

## Часть III

# Структурный подход в распознавании образов (2)

## └ Введение в синтаксический подход к распознаванию образов

## Разделы

### Введение в синтаксический подход к распознаванию образов

Левенштейновская аппроксимация слова словом из регулярного языка

Введение в проблему

Основной результат

Алгоритм решения задачи РЛ

Что ещё почитать

## Разделы

Введение в синтаксический подход к распознаванию образов

**Левенштейновская аппроксимация слова словом из регулярного языка**

Введение в проблему

Основной результат

Алгоритм решения задачи РЛ

Что ещё почитать

└ Левенштейновская аппроксимация слова словом из регулярного языка

└ Введение в проблему

## Разделы

Введение в синтаксический подход к распознаванию образов

**Левенштейновская аппроксимация слова словом из регулярного языка**

Введение в проблему

Основной результат

Алгоритм решения задачи РЛ

Что ещё почитать

## └ Левенштейновская аппроксимация слова словом из регулярного языка

## └ Введение в проблему

## Отличие последовательности $\bar{x}$ от языка $L$

Пусть заданы

- ▶  $L$  — регулярный язык, задаваемый генерирующими автоматом  $\tilde{A} = \langle X, K, \varphi, P, \psi \rangle$ ;
- ▶  $d : X^* \times X^* \rightarrow \mathbb{R}$  — функция отличия слова  $\bar{x}_2 \in X^*$  от слова  $\bar{x}_1 \in X^*$ .

Отличие не обязательно (1) симметричная функция и (2) образует метрику на множестве последовательностей.

**Задача:** построить алгоритм, который для каждого слова  $\bar{x} \in X^*$  и каждого регулярного языка  $L \subset X^*$  вычисляет отличие слова  $\bar{x}$  от языка  $L$  — число

$$D(\bar{x}) = \min_{\bar{y} \in L} \{ d(\bar{y}, \bar{x}) \}.$$

Далее рассматривается случай, когда функция  $d$  принадлежит классу т.н. левенштейновских функций.

└ Левенштейновская аппроксимация слова словом из регулярного языка

└ Введение в проблему

## В.И. Левенштейн



*Владимир Иосифович Левенштейн*  
(20.05.1935) — российский учёный-математик,  
д.ф.-м.н, вед.н.с. ИПМ им. М. В. Келдыша.

В 1965 г. ввёл понятие расстояния  
редактирования для  
0-1 последовательностей.

В 2006 году получил престижную  
награду США — Медаль Ричарда Хэмминга.

Пример: чтобы перевести слово КОНЬ в слово КОТ нужно  
совершить одно удаление и одну замену, соответственно  
расстояние Левенштейна составляет 2:

КОНЬ  $\xrightarrow{\text{заменяем Н на Т}}$  КОТЬ  $\xrightarrow{\text{удаляем Ъ}}$  КОТ

└ Левенштейновская аппроксимация слова словом из регулярного языка

└ Введение в проблему

## Операции редактирования слов

Определим 3 операции посимвольного редактирования слов и действительные неотрицательные функции их стоимости (все символы  $x, x' \in X$ , все слова  $\bar{x} \in X^*$ ):

**I**Insert (вставка) преобразует слово  $\bar{x}_1\bar{x}_2$  в слово  $\bar{x}_1x\bar{x}_2$ ,  
стоимость —  $in(x)$ ;

**C**Change (замена) преобразует слово  $\bar{x}_1x\bar{x}_2$  в слово  $\bar{x}_1x'\bar{x}_2$ ,  
стоимость —  $ch(x, x')$ ;

**D**Elete (исключение) преобразует слово  $\bar{x}_1x\bar{x}_2$  в слово  $\bar{x}_1\bar{x}_2$ ,  
стоимость —  $de(x)$ .

Стоимость последовательности операций = сумма стоимостей операций, входящих в эту последовательность; стоимость пустой последовательности операций = 0.

└ Левенштейновская аппроксимация слова словом из регулярного языка

└ Введение в проблему

## Операции редактирования слов

### Определение

Стоимость  $d(\bar{x}_1, \bar{x}_2)$  самой дешёвой последовательности редакторских операций, преобразующей  $\bar{x}_1 \rightarrow \bar{x}_2$  называют левенштейновым отличием слова  $\bar{x}_2$  от слова  $\bar{x}_1$ .

Нахождение стоимости  $d(\bar{x}_1, \bar{x}_2)$  — непростая задача: существует бесконечное количество последовательностей редакторских операций преобразования  $\bar{x}_1 \rightarrow \bar{x}_2$ .

Левенштейновы функции стоимости не обязательно задают метрику на множестве слов: они могут не удовлетворять условию треугольника и быть несимметричными.

└ Левенштейновская аппроксимация слова словом из регулярного языка

└ Введение в проблему

## Операции редактирования слов...

Определение левенштейновского отличия провоцирует предположения о некоторых свойствах, кажущихся очевидными, но не имеющих места в действительности.

Основанные на таких предположениях алгоритмы решают только некоторые задачи из указанного класса, а в общем случае их оптимальность не гарантируется и они выдают псевдорешение.

Поэтому нужно точно описать подкласс задач, решаемый таким алгоритмом правильно.

Известный и часто применяемый алгоритм вычисления функций Левенштейна является ярким примером такого псевдорешения.

Левенштейновская аппроксимация слова словом из регулярного языка

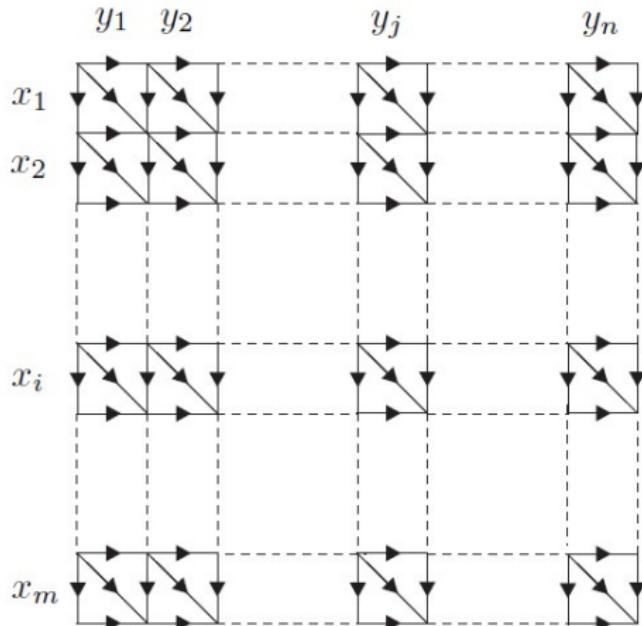
Введение в проблему

## Наивный алгоритм вычисления $d(\bar{y}, \bar{x})$

$\bar{x} = (x_1, \dots, x_i, \dots, x_m)$ ,  $\bar{y} = (y_1, \dots, y_j, \dots, y_n)$  — слова из  $X^*$ .

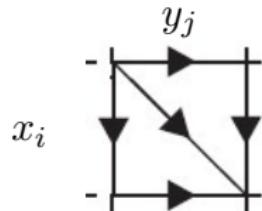
Алгоритм вычисления стоимости  $d(\bar{y}, \bar{x})$  преобразования

$\bar{y} \rightarrow \bar{x}$  зададим на графе  $\Gamma_0(\bar{y}, \bar{x})$ :



Левенштейновская аппроксимация слова словом из регулярного языка  
 Введение в проблему

## Наивный алгоритм вычисления $d(\bar{y}, \bar{x})$ ...



$i$ -ой строке приписан  $i$ -й символ слова  $\bar{x}$ .  
 $j$ -му столбцу приписан  $j$ -й символ слова  $\bar{y}$ .

Рёбра (стрелки) задают множество допустимых путей из левого верхнего угла

графа в правый нижний и каждому пути соответствует последовательность редакторских операций преобразования  $\bar{y} \rightarrow \bar{x}$  слов: прохождению

- ▶ вертикальной стрелке в  $i$ -й строке соответствует вставка символа  $x_i$ ;
- ▶ горизонтальной стрелке  $j$ -м столбце соответствует исключение символа  $y_j$ ;
- ▶ диагональной стрелке в  $i$ -й и  $j$ -м столбце соответствует замена  $y_j \mapsto x_i$  символов.

Левенштейновская аппроксимация слова словом из регулярного языка

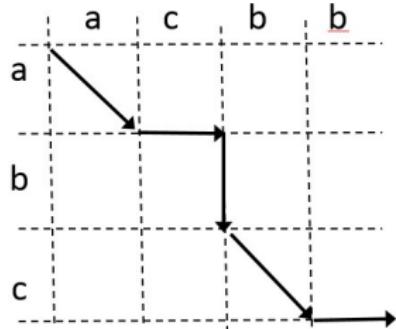
Введение в проблему

## Наивный алгоритм вычисления $d(\bar{y}, \bar{x})$ ...

Слова обрабатываются последовательно «слева направо»: на каждом шаге преобразуемое слово имеет вид  $\bar{x}'\bar{y}'$ , где  $\bar{x}'$  — префикс слова  $\bar{x}$ , а  $\bar{y}'$  — окончание слова  $\bar{y}$ .

Пример. Пусть  $X = \{a, b, c\}$ .

Преобразуем по данному алгоритму слово  $\bar{y} = acbb$  в слово  $\bar{x} = abc$  по указанному пути:



a	c	b	b
a	c	b	b
a	b	b	
a	b	b	b
a	b	c	b
a	b	c	

└ Левенштейновская аппроксимация слова словом из регулярного языка  
└ Введение в проблему

## Наивный алгоритм вычисления $d(\bar{y}, \bar{x})\dots$

Присвоим стрелкам неотрицательные длины: длина каждой

- ▶ вертикальной стрелки в  $i$ -й строке равна стоимости  $in(x_i)$ ;
- ▶ горизонтальной стрелки в  $j$ -м столбце — стоимости  $de(y_j)$ ;
- ▶ наклонной стрелки в  $i$ -ой строке и  $j$ -ом столбце — стоимости  $ch(y_j, x_i)$ .

Длина каждого пути = стоимость последовательности операций, которую этот путь представляет.

**Вроде бы:** поиск оптимальной слова операций преобразования  $\bar{y} \rightarrow \bar{x}$  сводится к поиску кратчайшего пути на графе от верхнего левого угла к правому нижнему?

Покажем ошибочность данного предположения.

## └ Левенштейновская аппроксимация слова словом из регулярного языка

## └ Введение в проблему

**Наивный алгоритм вычисления  $d(\bar{y}, \bar{x})$ ...**

Пример. Пусть в алфавите  $X = \{a, b, c, d\}$  даны слова  
 $\bar{x} = (b)$ ,  $\bar{y} = (b)$ ; вычислить  $d(\bar{y}, \bar{x})$ .

*a*

Ответ. По графу  $\Gamma_0(\bar{y}, \bar{x})$ :  $d(\bar{y}, \bar{x}) =$   
 $= \min \{ ch(a, b), de(a) + in(b), in(b) + de(a) \}$ .

Но имеется и много других вариантов, например:

$$a \xrightarrow{ch(a,c)} c \xrightarrow{de(c)} d \xrightarrow{in(d)} b$$

Граф  $\Gamma_0$  представляет лишь очень малую часть всех возможных редакторских операций преобразования  $a \rightarrow b$ .  
 $\therefore$  наивный алгоритм решает задачу правильно только в случае, когда он содержит самую дешевую последовательность.

Вывод: задача определения левенштейнового отличия слова от заданного языка должна быть строго формализована.

└ Левенштейновская аппроксимация слова словом из регулярного языка

└ Введение в проблему

## Граф преобразований слов

Определим бесконечный направленный мультиграф граф  $\Gamma$ :

- ▶  $V(\Gamma) \leftrightarrow X^*$  — множество всех слов конечной длины над конечным алфавитом  $X$ .
- ▶  $E(\Gamma)$  составляют дуги 3 типов  $in$ ,  $de$  и  $ch$ : две вершины, соответствующие последовательностям вида

$\bar{x}_1\bar{x}_2$  и  $\bar{x}_1x\bar{x}_2$  соединяют дуги типа  $in$  длины  $in(x)$  от первой вершины ко второй и типа  $de$  длины  $de(x)$  от второй вершины к первой;

$\bar{x}_1y\bar{x}_2$  и  $\bar{x}_1x\bar{x}_2$  соединяют дуги типа  $ch$  длины  $ch(y, x)$  от первой вершины ко второй и длины  $ch(x, y)$  от второй вершины к первой.

*Левенштейново отличие* — функция  $d : X^* \times X^* \rightarrow \mathbb{R}_{\geq 0}$ , значение которой  $d(\bar{y}, \bar{x})$  для пары  $\bar{y}, \bar{x}$  есть длина кратчайшего пути в  $\Gamma$  от вершины  $\bar{y}$  до вершины  $\bar{x}$ .

└ Левенштейновская аппроксимация слова словом из регулярного языка

└ Введение в проблему

## Свойства функций Левенштейна

Лемма (о порядке редакторских операций)

Для любых двух слов  $\bar{y}$  и  $\bar{x}$  из  $X^*$  существует кратчайший путь

- ▶ начинающийся последовательностью стрелок типа *in*,
- ▶ за которой следует последовательность стрелок типа *ch*,
- ▶ и завершающейся последовательностью стрелок типа *de*,

причём любая из этих последовательностей может быть пустой.

Доказательство.

Пусть  $\bar{y}, \bar{x}_1, \bar{x}_2, \dots, \bar{x}_n, \bar{x}$  — кратчайший путь от вершины  $\bar{y}$  к вершине  $\bar{x}$ , который не обладает указанным свойством, что обнаруживается при последовательных переходах от  $\bar{x}_{i-1}$  к  $\bar{x}_i$  и от  $\bar{x}_i$  к  $\bar{x}_{i+1}$ :

$$\bar{x}_{i-1} \longrightarrow \bar{x}_i \longrightarrow \bar{x}_{i+1}$$

└ Левенштейновская аппроксимация слова словом из регулярного языка

└ Введение в проблему

**Свойства функций Левенштейна:**  $in - ch - de$

Это может произойти только в трёх следующих ситуациях.

① Дуга  $(\bar{x}_{i-1}, \bar{x}_i)$  имеет тип  $ch$ , а дуга  $(\bar{x}_i, \bar{x}_{i+1})$  — тип  $in$ .

Это значит, что слова  $\bar{x}_{i-1}, \bar{x}_i, \bar{x}_{i+1}$  имеют один из двух следующих видов:

$$\left\{ \begin{array}{l} \bar{x}_{i-1} = \bar{x}'y\bar{x}''\bar{x}''', \\ \bar{x}_i = \bar{x}'x\bar{x}''\bar{x}''', \\ \bar{x}_{i+1} = \bar{x}'x\bar{x}''z\bar{x}''' , \end{array} \right. \text{или} \quad \left\{ \begin{array}{l} \bar{x}_{i-1} = \bar{x}'\bar{x}''y\bar{x}''', \\ \bar{x}_i = \bar{x}'\bar{x}''x\bar{x}''', \\ \bar{x}_{i+1} = \bar{x}'z\bar{x}''x\bar{x}''' . \end{array} \right.$$

В первом случае заменяем вершину  $\bar{x}_i$  на  $\bar{x}'y\bar{x}''z\bar{x}'''$ , а во втором — на  $\bar{x}'z\bar{x}''y\bar{x}'''$ .

В обоих случаях получим новый путь из вершины  $\bar{y}$  в вершину  $\bar{x}$  с той же длиной, но в этом пути первая рассматриваемая стрелка будет иметь тип  $in$ , а вторая — тип  $ch$ .

└ Левенштейновская аппроксимация слова словом из регулярного языка

└ Введение в проблему

## Свойства функций Левенштейна: $in - ch - de\dots$

② Дуга  $(\bar{x}_{i-1}, \bar{x}_i)$  имеет тип  $de$ , а дуга  $(\bar{x}_i, \bar{x}_{i+1})$  — тип  $in$ .

Это значит, что слова  $\bar{x}_{i-1}, \bar{x}_i, \bar{x}_{i+1}$  имеют один из двух следующих видов ( $\bar{x}', \bar{x}'', \bar{x}''' \in X^*$ ,  $x, y \in X$ ):

$$\left\{ \begin{array}{lcl} \bar{x}_{i-1} & = & \bar{x}'y\bar{x}''\bar{x}''', \\ \bar{x}_i & = & \bar{x}'\bar{x}''\bar{x}''', \\ \bar{x}_{i+1} & = & \bar{x}'\bar{x}''x\bar{x}''', \end{array} \right. \quad \text{или} \quad \left\{ \begin{array}{lcl} \bar{x}_{i-1} & = & \bar{x}'\bar{x}''y\bar{x}''', \\ \bar{x}_i & = & \bar{x}'\bar{x}''\bar{x}''', \\ \bar{x}_{i+1} & = & \bar{x}'x\bar{x}''\bar{x}'''. \end{array} \right.$$

В первом случае вершину  $\bar{x}_i$  заменяем на  $\bar{x}'y\bar{x}''x\bar{x}'''$ , а во втором — на  $\bar{x}'x\bar{x}''y\bar{x}'''$ .

В обоих случаях получим новый путь с той же длиной, но в этом пути первая рассматриваемая стрелка будет иметь тип  $in$ , а вторая — тип  $de$ .

└ Левенштейновская аппроксимация слова словом из регулярного языка

└ Введение в проблему

**Свойства функций Левенштейна:**  $in - ch - de\dots$

③ Дуга  $(\bar{x}_{i-1}, \bar{x}_i)$  имеет тип  $de$ , а дуга  $(\bar{x}_i, \bar{x}_{i+1})$  — тип  $ch$ .  
Это возможно в двух случаях:

$$\left\{ \begin{array}{l} \bar{x}_{i-1} = \bar{x}'x\bar{x}''y\bar{x}''', \\ \bar{x}_i = \bar{x}'\bar{x}''y\bar{x}''', \\ \bar{x}_{i+1} = \bar{x}'x\bar{x}''z\bar{x}''' \end{array} \right. \text{или} \quad \left\{ \begin{array}{l} \bar{x}_{i-1} = \bar{x}'y\bar{x}''x\bar{x}''', \\ \bar{x}_i = \bar{x}'y\bar{x}''\bar{x}''', \\ \bar{x}_{i+1} = \bar{x}'z\bar{x}''\bar{x}''' \end{array} \right.$$

Заменяем в первом случае вершину  $\bar{x}_i$  на  $\bar{x}'x\bar{x}''z\bar{x}'''$ , а во втором — на  $\bar{x}'z\bar{x}''x\bar{x}'''$ .

В обоих случаях получим новый путь с той же длиной, но в этом пути первая рассматриваемая стрелка будет иметь тип  $ch$ , а вторая — тип  $de$ .

Последовательно изменяя путь от  $\bar{y}$  до  $\bar{x}$  по указанным правилам, найдем путь, в котором ни одна из указанных трех ситуаций не встретится.

└ Левенштейновская аппроксимация слова словом из регулярного языка

└ Введение в проблему

## Эквивалентное определение левенштейнова отличия

— на основе доказанной леммы.

① Определим три частных отличия  $d_{in}$ ,  $d_{ch}$  и  $d_{de}$  по построенному кратчайшему пути: они равны длинам пути по стрелкам соответствующего типа, при этом если  $\bar{y} = \bar{x}$ , то полагаем все отличия равными 0, а если пути по стрелкам данного типа нет, то полагаем соответствующее отличие равным  $\infty$ .

② Введём новые «длинные» стрелки в графе  $\Gamma$  (ранее введённые — «короткие»):

- ▶ если  $\bar{x}$  получена из  $\bar{y}$  вставкой некоторых символов, то введём в граф  $\Gamma$  две длинные стрелки: типа  $in$  от  $\bar{y}$  до  $\bar{x}$  длины  $d_{in}(\bar{y}, \bar{x})$  и типа  $de$  от  $\bar{x}$  до  $\bar{y}$  длины  $d_{de}(\bar{x}, \bar{y})$ ;
- ▶ если  $\bar{x}$  и  $\bar{y}$  имеют одинаковую длину, введём в граф  $\Gamma$  длинную стрелку типа  $ch$  от  $\bar{y}$  до  $\bar{x}$  длины  $d_{ch}(\bar{y}, \bar{x})$ .

## └ Левенштейновская аппроксимация слова словом из регулярного языка

## └ Введение в проблему

## Эквивалентное определение левенштейнова отличия...

Ясно, что

- ▶ длина кратчайшего пути от  $\bar{y}$  до  $\bar{x}$  по коротким стрелкам  
= длине кратчайшего пути по длинным стрелкам,
- ▶ и один из этих кратчайших путей содержит не более, чем  
три длинные стрелки типа  $in$ ,  $ch$  и  $de$ , идущие друг за  
другом в указанном порядке.

Математическое представлением этого высказывания —

$$d(\bar{y}, \bar{x}) = \min_{\bar{z}_1 \in X^*} \min_{\bar{z}_2 \in X^*} \{ d_{in}(\bar{y}, \bar{z}_1) + d_{ch}(\bar{z}_1, \bar{z}_2) + d_{de}(\bar{z}_2, \bar{x}) \}$$

не годится для конструктивного вычисления  $d(\bar{y}, \bar{x})$ , но  
полезно, т.к. раскладывает понятие левенштейнова отличия на  
три частные понятия: его вычисление сводится к отысканию  
двух вспомогательных слов  $\bar{z}_1$  и  $\bar{z}_2$  и  $|\bar{y}| \leq |\bar{z}_1| = |\bar{z}_2| \geq |\bar{x}|$ .

└ Левенштейновская аппроксимация слова словом из регулярного языка

└ Основной результат

## Разделы

Введение в синтаксический подход к распознаванию образов

**Левенштейновская аппроксимация слова словом из регулярного языка**

Введение в проблему

Основной результат

Алгоритм решения задачи РЛ

Что ещё почитать

└ Левенштейновская аппроксимация слова словом из регулярного языка

└ Основной результат

## Задача РЛ вычисления расстояния Левинштейна

Пусть для конечного алфавита  $X$  заданы:

- ▶ регулярный язык  $L$  как подмножество  $\{(x_1, \dots, x_n)\}$  слов  $X^*$ , генерируемых автоматом  $\tilde{\mathcal{A}} = \langle X, K, \varphi, P, \psi \rangle$ , т.е. для которых справедливо утверждение

$$\bigvee_{k_0 \in K} \dots \bigvee_{k_n \in K} \varphi(k_0) \& \bigwedge_{i=1}^n P(k_{i-1}, x_i, k_i) \& \psi(k_n);$$

- ▶ три функции  $in$ ,  $ch$  и  $de$  на  $X^*$ ,  $(X^*)^2$  и  $X^*$  соответственно, определяющие левенштейново отличие слов  $d : (X^*)^2 \rightarrow \mathbb{R}_{\geq 0}$ .

Задача РЛ: создать алгоритм, который для каждого слова  $\bar{x} \in X^*$  и каждой шестерки функций  $(\varphi, P, \psi, in, ch, de)$  вычисляет левенштейновское отличие

$$D(\bar{x}) = \min_{\bar{y} \in L} d(\bar{y}, \bar{x}).$$

└ Левенштейновская аппроксимация слова словом из регулярного языка

└ Основной результат

## Особенности задачи РЛ

- нахождение  $D(\bar{x}) = \min_{\bar{y} \in L} d(\bar{y}, \bar{x})$ .

Обычно рассматривают многомерные задачи нахождения  $\sup_x f(x)$  — оптимизации функций целевых функций  $f(x)$ , в которых

- ▶ количество переменных, может быть, большое заранее задано, в то время, как задача РЛ требуется найти слово с неизвестной заранее длиной из бесконечного множества;
- ▶ функция  $f(x)$ , заданными в виде явной формулы, а задаче РЛ функция  $d(\bar{y}, \bar{x})$ , не представлена в виде вспомогательной задачи её поиска.

Основная задача — оптимизация найденной в результате решения вспомогательной задачи функции  $d(\bar{y}, \bar{x})$ .

└ Левенштейновская аппроксимация слова словом из регулярного языка

└ Основной результат

## Эквивалентное представление левенштейнова отличия

### Теорема

Пусть  $X$  и  $K$  — два конечных множества,

$$\varphi : K \rightarrow \{0, 1\}, \quad P : K \times X \times K \rightarrow \{0, 1\}, \quad \psi : K \rightarrow \{0, 1\}$$

— три функции, определяющие регулярный язык  $L \subset X^*$  как множество слов  $(x_1, x_2, \dots, x_n)$ , для которых истинен предикат

$$\bigvee_{k_0 \in K} \dots \bigvee_{k_n \in K} \varphi(k_0) \& \bigwedge_{i=1}^n P(k_{i-1}, x_i, k_i) \& \psi(k_n).$$

Пусть также  $in : X \rightarrow \mathbb{R}$ ,  $ch : X \times X \rightarrow \mathbb{R}$ ,  $de : X \rightarrow \mathbb{R}$  — три неотрицательные функции, определяющие левенштейновы отличия  $d : X^* \times X^* \rightarrow \mathbb{R}$  и  $D : X^* \rightarrow \mathbb{R}$ ,

$$D(\bar{x}) = \min_{\bar{y} \in L} d(\bar{y}, \bar{x}).$$

└ Левенштейновская аппроксимация слова словом из регулярного языка

└ Основной результат

## Эквивалентное представление левенштейнова отличия...

Теорема (продолжение)

Тогда для каждой шестерки функций  $(\varphi, P, \psi, in, ch, de)$  существует такая пара функций  $P', \psi'$ , что равенство

$$D(\bar{x}) = \min_{k_0 \in K} \dots \min_{k_n \in K} \left\{ \varphi(k_0) + \sum_i^n P'(k_{i-1}, x_i, k_i) + \psi'(k_n) \right\}.$$

выполняется для любого слова  $(x_1, x_2, \dots, x_n) \in X^*$ .

└ Левенштейновская аппроксимация слова словом из регулярного языка

└ Основной результат

## Следствия и выводы

- ▶ Вычисление числа  $D(\bar{x}) = \min_{\bar{y} \in L} d(\bar{y}, \bar{x})$ , вопреки всей сложности его определения, имеет сложность  $O(|K|^2 n)$  что и при распознавании принадлежности слова  $\bar{x}$  обыкновенному, не штрафному, регулярному языку.
- ▶ Суммарная сложность определения  $\bar{y} \stackrel{?}{\in} L$  и вычисление  $d(\bar{y}, \bar{x})$  имеет порядок  $O(|K|^2 |\bar{y}| + |\bar{y}| |\bar{x}|)$ .  
Т.е. вычисление  $D(\bar{x})$  имеет сложность  $O(|K|^2 |\bar{x}|)$ , которая не зависит от  $|\bar{y}|$ , на которой достигается минимум, и более того, меньше, чем сложность вычисления числа  $d(\bar{y}, \bar{x})$  для некоторых слов  $\bar{y} \in L$ .

Эти вытекающие из теоремы замечательные свойства априори неправдоподобны.

## └ Левенштейновская аппроксимация слова словом из регулярного языка

## └ Основной результат

## Следствия и выводы...

- ▶ *Редакционным предписанием* называется последовательность действий, необходимых для получения из первой строки второй кратчайшим образом. К рассмотренным действиям (вставить, заменить, удалить) добавляют MATch) — совпадение.  
Найти только расстояние Левенштейна — более простая задача, чем найти ещё и редакционное предписание.
- ▶ Если к списку разрешённых операций добавить транспозицию (два соседних символа меняются местами), приходим к понятию *расстояния Дамерау — Левенштейна*. Расстояние Дамерау — Левенштейна используется —
  - ▶ при анализе текстов: Дамерау показал, что 80% ошибок при наборе текста человеком являются транспозициями;
  - ▶ в биоинформатике.

└ Левенштейновская аппроксимация слова словом из регулярного языка

└ Алгоритм решения задачи РЛ

## Разделы

Введение в синтаксический подход к распознаванию образов

**Левенштейновская аппроксимация слова словом из регулярного языка**

Введение в проблему

Основной результат

Алгоритм решения задачи РЛ

Что ещё почитать

└ Левенштейновская аппроксимация слова словом из регулярного языка

└ Алгоритм решения задачи РЛ

## Исходная постановка задачи (повторение)

Пусть даны конечные множества  $X$  и  $K$  и функции

$\varphi : K \rightarrow \{0, \infty\}$ ,  $P : K \times X \times K \rightarrow \{0, \infty\}$ ,  $\psi : K \rightarrow \{0, \infty\}$ , задающие множество  $L \in X^*$  слов, для которых существует такая слово  $(k_0, k_1, \dots, k_n)$ , что

- ①  $\varphi(k_0) = 0$ ,
- ②  $P(k_{i-1}, x_i, k_i) = 0$ ,  $i = \overline{1, n}$ ,
- ③  $\psi(k_n) = 0$ .

Пусть также даны также три функции  $in : X \rightarrow \mathbb{R}$ ,  $ch : X \times X \rightarrow \mathbb{R}$ ,  $de : X \rightarrow \mathbb{R}$ , которые определяют функцию  $d : X \times X \rightarrow \mathbb{R}$ , значения которой  $d(\bar{y}, \bar{x})$  есть левенштейново отличие слова  $\bar{x}$  от слова  $\bar{y}$ .

Задача: построить алгоритм, который для любой поданной на его вход слова  $\bar{x} \in X^*$  вычисляет число

$$D(\bar{x}) = \min_{\bar{y} \in L} d(\bar{y}, \bar{x}).$$

└ Левенштейновская аппроксимация слова словом из регулярного языка

└ Алгоритм решения задачи РЛ

## Алгоритм решения

Алгоритм вычисления  $D(\bar{x})$  состоит из двух частей.

I. Первая часть — подготовительная

и заключается в построении функций  $P'$  и  $\psi'$ , которые получают из функций  $P$ ,  $\psi$ ,  $in$ ,  $ch$ ,  $de$ .

Вычисления в этой части не зависят от входной слова  $\bar{x}$  и для данного множества  $L$  и данной левенштейновой функции выполняются только один раз.

II. Вторая часть вычислений зависит от входной слова и состоит собственно в вычислении  $D(\bar{x})$ .

└ Левенштейновская аппроксимация слова словом из регулярного языка

└ Алгоритм решения задачи РЛ

## Алгоритм решения: часть I.

- ① Построить функцию  $P_1 : K \times X \times K \rightarrow \mathbb{R}$ :

$$P_1(k', y, k'') = \begin{cases} \min \{ P(k', y', k''), \text{in}(y) \}, & \text{если } k' = k'', \\ P(k', y', k''), & \text{иначе.} \end{cases}$$

Числа  $P_1(k', y, k'')$  обозначают стоимость самого дешевого добавления символа  $y$  в конец строки при условии, что до этого автомат находился в состоянии  $k'$ , а после будет находится в состоянии  $k''$ . При

$k' \neq k''$  сгенерируемый автоматом символ  $y$  дописывается к строке, стоимость дописывания —  $P(k', y', k'')$ ;

$k' = k'' = k$  из этих двух возможностей: (1) символ  $y$  генерируется автоматом, стоимость  $P(k, y, k)$  и (2) символ  $y$  появляется в результате редакторской операции вставки со стоимостью  $\text{in}(y)$  — выбирается более дешевая.

└ Левенштейновская аппроксимация слова словом из регулярного языка

└ Алгоритм решения задачи РЛ

## Алгоритм решения: часть I...

② Построить функцию  $ch^* : X \times X \rightarrow \mathbb{R}$ , например, следующим образом: сначала положим  $ch^*(x, y) = 0$  при  $x = y$  и  $ch^*(x, y) = ch(x, y) = 0$ , иначе; затем эти числа многократно преобразуются оператором

$$ch^*(x, y) = \min_{z \in X} \{ ch^*(x, z) + ch^*(z, y) \}.$$

Число  $ch^*$  есть стоимость самой дешевой слова замен (возможно, пустой), превращающей символ  $x$  в символ  $y$ .

└ Левенштейновская аппроксимация слова словом из регулярного языка

└ Алгоритм решения задачи РЛ

## Алгоритм решения: часть I...

③ Построить функцию  $P_2 : K \times X \times K \rightarrow \mathbb{R}$ :

$$P_2(k', x, k'') = \min_{y \in X} \{ P_1(k', y, k'') + ch^*(y, x) \}.$$

Число  $P_2(k', x, k'')$  — это стоимость самого дешевого способа дописывания символа  $x$  в конец слова при условии, что до этого дописывания автомат находился в состоянии  $k'$ , а после дописывания — в состоянии  $k''$ .

Добавленный символ мог быть сгенерирован автоматом или вставлен редактором.

После этого с этим символом выполняется (или не выполняется) сколь угодно длинная слово замен, результатом которой является символ  $x$ , т.е. число  $P_2(k', x, k'')$  — результат оптимального выбора из довольно большого множества.

└ Левенштейновская аппроксимация слова словом из регулярного языка

└ Алгоритм решения задачи РЛ

## Алгоритм решения: часть I...

- ④ Построить вспомогательную функцию  $q : K \times K \rightarrow \mathbb{R}$ :

$$q(k', k'') = \begin{cases} 0, & \text{если } k' = k'', \\ \min_{x \in K} \{ P_2(k', x, k'') + de(x) \}, & \text{иначе.} \end{cases}$$

Число  $q(k', k'')$  есть стоимость самого дешевого процесса, в результате которого автомат переходит из состояния  $k'$  в состояние  $k''$ , причем такого, что после окончания процесса слово символов оказывается такой же, как до его начала, хотя в течение самого процесса к этой слова и дописывался какой-то символ.

Этот процесс состоит из следующих частей:

- ▶ добавление символа в конец слова, сгенерировав его автоматом или выполнив редакторскую вставку;
- ▶ слово (возможно, пустая) замен добавленного символа;
- ▶ исключение символа из слова.

└ Левенштейновская аппроксимация слова словом из регулярного языка

└ Алгоритм решения задачи РЛ

## Алгоритм решения: часть I...

- ⑤ Построить вспомогательную функцию  $q^* : K \times K \rightarrow \mathbb{R}$ :  
сначала выполнить присвоение

$$q^*(k', k'') = \begin{cases} 0, & \text{если } k' = k'', \\ q(k', k''), & \text{иначе.} \end{cases}$$

Затем многократно выполнить оператор

$$q^*(k', k'') = \min_{k \in K} \{ q^*(k', k) + q^*(k, k'') \}.$$

Число  $q^*(k', k'')$  подобно числу  $q(k', k'')$ , а различие в том, что последнее число есть стоимость самого дешевого способа перехода из состояние, при котором разрешено один и только один раз дописать символ в слово, выполнить с ним ряд замен и исключить, а первое — стоимость самого дешевого способа перехода из состояния  $k'$  в состояние  $k''$ , при котором в слово дописывается какоеугодно количество символов, включая нулевое, выполняются с ними какие-угодно замены (или не выполняются их) и в конечном итоге все эти символы исключаются.

└ Левенштейновская аппроксимация слова словом из регулярного языка

└ Алгоритм решения задачи РЛ

## Алгоритм решения: часть I...

- ⑥ Построить функцию  $P : K \times X \times K \rightarrow \mathbb{R}$ :

$$P'(k', x, k'') = \min_{k \in K} \{ q^*(k', k) + P_2(k, x, k'') \}.$$

Число  $P'(k', x, k'')$  есть стоимость самого дешевого процесса, в результате которого автомат переходит из состояния  $k'$  в состояние  $k''$ , а слово символов наращивается символом  $x$ . Во время этого процесса автомат генерирует какую-то слово символов, с каждым из них выполняются какие-то замены, и в конечном итоге все они исключаются.

Затем в слово дописывается один символ, либо позволяя автомату сгенерировать его, либо вставляя его редактором, с этим символом выполняется ряд замен, и в конечном итоге он остается в слова.

└ Левенштейновская аппроксимация слова словом из регулярного языка

└ Алгоритм решения задачи РЛ

## Алгоритм решения: часть I...

- ⑦ Вычислить числа  $\psi'(k)$ :

$$\psi'(k) = \min_{k' \in K} \{ q^*(k, k') + \psi(k') \}.$$

Число  $\psi'(k)$  есть стоимость самого дешевого процесса следующего класса: автомат, находящийся в состоянии  $k$ , генерирует какую-то слово символов и оказывается в состоянии  $k'$ , в котором он прекращает работу, а затем каждый сгенерированный символ произвольное количество раз заменяется другим символом и в конечном итоге исключается.

└ Левенштейновская аппроксимация слова словом из регулярного языка

└ Алгоритм решения задачи РЛ

## Алгоритм решения: часть II

Вычислительная процедура вычислении  $D(\bar{x})$  имеет следующий вид: для поданной на вход алгоритма слова

$\bar{x} = (x_0, x_1, \dots, x_n)$  вычисляются числа

$f_i(k), k \in K, i = 0, 1, \dots, n$ , и число  $D(\bar{x})$  по формулам

$$f_0(k_0) = \varphi(k_0), k_0 \in K,$$

$$f_i(k_i) = \min_{k_{i-1} \in K} \{ f_{i-1}(k_{i-1}) + P'(k_{i-1}, x_i, k_i) \}, k_i \in K, i = \overline{1, n},$$

$$D(\bar{x}) = \min_{k_n \in K} \{ f_n(k_n) + \psi'(k_n) \}.$$

└ Левенштейновская аппроксимация слова словом из регулярного языка

└ Алгоритм решения задачи РЛ

## Алгоритм решения: замечания

«Что касается убедительности обоснованности [описанного алгоритма] ... то нам представляется почти безнадежным сделать это с помощью одних лишь так называемых разумных соображений, выраженных словами естественного языка».

Рассмотренный алгоритм реализует метод ближайшего соседа в случае, когда  $L$  есть регулярный язык, а  $d$  — есть функция Левенштейна.

Допустим, что на основании слова  $\bar{x} = (x_1, x_2, \dots, x_i, \dots, x_n)$  наблюдений нужно определить слово  $\bar{k} = (k_0, k_1, \dots, k_n)$  состояний. Все описанные в лекциях алгоритмы сходны в том, что решение о всей слова  $\bar{k}$  целиком принимается на основании всей слова  $\bar{x}$ .

Известны результаты по левенштейновой аппроксимации в более общем случае контекстно-свободных языков.

└ Что ещё почитать

---

## Разделы

Введение в синтаксический подход к распознаванию образов

Левенштейновская аппроксимация слова словом из регулярного языка

Введение в проблему

Основной результат

Алгоритм решения задачи РЛ

Что ещё почитать

## Литература |

-  Сойфер В.А. (ред.) Методы компьютерной обработки изображений. — М.: Физматлит, 2003.
-  Структурное распознавание образов. Учебно-методическое пособие для вузов. / Составитель Н. М. Новикова. — Воронеж: Издат.-полиграфич. центр Воронежского государств. унив-та, 2008.
-  Шлезингер М., Главач В. Десять лекций по статистическому и структурному распознаванию. — К.: Наукова думка, 2004.
-  Фу К. Структурные методы в распознавании образов. — М.: Мир, 1997.
-  Хэмминг Р.В. Цифровые фильтры. — М.: Сов. радио, 1980.