, T_{10}) + 1 = 1 \text{ (т.к. } c \neq \text{ш)}.$$

Пример вычисления расстояния Левенштейна

$$d(\text{штора}, \text{строка}) = ?$$

			с	т	р	о	к	а
		0	1	2	3	4	5	6
ш т о р а	0	0	1	2	3	4	5	6
	1	1	1					
	2	2						
	3	3						
	4	4						
	5	5						

$$T_{11} = \min(T_{00}, T_{01}, T_{10}) + 1 = 1 \text{ (т.к. } c \neq \text{ш)}.$$

Пример вычисления расстояния Левенштейна

$$d(\text{штора}, \text{строка}) = ?$$

			с	т	р	о	к	а
		0	1	2	3	4	5	6
ш т о р а	0	0	1	2	3	4	5	6
	1	1	1					
	2	2						
	3	3						
	4	4						
	5	5						

Поскольку “ш” не входит в слово “строка”, получаем:

Пример вычисления расстояния Левенштейна

$$d(\text{штора}, \text{строка}) = ?$$

			с	т	р	о	к	а
		0	1	2	3	4	5	6
ш т о р а	0	0	1	2	3	4	5	6
	1	1	1	2	3	4	5	6
	2	2						
	3	3						
	4	4						
	5	5						

Пример вычисления расстояния Левенштейна

$d(\text{штора}, \text{строка}) = ?$

			с	т	р	о	к	а
		0	1	2	3	4	5	6
ш т о р а	0	0	1	2	3	4	5	6
	1	1	1	2	3	4	5	6
	2	2						
	3	3						
	4	4						
	5	5						

$$T_{21} = \min(T_{20}, T_{10}, T_{11}) + 1 = 2$$

Пример вычисления расстояния Левенштейна

$$d(\text{штора}, \text{строка}) = ?$$

			с	т	р	о	к	а
		0	1	2	3	4	5	6
ш т о р а	0	0	1	2	3	4	5	6
	1	1	1	2	3	4	5	6
	2	2	2					
	3	3						
	4	4						
	5	5						

Пример вычисления расстояния Левенштейна

$$d(\text{штора}, \text{строка}) = ?$$

			с	т	р	о	к	а
		0	1	2	3	4	5	6
ш т о р а	0	0	1	2	3	4	5	6
	1	1	1	2	3	4	5	6
	2	2	2					
	3	3						
	4	4						
	5	5						

$$T_{22} = T_{11} = 1, \text{ поскольку } u[1] = v[1] = \text{т}$$

Пример вычисления расстояния Левенштейна

$$d(\text{штора}, \text{строка}) = ?$$

			с	т	р	о	к	а
		0	1	2	3	4	5	6
ш т о р а	0	0	1	2	3	4	5	6
	1	1	1	2	3	4	5	6
	2	2	2	1				
	3	3						
	4	4						
	5	5						

Пример вычисления расстояния Левенштейна

$$d(\text{штора}, \text{строка}) = ?$$

			с	т	р	о	к	а
		0	1	2	3	4	5	6
ш т о р а	0	0	1	2	3	4	5	6
	1	1	1	2	3	4	5	6
	2	2	2	1				
	3	3						
	4	4						
	5	5						

Дальше заполняем строку по алгоритму:

Пример вычисления расстояния Левенштейна

$$d(\text{штора}, \text{строка}) = ?$$

			с	т	р	о	к	а
		0	1	2	3	4	5	6
ш т о р а	0	0	1	2	3	4	5	6
	1	1	1	2	3	4	5	6
	2	2	2	1	2	3	4	5
	3	3						
	4	4						
	5	5						

Пример вычисления расстояния Левенштейна

$$d(\text{штора}, \text{строка}) = ?$$

			с	т	р	о	к	а
		0	1	2	3	4	5	6
ш т о р а	0	0	1	2	3	4	5	6
	1	1	1	2	3	4	5	6
	2	2	2	1	2	3	4	5
	3	3						
	4	4						
	5	5						

Заполняем третью строку:

Пример вычисления расстояния Левенштейна

$$d(\text{штора}, \text{строка}) = ?$$

			с	т	р	о	к	а
		0	1	2	3	4	5	6
ш т о р а	0	0	1	2	3	4	5	6
	1	1	1	2	3	4	5	6
	2	2	2	1	2	3	4	5
	3	3	3	2	2			
	4	4						
	5	5						

Пример вычисления расстояния Левенштейна

$$d(\text{штора}, \text{строка}) = ?$$

			с	т	р	о	к	а
		0	1	2	3	4	5	6
ш т о р а	0	0	1	2	3	4	5	6
	1	1	1	2	3	4	5	6
	2	2	2	1	2	3	4	5
	3	3	3	2	2			
	4	4						
	5	5						

Поскольку $u[2] = v[3] = o$, то $T_{34} = T_{23} = 2$

Пример вычисления расстояния Левенштейна

$$d(\text{штора}, \text{строка}) = ?$$

			с	т	р	о	к	а
		0	1	2	3	4	5	6
ш т о р а	0	0	1	2	3	4	5	6
	1	1	1	2	3	4	5	6
	2	2	2	1	2	3	4	5
	3	3	3	2	2	2		
	4	4						
	5	5						

Пример вычисления расстояния Левенштейна

$$d(\text{штора}, \text{строка}) = ?$$

			с	т	р	о	к	а
		0	1	2	3	4	5	6
ш т о р а	0	0	1	2	3	4	5	6
	1	1	1	2	3	4	5	6
	2	2	2	1	2	3	4	5
	3	3	3	2	2	2		
	4	4						
	5	5						

Действуя по алгоритму, заполняем таблицу до конца:

Пример вычисления расстояния Левенштейна

$$d(\text{штора}, \text{строка}) = ?$$

			с	т	р	о	к	а
		0	1	2	3	4	5	6
ш т о р а	0	0	1	2	3	4	5	6
	1	1	1	2	3	4	5	6
	2	2	2	1	2	3	4	5
	3	3	3	2	2	2	3	4
	4	4	4	3	2	3	3	4
	5	5	5	4	3	3	4	3

Пример вычисления расстояния Левенштейна

$$d(\text{штора}, \text{строка}) = ?$$

			с	т	р	о	к	а
		0	1	2	3	4	5	6
ш т о р а	0	0	1	2	3	4	5	6
	1	1	1	2	3	4	5	6
	2	2	2	1	2	3	4	5
	3	3	3	2	2	2	3	4
	4	4	4	3	2	3	3	4
	5	5	5	4	3	3	4	3

Таким образом, $d(\text{строка}, \text{штора}) = T_{65} = 3$

Восстановление оптимального выравнивания

По таблице можно найти оптимальное выравнивание:

Восстановление оптимального выравнивания

По таблице можно найти оптимальное выравнивание:

			с	т	р	о	к	а
		0	1	2	3	4	5	6
ш т о р а	0	0	1	2	3	4	5	6
	1	1	1	2	3	4	5	6
	2	2	2	1	2	3	4	5
	3	3	3	2	2	2	3	4
	4	4	4	3	2	3	3	4
	5	5	5	4	3	3	4	3

Восстановление оптимального выравнивания

По таблице можно найти оптимальное выравнивание:

		с	т	р	о	к	а	
		0	1	2	3	4	5	6
0		0	1	2	3	4	5	6
ш	1	1	1	2	3	4	5	6
т	2	2	2	1	2	3	4	5
о	3	3	3	2	2	2	3	4
р	4	4	4	3	2	3	3	4
а	5	5	5	4	3	3	4	3

с	т	р	о	к	а
↑		↓		↑	
↕		↓		↕	
ш	т		о	р	а

Взвешенное расстояние Левенштейна

- Не всегда расстояние Левенштейна приводит к оптимальному выравниванию:

Взвешенное расстояние Левенштейна

- Не всегда расстояние Левенштейна приводит к оптимальному выравниванию:
- $d(loup, lobo) = 2$:

<i>l</i>	<i>o</i>	<i>u</i>	<i>p</i>
<i>l</i>	<i>o</i>	<i>b</i>	<i>o</i>

Взвешенное расстояние Левенштейна

- Не всегда расстояние Левенштейна приводит к оптимальному выравниванию:
- $d(\text{loup}, \text{lobo}) = 2$:

<i>l</i>	<i>o</i>	<i>u</i>	<i>p</i>
<i>l</i>	<i>o</i>	<i>b</i>	<i>o</i>

- Естественное выравнивание даёт $d = 3$:

<i>l</i>	<i>o</i>	<i>u</i>	<i>p</i>	$\emptyset$
<i>l</i>	<i>o</i>	$\emptyset$	<i>b</i>	<i>o</i>

Взвешенное расстояние Левенштейна

- Не всегда расстояние Левенштейна приводит к оптимальному выравниванию:
- $d(\text{loup}, \text{lobo}) = 2$:

<i>l</i>	<i>o</i>	<i>u</i>	<i>p</i>
<i>l</i>	<i>o</i>	<i>b</i>	<i>o</i>

- Естественное выравнивание даёт $d = 3$:

<i>l</i>	<i>o</i>	<i>u</i>	<i>p</i>	$\emptyset$
<i>l</i>	<i>o</i>	$\emptyset$	<i>b</i>	<i>o</i>

- Надо присвоить различным операциям веса, зависящие от заменяемых/удаляемых/вставляемых символов.

Взвешенное расстояние Левенштейна

- Не всегда расстояние Левенштейна приводит к оптимальному выравниванию:
- $d(\text{loup}, \text{lobo}) = 2$:

<i>l</i>	<i>o</i>	<i>u</i>	<i>p</i>
<i>l</i>	<i>o</i>	<i>b</i>	<i>o</i>

- Естественное выравнивание даёт $d = 3$:

<i>l</i>	<i>o</i>	<i>u</i>	<i>p</i>	$\emptyset$
<i>l</i>	<i>o</i>	$\emptyset$	<i>b</i>	<i>o</i>

- Надо присвоить различным операциям веса, зависящие от заменяемых/удаляемых/вставляемых символов.
- Алгоритм вычисления расстояния от этого не изменится (при естественных ограничениях на веса).

Применение к исправлению опечаток

- Как исправлять опечатки с помощью расстояния Левенштейна?

Применение к исправлению опечаток

- Как исправлять опечатки с помощью расстояния Левенштейна?
- Наивный подход: пройти по словарю, подсчитать расстояние до каждого слова, выбрать ближайшее.

Применение к исправлению опечаток

- Как исправлять опечатки с помощью расстояния Левенштейна?
- Наивный подход: пройти по словарю, подсчитать расстояние до каждого слова, выбрать ближайшее.
- Нельзя: словари большие (агглютинативные языки — сотни тысяч слов), а расстояние считается медленно:

Применение к исправлению опечаток

- Как исправлять опечатки с помощью расстояния Левенштейна?
- Наивный подход: пройти по словарю, подсчитать расстояние до каждого слова, выбрать ближайшее.
- Нельзя: словари большие (агглютинативные языки — сотни тысяч слов), а расстояние считается медленно:
 - Словарь состоит из 119774 слов (стандартный словарь в `/usr/share/dic` в UNIX-системах),

Применение к исправлению опечаток

- Как исправлять опечатки с помощью расстояния Левенштейна?
- Наивный подход: пройти по словарю, подсчитать расстояние до каждого слова, выбрать ближайшее.
- Нельзя: словари большие (агглютинативные языки — сотни тысяч слов), а расстояние считается медленно:
 - Словарь состоит из 119774 слов (стандартный словарь в /usr/share/dic в UNIX-системах),
 - Время расчёта (Intel Atom 1.67GHz):

Python3	Python3 (Levenshtein)	C++	C++ (-O3)
144.06	0.51	4.01	1.05

Применение к исправлению опечаток

- Как исправлять опечатки с помощью расстояния Левенштейна?
- Наивный подход: пройти по словарю, подсчитать расстояние до каждого слова, выбрать ближайшее.
- Нельзя: словари большие (агглютинативные языки — сотни тысяч слов), а расстояние считается медленно:
 - Словарь состоит из 119774 слов (стандартный словарь в /usr/share/dic в UNIX-системах),
 - Время расчёта (Intel Atom 1.67GHz):

Python3	Python3 (Levenshtein)	C++	C++ (-O3)
144.06	0.51	4.01	1.05

- Менее наивный подход: породить все слова, расстояние до которых меньше порога d , найти их в словаре.

Применение к исправлению опечаток

- Как исправлять опечатки с помощью расстояния Левенштейна?
- Наивный подход: пройти по словарю, подсчитать расстояние до каждого слова, выбрать ближайшее.
- Нельзя: словари большие (агглютинативные языки — сотни тысяч слов), а расстояние считается медленно:
 - Словарь состоит из 119774 слов (стандартный словарь в /usr/share/dic в UNIX-системах),
 - Время расчёта (Intel Atom 1.67GHz):

Python3	Python3 (Levenshtein)	C++	C++ (-O3)
144.06	0.51	4.01	1.05

- Менее наивный подход: породить все слова, расстояние до которых меньше порога d , найти их в словаре.
- Как порождать такие слова? **С помощью конечных автоматов и преобразователей!**

Применение к исправлению опечаток


- Как исправлять опечатки с помощью расстояния Левенштейна?
- Наивный подход: пройти по словарю, подсчитать расстояние до каждого слова, выбрать ближайшее.
- Нельзя: словари большие (агглютинативные языки — сотни тысяч слов), а расстояние считается медленно:
 - Словарь состоит из 119774 слов (стандартный словарь в /usr/share/dic в UNIX-системах),
 - Время расчёта (Intel Atom 1.67GHz):

Python3	Python3 (Levenshtein)	C++	C++ (-O3)
144.06	0.51	4.01	1.05

- Менее наивный подход: породить все слова, расстояние до которых меньше порога d , найти их в словаре.
- Как порождать такие слова? **С помощью конечных автоматов и преобразователей!**
- Мы пока что не будем определять, что это такое.


Автомат Левенштейна

Конечный преобразователь, порождающий все слова, находящиеся на расстоянии не больше d от слова $w = w_0 \dots w_{n-1}$.



Автомат Левенштейна

Конечный преобразователь, порождающий все слова, находящиеся на расстоянии не больше d от слова $w = w_0 \dots w_{n-1}$.



Состояние (i, j) принимает все слова, находящиеся на расстоянии i от префикса $w[0..j]$

Применение автомата Левенштейна


- Но считать расстояние Левенштейна можно и без автомата...
Зачем он?

Применение автомата Левенштейна

- Но считать расстояние Левенштейна можно и без автомата...
Зачем он?
- Экономия по памяти (при $d > 1$ список слов слишком длинный).


Применение автомата Левенштейна

- Но считать расстояние Левенштейна можно и без автомата...
Зачем он?
- Экономия по памяти (при $d > 1$ список слов слишком длинный).
- Сам словарь тоже часто хранят в форме ациклического автомата (префиксный бор):



Применение автомата Левенштейна

- Но считать расстояние Левенштейна можно и без автомата...
Зачем он?
- Экономия по памяти (при $d > 1$ список слов слишком длинный).
- Сам словарь тоже часто хранят в форме ациклического автомата (префиксный бор):



- Тодга можна параллельно йти по обоим автоматам...

Алгоритм поиска кандидатов

Алгоритм поиска слов-кандидатов:

- Построить (можно неявно) автомат $A_{w,d}$ для текущего слова w и порога расстояния d .

Алгоритм поиска кандидатов

Алгоритм поиска слов-кандидатов:

- Построить (можно неявно) автомат $A_{w,d}$ для текущего слова w и порога расстояния d .
- Вернуть список слов из языка $L(A_{dict} \cap A_{w,d})$, где A_{dict} — автомат для словаря.

Алгоритм поиска кандидатов

Алгоритм поиска слов-кандидатов:

- Построить (можно неявно) автомат $A_{w,d}$ для текущего слова w и порога расстояния d .
- Вернуть список слов из языка $L(A_{dict} \cap A_{w,d})$, где A_{dict} — автомат для словаря.
- Вернуть все или выбрать наиболее удачное (каким образом).

Алгоритм поиска кандидатов

Алгоритм поиска слов-кандидатов:

- Построить (можно неявно) автомат $A_{w,d}$ для текущего слова w и порога расстояния d .
- Вернуть список слов из языка $L(A_{dict} \cap A_{w,d})$, где A_{dict} — автомат для словаря.
- Вернуть все или выбрать наиболее удачное (каким образом).
- Как инкорпорировать в эту модель веса операций?

Алгоритм поиска кандидатов


Алгоритм поиска слов-кандидатов:

- Построить (можно неявно) автомат $A_{w,d}$ для текущего слова w и порога расстояния d .
- Вернуть список слов из языка $L(A_{dict} \cap A_{w,d})$, где A_{dict} — автомат для словаря.
- Вернуть все или выбрать наиболее удачное (каким образом).
- Как инкорпорировать в эту модель веса операций?
- Можно добавить веса на рёбра автомата...

Взвешенные конечные автоматы

Пример взвешенного автомата:


Данный автомат принимает слово a с весом 0.8 , а также слова вида ab^ka с весами $k + 1.0$.



Взвешенные конечные автоматы

Пример взвешенного автомата:

Данный автомат принимает слово a с весом 0.8 , а также слова вида $ab^k a$ с весами $k + 1.0$.



Так же можно взвешивать и преобразователи. Но там много тонкостей... Нам важно, что при композиции (и пересечении) веса складываются.

Алгоритм поиска кандидатов

Алгоритм поиска слов-кандидатов:

- Построить (можно неявно) взвешенный автомат/преобразователь $A_{w,d}$ данного слова w и порога расстояния d .

Алгоритм поиска кандидатов

Алгоритм поиска слов-кандидатов:

- Построить (можно неявно) взвешенный автомат/преобразователь $A_{w,d}$ данного слова w и порога расстояния d .
- Вернуть список слов из языка $L(A_{dict} \cap A_{w,d})$, где A_{dict} — автомат для словаря вместе с их весами в автомате $A_{w,d}$.

Алгоритм поиска кандидатов

Алгоритм поиска слов-кандидатов:

- Построить (можно неявно) взвешенный автомат/преобразователь $A_{w,d}$ данного слова w и порога расстояния d .
- Вернуть список слов из языка $L(A_{dict} \cap A_{w,d})$, где A_{dict} — автомат для словаря вместе с их весами в автомате $A_{w,d}$.
- Выбрать кандидата (или несколько) наименьшего веса.

Алгоритм поиска кандидатов

Алгоритм поиска слов-кандидатов:

- Построить (можно неявно) взвешенный автомат/преобразователь $A_{w,d}$ данного слова w и порога расстояния d .
- Вернуть список слов из языка $L(A_{dict} \cap A_{w,d})$, где A_{dict} — автомат для словаря вместе с их весами в автомате $A_{w,d}$.
- Выбрать кандидата (или несколько) наименьшего веса.
- Откуда взять веса?

Вероятностная модель взвешивания

- Вспомним, что на рёбрах написаны операции вида $\beta : \alpha$, соответствующие «опечаткам» вида $\alpha \rightarrow \beta$.

Вероятностная модель взвешивания

- Вспомним, что на рёбрах написаны операции вида $\beta : \alpha$, соответствующие «опечаткам» вида $\alpha \rightarrow \beta$.
- У каждой такой операции есть вероятность, которую можно как-то оценить.

Вероятностная модель взвешивания

- Вспомним, что на рёбрах написаны операции вида $\beta : \alpha$, соответствующие «опечаткам» вида $\alpha \rightarrow \beta$.
- У каждой такой операции есть вероятность, которую можно как-то оценить.
- Положим $w(\beta : \alpha) = -\log p(\alpha \rightarrow \beta)$.

Вероятностная модель взвешивания

- Вспомним, что на рёбрах написаны операции вида $\beta : \alpha$, соответствующие «опечаткам» вида $\alpha \rightarrow \beta$.
- У каждой такой операции есть вероятность, которую можно как-то оценить.
- Положим $w(\beta : \alpha) = -\log p(\alpha \rightarrow \beta)$.
- Маленьким вероятностям соответствуют большие веса.

Вероятностная модель взвешивания

- Вспомним, что на рёбрах написаны операции вида $\beta : \alpha$, соответствующие «опечаткам» вида $\alpha \rightarrow \beta$.
- У каждой такой операции есть вероятность, которую можно как-то оценить.
- Положим $w(\beta : \alpha) = -\log p(\alpha \rightarrow \beta)$.
- Маленьким вероятностям соответствуют большие веса.
- Положим входные и выходные веса равными 0.

Вероятностная модель взвешивания

- Вспомним, что на рёбрах написаны операции вида $\beta : \alpha$, соответствующие «опечаткам» вида $\alpha \rightarrow \beta$.
- У каждой такой операции есть вероятность, которую можно как-то оценить.
- Положим $w(\beta : \alpha) = -\log p(\alpha \rightarrow \beta)$.
- Маленьким вероятностям соответствуют большие веса.
- Положим входные и выходные веса равными 0.
- Какой в этом смысл?

Вероятностная модель взвешивания: обоснование

- Пусть $(a_1 : b_1, w_1) \dots (a_r : b_r, w_r)$ — путь наименьшего веса в преобразователе M , «исправляющий» слово $u = a_1 \dots a_r$ на $v = b_1 \dots b_r$, а $W(a_1 \dots a_r : b_1 \dots b_r)$ — стоимость этого пути.

Вероятностная модель взвешивания: обоснование

- Пусть $(a_1 : b_1, w_1) \dots (a_r : b_r, w_r)$ — путь наименьшего веса в преобразователе M , «исправляющий» слово $u = a_1 \dots a_r$ на $v = b_1 \dots b_r$, а $W(a_1 \dots a_r : b_1 \dots b_r)$ — стоимость этого пути.
- Тогда $W(a_1 \dots a_r : b_1 \dots b_r) = \sum_{i=1}^r w_i = - \sum_{i=1}^r \log p(b_i \rightarrow a_i) =$
 $-\log \prod_{i=1}^r p(b_i \rightarrow a_i) \approx -\log p(b_1 \dots b_r \rightarrow a_1 \dots a_r) \approx$
 $-\log p(v \rightarrow u).$

Вероятностная модель взвешивания: обоснование

- Пусть $(a_1 : b_1, w_1) \dots (a_r : b_r, w_r)$ — путь наименьшего веса в преобразователе M , «исправляющий» слово $u = a_1 \dots a_r$ на $v = b_1 \dots b_r$, а $W(a_1 \dots a_r : b_1 \dots b_r)$ — стоимость этого пути.
- Тогда $W(a_1 \dots a_r : b_1 \dots b_r) = \sum_{i=1}^r w_i = - \sum_{i=1}^r \log p(b_i \rightarrow a_i) =$
 $-\log \prod_{i=1}^r p(b_i \rightarrow a_i) \approx -\log p(b_1 \dots b_r \rightarrow a_1 \dots a_r) \approx$
 $-\log p(v \rightarrow u).$
- Вес преобразования $u : v$ — (приблизительно) отрицательный логарифм вероятности получить v из u .

Вероятностная модель взвешивания: обоснование

- Пусть $(a_1 : b_1, w_1) \dots (a_r : b_r, w_r)$ — путь наименьшего веса в преобразователе M , «исправляющий» слово $u = a_1 \dots a_r$ на $v = b_1 \dots b_r$, а $W(a_1 \dots a_r : b_1 \dots b_r)$ — стоимость этого пути.
- Тогда $W(a_1 \dots a_r : b_1 \dots b_r) = \sum_{i=1}^r w_i = - \sum_{i=1}^r \log p(b_i \rightarrow a_i) = -\log \prod_{i=1}^r p(b_i \rightarrow a_i) \approx -\log p(b_1 \dots b_r \rightarrow a_1 \dots a_r) \approx -\log p(v \rightarrow u)$.
- Вес преобразования $u : v$ — (приблизительно) отрицательный логарифм вероятности получить v из u .
- Кажется весьма разумным...

Вероятностная модель взвешивания: обоснование

- Пусть $(a_1 : b_1, w_1) \dots (a_r : b_r, w_r)$ — путь наименьшего веса в преобразователе M , «исправляющий» слово $u = a_1 \dots a_r$ на $v = b_1 \dots b_r$, а $W(a_1 \dots a_r : b_1 \dots b_r)$ — стоимость этого пути.
- Тогда $W(a_1 \dots a_r : b_1 \dots b_r) = \sum_{i=1}^r w_i = - \sum_{i=1}^r \log p(b_i \rightarrow a_i) =$
 $-\log \prod_{i=1}^r p(b_i \rightarrow a_i) \approx -\log p(b_1 \dots b_r \rightarrow a_1 \dots a_r) \approx$
 $-\log p(v \rightarrow u).$
- Вес преобразования $u : v$ — (приблизительно) отрицательный логарифм вероятности получить v из u .
- Кажется весьма разумным...
- Но есть недостаток...

Вероятностная модель исправления опечаток

- Кажется естественным выбирать в качестве исправления c для слова u наиболее вероятное слово: $c = \operatorname{argmax}_v p(v|u)$.

Вероятностная модель исправления опечаток

- Кажется естественным выбирать в качестве исправления c для слова u наиболее вероятное слово: $c = \operatorname{argmax}_v p(v|u)$.
- У нас же $p(u|v)$, как перейти?

Вероятностная модель исправления опечаток

- Кажется естественным выбирать в качестве исправления c для слова u наиболее вероятное слово: $c = \operatorname{argmax}_v p(v|u)$.
- У нас же $p(u|v)$, как перейти?
- Формула Байеса:

$$p(v|u) = \frac{p(u|v)p(v)}{p(u)}$$

Вероятностная модель исправления опечаток

- Кажется естественным выбирать в качестве исправления c для слова u наиболее вероятное слово: $c = \operatorname{argmax}_v p(v|u)$.
- У нас же $p(u|v)$, как перейти?
- Формула Байеса:

$$p(v|u) = \frac{p(u|v)p(v)}{p(u)}$$

- $p(u)$ не влияет на выбор кандидата, поэтому:

$$c = \operatorname{argmax}_v p(u|v)p(v)$$

Вероятностная модель исправления опечаток

- Кажется естественным выбирать в качестве исправления c для слова u наиболее вероятное слово: $c = \operatorname{argmax}_v p(v|u)$.
- У нас же $p(u|v)$, как перейти?
- Формула Байеса:

$$p(v|u) = \frac{p(u|v)p(v)}{p(u)}$$

- $p(u)$ не влияет на выбор кандидата, поэтому:

$$c = \operatorname{argmax}_v p(u|v)p(v)$$

- В модели весов это соответствует формуле $W(a_1 \dots a_r : b_1 \dots b_r) = - \sum_{i=1}^r \log p(b_i \rightarrow a_i) - \log p(v)$, где $v = b_1 \dots b_r$ — искомое словарное слово.

Вероятностная модель исправления опечаток

- Кажется естественным выбирать в качестве исправления c для слова u наиболее вероятное слово: $c = \operatorname{argmax}_v p(v|u)$.
- У нас же $p(u|v)$, как перейти?
- Формула Байеса:

$$p(v|u) = \frac{p(u|v)p(v)}{p(u)}$$

- $p(u)$ не влияет на выбор кандидата, поэтому:

$$c = \operatorname{argmax}_v p(u|v)p(v)$$

- В модели весов это соответствует формуле $W(a_1 \dots a_r : b_1 \dots b_r) = - \sum_{i=1}^r \log p(b_i \rightarrow a_i) - \log p(v)$, где $v = b_1 \dots b_r$ — искомое словарное слово.
- Добавим $-\log p(v)$ в качестве выходного веса в автомат A_{dict} в вершину, соответствующую слову v .

Финальный алгоритм

Финальный алгоритм поиска слов-кандидатов:

- Взять словарь с проставленными вероятностями слов $p(c)$ (вероятности собрать из корпуса), преобразовать во взвешенный автомат с выходными весами $-\log p(c)$.

Финальный алгоритм

Финальный алгоритм поиска слов-кандидатов:

- Взять словарь с проставленными вероятностями слов $p(c)$ (вероятности собрать из корпуса), преобразовать во взвешенный автомат с выходными весами $-\log p(c)$.
- Построить (можно неявно) взвешенный автомат $A_{w,d}$ для текущего слова w и порога расстояния d .

Финальный алгоритм

Финальный алгоритм поиска слов-кандидатов:

- Взять словарь с проставленными вероятностями слов $p(c)$ (вероятности собрать из корпуса), преобразовать во взвешенный автомат с выходными весами $-\log p(c)$.
- Построить (можно неявно) взвешенный автомат $A_{w,d}$ для текущего слова w и порога расстояния d .
- Вернуть список слов из языка $L(A_{dict} \cap A_{w,d})$ с их весами.

Финальный алгоритм

Финальный алгоритм поиска слов-кандидатов:

- Взять словарь с проставленными вероятностями слов $p(c)$ (вероятности собрать из корпуса), преобразовать во взвешенный автомат с выходными весами $-\log p(c)$.
- Построить (можно неявно) взвешенный автомат $A_{w,d}$ для текущего слова w и порога расстояния d .
- Вернуть список слов из языка $L(A_{dict} \cap A_{w,d})$ с их весами.
- Вернуть кандидата/несколько кандидатов наименьшего веса.

Финальный алгоритм

Финальный алгоритм поиска слов-кандидатов:

- Взять словарь с проставленными вероятностями слов $p(c)$ (вероятности собрать из корпуса), преобразовать во взвешенный автомат с выходными весами $-\log p(c)$.
- Построить (можно неявно) взвешенный автомат $A_{w,d}$ для текущего слова w и порога расстояния d .
- Вернуть список слов из языка $L(A_{dict} \cap A_{w,d})$ с их весами.
- Вернуть кандидата/несколько кандидатов наименьшего веса.
- Последняя проблема: как вычислять веса?

Вероятности опечаток

- Вероятности замен можно настроить по корпусу опечаток или с помощью эвристик.

Вероятности опечаток

- Вероятности замен можно настроить по корпусу опечаток или с помощью эвристик.
- Эвристики: что влияет на веса замен:
 - Опечатки: расположение символов на клавиатуре

Вероятности опечаток

- Вероятности замен можно настроить по корпусу опечаток или с помощью эвристик.
- Эвристики: что влияет на веса замен:
 - Опечатки: расположение символов на клавиатуре
 - Орфографические ошибки: фонетическая близость

Вероятности опечаток

- Вероятности замен можно настроить по корпусу опечаток или с помощью эвристик.
- Эвристики: что влияет на веса замен:
 - Опечатки: расположение символов на клавиатуре
 - Орфографические ошибки: фонетическая близость
 - Ошибки распознавания: графическая близость

Вероятности опечаток

- Вероятности замен можно настроить по корпусу опечаток или с помощью эвристик.
- Эвристики: что влияет на веса замен:
 - Опечатки: расположение символов на клавиатуре
 - Орфографические ошибки: фонетическая близость
 - Ошибки распознавания: графическая близость
- Веса можно настраивать и автоматически по обычному корпусу (*EM*-алгоритм), хотя это достаточно трудоёмко.

Онлайн-материалы

- <http://norvig.com/spell-correct.html> — страница Питера Норвига. Простейшая работающая программа для исправления опечаток из 21 строчки (Python 2.5).

Онлайн-материалы

- <http://norvig.com/spell-correct.html> — страница Питера Норвига. Простейшая работающая программа для исправления опечаток из 21 строчки (Python 2.5).
- Ещё много материалов: <http://norvig.com>

Онлайн-материалы

- <http://norvig.com/spell-correct.html> — страница Питера Норвига. Простейшая работающая программа для исправления опечаток из 21 строчки (Python 2.5).
- Ещё много материалов: <http://norvig.com>
- <http://web.stanford.edu/class/cs124/lec/spelling.pdf> — лекция Дэниэла Журафски по исправлению опечаток.