

Об одном способе осуществления синтеза предложения при МП /на основе синтагматического анализа/.

Ч. А. Хоар.

my first article, published
written summer 1960 in Машинный

По обычным представлениям, в результате синтагматического анализа получается список синтагм, т.е., список упорядоченных пар слов, первое из которых "подчиняет" второе, причем для каждой синтагмы имеется признак, указывающий на то, какой тип связи имеет место в данной синтагме. При синтезировании предложения /или на том же/ ямке, из списка пар надо получить линейную последовательность слов, образующую синтаксически и морфологически правильное предложение. При этом надо определить, какой именно набор признаков синтагм окажется наиболее удобным. В настоящей заметке я не буду рассматривать морфологическую сторону синтеза; я ограничусь вопросом *или* о расстановке слов в нужном *порядке* /что более существенно для синтеза предложения, например, на английском языке, и вообще представляется более сложной задачей/.

Предлагаемый метод синтеза основывается на том, что во многих языках линии зависимости не пересекаются, т.е., если слова a и b входят в одну синтагму (a, b) , и слова c и d входят в другую синтагму (c, d) , то эти слова нельзя ставить в таком порядке, что линия, проведенная между a и b пересекается с линией, проведенной между c и d . Это значит, следующие возможности исключаются:

$a \dots b \dots c \dots d$	$a \dots d \dots b$
$a \dots c \dots b \dots d$	$d \dots a \dots c \dots b$
$a \dots c \dots d \dots b$	$c \dots b \dots d \dots a$
$b \dots d \dots a \dots c$	$d \dots b \dots c \dots a$

4) Это утверждение верно во всех случаях, когда легко по интуиции установить линии зависимости. В разборе более сложных случаев, надо обеспечить, чтобы осталось верным.

Мы можем использовать этот факт, если мы синтезируем фразу слева направо /размещая сперва первое слово, потом второе, и так далее/. Положим, что на данном шагу мы правильно расставили первые n слов /которые мы в дальнейшем обозначим расставленными словами/. Мы размещаем теперь $n+1$ ое слово /разумеется, среди нерасставленных слов/. И здесь полезно определить понятие "косвенной зависимости". Слово a прямо зависит от слова b , если существует синтагма (b, a) x в анализируемом предложении; слово a косвенно зависит от слова b , если существует в анализируемом предложении последовательность слов x_1, x_2, \dots, x_n , причем x_1 прямо зависит от b , x_{i+1} прямо зависит от x_i /для каждого i / и a прямо зависит от x_n . Иными словами, b является в некотором смысле "предком" слова a . Теперь мы можем сформулировать следующие правила:

I. Если существует не расставленное слово, прямо зависящее от n -ого слова, то в качестве $n+1$ -ого слова нельзя выбрать слово, которое не зависит /прямо или косвенно/ от n -ого слова /если бы мы выбрали такое слово, это неизбежно привело бы к пересечению линий зависимости/.

II. Если не существует слова, зависящего от n -ого, но есть слово, подчиняющее n -ое слово, то можно выбрать в качестве $n+1$ -ого слова только это слово или слово, прямо или косвенно зависящее от него.

Мы могли бы привести другие правила, ограничивающие возможности выбора следующего слова; но достаточно этих двух, чтобы показать каким именно образом выбор очередного слова может быть значительно сокращен.

Такие правила, однако, не определяют однозначно какое именно слово надо выбрать в случае если существует больше одного нерасставленного слова, зависящего от последнего / n -ого/ и расставленного слова. Для таких случаев мы вводим особые признаки синтагм. Эти признаки должны указывать, стоит ли зависящее слово налево или направо от управляющего слова, и как "тесно" они связаны. В качестве таких признаков используются целые числа: отрицательные числа обозначают, что зависящее слово стоит налево, и положительные числа - направо; причем меньшая абсолютная величина обозначает более тесную связь, и наоборот.

Если слово b более тесно связано со словом a чем c , это обозначает, что b должно стоять ближе к a чем c , т.е., порядок слов будет a, b, c /в случае левой зависимости/ или a, c, b /в случае правой зависимости/.

Положим теперь, что два нерасставленных слова b и c зависят от последнего / a / слова в синтагмах $+1(a, b)$ и $+3(a, c)$. В таком случае мы не можем выбрать слово c , так как b более тесно связано с a чем c / $|+1| < |+3|$ /.

/Здесь мы предполагаем, что признаки приписываются с таким расчетом, чтобы никогда не встречались два слова, зависящих от данного слова с одним и тем же признаком/.

Но мы еще не можем сказать, что именно b есть следующее слово: если другое слово d "зависит налево" /т.е., с отрицательным признаком/ от слова b , то d непременно должно стоять перед b . Если два слова "зависят налево" от b , то мы выбираем в качестве "кандидата" на следующее место то слово, которое менее тесно связано с b , то есть, которое должно стоять дальше налево от него. Обозначим это слово e . Если не существует не расставленного слова, зависящего от e налево, мы можем определенно ставить e на $n+1$ -ом месте, и потом весь процесс начинается с самого начала. Если, однако, существуют слова, зависящие от e налево, мы выбираем на место "кандидата" то слово, которое должно стоять дальше налево: бывший кандидат e отвергается. Мы продолжаем этот процесс, пока не найдем "кандидат", от которого ничего не зависит налево: именно это слово будет $n+1$ -ым словом в синтезируемом предложении. Можно грубо описать изложенный процесс следующим образом: искать "первое" слово, зависящее направо от последнего расставленного слова; обозначим его b . Потом искать "крайнее" слово, прямо или косвенно зависящее налево от b : ставить это слово на следующем месте после a .

полагать минимальным признаком

Я еще не рассматривал такой случай, когда не существует не расставленного слова, зависящего направо от последнего расставленного слова. Этот случай легко разбирается. Мы переходим на $n-1$ ое слово, и обрабатываем его как будто оно и является последним расставленным словом: если и у него нет зависящих направо, то мы переходим на $n-2$ ое слово, и т.д. Но когда мы нашли искомое слово w_{i+1} , мы всё равно ставим его на $n+1$ ом месте: никаких вставок не может быть.

До сих пор я предполагал, что мы уже расставили первые n слов: теперь надо объяснить как выбирается первое слово /в случае $n=0$ /. Здесь мы рассматриваем такой метод анализа, при котором остается одно и только одно слово, которое не зависит от другого слова. В самом начале синтеза удобно взять это независимое слово в качестве "первого" слова, и, идя слева направо, синтезировать вышеописанным образом ту часть фразы, которая стоит направо от него. Потом мы синтезируем левую часть фразы, начиная еще раз с независимого слова, но идя теперь справа налево. При этом, можно использовать тот же самый алгоритм, если только заменить повсюду слова "правое" на "левое", "за" на "перед", и "следующее" на "предыдущее".

Остается теперь лишь один вопрос: каким образом приписать синтагмам признаки, т.е., как определить "тесноту" связей в синтезируемом предложении. Здесь я возьму в качестве иллюстрации английский язык. Можно перечислить для примера некоторые типы синтагм, в которых существительное фигурирует как управляющий член.

Тип синтагмы	Пример	Признак
(S, артикль)	the	-3
(S, прилагательное)	new	-2
(S, S как прилагательное)	Leica camera	-1
(S, S в оппозиции)	(type III)	+1
(S, предлог)	in a leather case	+2
(S, причастие)	bought in Germany	+3
(S, соч. союз)	, and an exposure metre	+4

Достоинство предлагаемого метода состоит в следующем :

1 Лингвистическая проблема синтеза целого предложения /в случае регулярности/ к проблеме правильной расстановке только двух слов, зависящих от одного слова /так как правильный порядок всех слов, зависящих от данного слова однозначно определяется, если только знать правильный порядок всех пар слов. Тогда можно составить алгоритм который приписывает синтагмам нужные признаки.

2 Алгоритм имеет циклический характер, так что программа будет очень проста, и для реализации процесса понадобится незначительное число ячеек машинной памяти.

Недостатком предлагаемого метода является то обстоятельство, что его осуществление требует много машинных операций : чтобы найти на каждом шагу крайнее слово налево, надо будет пройти несколько раз весь список синтагм. Этот недостаток может быть существенен, если мы переводим на язык, в котором вообще мало приходится переставить.

Автор хочет выразить свою благодарность И.А.Мельчуку который ~~внимательно~~ поправил изложение во многих местах, и вел со мной разговоры, на которых эта статья основана.

thoare

Customer Order Form_N1.pdf
27-09-06 10:06



thoare

India.pdf
27-09-06 10:05

