ОСНОВЫ ОБРАБОТКИ ТЕКСТОВ

Лекция #6:
Синтаксический анализ

Лектор: м.н.с. ИСП РАН Майоров Владимир Дмитриевич

Синтаксис

- Предложение – это единица языка, которая представляет собой грамматически организованное соединение слов, обладающее смысловой законченностью.

- Грамматика – раздел лингвистики, который изучает закономерности построения правильных осмысленных речевых отрезков (словоформ, словосочетаний, предложений, текстов).
- Синтаксис — раздел лингвистики, изучающий и моделирующий правила, по которым образуются единицы, более крупные, чем слово, а именно словосочетания и предложения.

Синтаксические правила

- Существительное сочетается с прилагательным

быстрый + бег → быстрый бег

быстро + бег → не словосочетание

- Глагол сочетается с наречием

бегать + быстрый → не словосочетание

бегать + быстро → бегать быстро

Синтаксическая структура

- Представление предложения в виде вложенных составляющих.
- Составляющая (фраза, синтаксическая группа) – структурная единица предложения, составленная из более тесно связанных друг с другом составляющих меньшего размера.

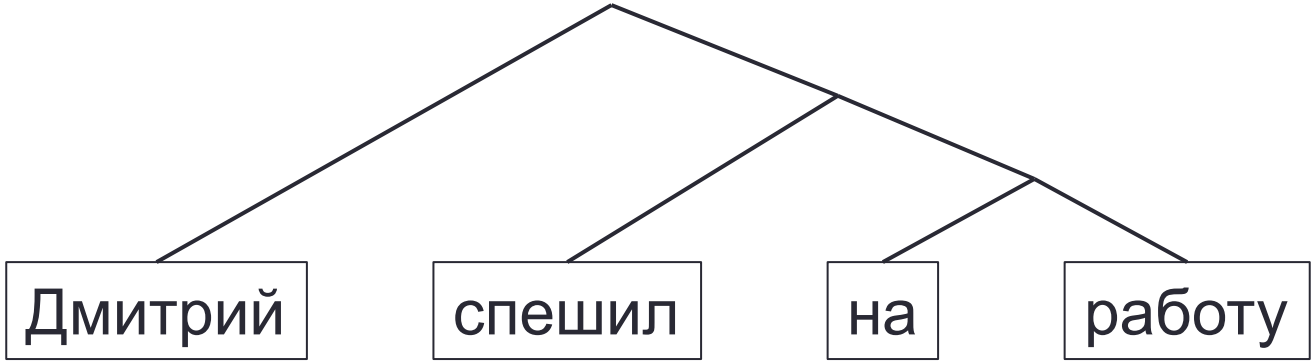

Синтаксические правила

- Существительное управляет прилагательным

красная книга → красная книга

красный книга → не словосочетание

- Предлог управляет существительным

в книга → не словосочетание

в книге → в книге

Синтаксические правила

- В зависимости от главного слова в словосочетании выделяют
  - Именные группы (главное – существительное)
  - Группа прилагательного
  - Наречная группа
  - Предложная группа
  - Глагольная группа
  - Предложение

Синтаксические правила

- В зависимости от главного слова в словосочетании выделяют
  - Именные группы (главное – существительное)
  - Группа прилагательного
  - Наречная группа
  - Предложная группа
  - Глагольная группа
  - Предложение

Синтаксическая структура

- Каждой составляющей назначается тип в зависимости от главного слова

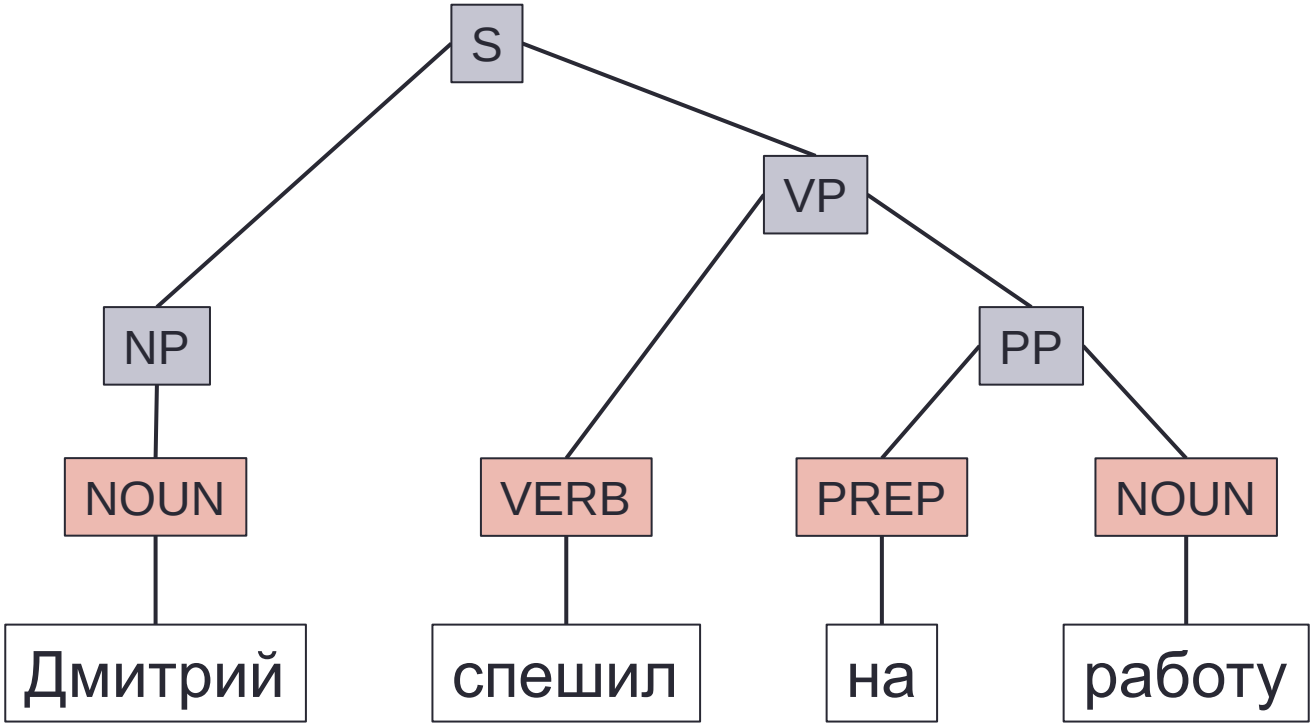

Формальная грамматика

- Способ описания формального языка.
- Формальная грамматика состоит из:
  - Σ – множество терминальных символов
  - N – множество нетерминальных символов
  - P – набор правил вывода $\alpha \longrightarrow \beta$, где
    - α – последовательность символов из $\Sigma \cup N$, хотя бы один из N
    - β – последовательность символов из $\Sigma \cup N$
  - S – начальный символ (из N)

Формальная грамматика

- P – набор правил вывода $\alpha \longrightarrow \beta$, где
  - α – последовательность символов из $\Sigma \cup N$, хотя бы один из N
  - β – последовательность символов из $\Sigma \cup N$

- Иерархия Хомского
  - тип 0. неограниченные грамматики
    любые правила
  - тип 1. контекстно-зависимые грамматики
    правила вида $c_1 A c_2 \longrightarrow c_1 \beta c_2$
  - тип 2. контекстно-свободные грамматики
    правила вида $A \longrightarrow \beta$
  - тип 3. регулярные грамматики
    правила вида $A \longrightarrow a$, $A \longrightarrow aB$ или $A \longrightarrow \varepsilon$

Формальная грамматика

$\Sigma = \{booked, flight, Moscow, I, a, from\}$

$N = \{S, VP, NP, PP, Verb, Noun, Pro, Det, Prep\}$

S

1. $S \rightarrow NP\ VP$
2. $VP \rightarrow Verb\ NP$
3. $VP \rightarrow Verb\ NP\ PP$
4. $NP \rightarrow Pro$
5. $NP \rightarrow Det\ NP$
6. $NP \rightarrow Noun\ PP$
7. $NP \rightarrow Noun$
8. $PP \rightarrow Prep\ Noun$
9. $Verb \rightarrow booked$
10. $Noun \rightarrow flight$
11. $Noun \rightarrow Moscow$
12. $Pro \rightarrow I$
13. $Det \rightarrow a$
14. $Prep \rightarrow from$

Формальная грамматика

$\Sigma = \{booked, flight, Moscow, I, a, from\}$

$N = \{S, VP, NP, PP, Verb, Noun, Pro, Det, Prep\}$

$S \xrightarrow{1} NP\ VP$

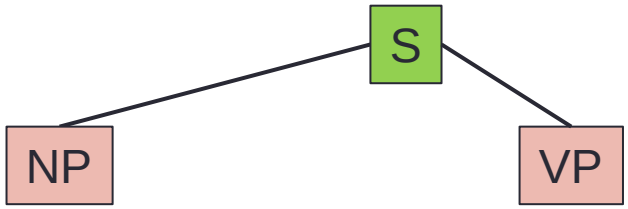

1. $S \rightarrow NP\ VP$
2. $VP \rightarrow Verb\ NP$
3. $VP \rightarrow Verb\ NP\ PP$
4. $NP \rightarrow Pro$
5. $NP \rightarrow Det\ NP$
6. $NP \rightarrow Noun\ PP$
7. $NP \rightarrow Noun$
8. $PP \rightarrow Prep\ Noun$
9. $Verb \rightarrow booked$
10. $Noun \rightarrow flight$
11. $Noun \rightarrow Moscow$
12. $Pro \rightarrow I$
13. $Det \rightarrow a$
14. $Prep \rightarrow from$

Формальная грамматика

$\Sigma = \{booked, flight, Moscow, I, a, from\}$

$N = \{S, VP, NP, PP, Verb, Noun, Pro, Det, Prep\}$

$NP\ VP \overset{4}{\rightarrow} Pro\ VP$

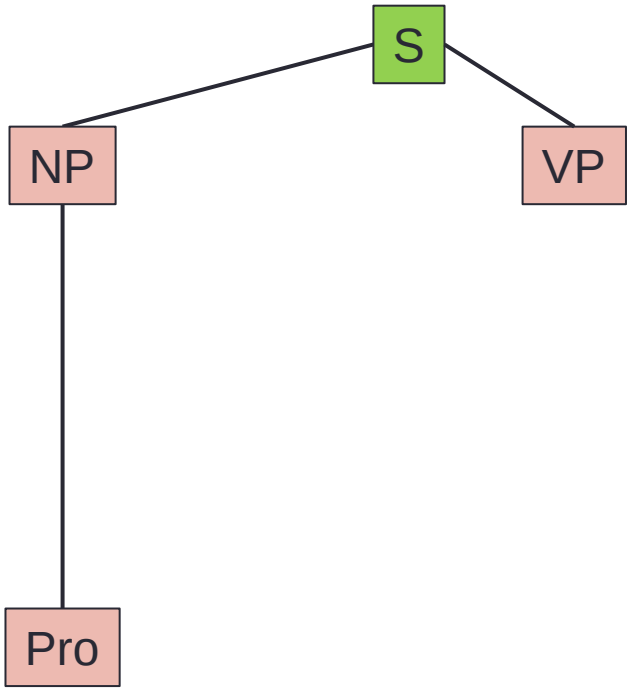

1. $S \rightarrow NP\ VP$
2. $VP \rightarrow Verb\ NP$
3. $VP \rightarrow Verb\ NP\ PP$
4. $\underline{NP \rightarrow Pro}$
5. $NP \rightarrow Det\ NP$
6. $NP \rightarrow Noun\ PP$
7. $NP \rightarrow Noun$
8. $PP \rightarrow Prep\ Noun$
9. $Verb \rightarrow booked$
10. $Noun \rightarrow flight$
11. $Noun \rightarrow Moscow$
12. $Pro \rightarrow I$
13. $Det \rightarrow a$
14. $Prep \rightarrow from$

Формальная грамматика

$\Sigma = \{booked, flight, Moscow, I, a, from\}$

$N = \{S, VP, NP, PP, Verb, Noun, Pro, Det, Prep\}$

$Pro\ VP \xrightarrow{12} I\ VP$

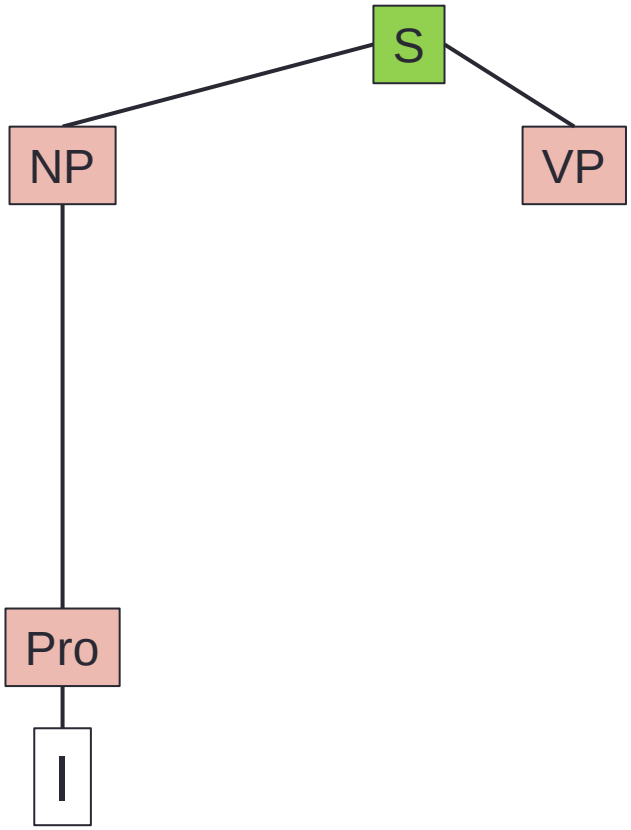

1. $S \rightarrow NP\ VP$
2. $VP \rightarrow Verb\ NP$
3. $VP \rightarrow Verb\ NP\ PP$
4. $NP \rightarrow Pro$
5. $NP \rightarrow Det\ NP$
6. $NP \rightarrow Noun\ PP$
7. $NP \rightarrow Noun$
8. $PP \rightarrow Prep\ Noun$
9. $Verb \rightarrow booked$
10. $Noun \rightarrow flight$
11. $Noun \rightarrow Moscow$
12. $\underline{Pro \rightarrow I}$
13. $Det \rightarrow a$
14. $Prep \rightarrow from$

Формальная грамматика

$\Sigma = \{booked, flight, Moscow, I, a, from\}$

$N = \{S, VP, NP, PP, Verb, Noun, Pro, Det, Prep\}$

$I\ VP \overset{2}{\rightarrow} I\ Verb\ NP$

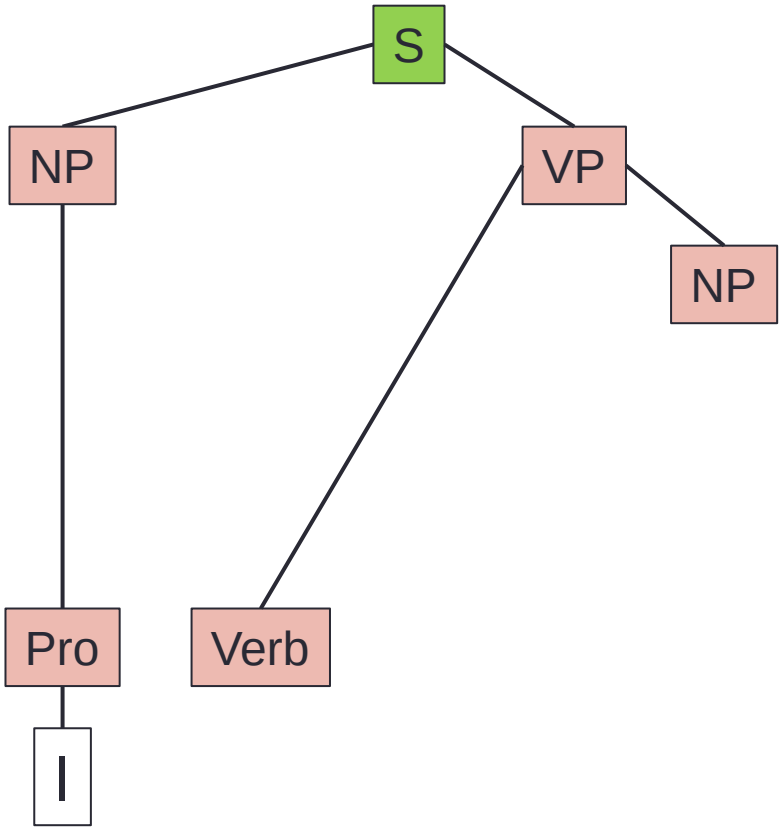

1. $S \rightarrow NP\ VP$
2. $\underline{VP \rightarrow Verb\ NP}$
3. $VP \rightarrow Verb\ NP\ PP$
4. $NP \rightarrow Pro$
5. $NP \rightarrow Det\ NP$
6. $NP \rightarrow Noun\ PP$
7. $NP \rightarrow Noun$
8. $PP \rightarrow Prep\ Noun$
9. $Verb \rightarrow booked$
10. $Noun \rightarrow flight$
11. $Noun \rightarrow Moscow$
12. $Pro \rightarrow I$
13. $Det \rightarrow a$
14. $Prep \rightarrow from$

Формальная грамматика

$\Sigma = \{booked, flight, Moscow, I, a, from\}$

$N = \{S, VP, NP, PP, Verb, Noun, Pro, Det, Prep\}$

$I\ Verb\ NP \overset{9}{\rightarrow} I\ booked\ NP$

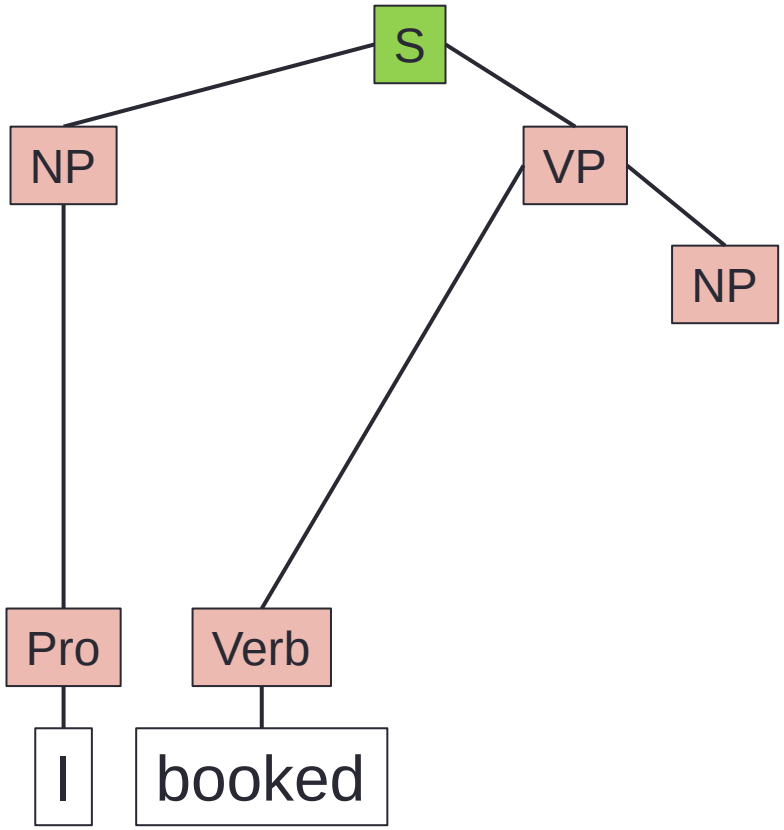

1. $S \rightarrow NP\ VP$
2. $VP \rightarrow Verb\ NP$
3. $VP \rightarrow Verb\ NP\ PP$
4. $NP \rightarrow Pro$
5. $NP \rightarrow Det\ NP$
6. $NP \rightarrow Noun\ PP$
7. $NP \rightarrow Noun$
8. $PP \rightarrow Prep\ Noun$
9. $\underline{Verb \rightarrow booked}$
10. $Noun \rightarrow flight$
11. $Noun \rightarrow Moscow$
12. $Pro \rightarrow I$
13. $Det \rightarrow a$
14. $Prep \rightarrow from$

Формальная грамматика

$\Sigma = \{booked, flight, Moscow, I, a, from\}$

$N = \{S, VP, NP, PP, Verb, Noun, Pro, Det, Prep\}$

$I\ booked\ NP \overset{5}{\rightarrow} I\ booked\ Det\ NP$

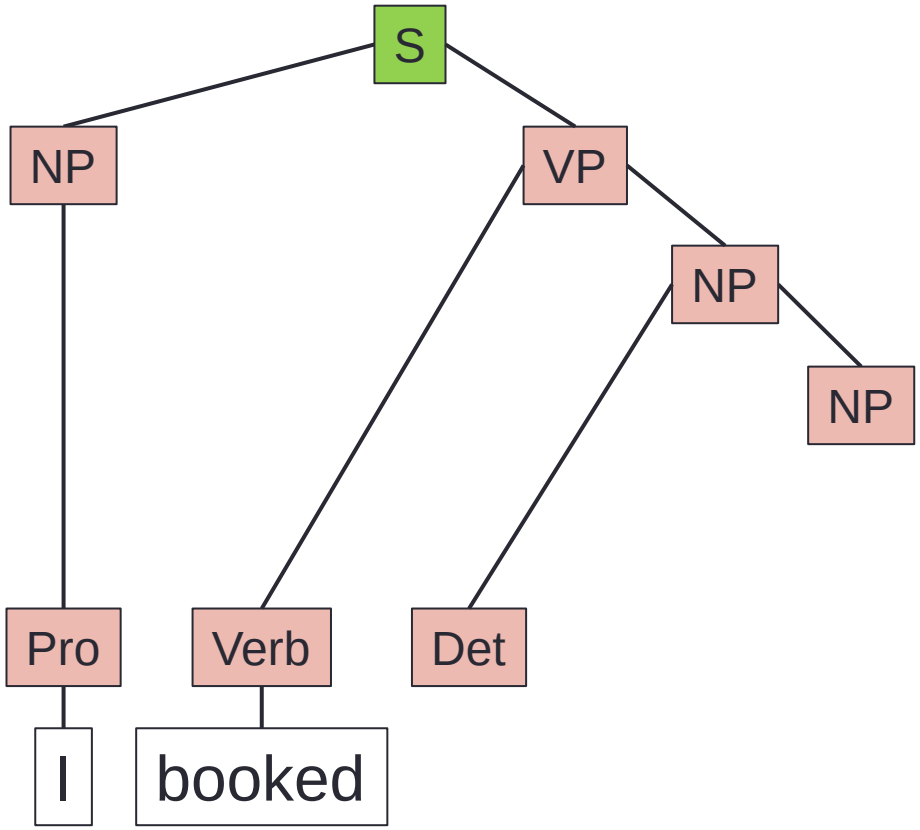

1. $S \rightarrow NP\ VP$
2. $VP \rightarrow Verb\ NP$
3. $VP \rightarrow Verb\ NP\ PP$
4. $NP \rightarrow Pro$
5. $\underline{NP \rightarrow Det\ NP}$
6. $NP \rightarrow Noun\ PP$
7. $NP \rightarrow Noun$
8. $PP \rightarrow Prep\ Noun$
9. $Verb \rightarrow booked$
10. $Noun \rightarrow flight$
11. $Noun \rightarrow Moscow$
12. $Pro \rightarrow I$
13. $Det \rightarrow a$
14. $Prep \rightarrow from$

Формальная грамматика

$\Sigma = \{booked, flight, Moscow, I, a, from\}$

$N = \{S, VP, NP, PP, Verb, Noun, Pro, Det, Prep\}$

$I\ booked\ Det\ NP \overset{13}{\rightarrow} I\ booked\ a\ NP$

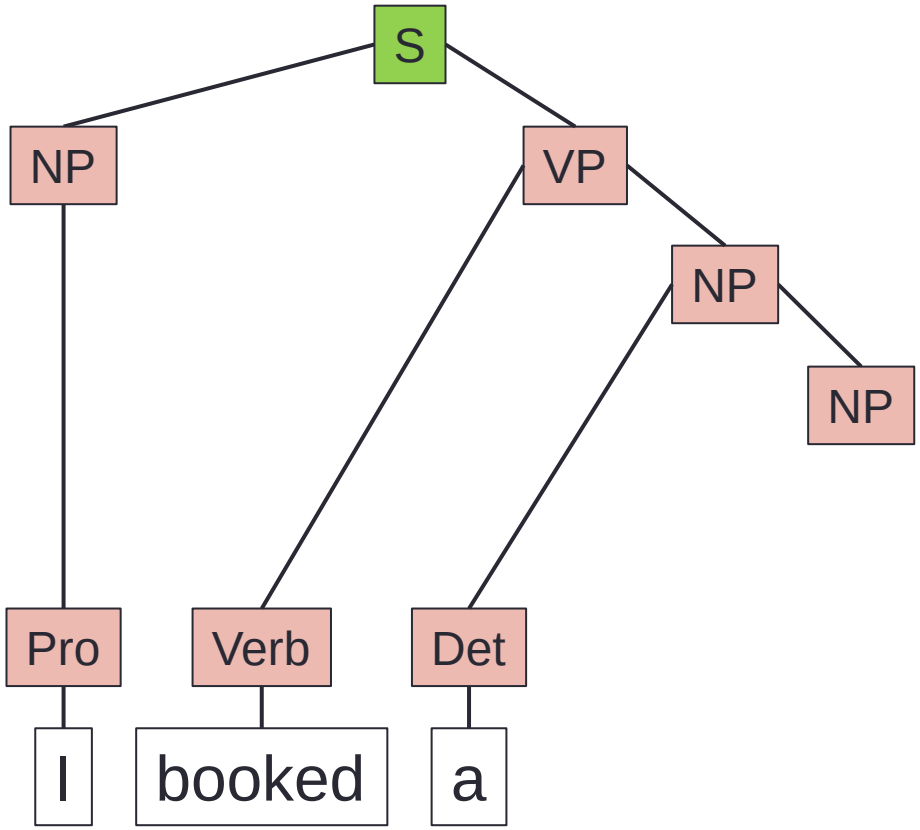

1. $S \rightarrow NP\ VP$
2. $VP \rightarrow Verb\ NP$
3. $VP \rightarrow Verb\ NP\ PP$
4. $NP \rightarrow Pro$
5. $NP \rightarrow Det\ NP$
6. $NP \rightarrow Noun\ PP$
7. $NP \rightarrow Noun$
8. $PP \rightarrow Prep\ Noun$
9. $Verb \rightarrow booked$
10. $Noun \rightarrow flight$
11. $Noun \rightarrow Moscow$
12. $Pro \rightarrow I$
13. $\underline{Det \rightarrow a}$
14. $Prep \rightarrow from$

Формальная грамматика

$\Sigma = \{booked, flight, Moscow, I, a, from\}$

$N = \{S, VP, NP, PP, Verb, Noun, Pro, Det, Prep\}$

$I\ booked\ a\ NP \overset{6}{\rightarrow} I\ booked\ a\ Noun\ PP$

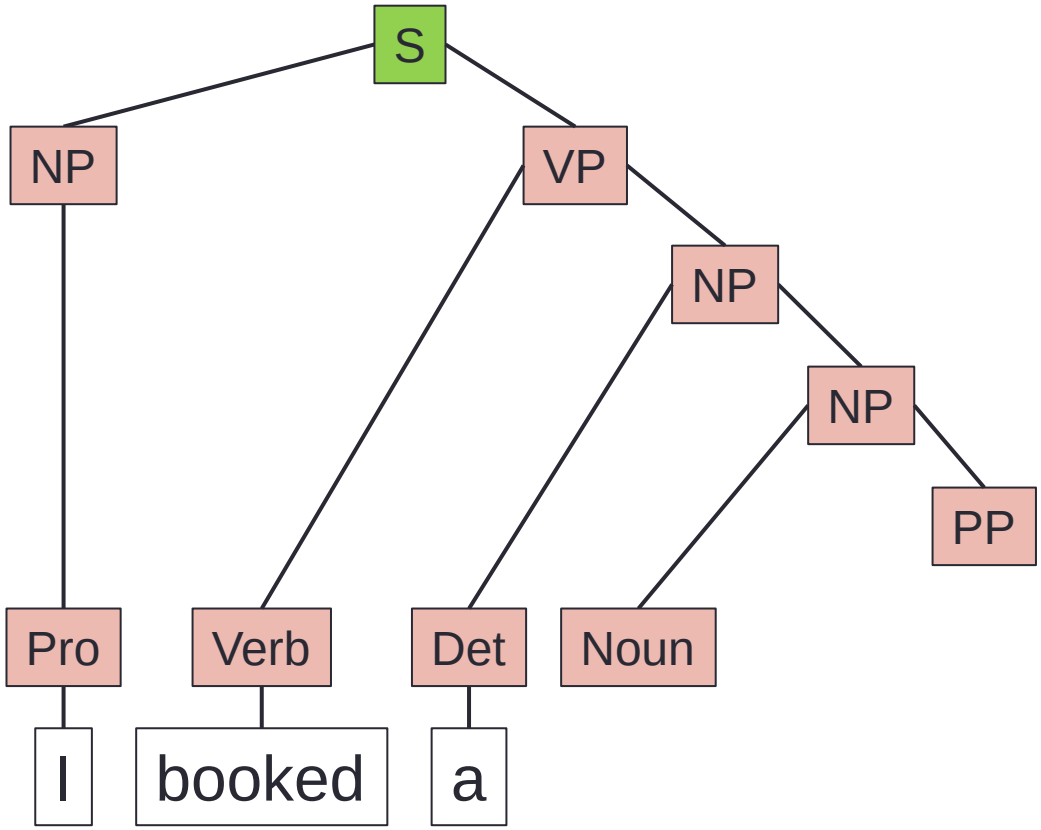

1. $S \rightarrow NP\ VP$
2. $VP \rightarrow Verb\ NP$
3. $VP \rightarrow Verb\ NP\ PP$
4. $NP \rightarrow Pro$
5. $NP \rightarrow Det\ NP$
6. $\underline{NP \rightarrow Noun\ PP}$
7. $NP \rightarrow Noun$
8. $PP \rightarrow Prep\ Noun$
9. $Verb \rightarrow booked$
10. $Noun \rightarrow flight$
11. $Noun \rightarrow Moscow$
12. $Pro \rightarrow I$
13. $Det \rightarrow a$
14. $Prep \rightarrow from$

Формальная грамматика

$\Sigma = \{booked, flight, Moscow, I, a, from\}$

$N = \{S, VP, NP, PP, Verb, Noun, Pro, Det, Prep\}$

$I\ booked\ a\ Noun\ PP \overset{8}{\rightarrow} I\ booked\ a\ Noun\ Prep\ Noun$

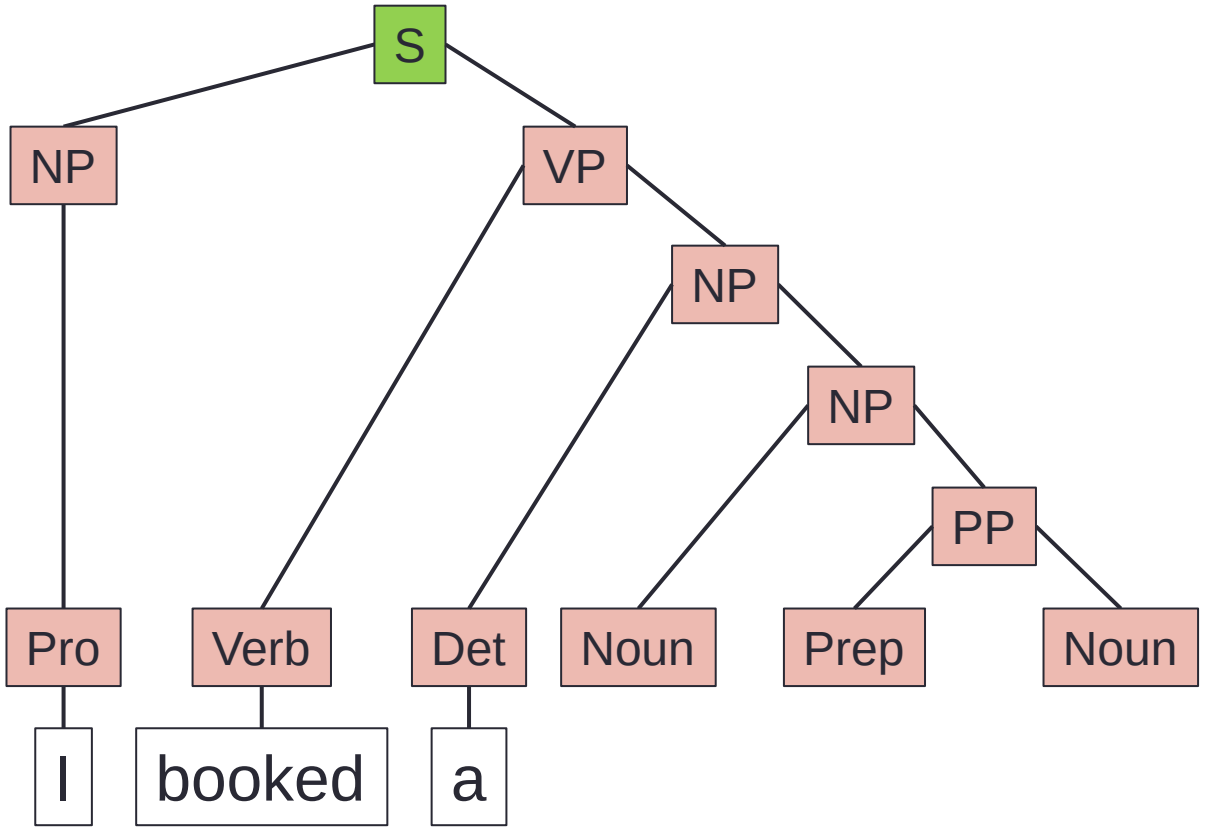

1. $S \rightarrow NP\ VP$
2. $VP \rightarrow Verb\ NP$
3. $VP \rightarrow Verb\ NP\ PP$
4. $NP \rightarrow Pro$
5. $NP \rightarrow Det\ NP$
6. $NP \rightarrow Noun\ PP$
7. $NP \rightarrow Noun$
8. $\underline{PP \rightarrow Prep\ Noun}$
9. $Verb \rightarrow booked$
10. $Noun \rightarrow flight$
11. $Noun \rightarrow Moscow$
12. $Pro \rightarrow I$
13. $Det \rightarrow a$
14. $Prep \rightarrow from$

Формальная грамматика

$\Sigma = \{booked, flight, Moscow, I, a, from\}$

$N = \{S, VP, NP, PP, Verb, Noun, Pro, Det, Prep\}$

$I\ booked\ a\ Noun\ Prep\ Noun \overset{10}{\rightarrow} \overset{14}{\rightarrow} \overset{11}{\rightarrow}$

$I\ booked\ a\ flight\ from\ Moscow$

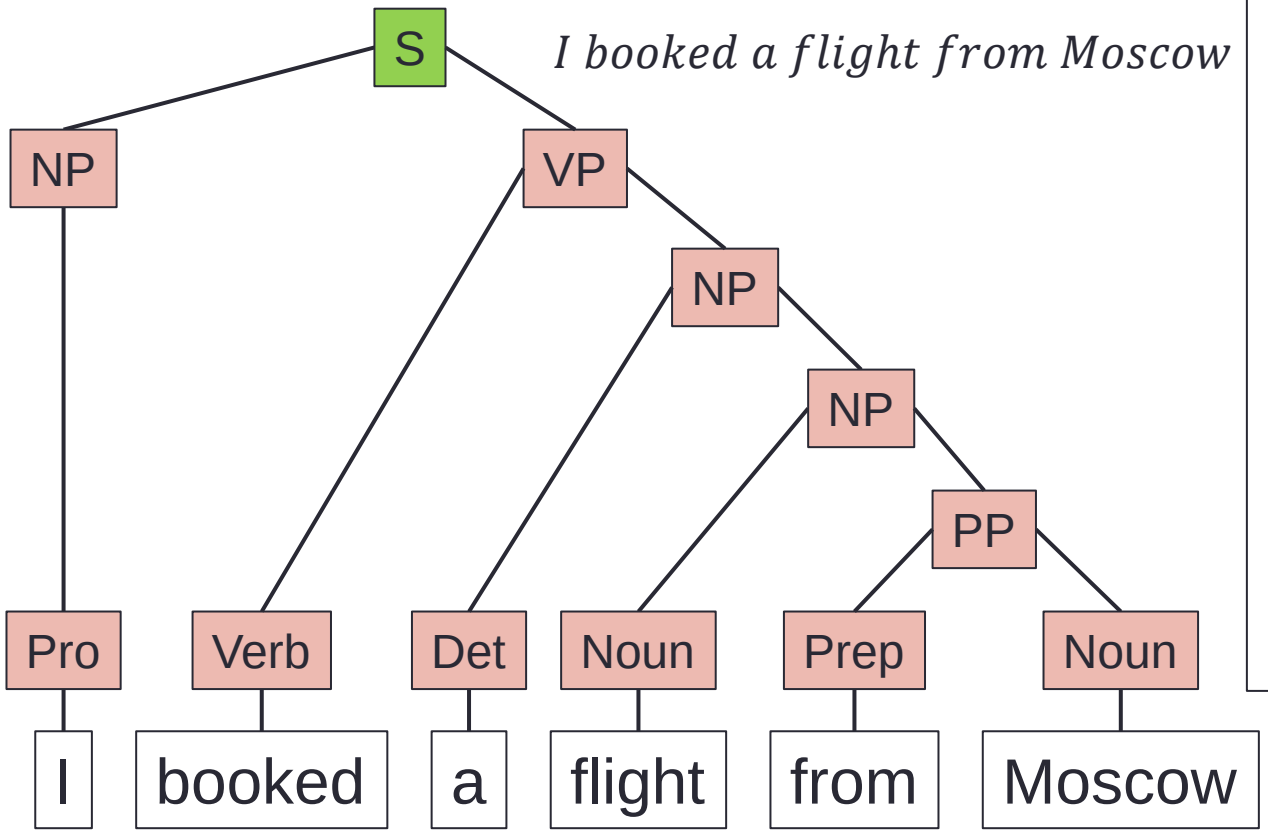

1. $S \rightarrow NP\ VP$
2. $VP \rightarrow Verb\ NP$
3. $VP \rightarrow Verb\ NP\ PP$
4. $NP \rightarrow Pro$
5. $NP \rightarrow Det\ NP$
6. $NP \rightarrow Noun\ PP$
7. $NP \rightarrow Noun$
8. $PP \rightarrow Prep\ Noun$
9. $Verb \rightarrow booked$
10. $Noun \rightarrow flight$
11. $Noun \rightarrow Moscow$
12. $Pro \rightarrow I$
13. $Det \rightarrow a$
14. $Prep \rightarrow from$

Разбор предложения

- На входе: последовательность символов из Σ (слова)
- На выходе:
  - Синтаксическое дерево
  - Последовательность правил для генерации входной строки

- Методы построения дерева:
  - Сверху-вниз

    Из начального символа S, вывести входную строку
  - Снизу-вверх

    Из входной строки вывести начальный символ S

Неоднозначность языка

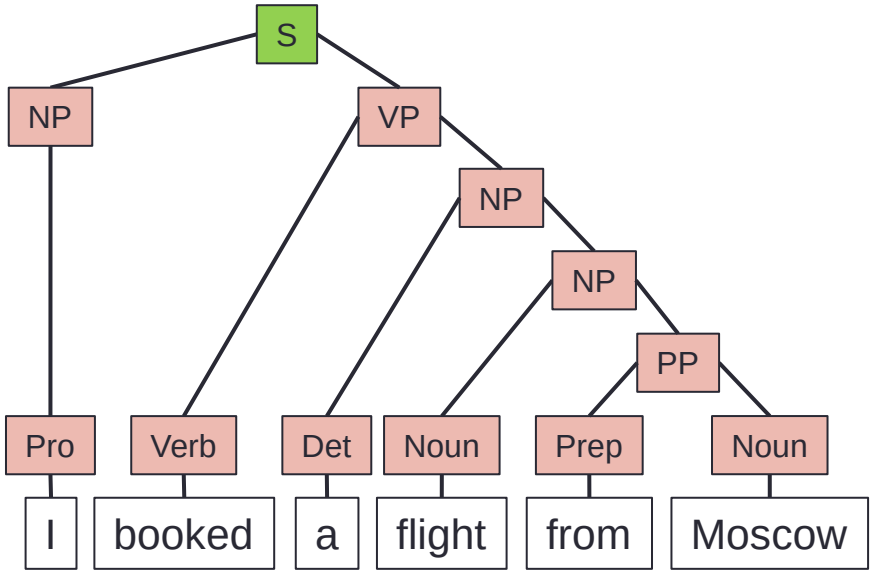

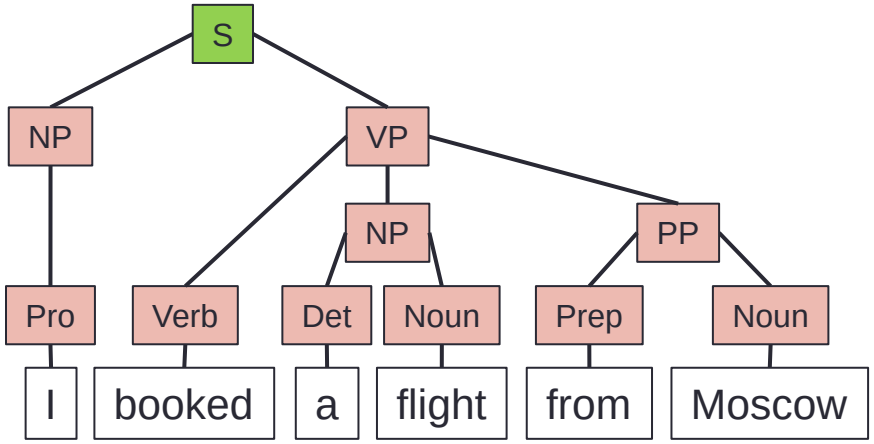

1. $S \rightarrow NP\ VP$
2. $VP \rightarrow Verb\ NP$
3. $\underline{VP \rightarrow Verb\ NP\ PP}$
4. $NP \rightarrow Pro$
5. $NP \rightarrow Det\ NP$
6. $NP \rightarrow Noun\ PP$
7. $NP \rightarrow Noun$
8. $PP \rightarrow Prep\ Noun$
9. $Verb \rightarrow booked$
10. $Noun \rightarrow flight$
11. $Noun \rightarrow Moscow$
12. $Pro \rightarrow I$
13. $Det \rightarrow a$
14. $Prep \rightarrow from$

Алгоритм CYK

- Для работы необходима КС грамматика в нормальной форме Хомского (CNF)
  - Все правила должны иметь вид: $A \longrightarrow BC$ или $A \longrightarrow \beta$
  - Любая КС грамматика может быть преобразована в CNF (кроме правила $S \longrightarrow \varepsilon$)
- Алгоритм позволяет определить выводимо ли предложение в заданной КС грамматике
- При небольшой модификации алгоритм строит все возможные разборы предложения

Алгоритм CYK

- Идея алгоритма заключается в рассмотрении всех подстрок исходной строки
  - Для каждой подстроки определить, можно ли вывести ее в заданной грамматике, зная какие подстроки меньшего размера можно вывести в этой грамматике

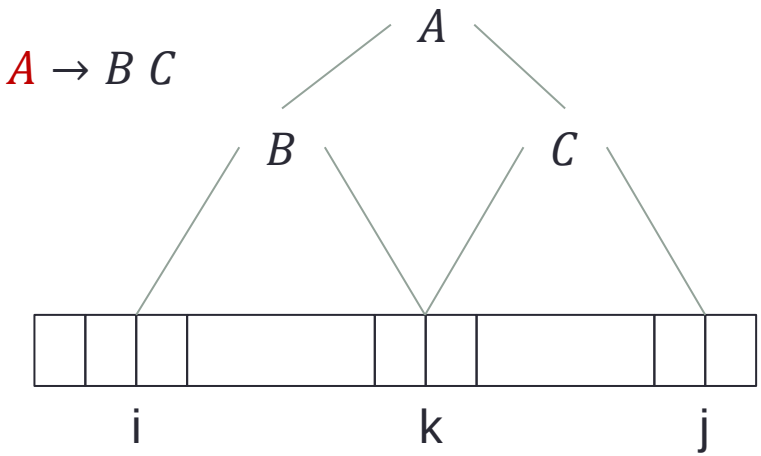

Алгоритм CYK

- Дана грамматика в CNF, N нетерминальных символов
- Дана строка w длины n
- Зададим трехмерный массив $d \in B^{N \times n \times n}$,
  $d[A][i][j] = 1$, если из A можно вывести строку $w[i..j]$

- Решаем задачу динамическим программированием
  - Будем рассматривать все подстроки длины m для $m = \overline{1..n}$
  - Для каждой подстроки [i..j] длины m рассмотрим все разбиения [i..k][k+1..j]
  - Для каждого правила $A \to B\ C$, если
    $d[B, i, k] = 1$ и $d[C, k+1, j] = 1$, то $d[A, i, j] = 1$

Алгоритм CYK

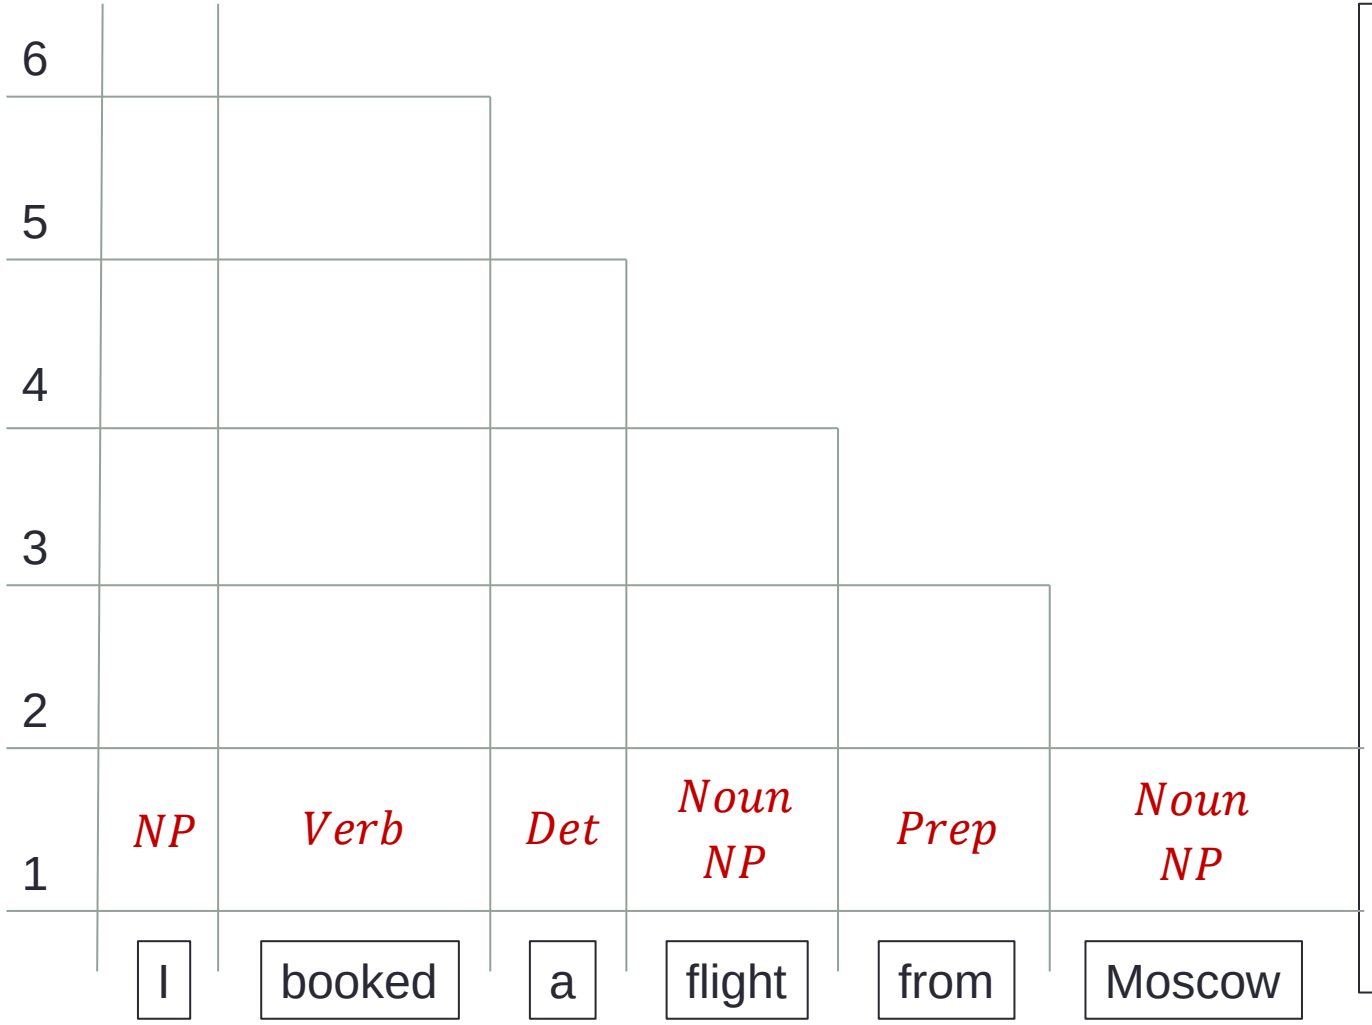

1. $S \rightarrow NP\ VP$
2. $VP \rightarrow Verb\ NP$
3. $VP \rightarrow Verb\ VP^*$
4. $VP^* \rightarrow NP\ PP$
5. $NP \rightarrow Det\ NP$
6. $NP \rightarrow Noun\ PP$
7. $PP \rightarrow Prep\ Noun$
8. $NP \rightarrow I$
9. $NP \rightarrow flight$
10. $NP \rightarrow Moscow$
11. $Verb \rightarrow booked$
12. $Noun \rightarrow flight$
13. $Noun \rightarrow Moscow$
14. $Det \rightarrow a$
15. $Prep \rightarrow from$

Алгоритм CYK

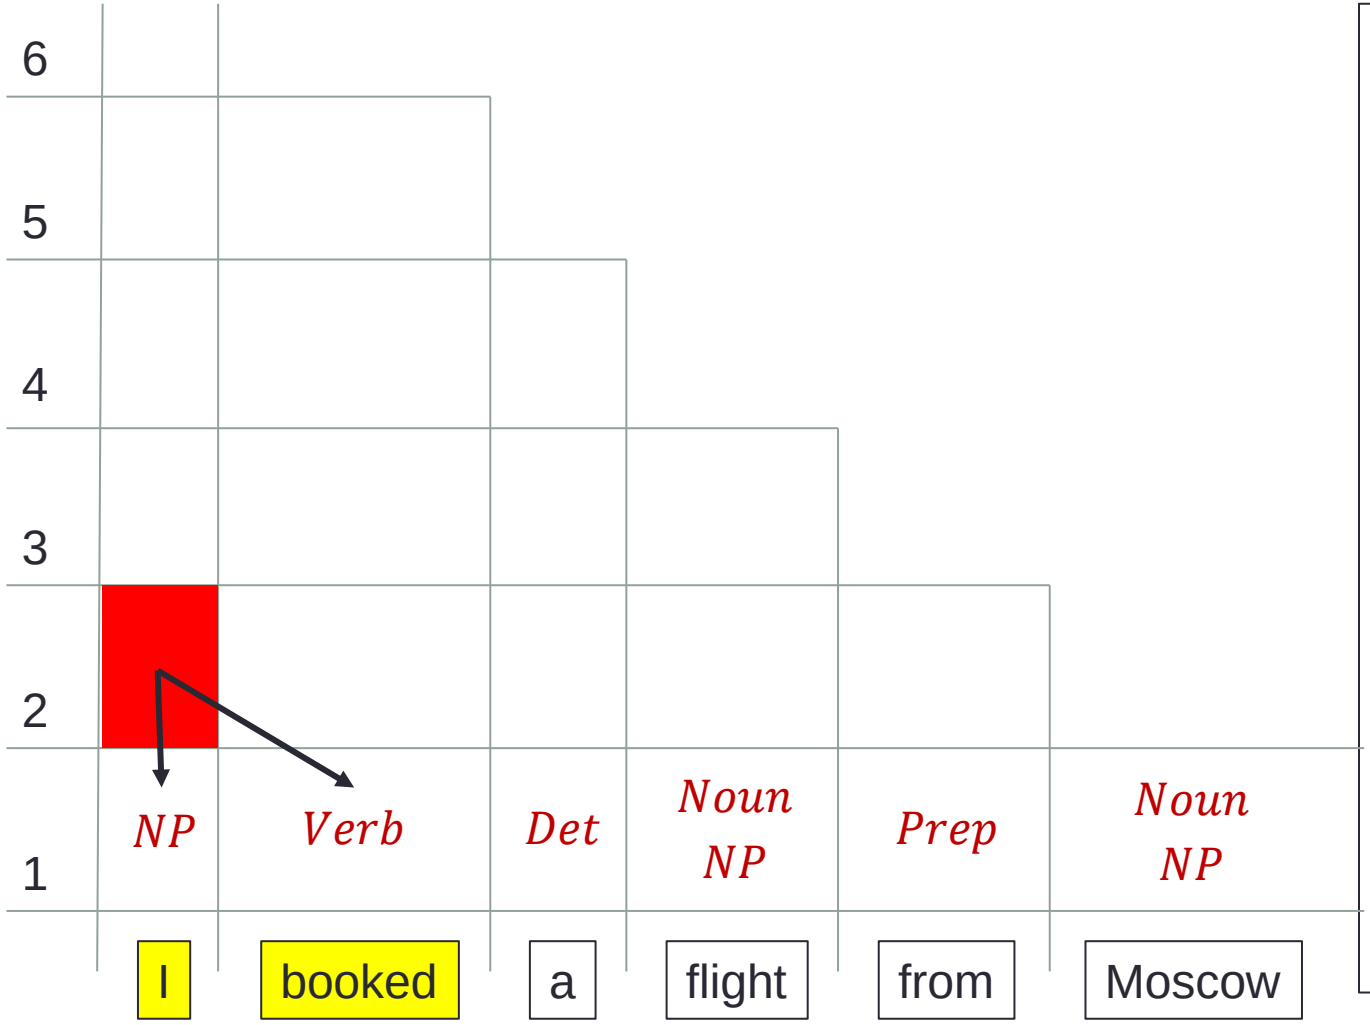

1. $S \rightarrow NP\ VP$
2. $VP \rightarrow Verb\ NP$
3. $VP \rightarrow Verb\ VP^*$
4. $VP^* \rightarrow NP\ PP$
5. $NP \rightarrow Det\ NP$
6. $NP \rightarrow Noun\ PP$
7. $PP \rightarrow Prep\ Noun$
8. $NP \rightarrow I$
9. $NP \rightarrow flight$
10. $NP \rightarrow Moscow$
11. $Verb \rightarrow booked$
12. $Noun \rightarrow flight$
13. $Noun \rightarrow Moscow$
14. $Det \rightarrow a$
15. $Prep \rightarrow from$

Алгоритм CYK

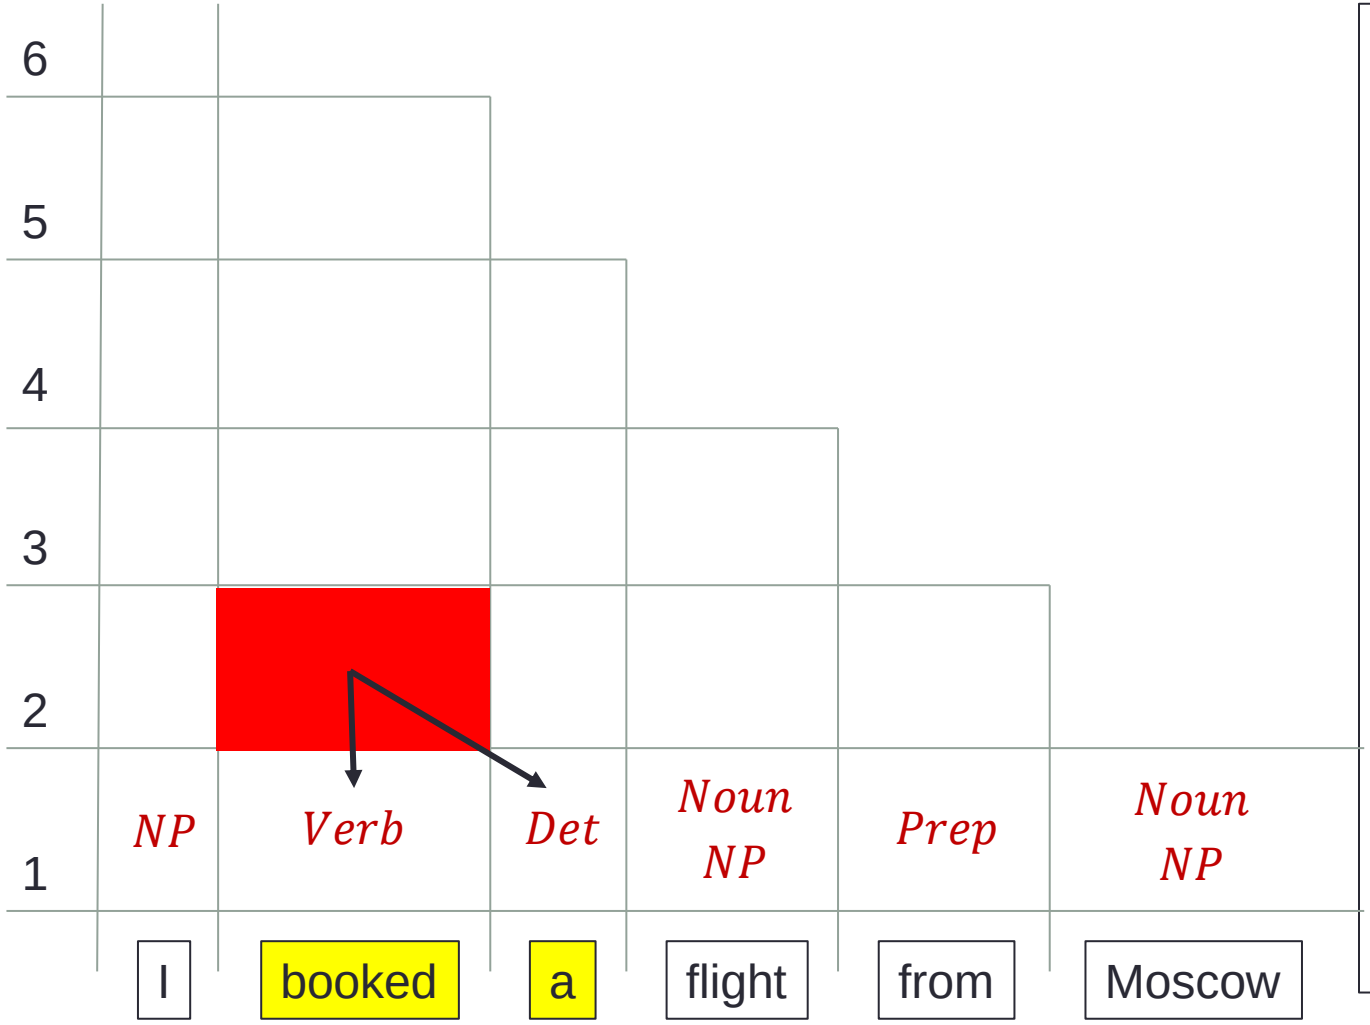

1. $S \rightarrow NP\ VP$
2. $VP \rightarrow Verb\ NP$
3. $VP \rightarrow Verb\ VP^*$
4. $VP^* \rightarrow NP\ PP$
5. $NP \rightarrow Det\ NP$
6. $NP \rightarrow Noun\ PP$
7. $PP \rightarrow Prep\ Noun$
8. $NP \rightarrow I$
9. $NP \rightarrow flight$
10. $NP \rightarrow Moscow$
11. $Verb \rightarrow booked$
12. $Noun \rightarrow flight$
13. $Noun \rightarrow Moscow$
14. $Det \rightarrow a$
15. $Prep \rightarrow from$

Алгоритм CYK

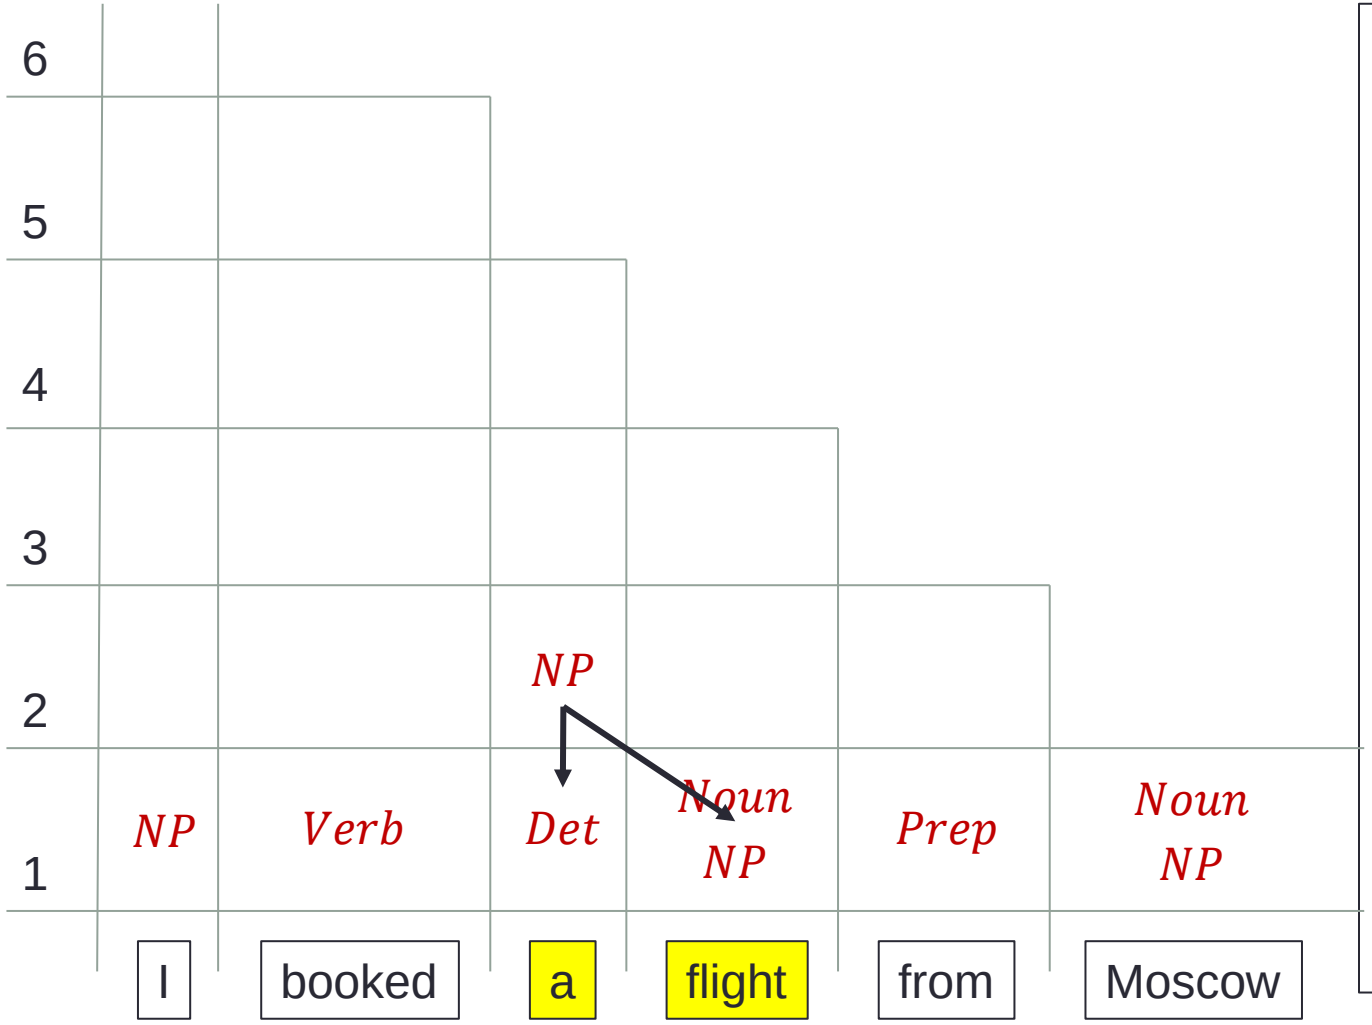

1. $S \rightarrow NP\ VP$
2. $VP \rightarrow Verb\ NP$
3. $VP \rightarrow Verb\ VP^*$
4. $VP^* \rightarrow NP\ PP$
5. $NP \rightarrow Det\ NP$
6. $NP \rightarrow Noun\ PP$
7. $PP \rightarrow Prep\ Noun$
8. $NP \rightarrow I$
9. $NP \rightarrow flight$
10. $NP \rightarrow Moscow$
11. $Verb \rightarrow booked$
12. $Noun \rightarrow flight$
13. $Noun \rightarrow Moscow$
14. $Det \rightarrow a$
15. $Prep \rightarrow from$

Алгоритм CYK

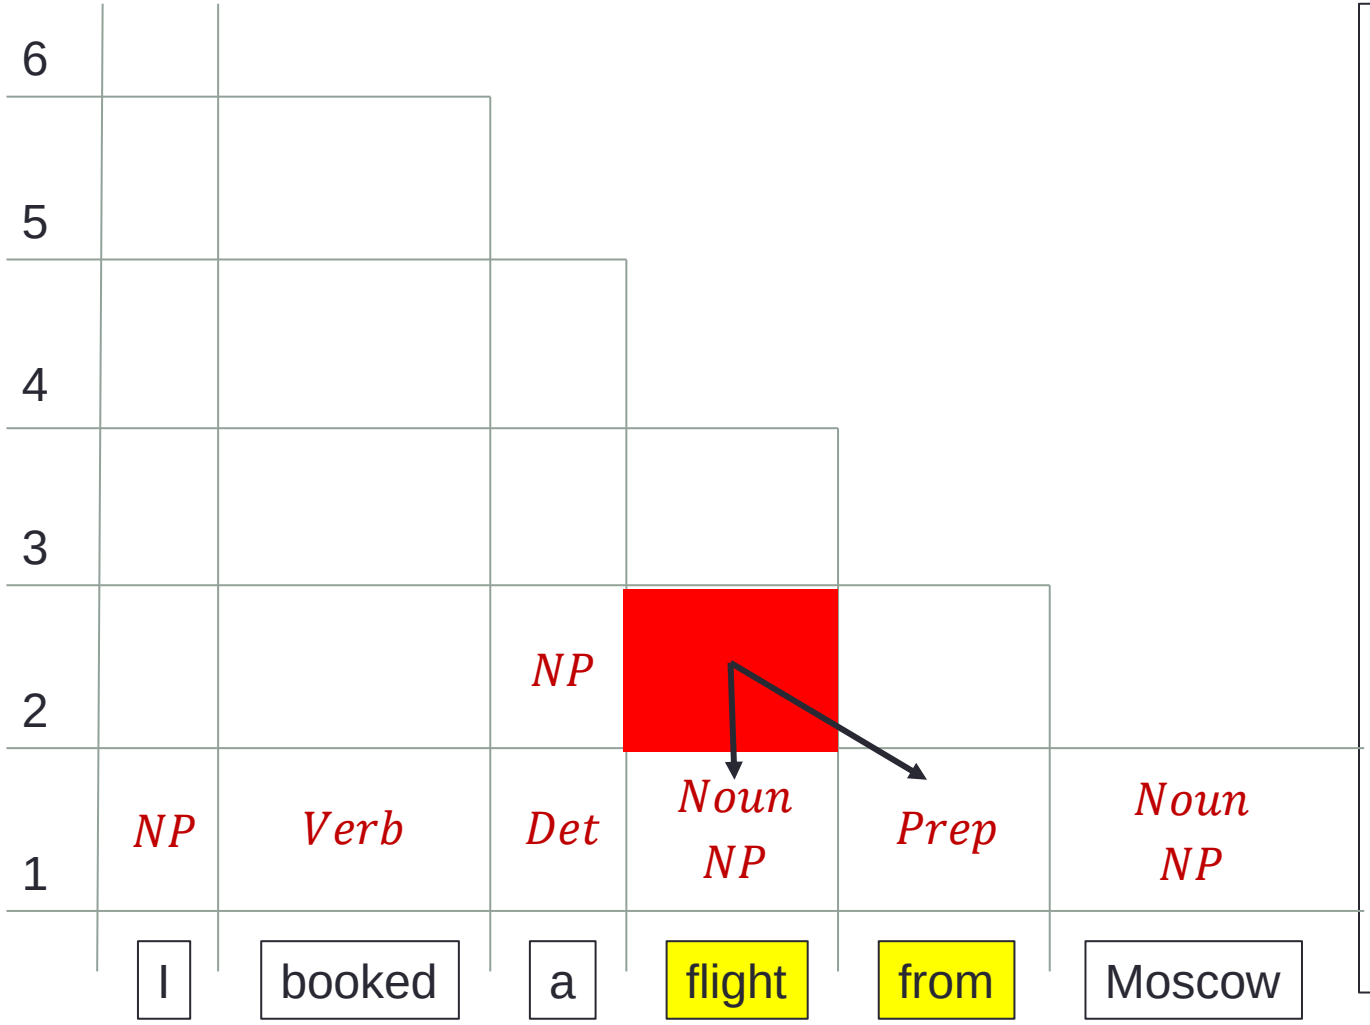

1. $S \rightarrow NP\ VP$
2. $VP \rightarrow Verb\ NP$
3. $VP \rightarrow Verb\ VP^*$
4. $VP^* \rightarrow NP\ PP$
5. $NP \rightarrow Det\ NP$
6. $NP \rightarrow Noun\ PP$
7. $PP \rightarrow Prep\ Noun$
8. $NP \rightarrow I$
9. $NP \rightarrow flight$
10. $NP \rightarrow Moscow$
11. $Verb \rightarrow booked$
12. $Noun \rightarrow flight$
13. $Noun \rightarrow Moscow$
14. $Det \rightarrow a$
15. $Prep \rightarrow from$

Алгоритм CYK

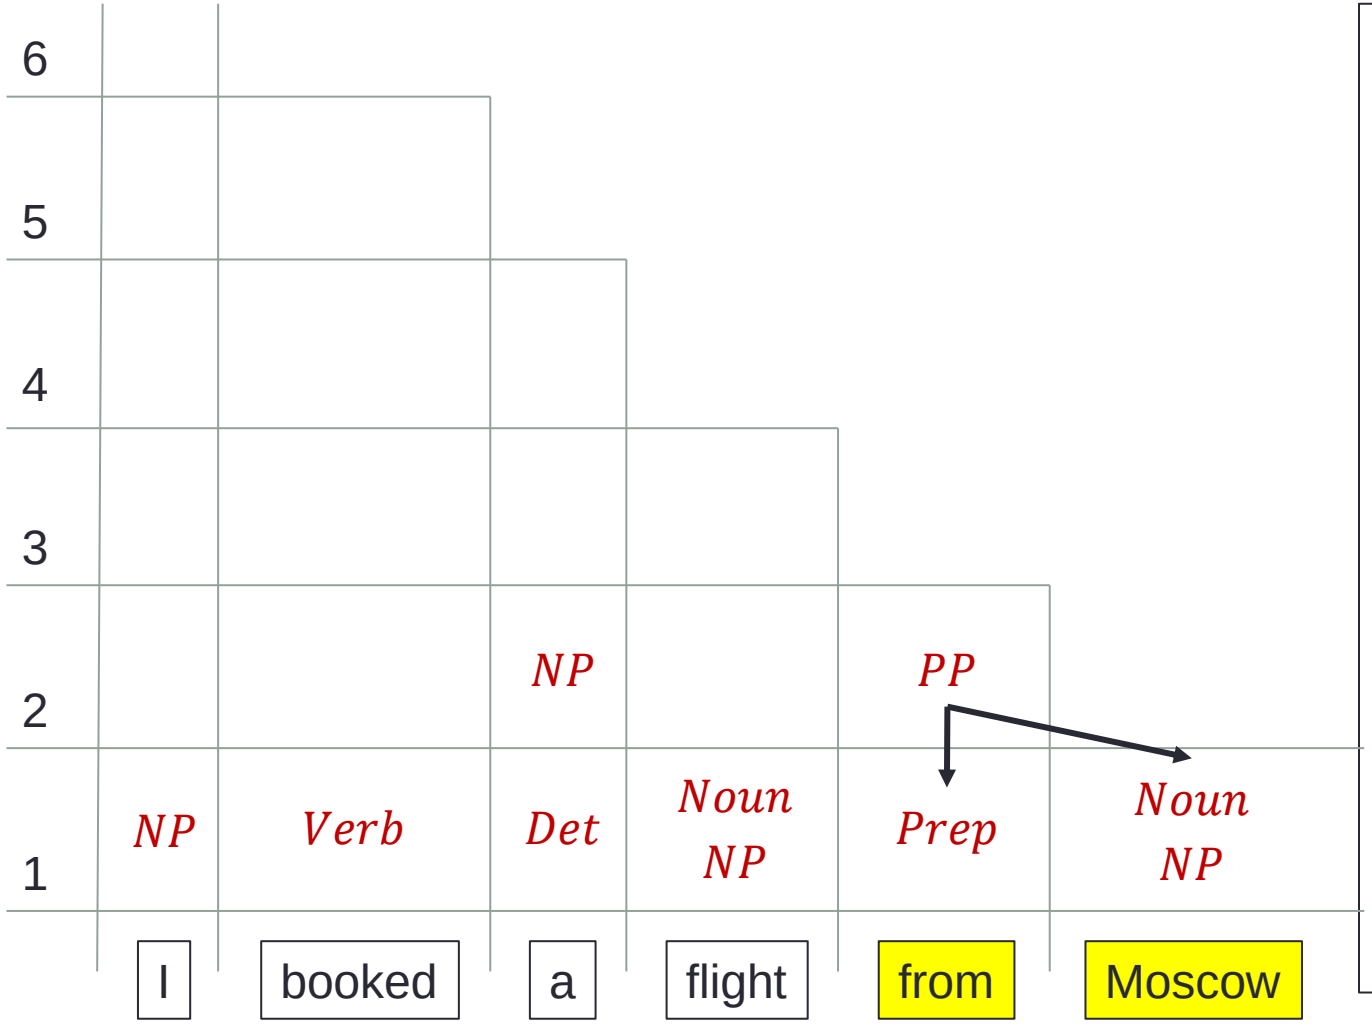

1. $S \rightarrow NP\ VP$
2. $VP \rightarrow Verb\ NP$
3. $VP \rightarrow Verb\ VP^*$
4. $VP^* \rightarrow NP\ PP$
5. $NP \rightarrow Det\ NP$
6. $NP \rightarrow Noun\ PP$
7. $PP \rightarrow Prep\ Noun$
8. $NP \rightarrow I$
9. $NP \rightarrow flight$
10. $NP \rightarrow Moscow$
11. $Verb \rightarrow booked$
12. $Noun \rightarrow flight$
13. $Noun \rightarrow Moscow$
14. $Det \rightarrow a$
15. $Prep \rightarrow from$

Алгоритм CYK

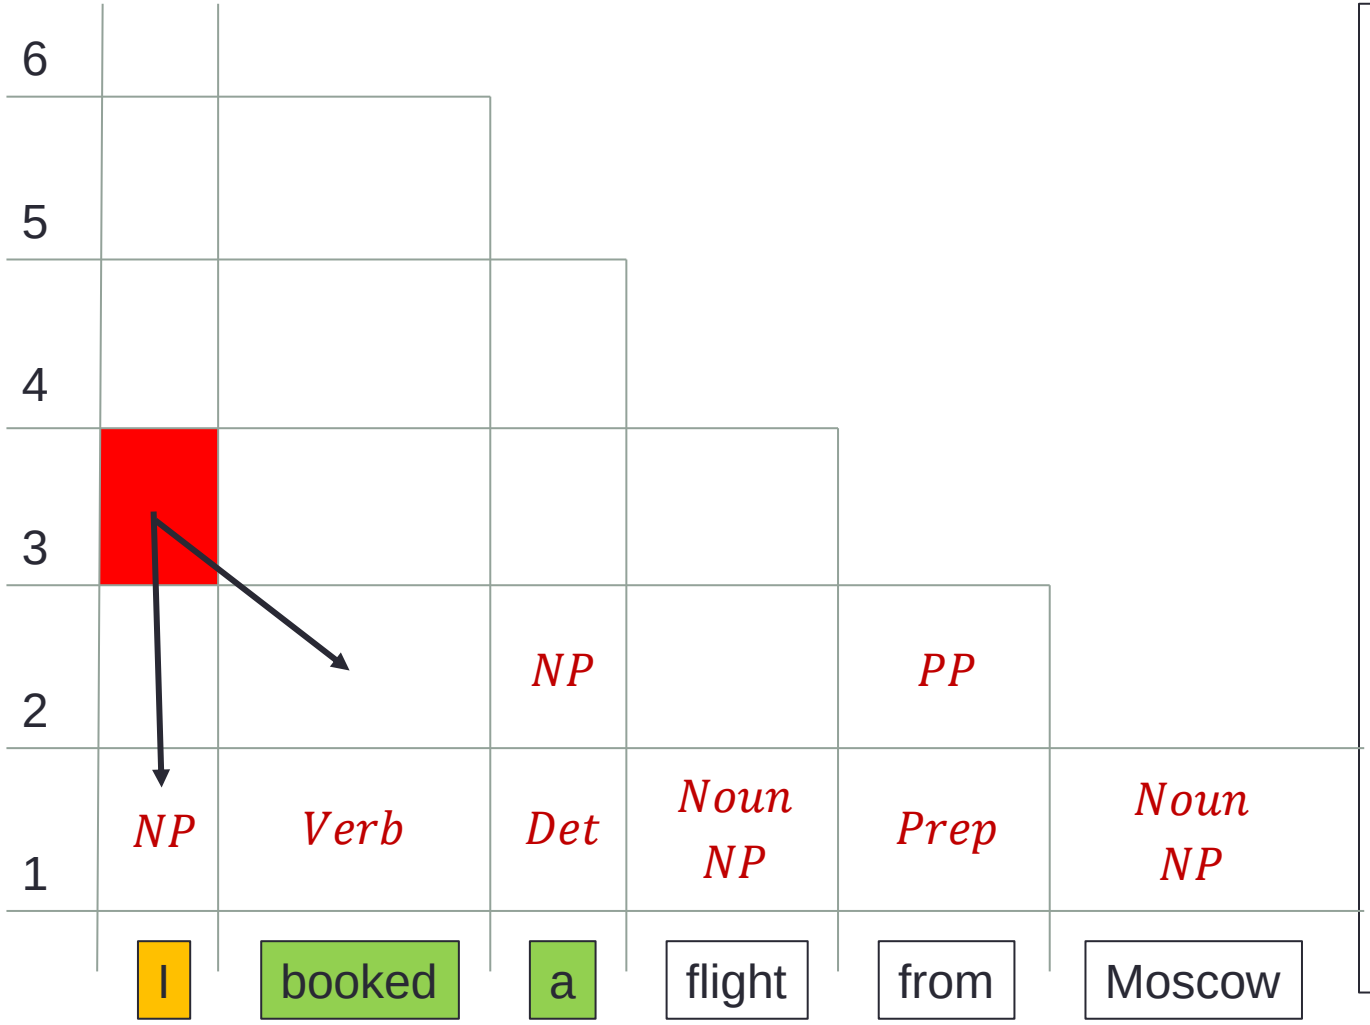

1. $S \rightarrow NP\ VP$
2. $VP \rightarrow Verb\ NP$
3. $VP \rightarrow Verb\ VP^*$
4. $VP^* \rightarrow NP\ PP$
5. $NP \rightarrow Det\ NP$
6. $NP \rightarrow Noun\ PP$
7. $PP \rightarrow Prep\ Noun$
8. $NP \rightarrow I$
9. $NP \rightarrow flight$
10. $NP \rightarrow Moscow$
11. $Verb \rightarrow booked$
12. $Noun \rightarrow flight$
13. $Noun \rightarrow Moscow$
14. $Det \rightarrow a$
15. $Prep \rightarrow from$

Алгоритм CYK

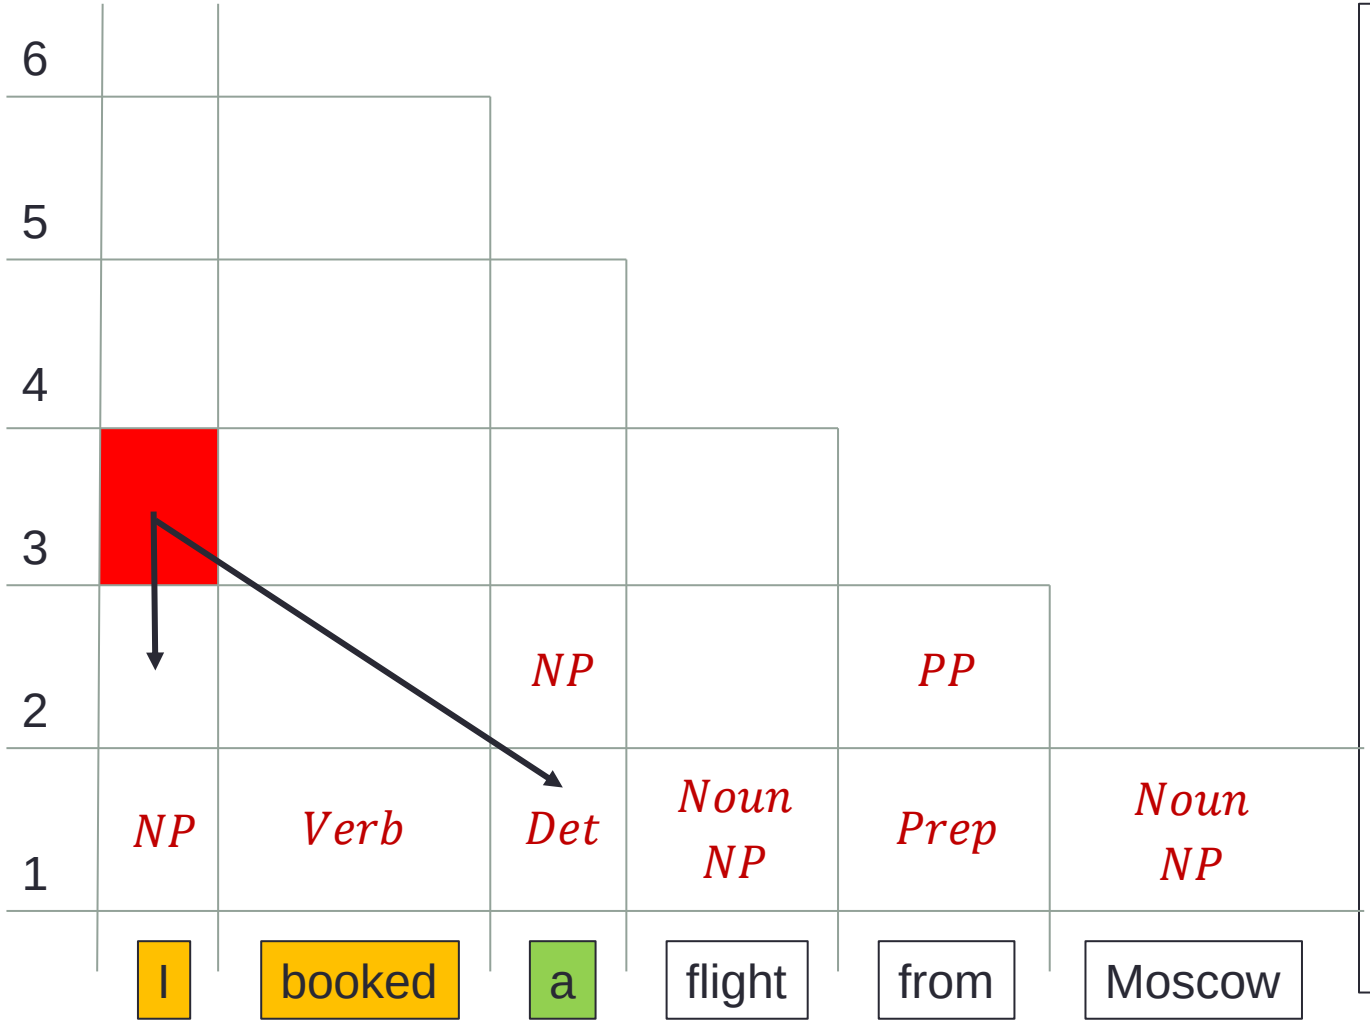

1. $S \rightarrow NP\ VP$
2. $VP \rightarrow Verb\ NP$
3. $VP \rightarrow Verb\ VP^*$
4. $VP^* \rightarrow NP\ PP$
5. $NP \rightarrow Det\ NP$
6. $NP \rightarrow Noun\ PP$
7. $PP \rightarrow Prep\ Noun$
8. $NP \rightarrow I$
9. $NP \rightarrow flight$
10. $NP \rightarrow Moscow$
11. $Verb \rightarrow booked$
12. $Noun \rightarrow flight$
13. $Noun \rightarrow Moscow$
14. $Det \rightarrow a$
15. $Prep \rightarrow from$

Алгоритм CYK

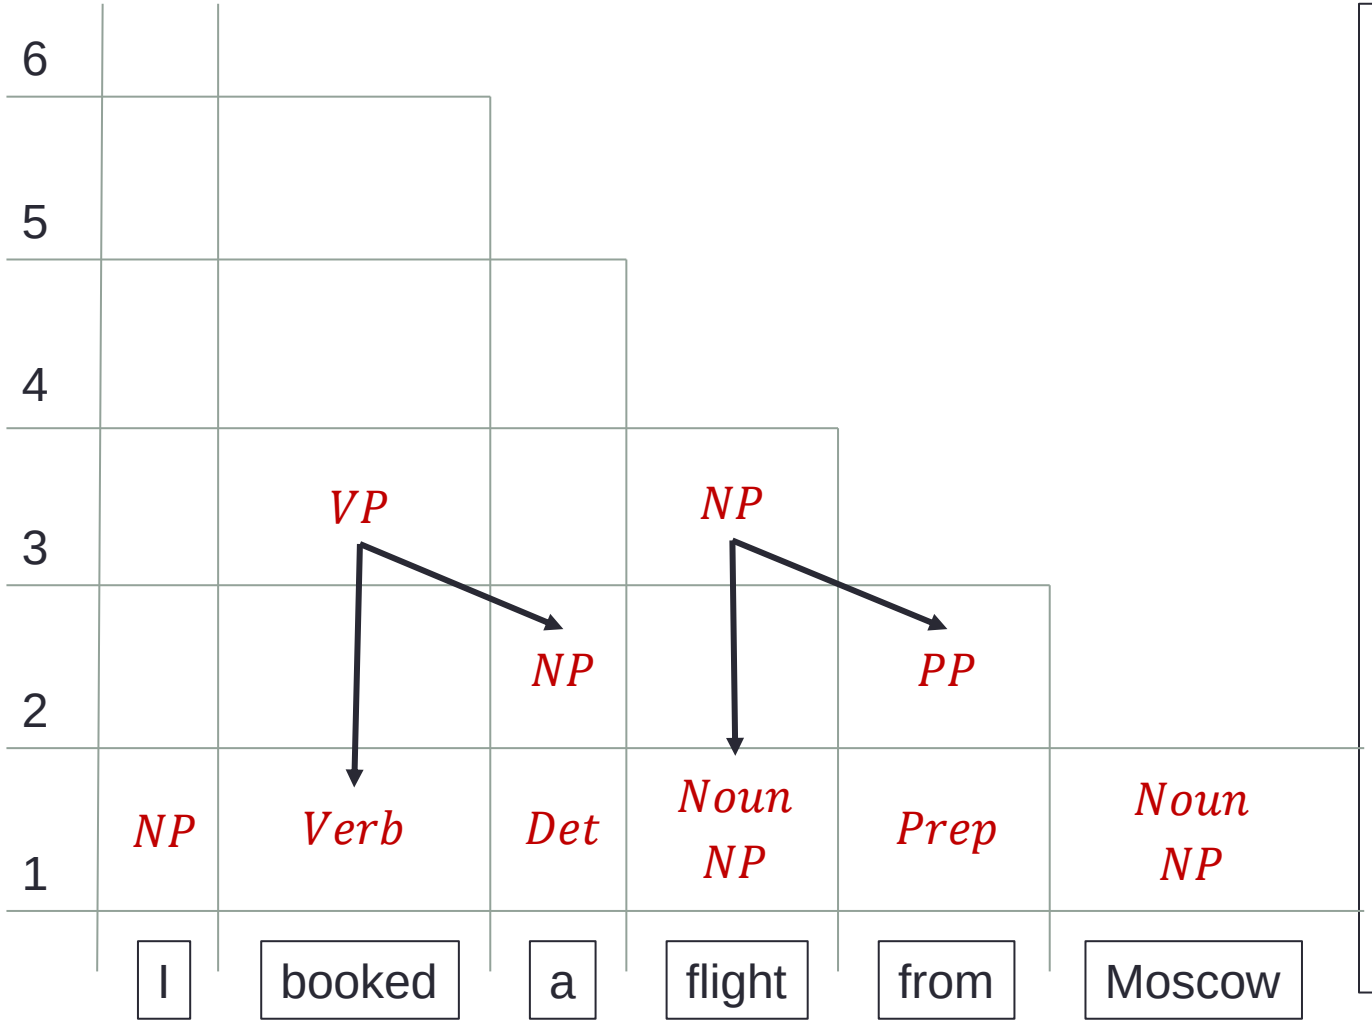

1. $S \rightarrow NP\ VP$
2. $\underline{VP \rightarrow Verb\ NP}$
3. $VP \rightarrow Verb\ VP^*$
4. $VP^* \rightarrow NP\ PP$
5. $NP \rightarrow Det\ NP$
6. $\underline{NP \rightarrow Noun\ PP}$
7. $PP \rightarrow Prep\ Noun$
8. $NP \rightarrow I$
9. $NP \rightarrow flight$
10. $NP \rightarrow Moscow$
11. $Verb \rightarrow booked$
12. $Noun \rightarrow flight$
13. $Noun \rightarrow Moscow$
14. $Det \rightarrow a$
15. $Prep \rightarrow from$

Алгоритм CYK

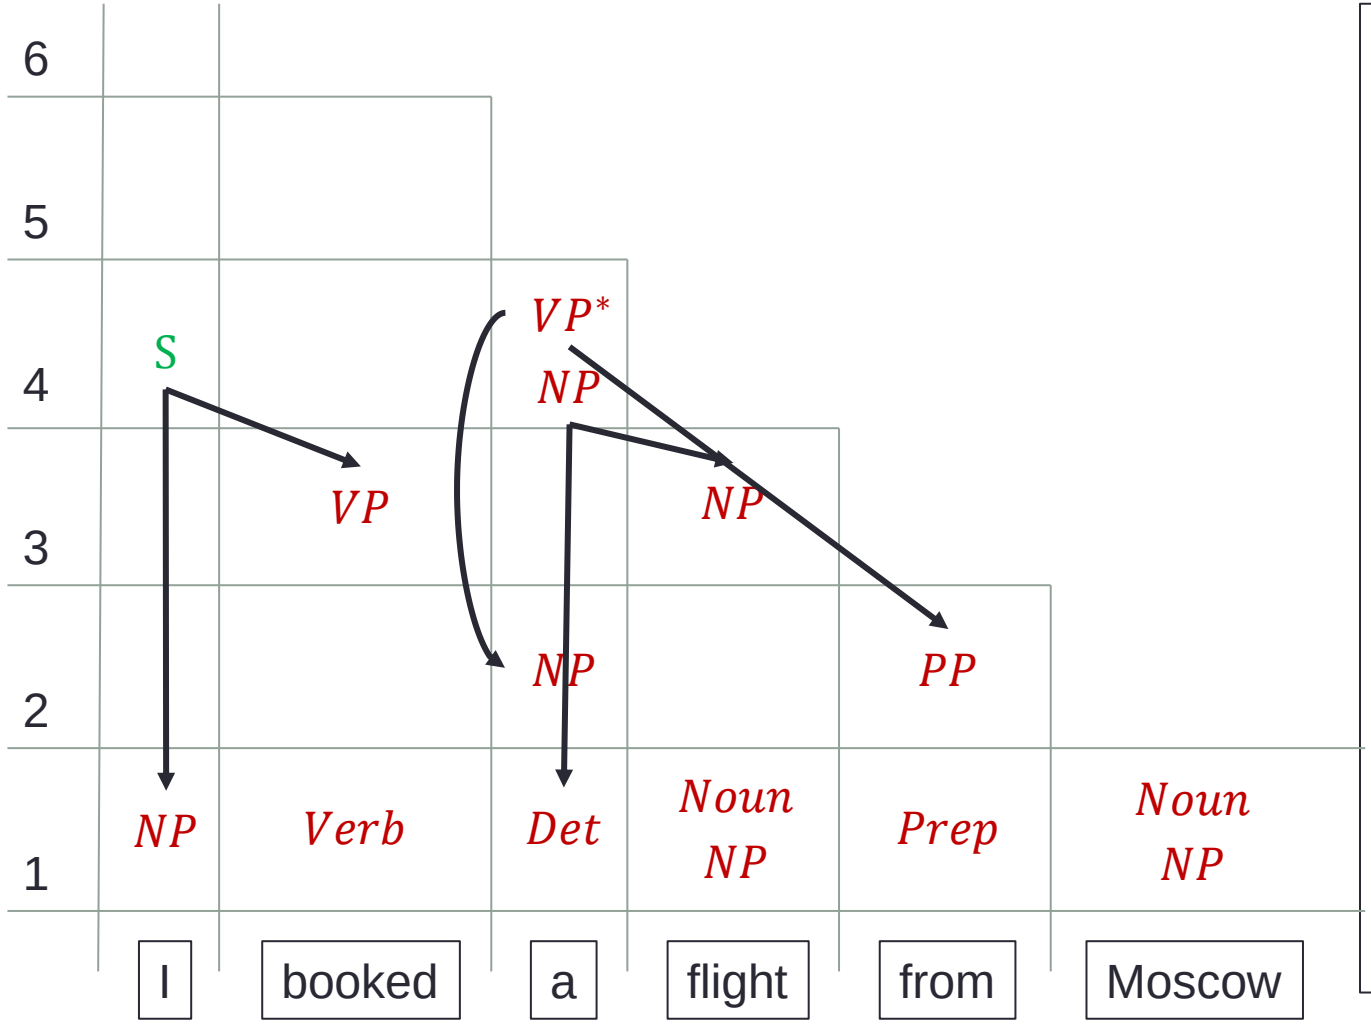

1. $S \rightarrow NP\ VP$
2. $VP \rightarrow Verb\ NP$
3. $VP \rightarrow Verb\ VP^*$
4. $VP^* \rightarrow NP\ PP$
5. $NP \rightarrow Det\ NP$
6. $NP \rightarrow Noun\ PP$
7. $PP \rightarrow Prep\ Noun$
8. $NP \rightarrow I$
9. $NP \rightarrow flight$
10. $NP \rightarrow Moscow$
11. $Verb \rightarrow booked$
12. $Noun \rightarrow flight$
13. $Noun \rightarrow Moscow$
14. $Det \rightarrow a$
15. $Prep \rightarrow from$

Алгоритм CYK

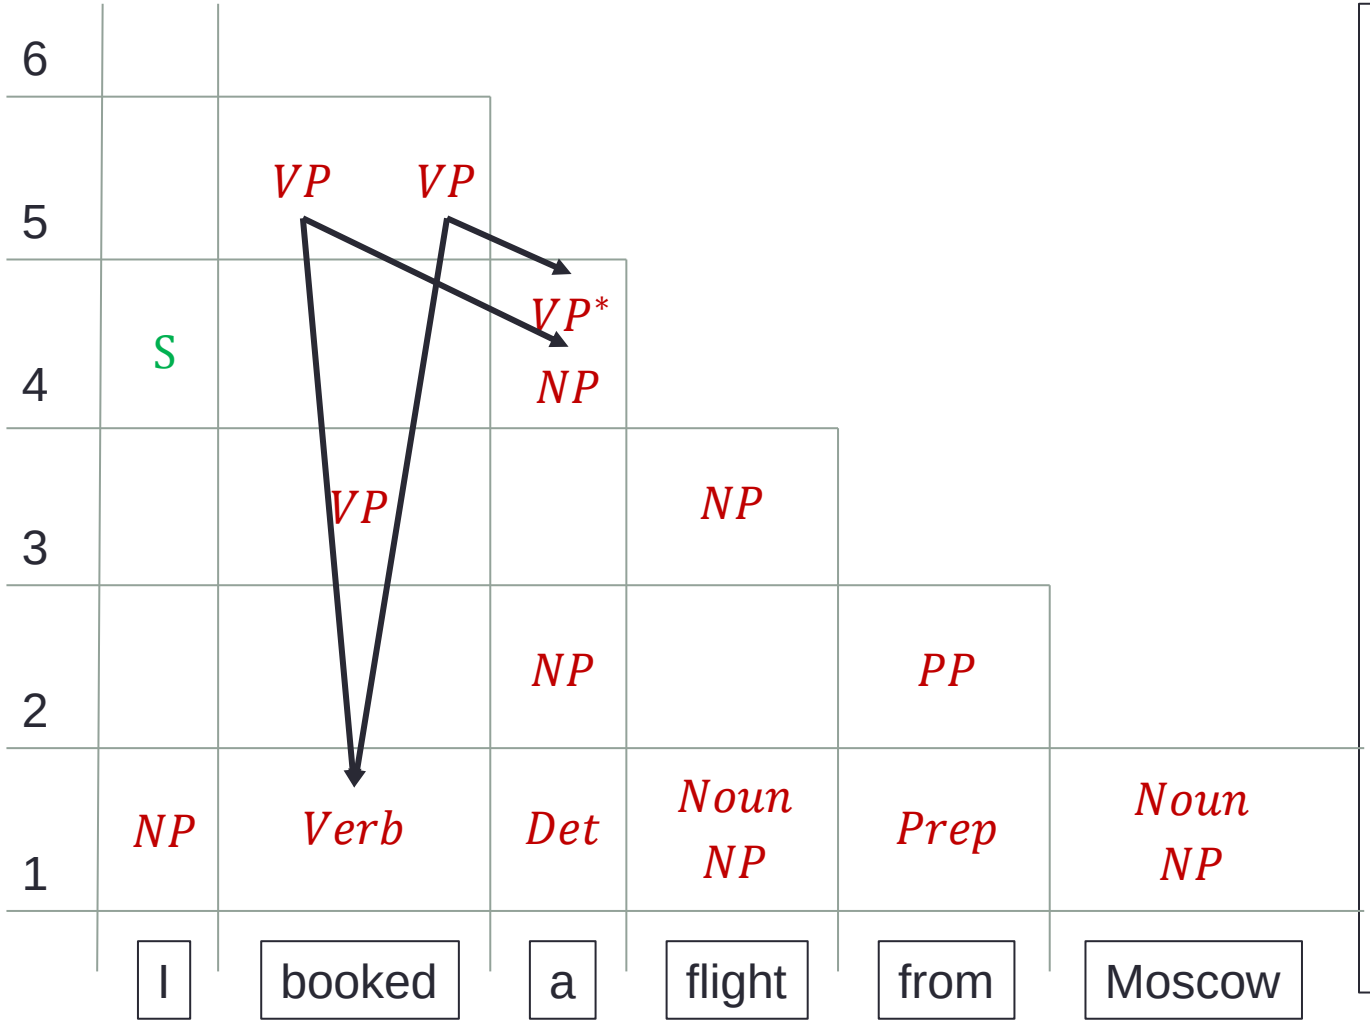

1. $S \rightarrow NP\ VP$
2. $VP \rightarrow Verb\ NP$
3. $VP \rightarrow Verb\ VP^*$
4. $VP^* \rightarrow NP\ PP$
5. $NP \rightarrow Det\ NP$
6. $NP \rightarrow Noun\ PP$
7. $PP \rightarrow Prep\ Noun$
8. $NP \rightarrow I$
9. $NP \rightarrow flight$
10. $NP \rightarrow Moscow$
11. $Verb \rightarrow booked$
12. $Noun \rightarrow flight$
13. $Noun \rightarrow Moscow$
14. $Det \rightarrow a$
15. $Prep \rightarrow from$

Алгоритм CYK

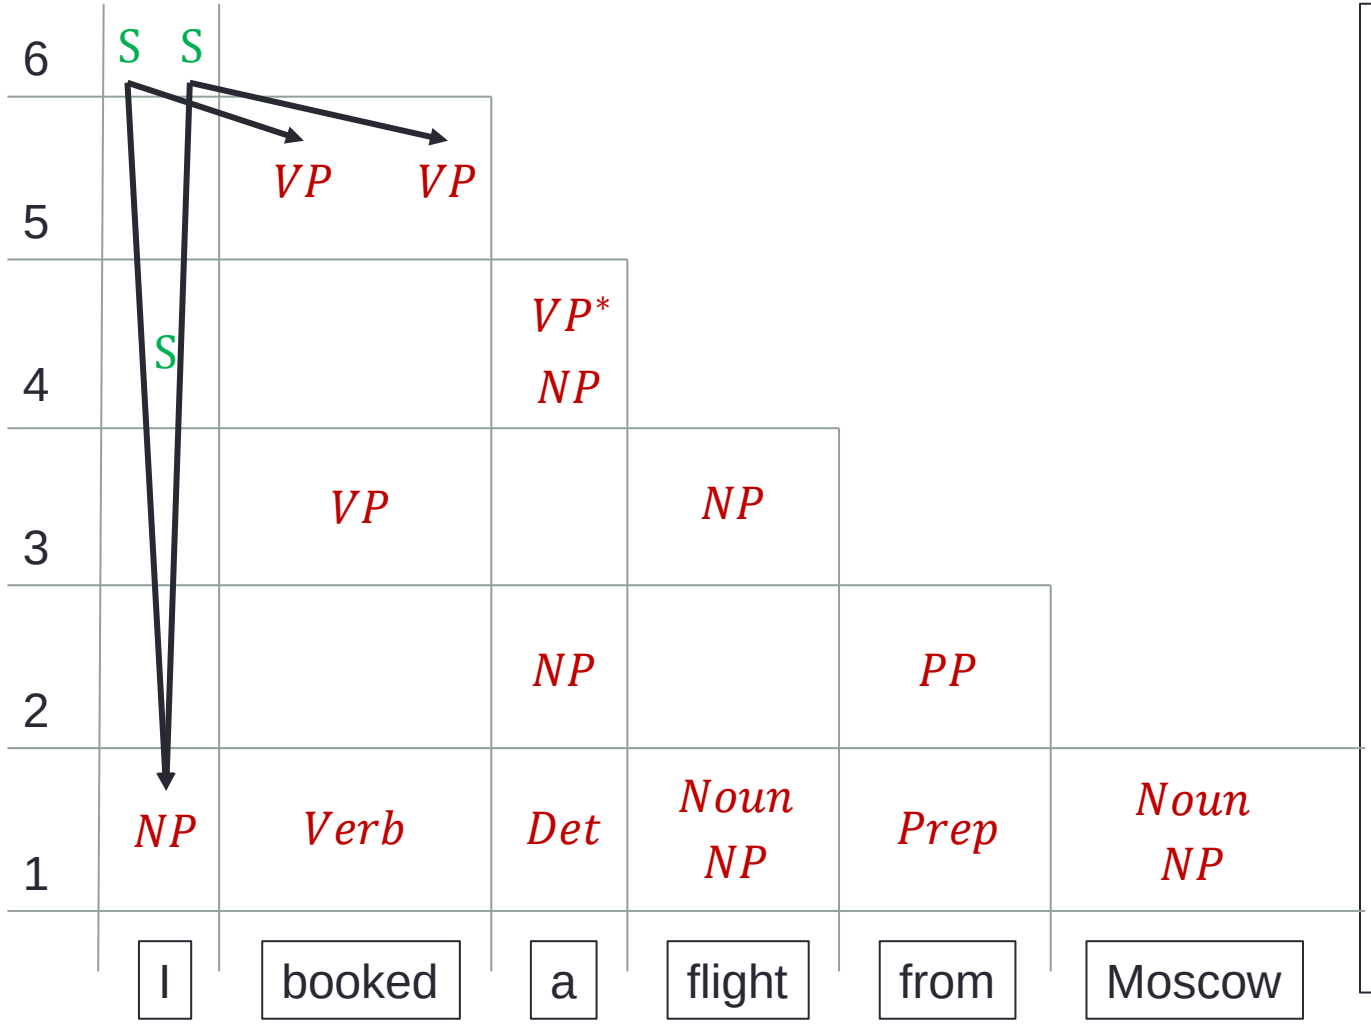

1. $S \rightarrow NP\ VP$
2. $VP \rightarrow Verb\ NP$
3. $VP \rightarrow Verb\ VP^*$
4. $VP^* \rightarrow NP\ PP$
5. $NP \rightarrow Det\ NP$
6. $NP \rightarrow Noun\ PP$
7. $PP \rightarrow Prep\ Noun$
8. $NP \rightarrow I$
9. $NP \rightarrow flight$
10. $NP \rightarrow Moscow$
11. $Verb \rightarrow booked$
12. $Noun \rightarrow flight$
13. $Noun \rightarrow Moscow$
14. $Det \rightarrow a$
15. $Prep \rightarrow from$

Выбор лучшего дерева

- Зададим каждому правилу вероятность его применения
- Будем оценивать вероятность разбора, как произведение вероятностей правил, участвующих в нем

1.	$S \rightarrow NP\ VP$	1.0
2.	$VP \rightarrow Verb\ NP$	0.90
3.	$VP \rightarrow Verb\ NP\ PP$	0.10
4.	$NP \rightarrow Pro$	0.2
5.	$NP \rightarrow Det\ NP$	0.3
6.	$NP \rightarrow Noun\ PP$	0.1
7.	$NP \rightarrow Noun$	0.4
8.	$PP \rightarrow Prep\ Noun$	1.0
9.	$Verb \rightarrow booked$	1.0
10.	$Noun \rightarrow flight$	0.3
11.	$Noun \rightarrow Moscow$	0.7

Построение грамматики

```
(S
        (NP
                (I Pro))
        (VP
                (booked Verb)
                (NP
                        (a Det)
                        (NP
                                (flight Noun)
                                (PP
                                        (from Prep)
                                        (Moscow Noun))))))
```

Построение грамматики

```
(S                                                    1.  S → NP VP
        (NP
                (I Pro))
        (VP
                (booked Verb)
                (NP
                        (a Det)
                        (NP
                                (flight Noun)
                                (PP
                                        (from Prep)
                                        (Moscow Noun))))))
```

Построение грамматики

```
(S
        (NP
                (I Pro))
        (VP
                (booked Verb)
                (NP
                        (a Det)
                        (NP
                                (flight Noun)
                                (PP
                                        (from Prep)
                                        (Moscow Noun))))))
```

1. $S \rightarrow NP\ VP$
2. $NP \rightarrow Pro$

Грамматика зависимостей

- Формальная модель описания структуры словосочетаний (предложений)
- Описывается в виде иерархии слов, между которыми установлено бинарное отношение зависимости
- Различают типы зависимостей (соответствуют типам синтаксических правил)

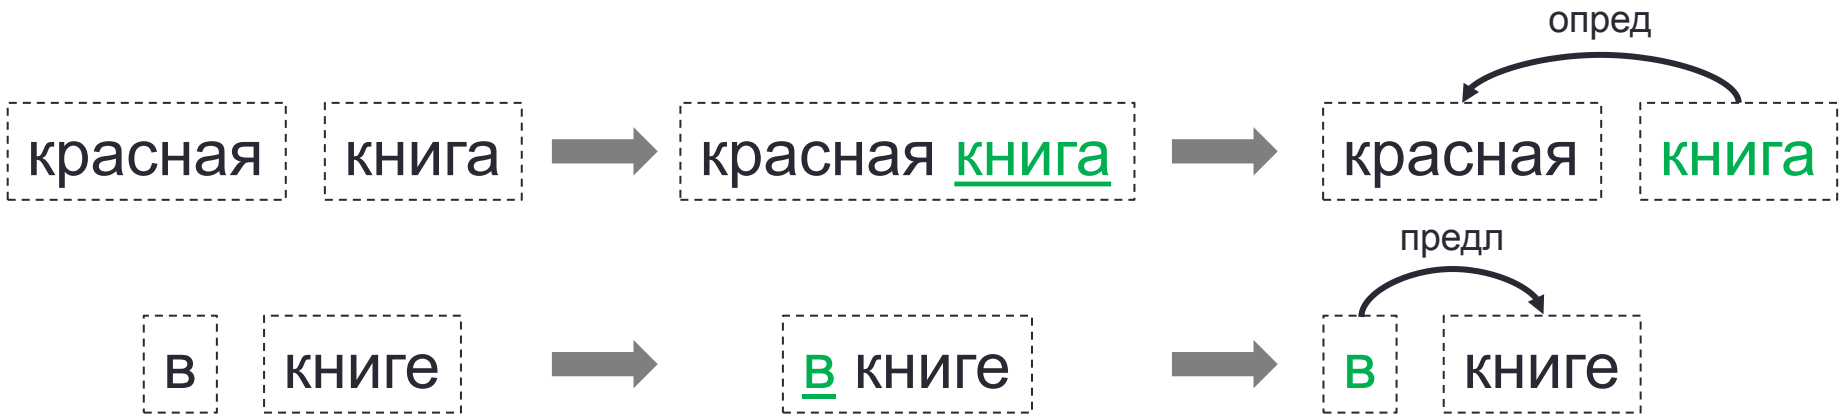

Грамматика зависимостей

- Дерево составляющих может быть преобразовано в дерево зависимостей

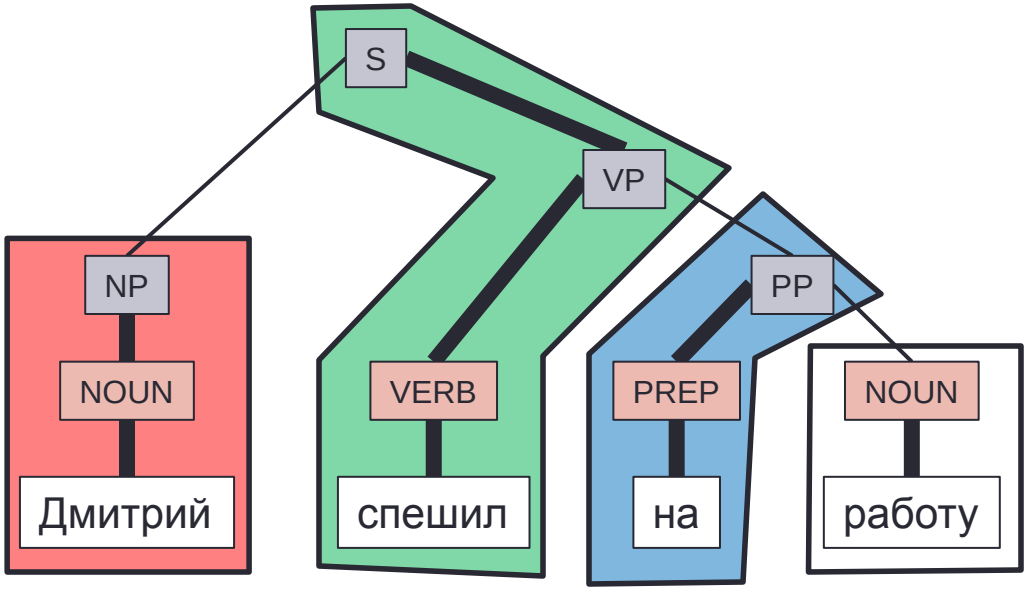

Грамматика зависимостей

- Не все синтаксические отношения подчинительные
  - Сочинительная группа

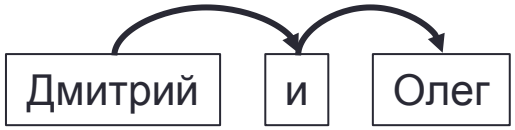

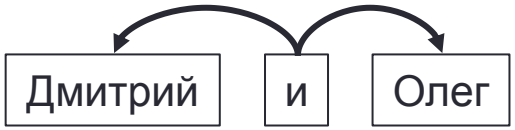

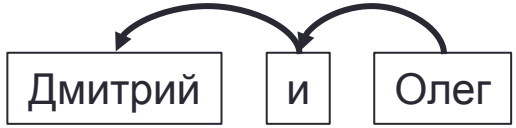

  - Сложносочиненные предложения

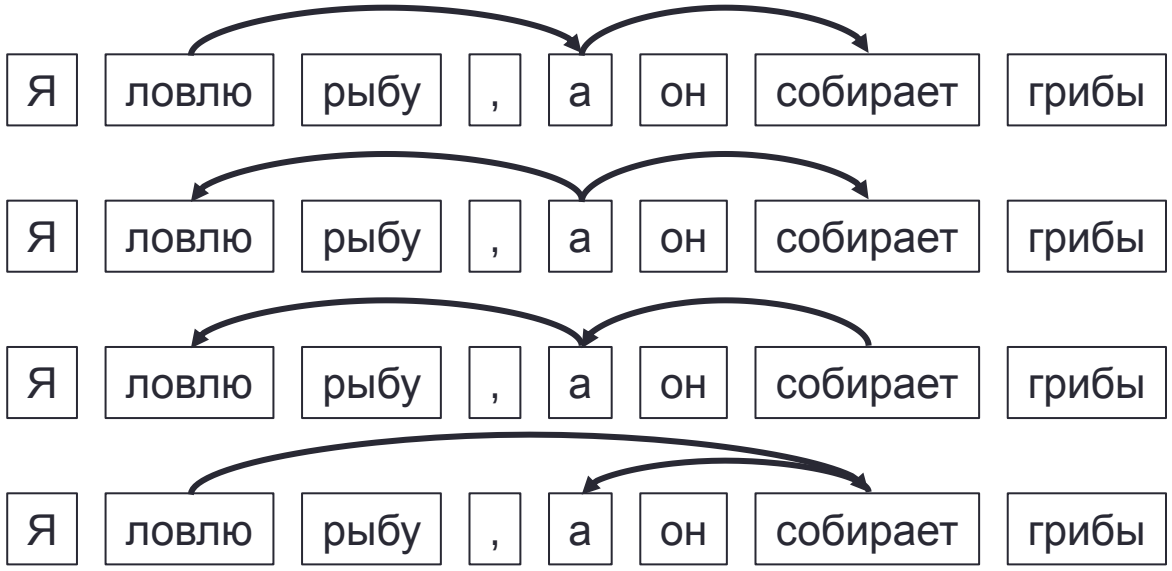

Грамматика зависимостей

- Не все синтаксические отношения подчинительные
  - Сочинительная группа

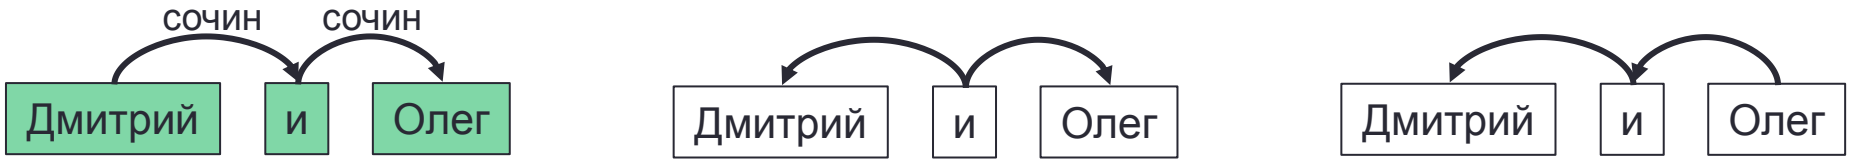

  - Сложносочиненные предложения

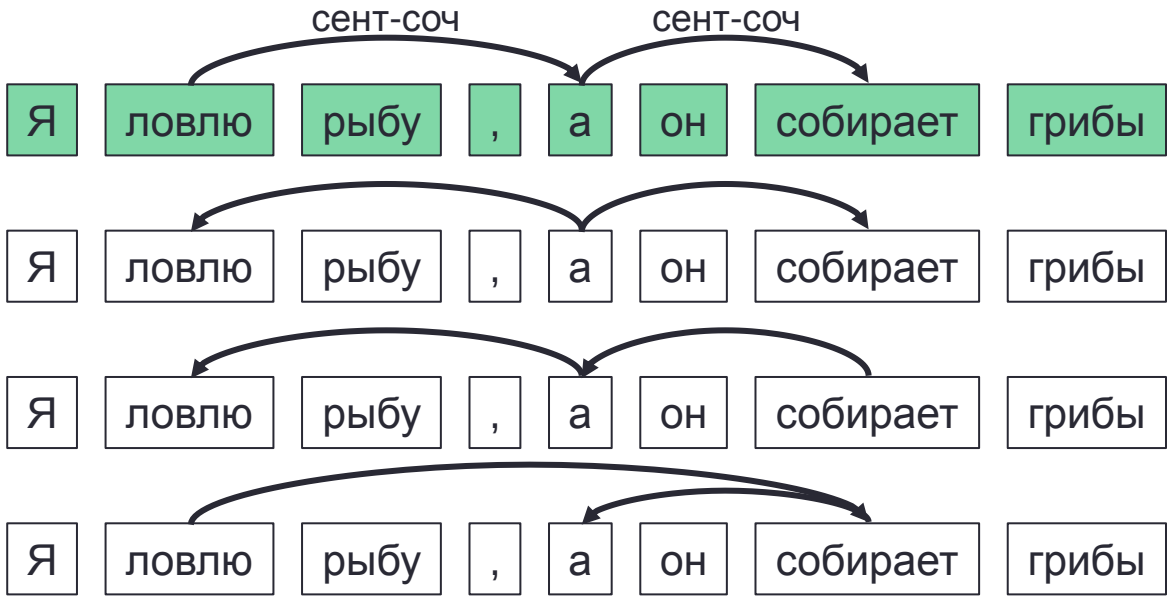

Проективное синтаксическое дерево

- Дерево зависимостей является проективным, если
  - Для каждой дуги в дереве существует направленный путь от главного слова до каждого из слов, расположенных между главным и зависимым словом этой дуги
  - $(i, l, j) \Rightarrow \forall k \in [\min(i, j), \max(i, j)], i \rightarrow^* k$

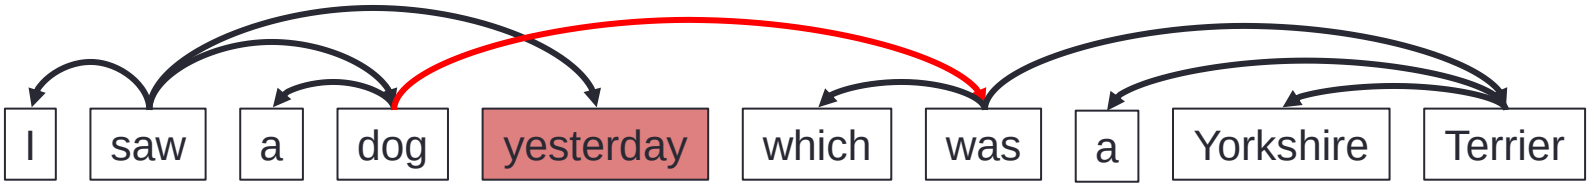

Методы динамического программирования

- Некоторое обобщение алгоритма CKY для грамматик зависимостей
  - Строится дерево разбора предложения снизу-вверх
  - На каждом этапе рассматриваются подстроки исходной строки
  - Если подстрока состоит из двух деревьев, оценивается левая и правая дуга между ними:
    - $score(A) = score(B) + score(C) + score(arc)$

- Варианты
  - Алгоритм Коллинса. Сложность $O(n^5)$
  - Алгоритм Эйснера. Сложность $O(n^3)$

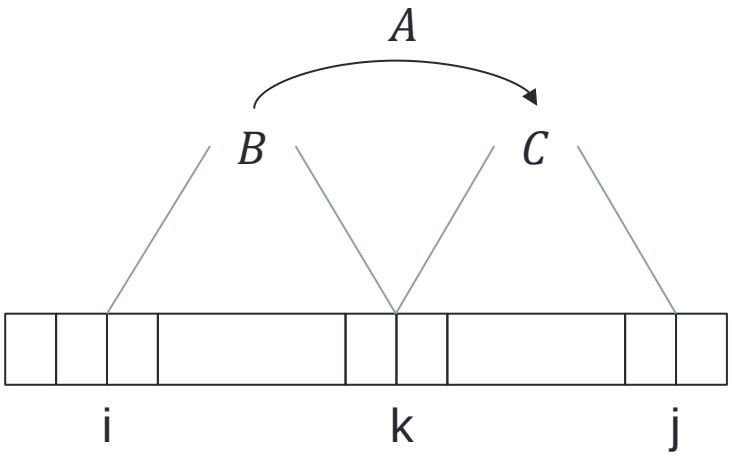

Графовые методы

- Предложение представляется в виде взвешенного полного графа (ориентированного)
  - Вершины графа – слова + root
  - Дуги графа – отношения между словами
- Цель
  - Найти подграф, являющийся деревом зависимостей

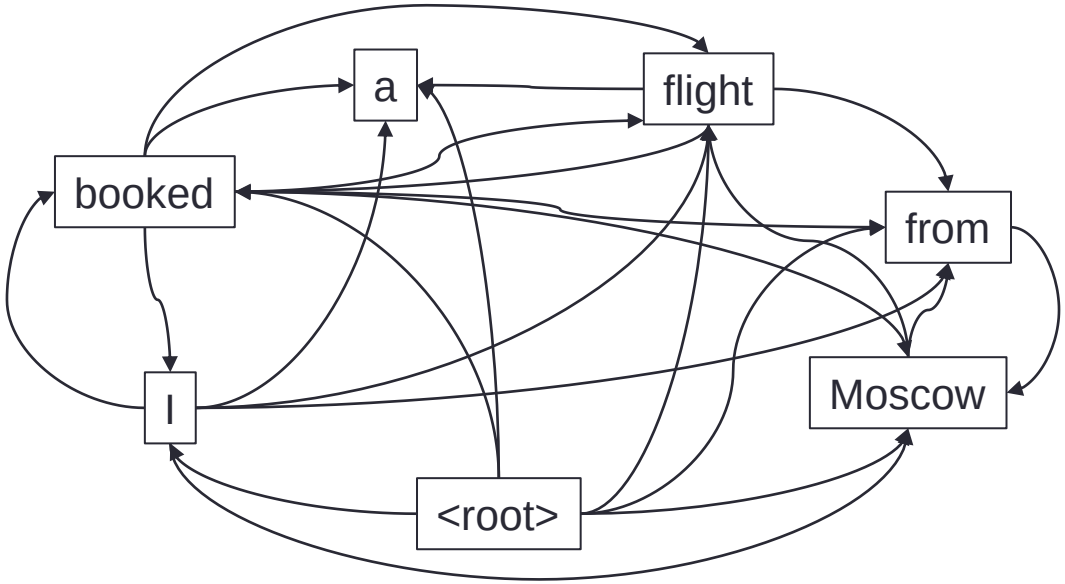

Графовые методы

- Для каждой дуги (i, j) вычисляется ее вес $s(i, j)$
- Вес подграфа в графе $s(x, y) = \sum_{(i,j) \in y} s(i, j)$, где
  - x – вершины подграфа,
  - y – дуги подграфа

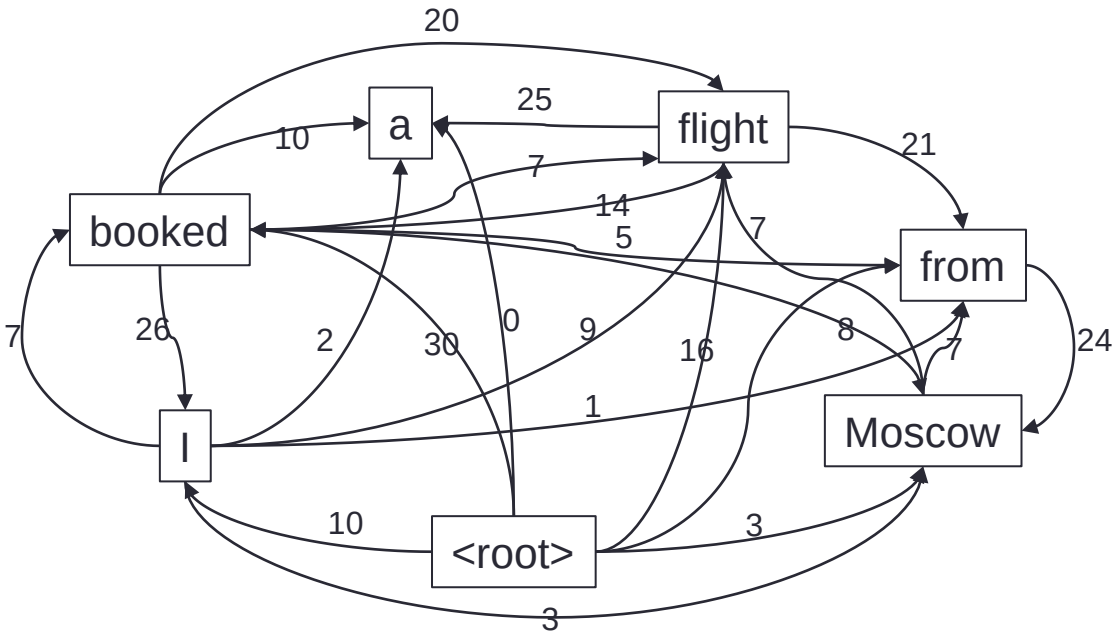

Максимальное покрывающее дерево (MST)

- Задача синтаксического анализа формулируется как задача нахождения максимального покрывающего дерева (MST) в связанном взвешенном графе
  - Дерево называется покрывающим, если
    - Включает все вершины графа
    - Содержит минимальное количество дуг из графа, так, чтобы из корня дерева можно было «дойти» до любой вершины графа

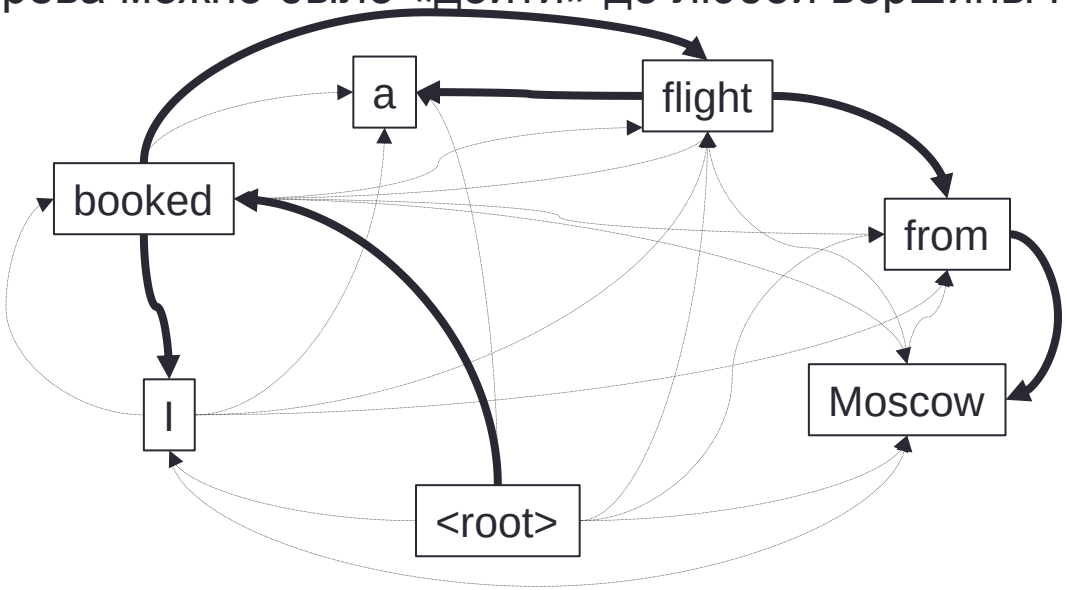

Transition-based parsing

- *Система переходов* состоит из
  - C – множество конфигураций
  - T – множество переходов. $t: C \rightarrow C$
  - c_s – функция инициализации
  - $C_t \subseteq C$ – множество конечных конфигураций

- *Конфигурация* состоит из:
  - Σ – стек
  - B – буфер
  - A – множество зависимостей (i, l, j)

- Последовательность переходов для последовательности x:
  - $c_0 = c_s(x)$
  - $c_i = t(c_{i-1}), i = \overline{1..m}$
  - $c_m \in C_t$

Transition-based parsing

- Алгоритм
  - Получить начальную конфигурацию $c = c_s(x)$
  - Пока $c \notin C_t$
    - Выбрать переход $t = \underset{t}{\operatorname{argmax}}\, Score(c, t)$
    - Выполнить переход $c = t(c)$
  - Извлечь множество зависимостей из $c.A$

Arc-standard

- Инициализация
  - $c_s(x = x_1 \dots x_n) = ([0], [1, \dots, n], \emptyset)$
- Конечное состояние
  - $C_t = \{c \in C | c = ([0], [\,], A)\}$
- Переходы
  - $(Shift)$ $(\sigma, [i|\beta], A) \rightarrow ([\sigma|i], \beta, A)$
  - $(LeftArc_l)$ $([\sigma|i|j], B, A) \rightarrow ([\sigma|j], B, A \cup \{(j, l, i)\})$, если $i \neq 0$
  - $(RightArc_l)$ $([\sigma|i|j], B, A) \rightarrow ([\sigma|i], B, A \cup \{(i, l, j)\})$

Arc-standard

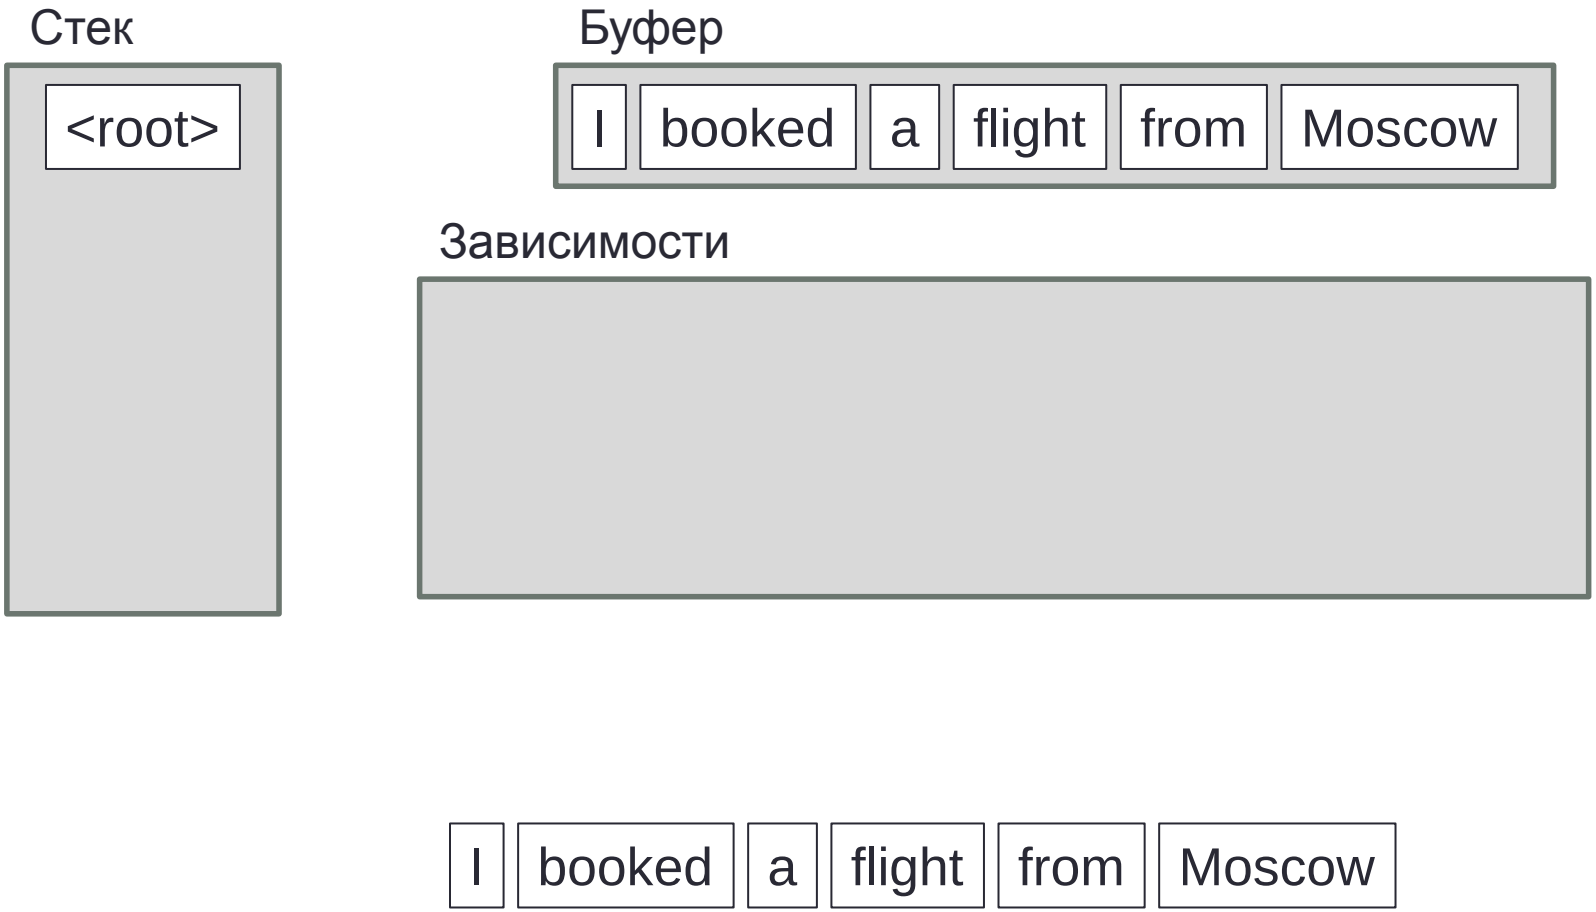

I | booked | a | flight | from | Moscow

Arc-standard

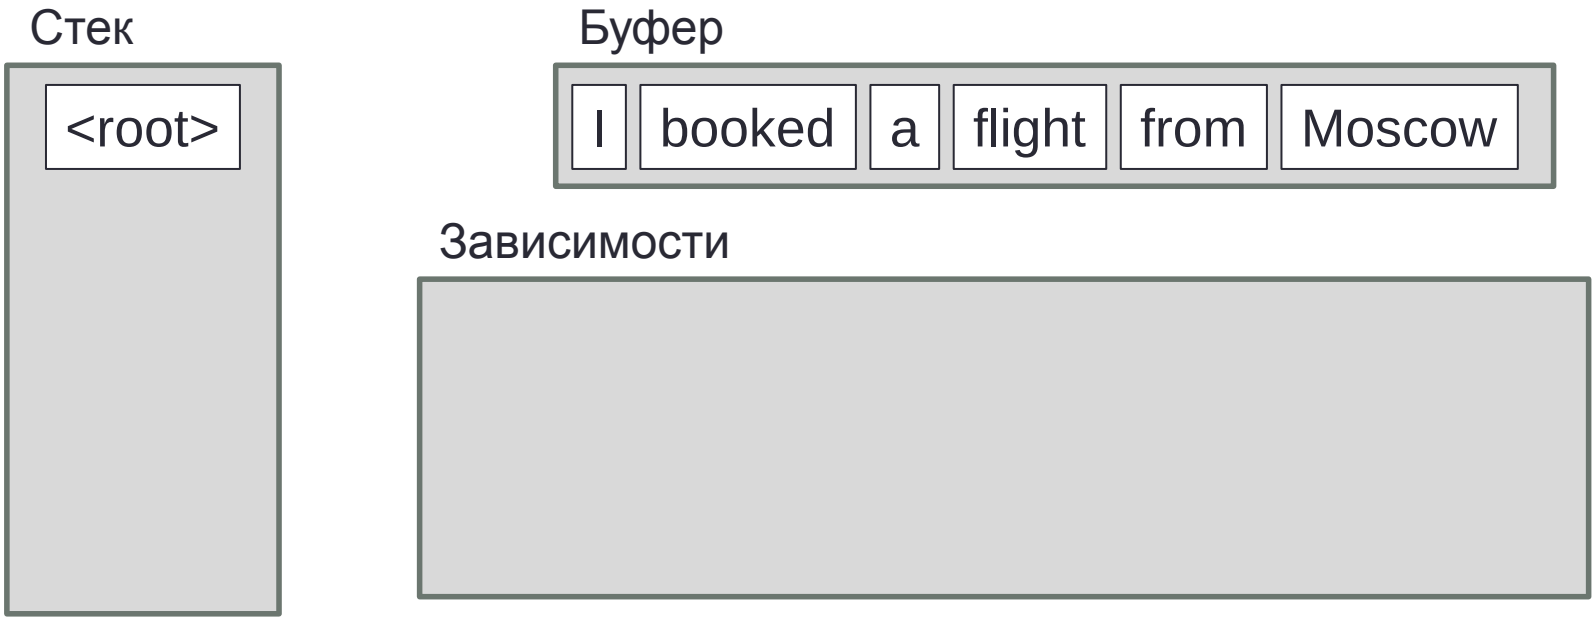

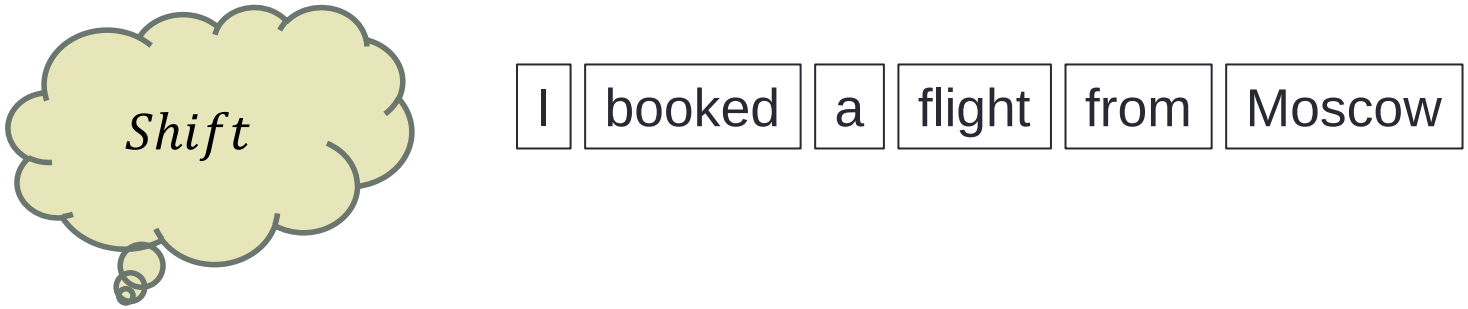

Arc-standard

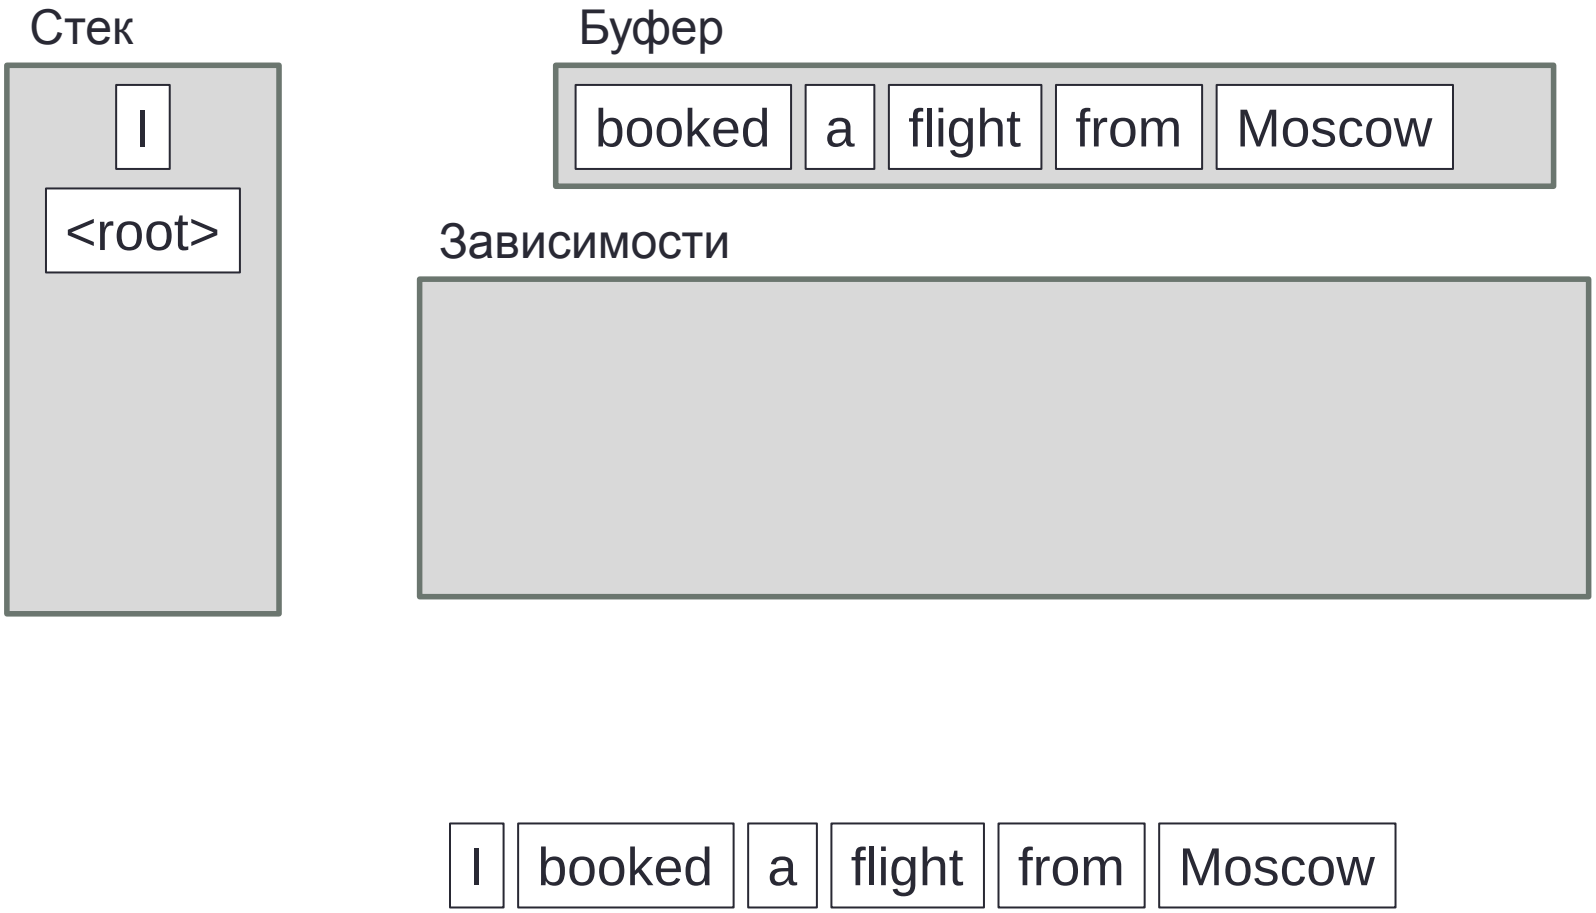

I | booked | a | flight | from | Moscow

Arc-standard

Arc-standard

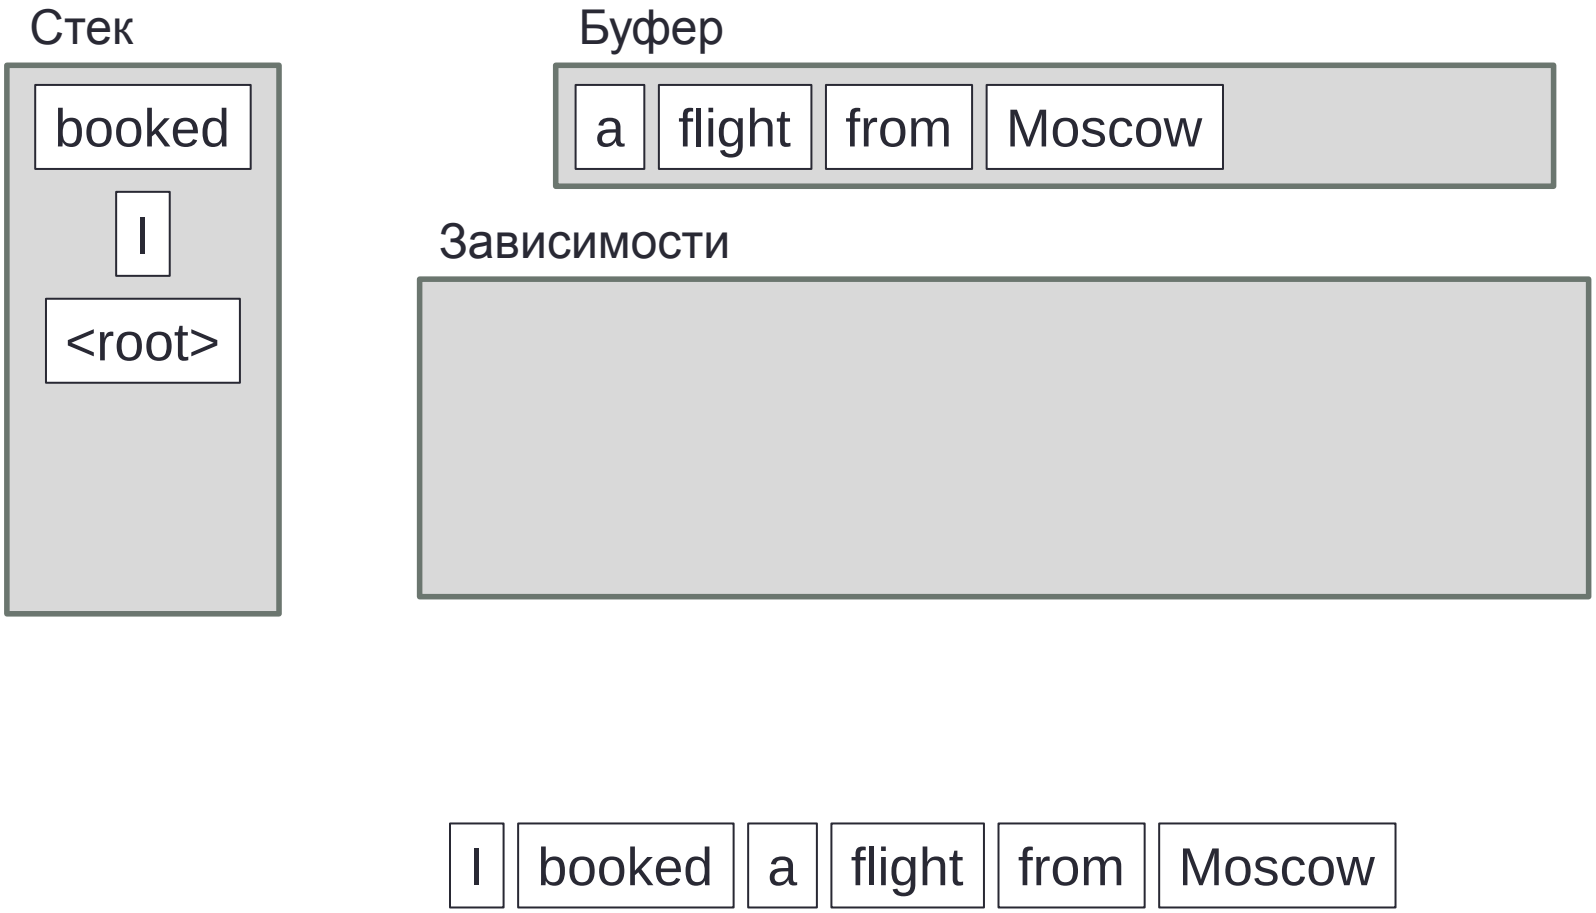

I | booked | a | flight | from | Moscow

Arc-standard

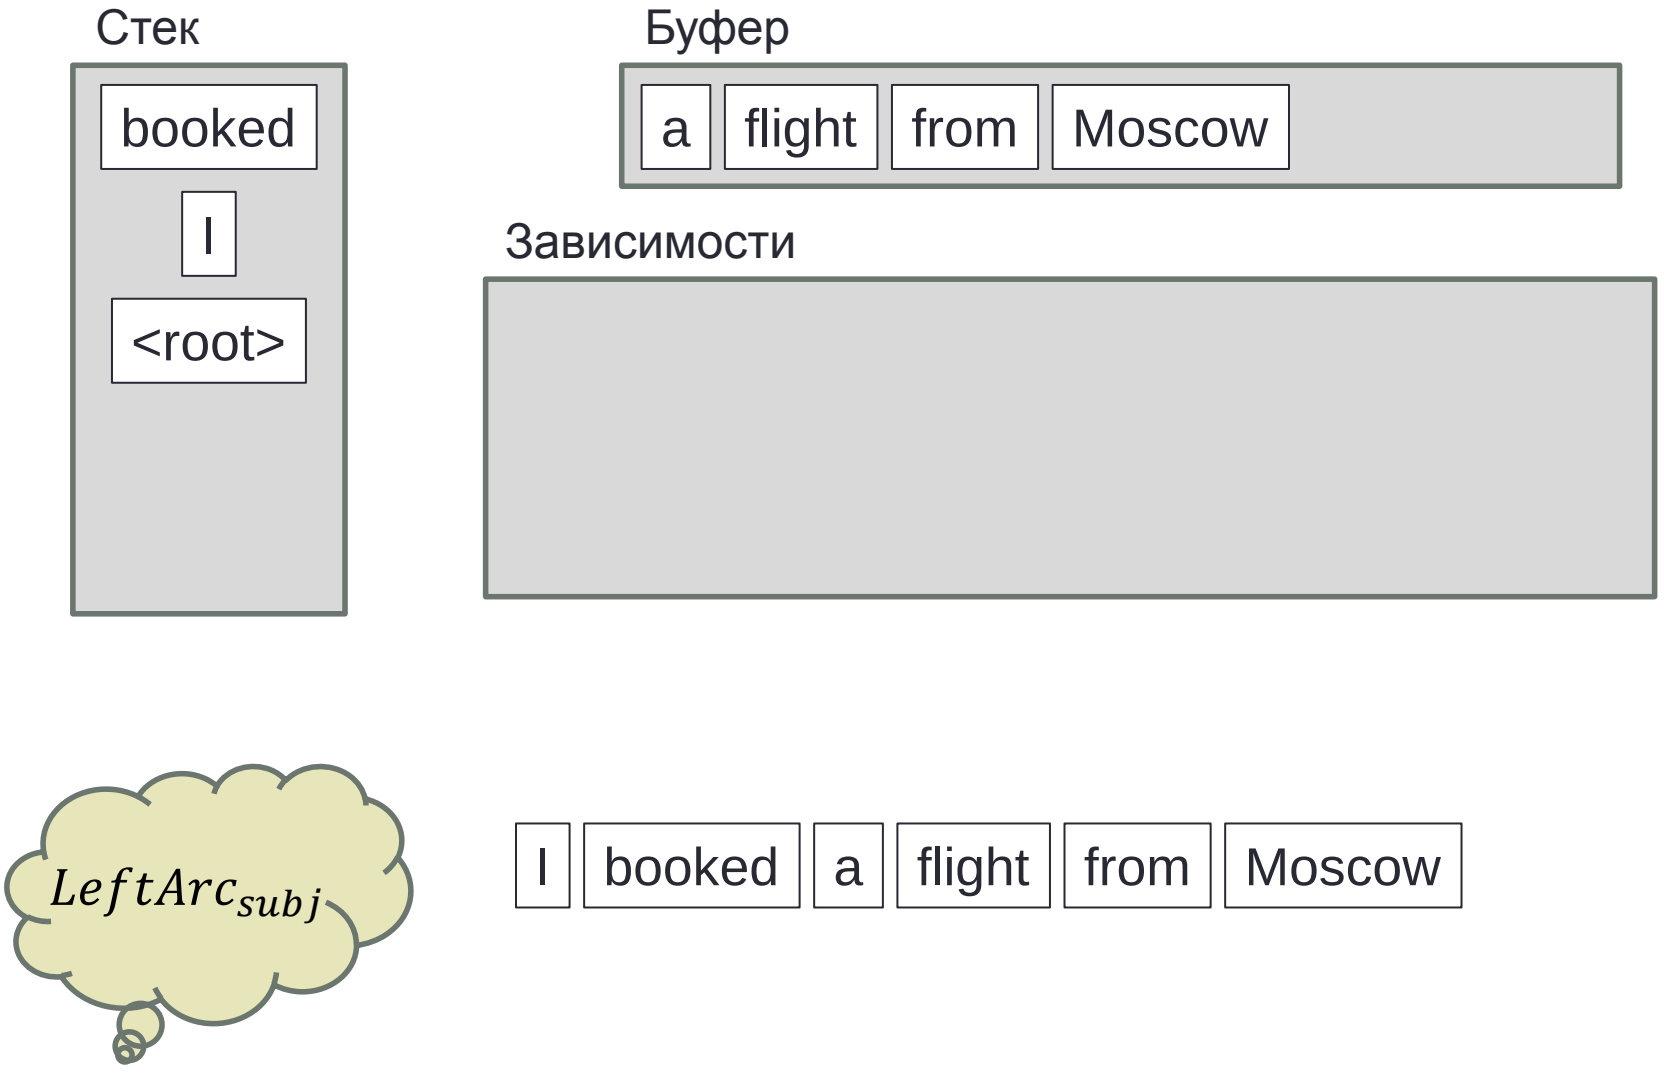

Arc-standard

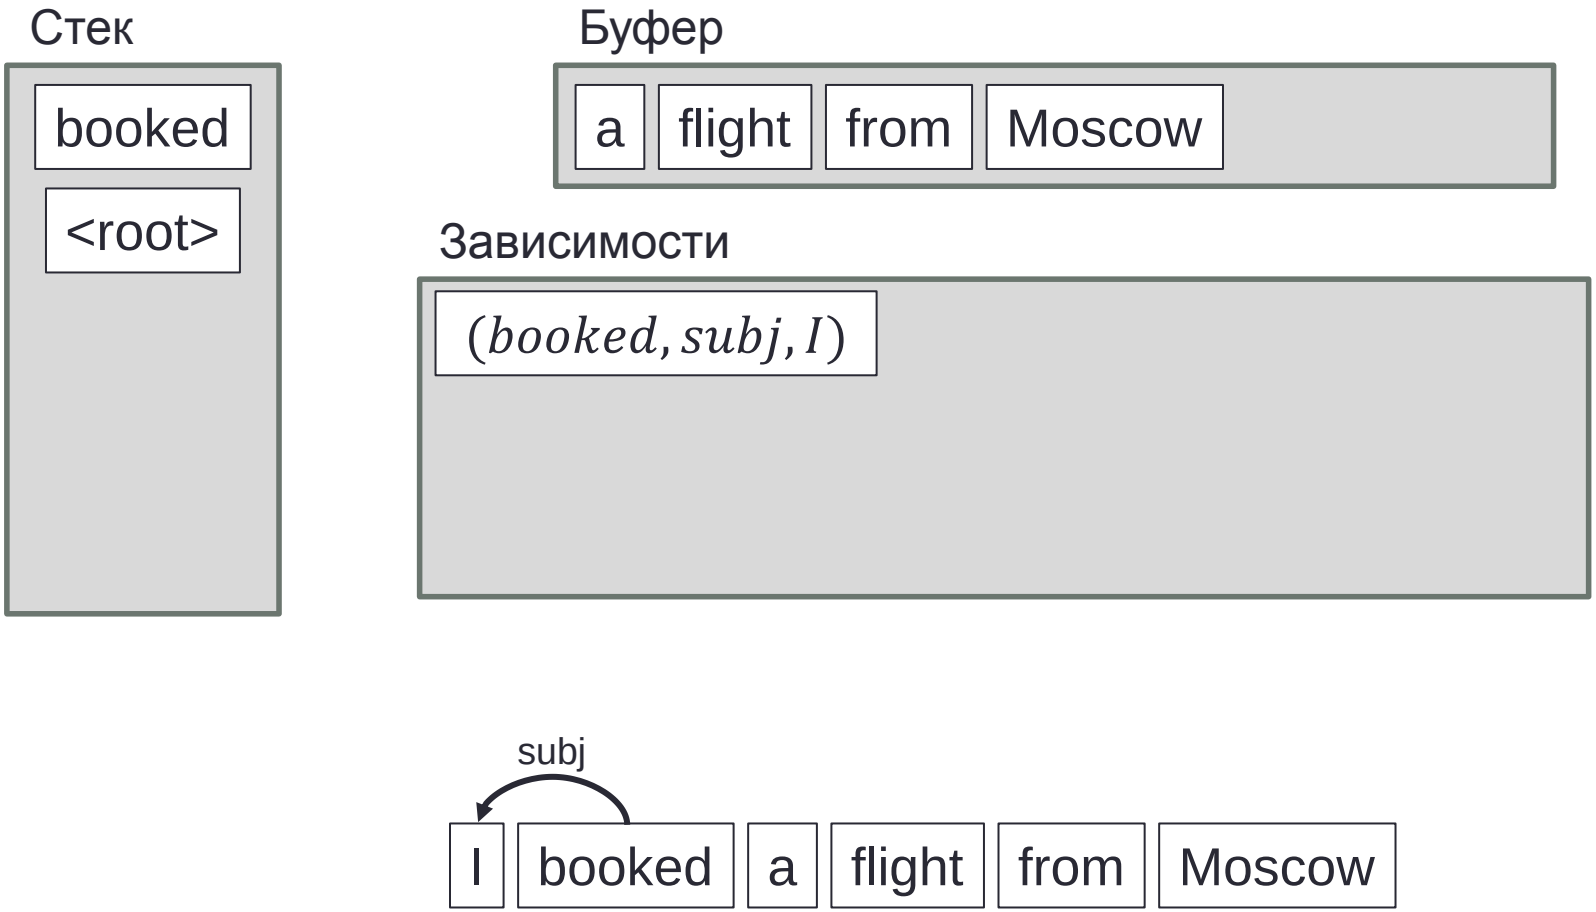

Arc-standard

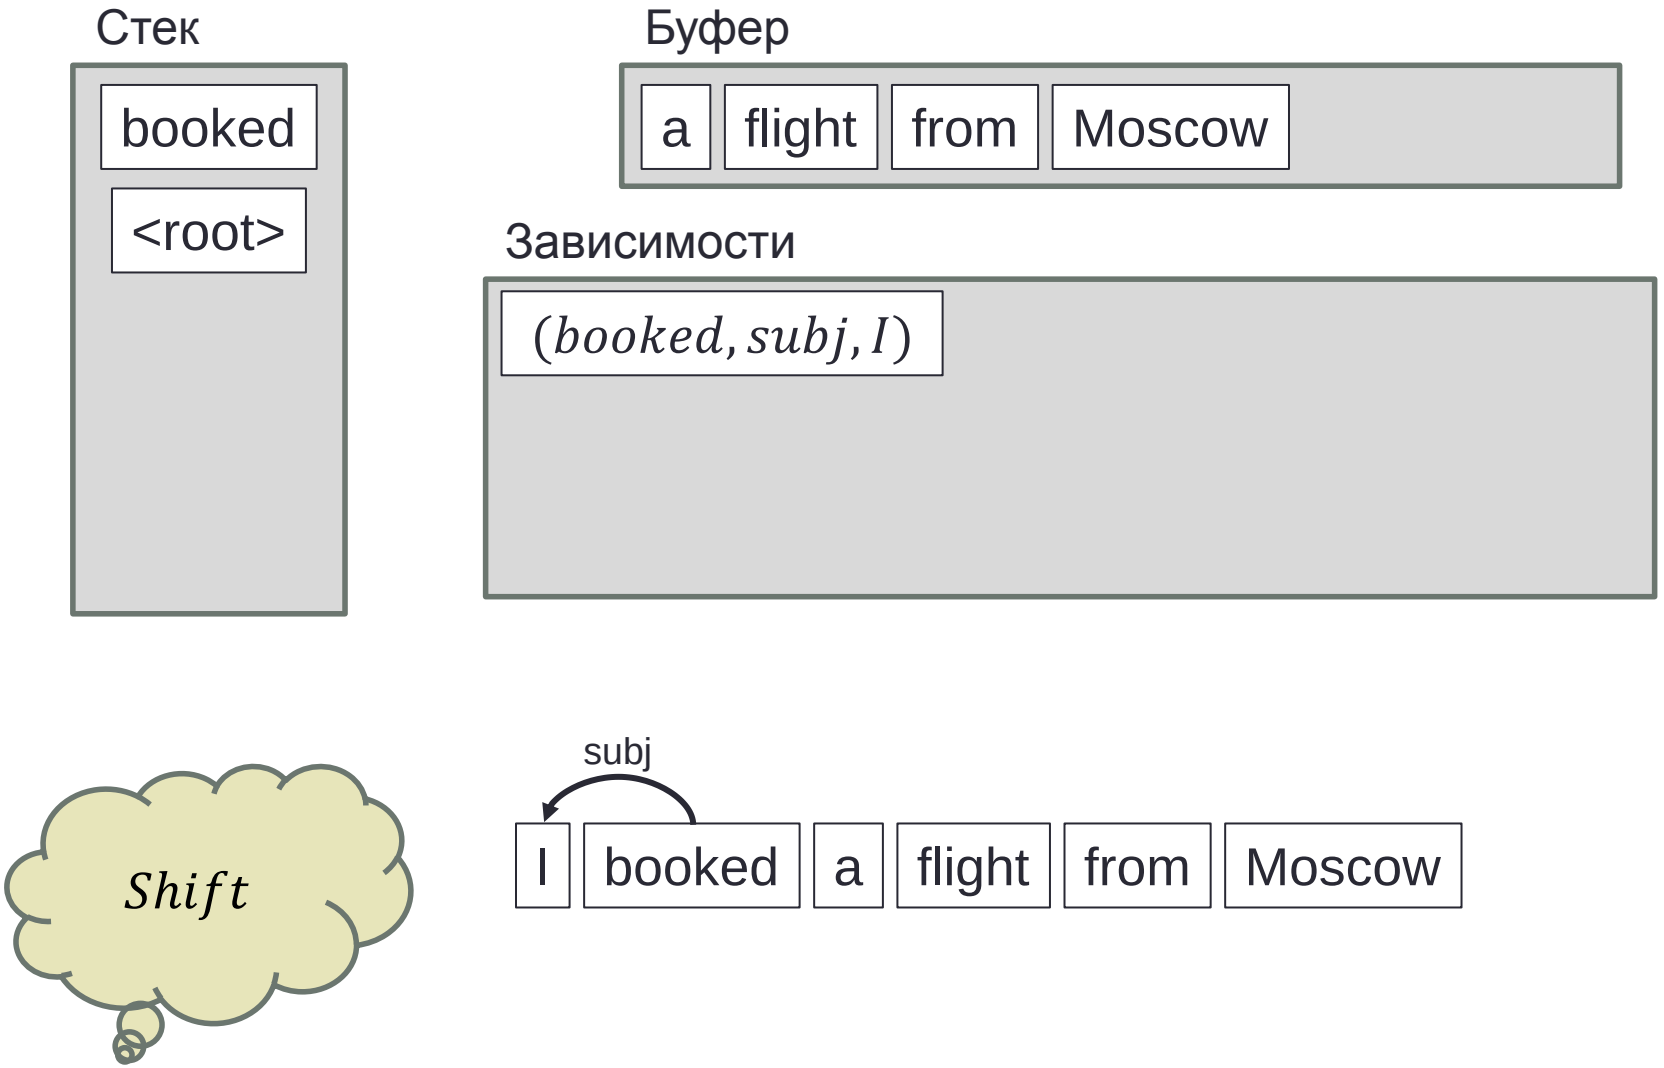

Arc-standard

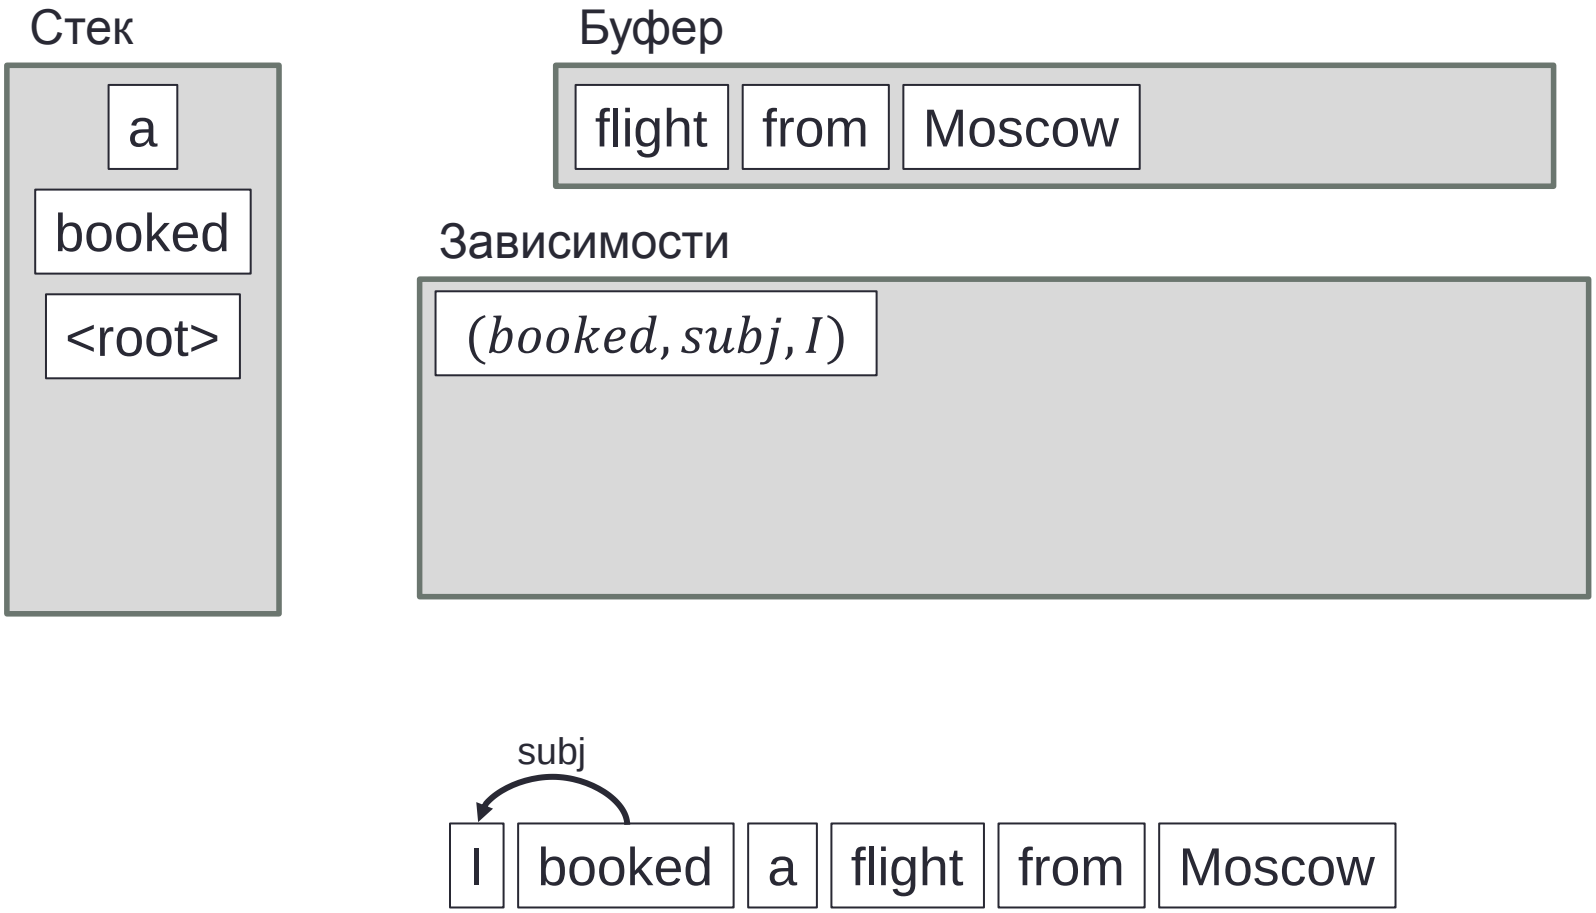

Arc-standard

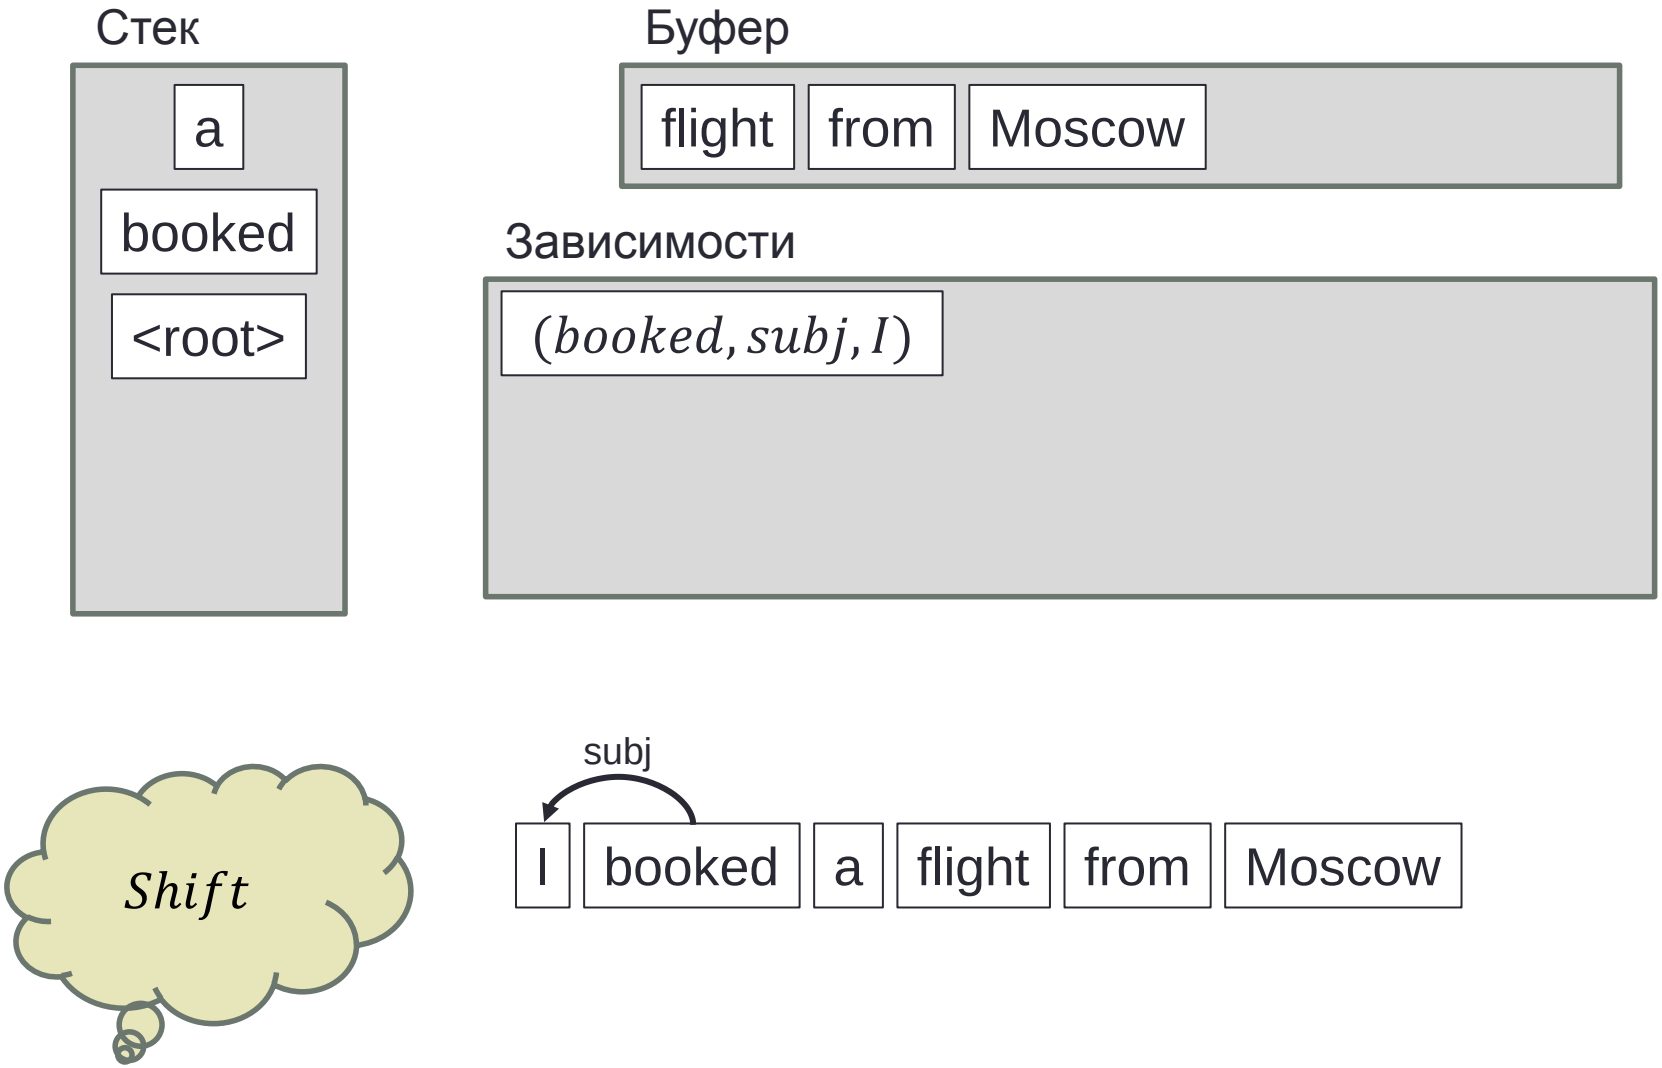

Arc-standard

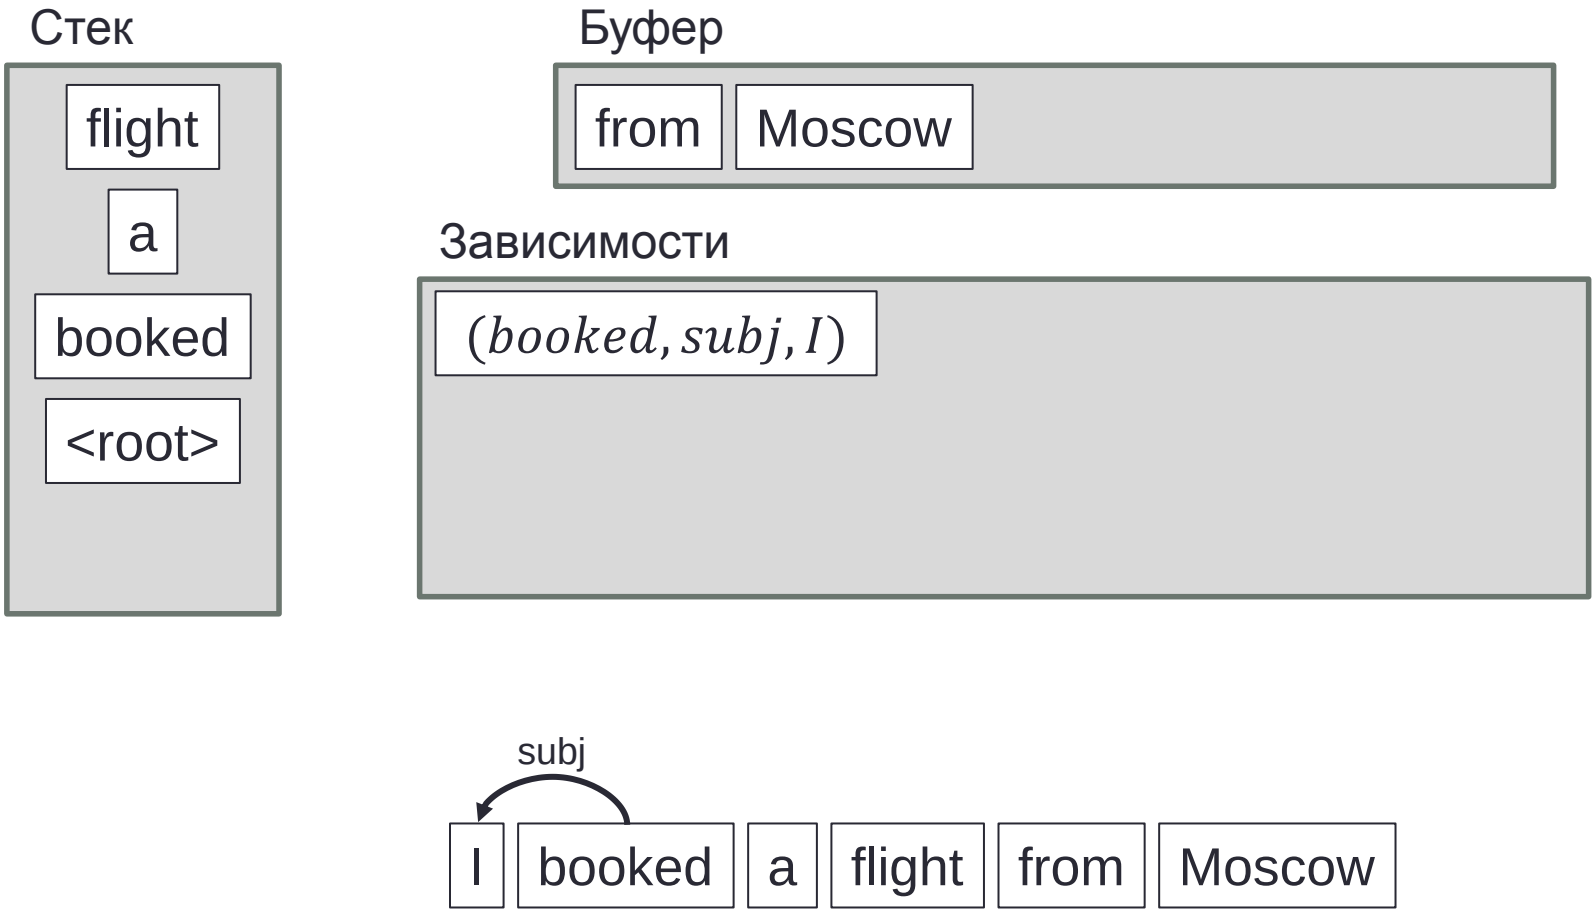

Arc-standard

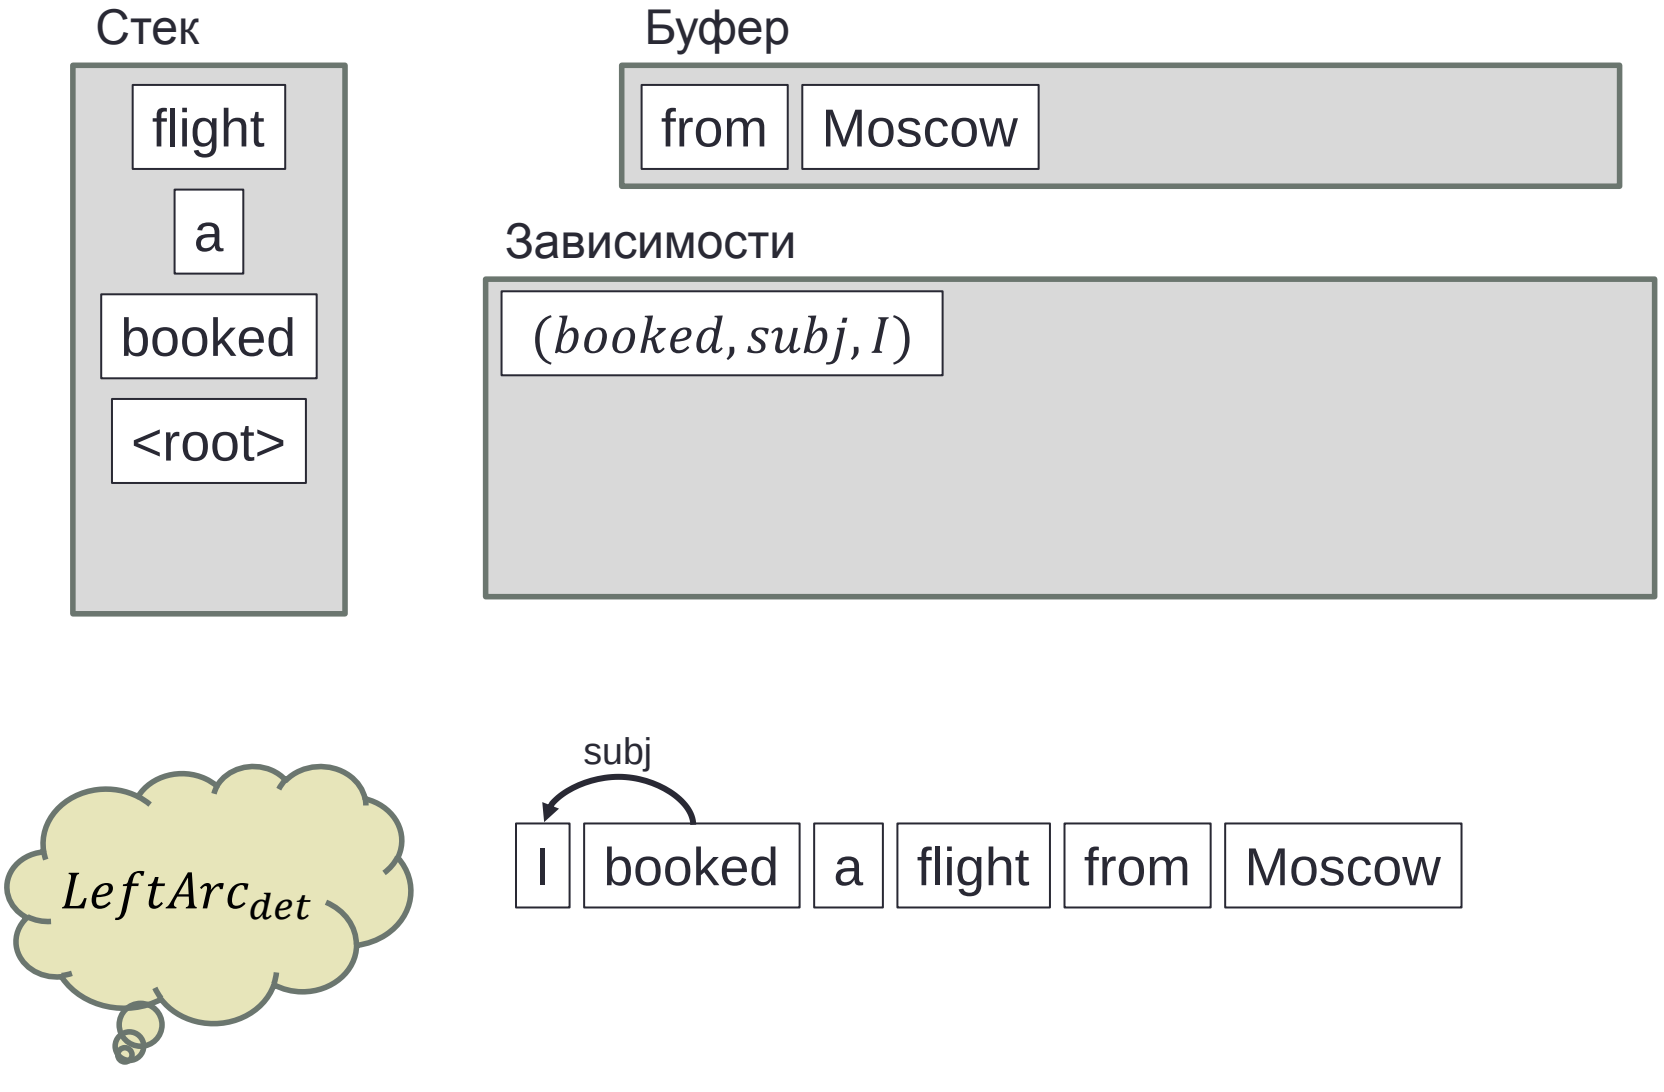

Arc-standard

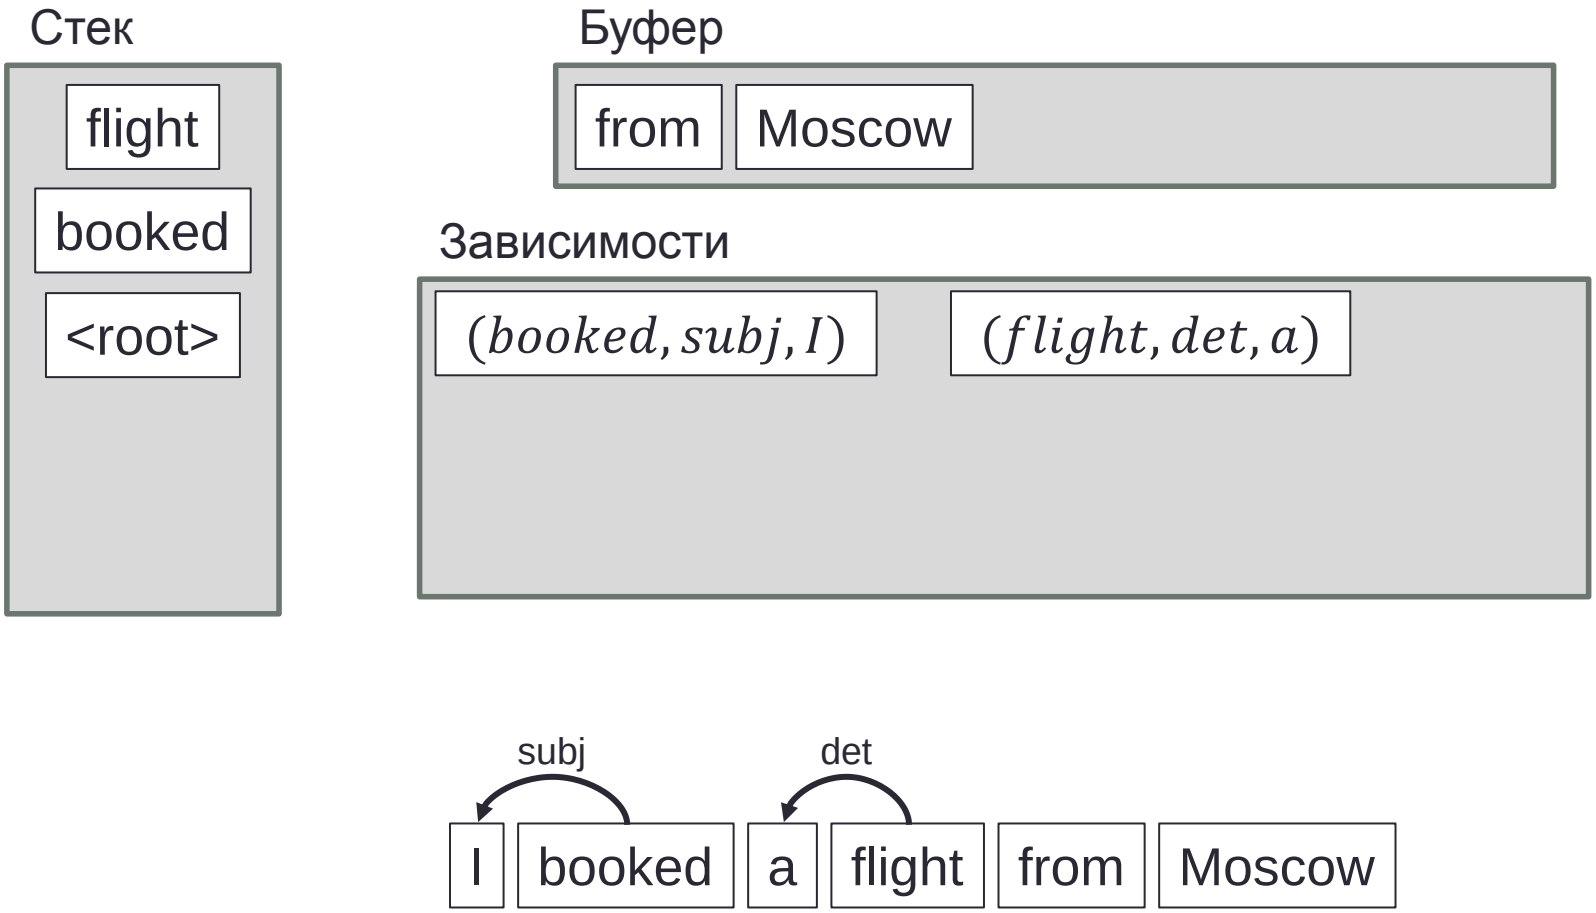

Arc-standard

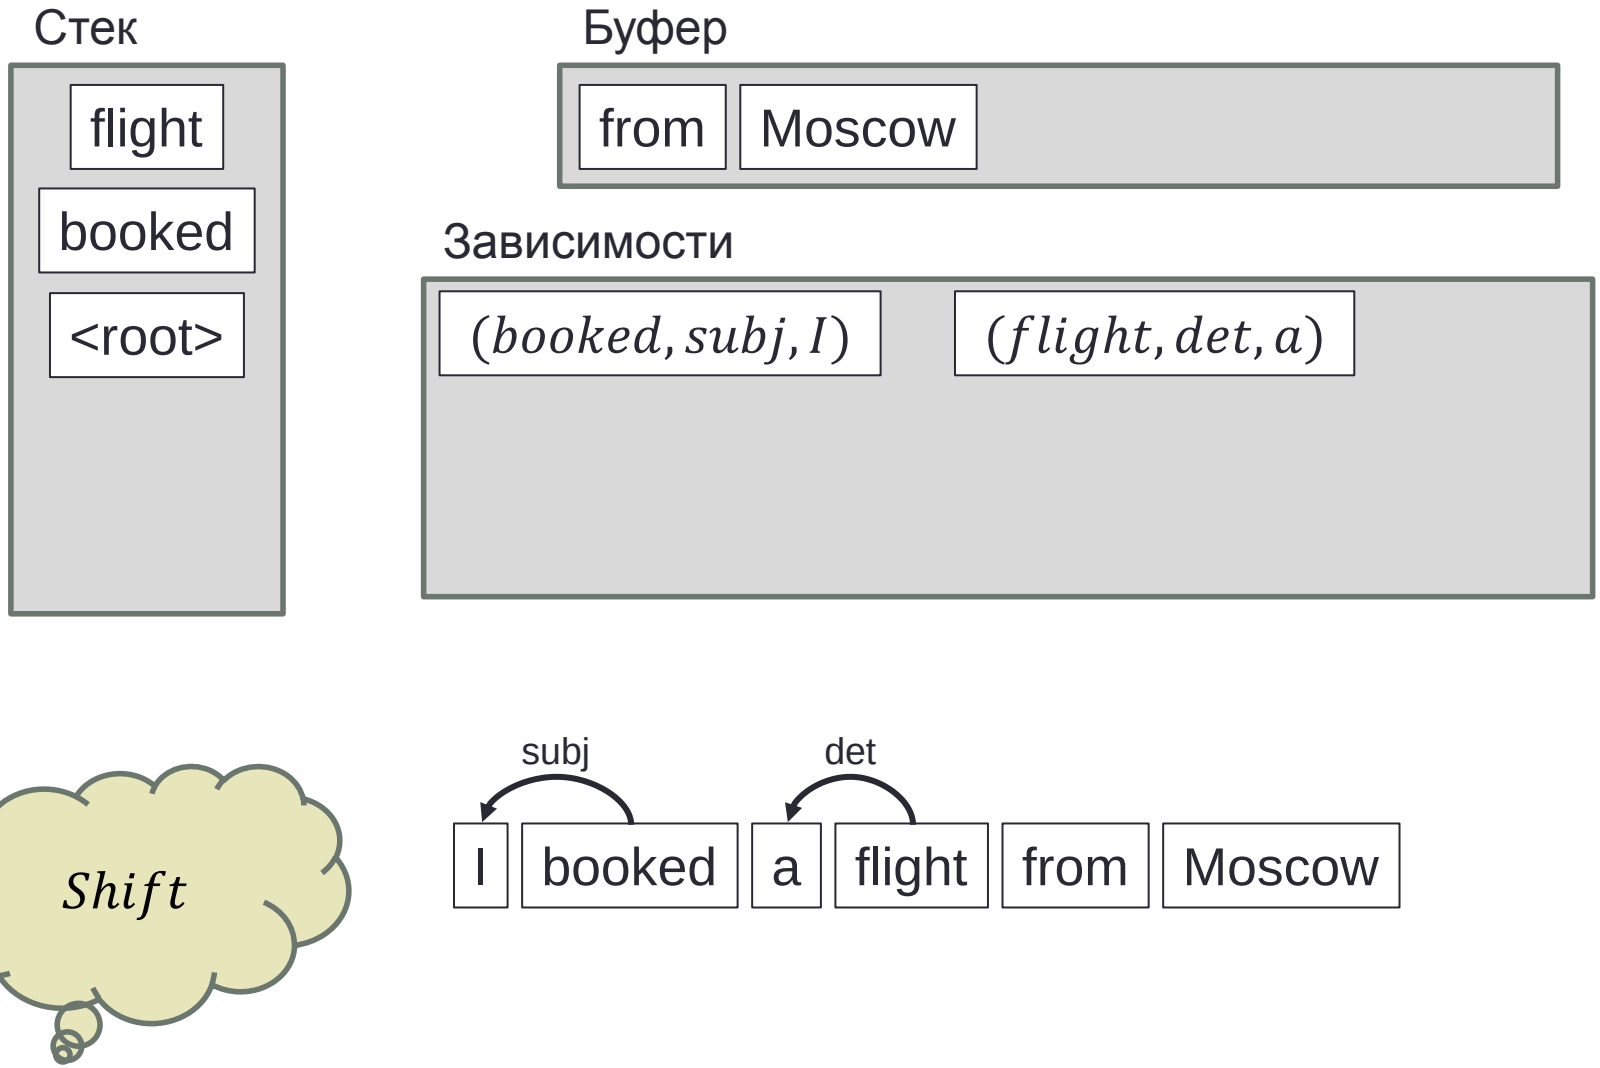

Arc-standard

Стек

- from
- flight
- booked
- <root>

Буфер

- Moscow

Зависимости

- $(booked, subj, I)$
- $(flight, det, a)$

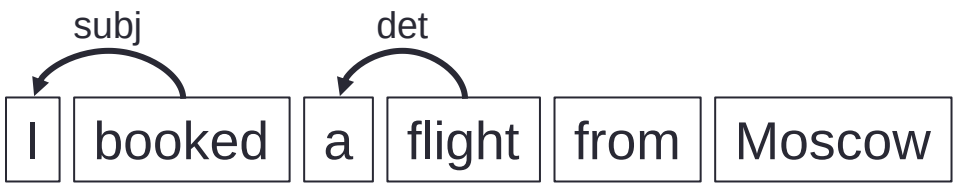

Arc-standard

Стек

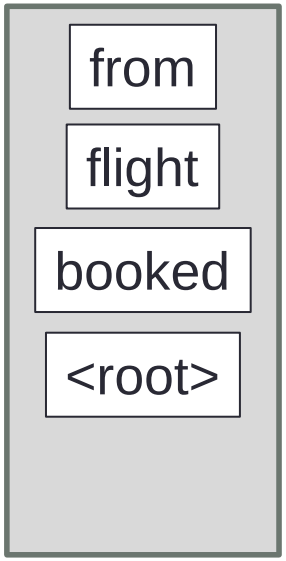

Буфер

Зависимости

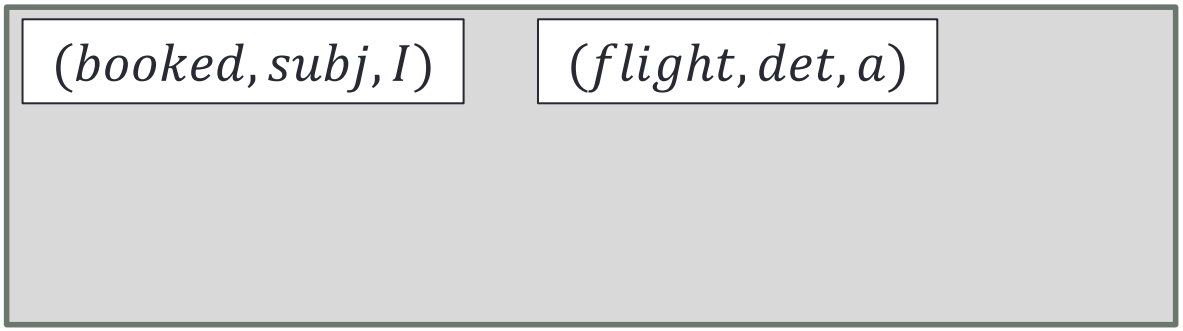

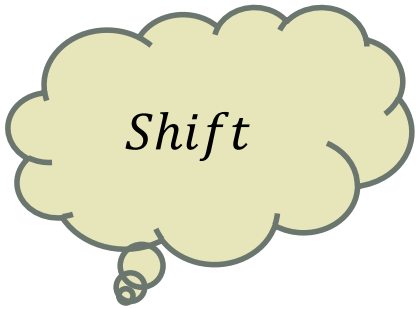

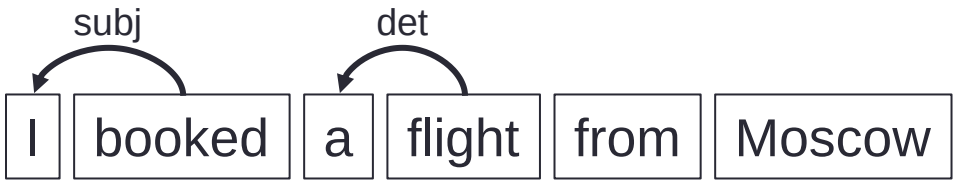

Arc-standard

Стек

Moscow

from

flight

booked

<root>

Буфер

Зависимости

$(booked, subj, I)$

$(flight, det, a)$

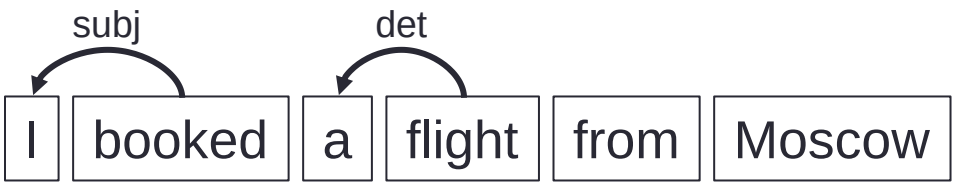

Arc-standard

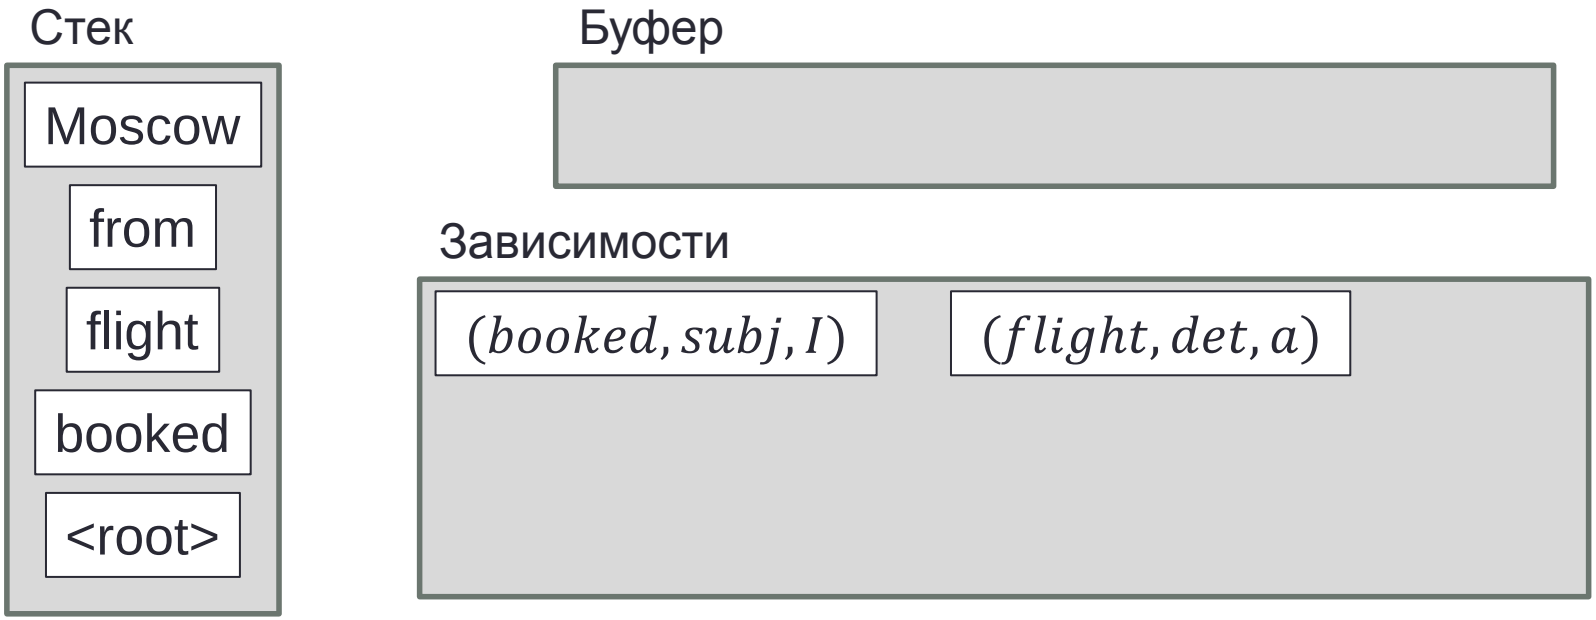

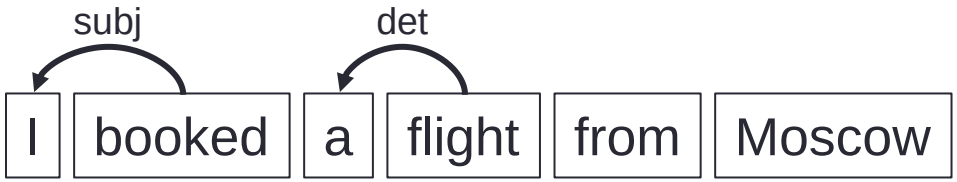

Arc-standard

Стек

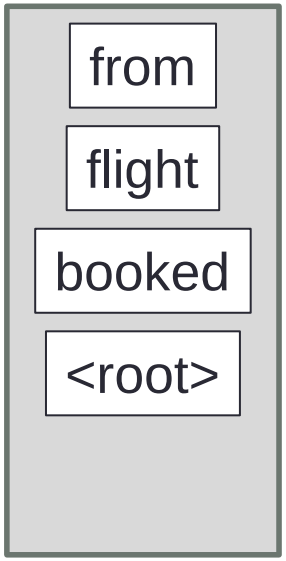

Буфер

Зависимости

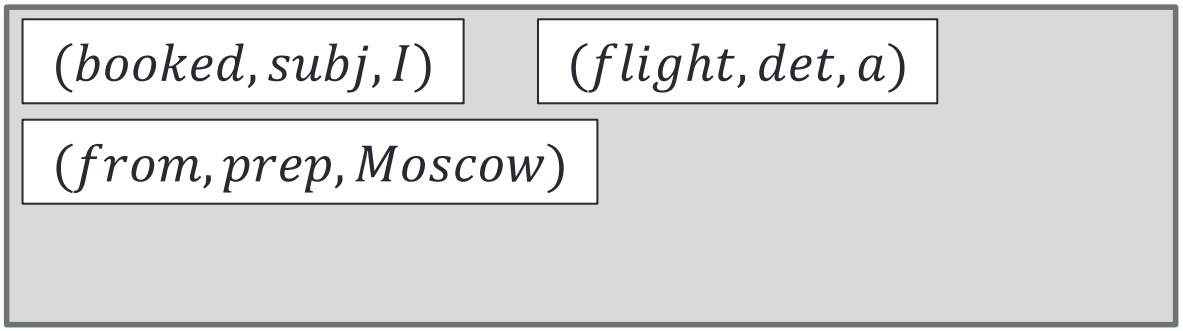

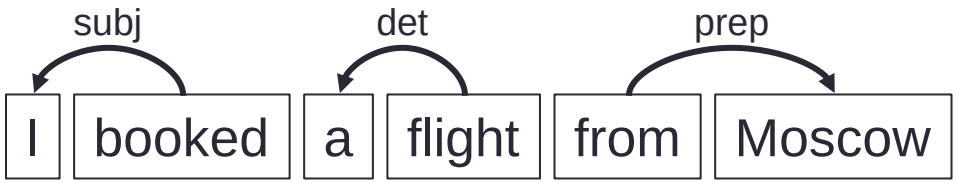

Arc-standard

Стек

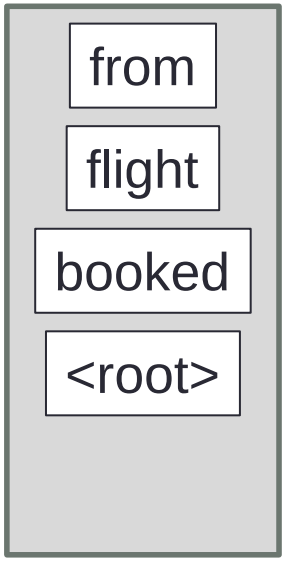

Буфер

Зависимости

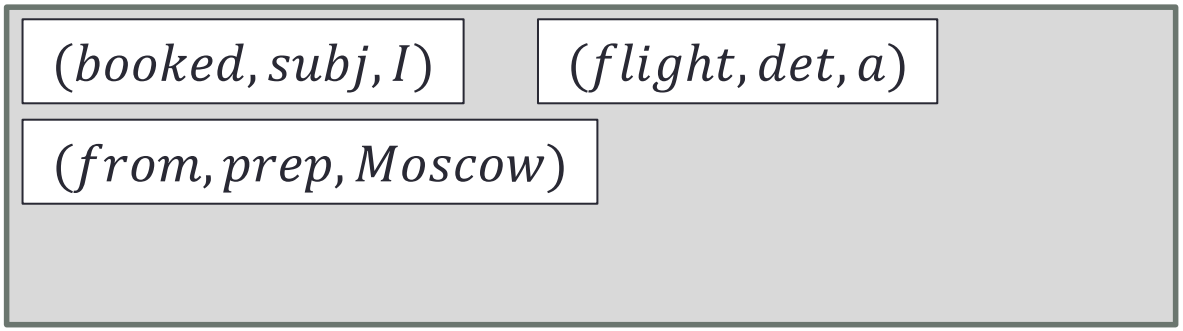

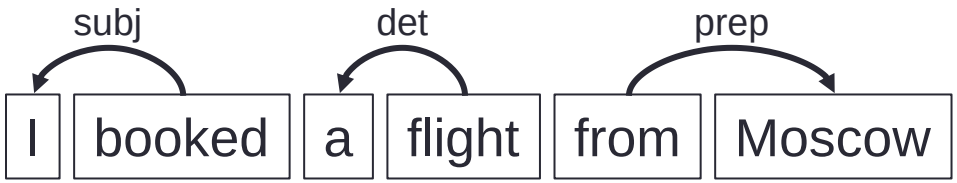

Arc-standard

Стек

flight

booked

<root>

Буфер

Зависимости

$(booked, subj, I)$

$(flight, det, a)$

$(from, prep, Moscow)$

$(flight, pmod, from)$

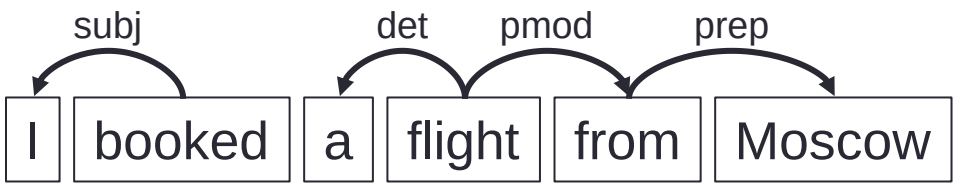

Arc-standard

Стек

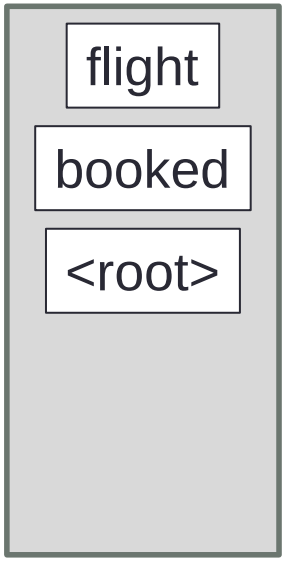

Буфер

Зависимости

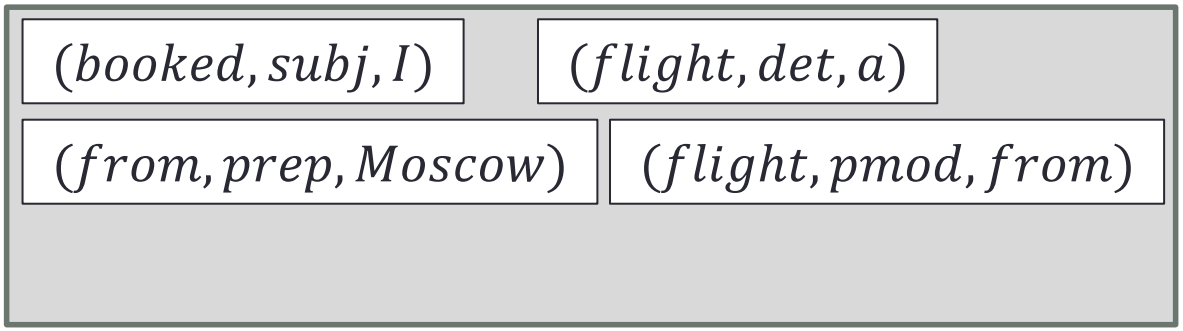

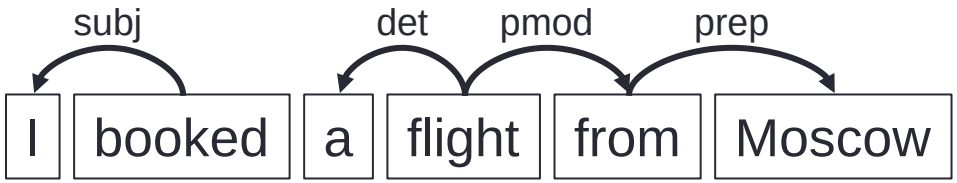

Arc-standard

Стек

booked

<root>

Буфер

Зависимости

$(booked, subj, I)$

$(flight, det, a)$

$(from, prep, Moscow)$

$(flight, pmod, from)$

$(booked, dobj, flight)$

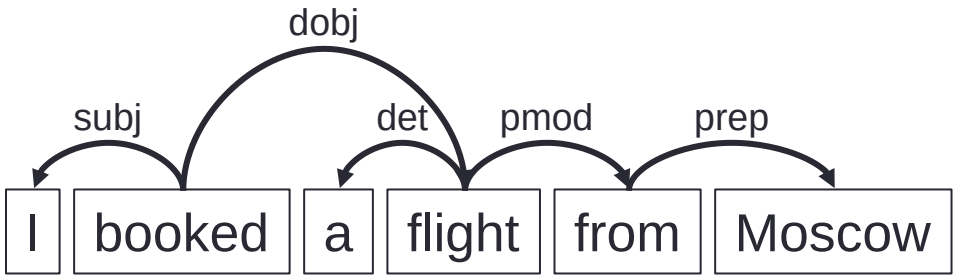

Arc-standard

Стек

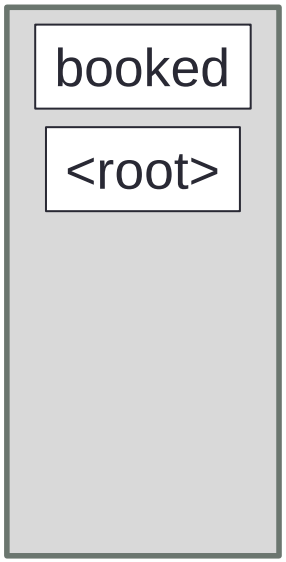

Буфер

Зависимости

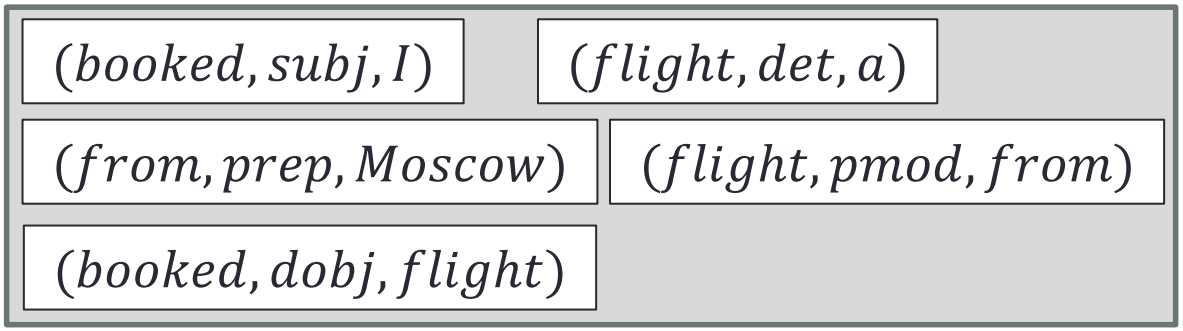

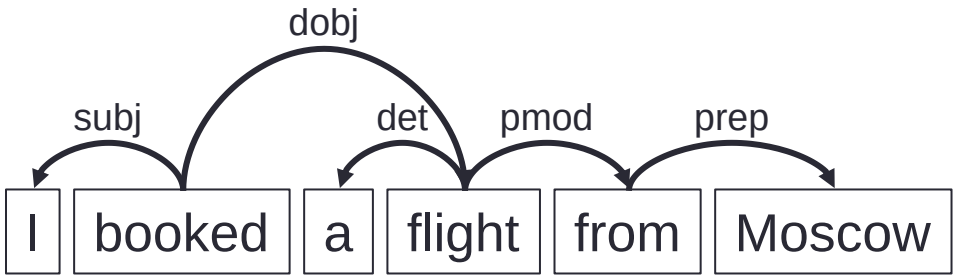

Arc-standard

Стек

<root>

Буфер

Зависимости

$(booked, subj, I)$

$(flight, det, a)$

$(from, prep, Moscow)$

$(flight, pmod, from)$

$(booked, dobj, flight)$

$(root, root, booked)$

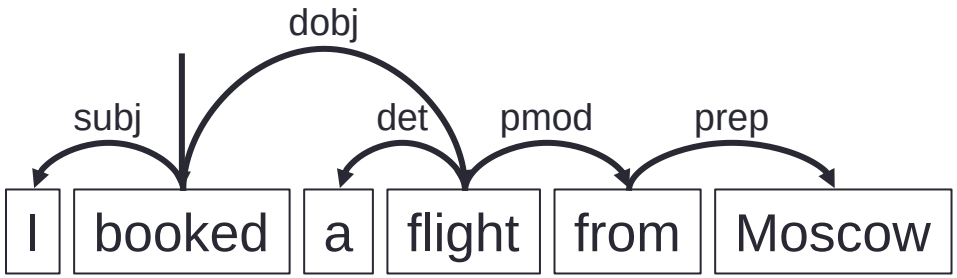

Arc-standard

Стек

<root>

Буфер

Зависимости

$(booked, subj, I)$

$(flight, det, a)$

$(from, prep, Moscow)$

$(flight, pmod, from)$

$(booked, dobj, flight)$

$(root, root, booked)$

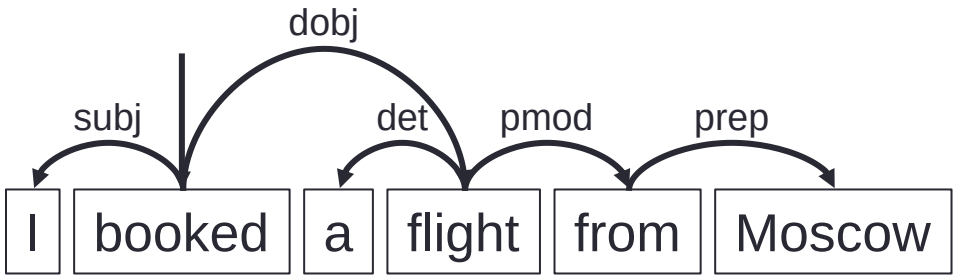

Arc-eager

- Инициализация
  - $c_s(x = x_1 \dots x_n) = ([0], [1, \dots, n], \emptyset)$
- Конечное состояние
  - $C_t = \{c \in C | c = (\Sigma, [\,], A)\}$
- Переходы
  - $(Shift)$ $(\sigma, [i|\beta], A) \rightarrow ([\sigma|i], \beta, A)$
  - $(LeftArc_l)$ $([\sigma|i], [j|\beta], A) \rightarrow (\sigma, [j|\beta], A \cup \{(j, l, i)\})$,
    если $i \neq 0$ и $\nexists k$: $(k, *, i) \in A$
  - $(RightArc_l)$ $([\sigma|i], [j|\beta], A) \rightarrow ([\sigma|i|j], \beta, A \cup \{(i, l, j)\})$
  - $(Reduce)$ $([\sigma|i], B, A) \rightarrow (\sigma, B, A)$
    если $\exists k$: $(k, *, i) \in A$

Arc-eager

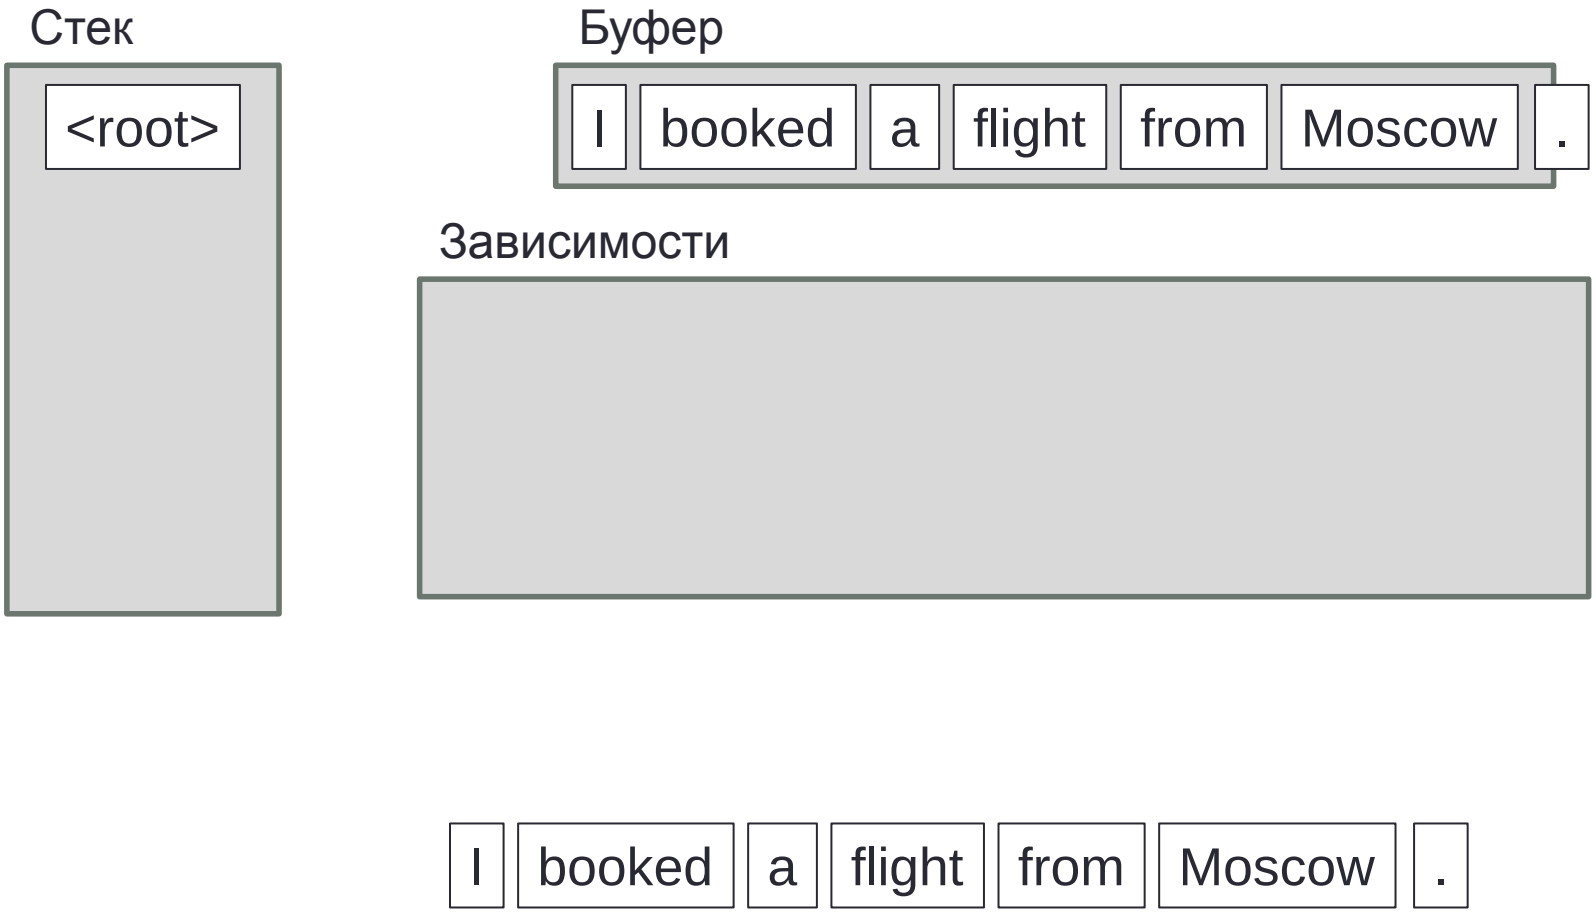

I | booked | a | flight | from | Moscow | .

Arc-eager

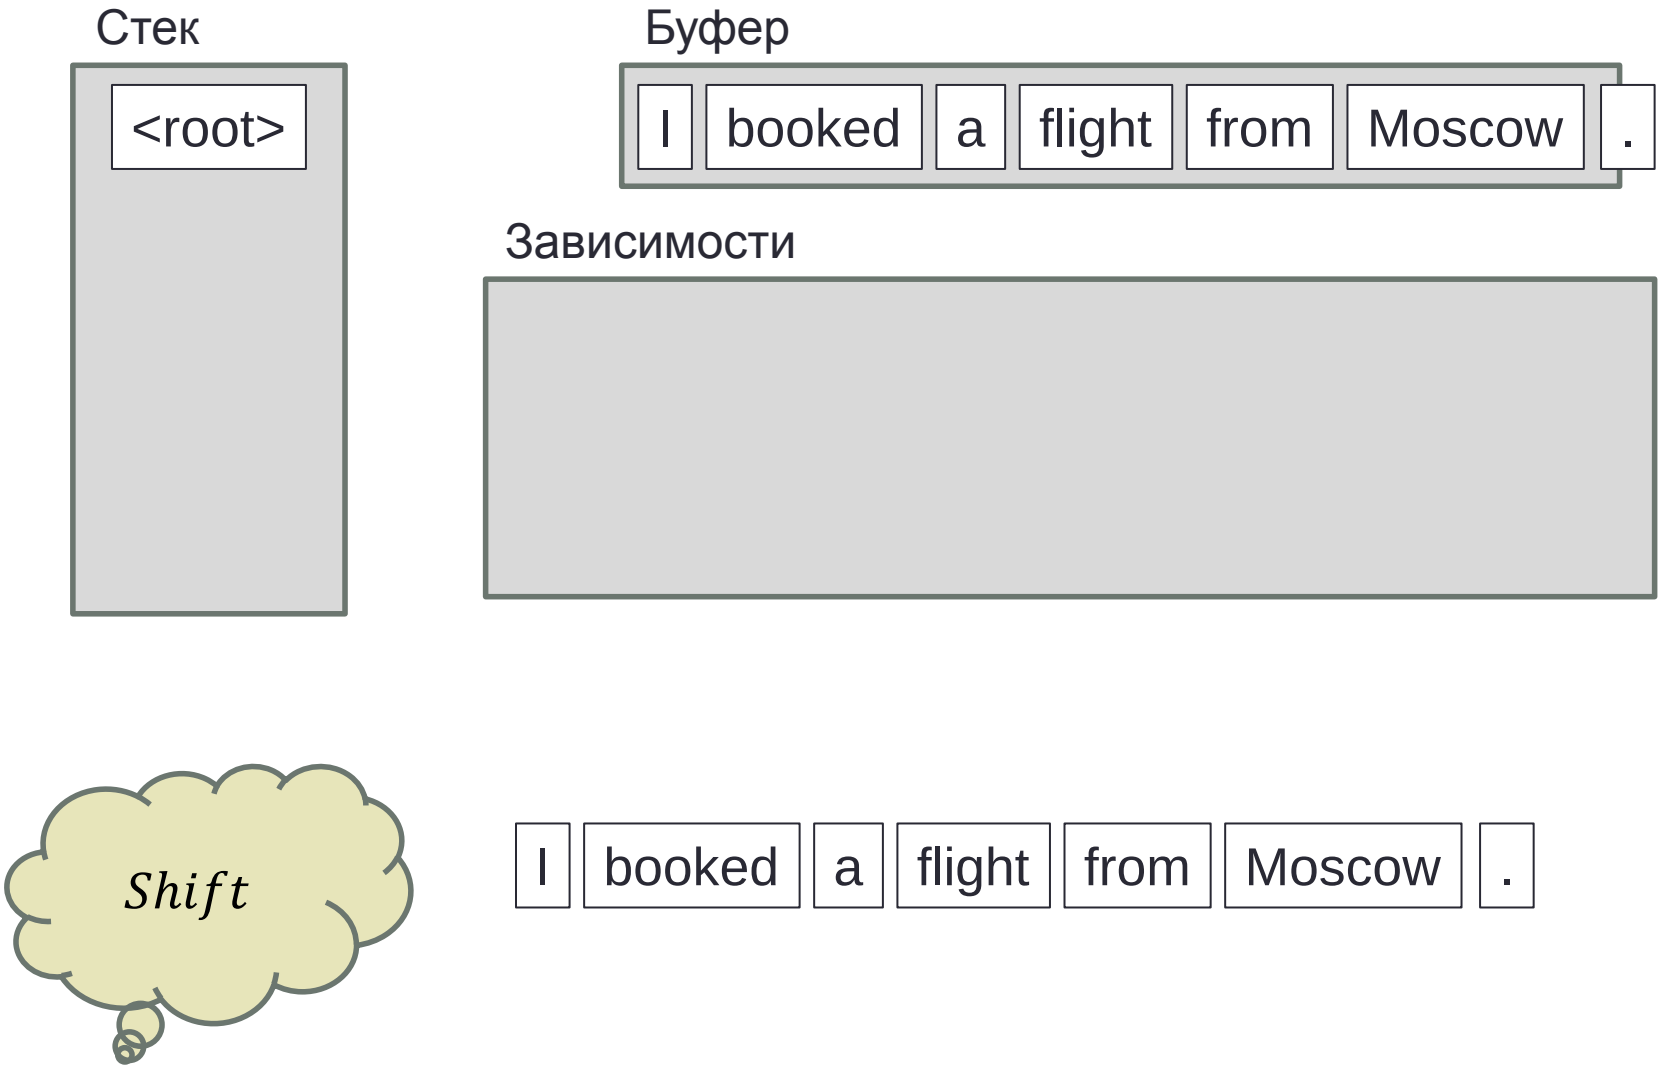
Стек
<root>
Буфер
I
booked
a
flight
from
Moscow
.
Зависимости
Shift
I
booked
a
flight
from
Moscow
.

Arc-eager

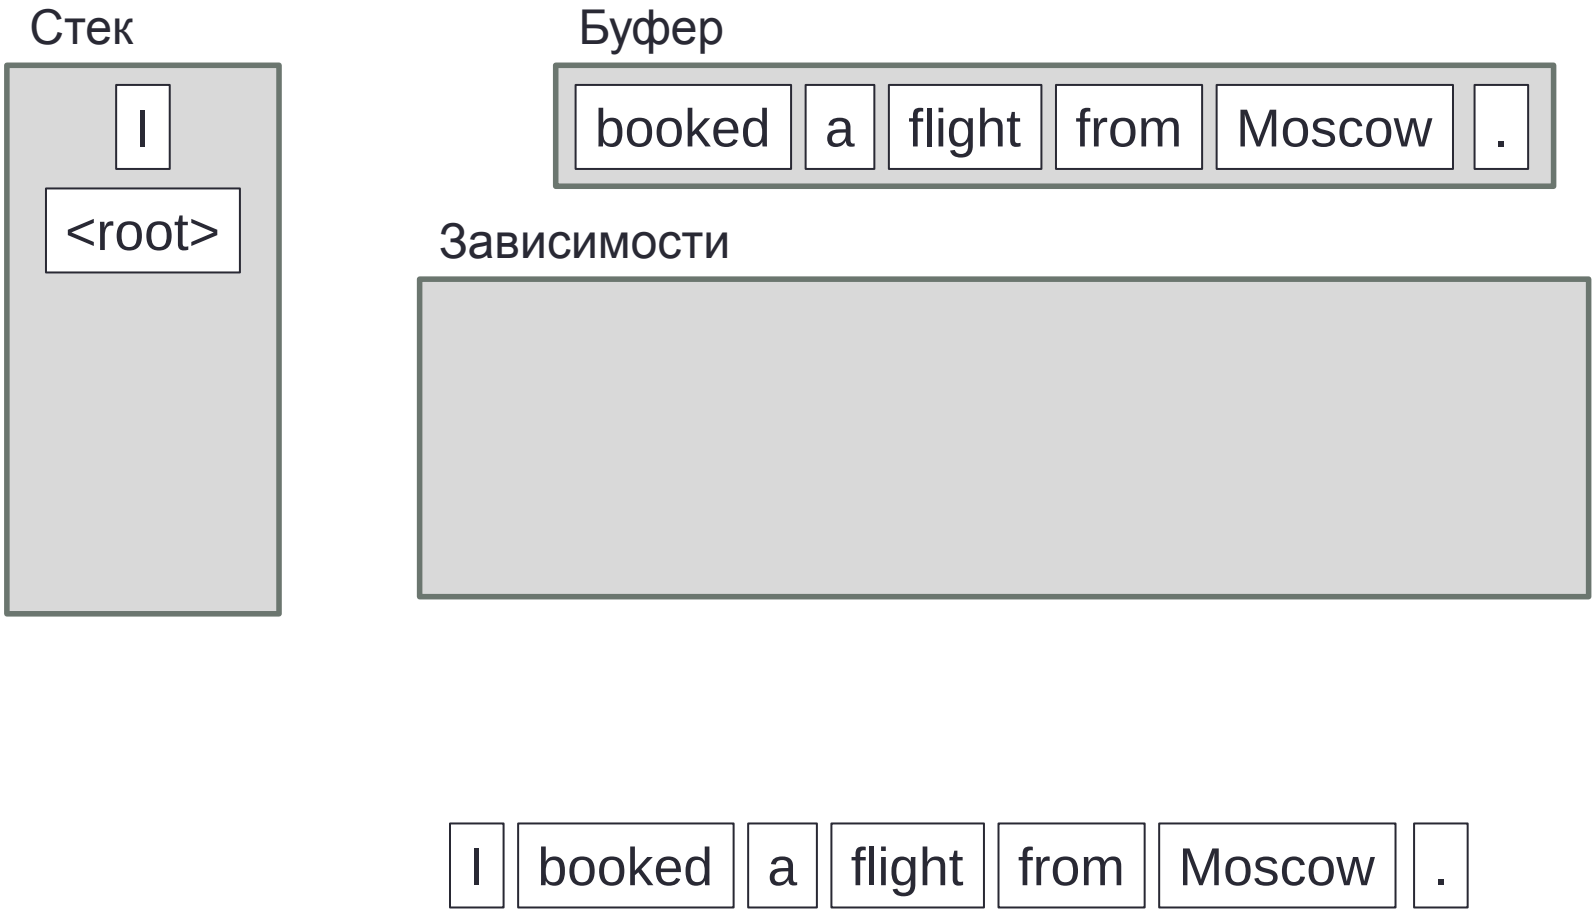
Стек
I
<root>
Буфер
booked
a
flight
from
Moscow
.
Зависимости
I
booked
a
flight
from
Moscow
.

Arc-eager

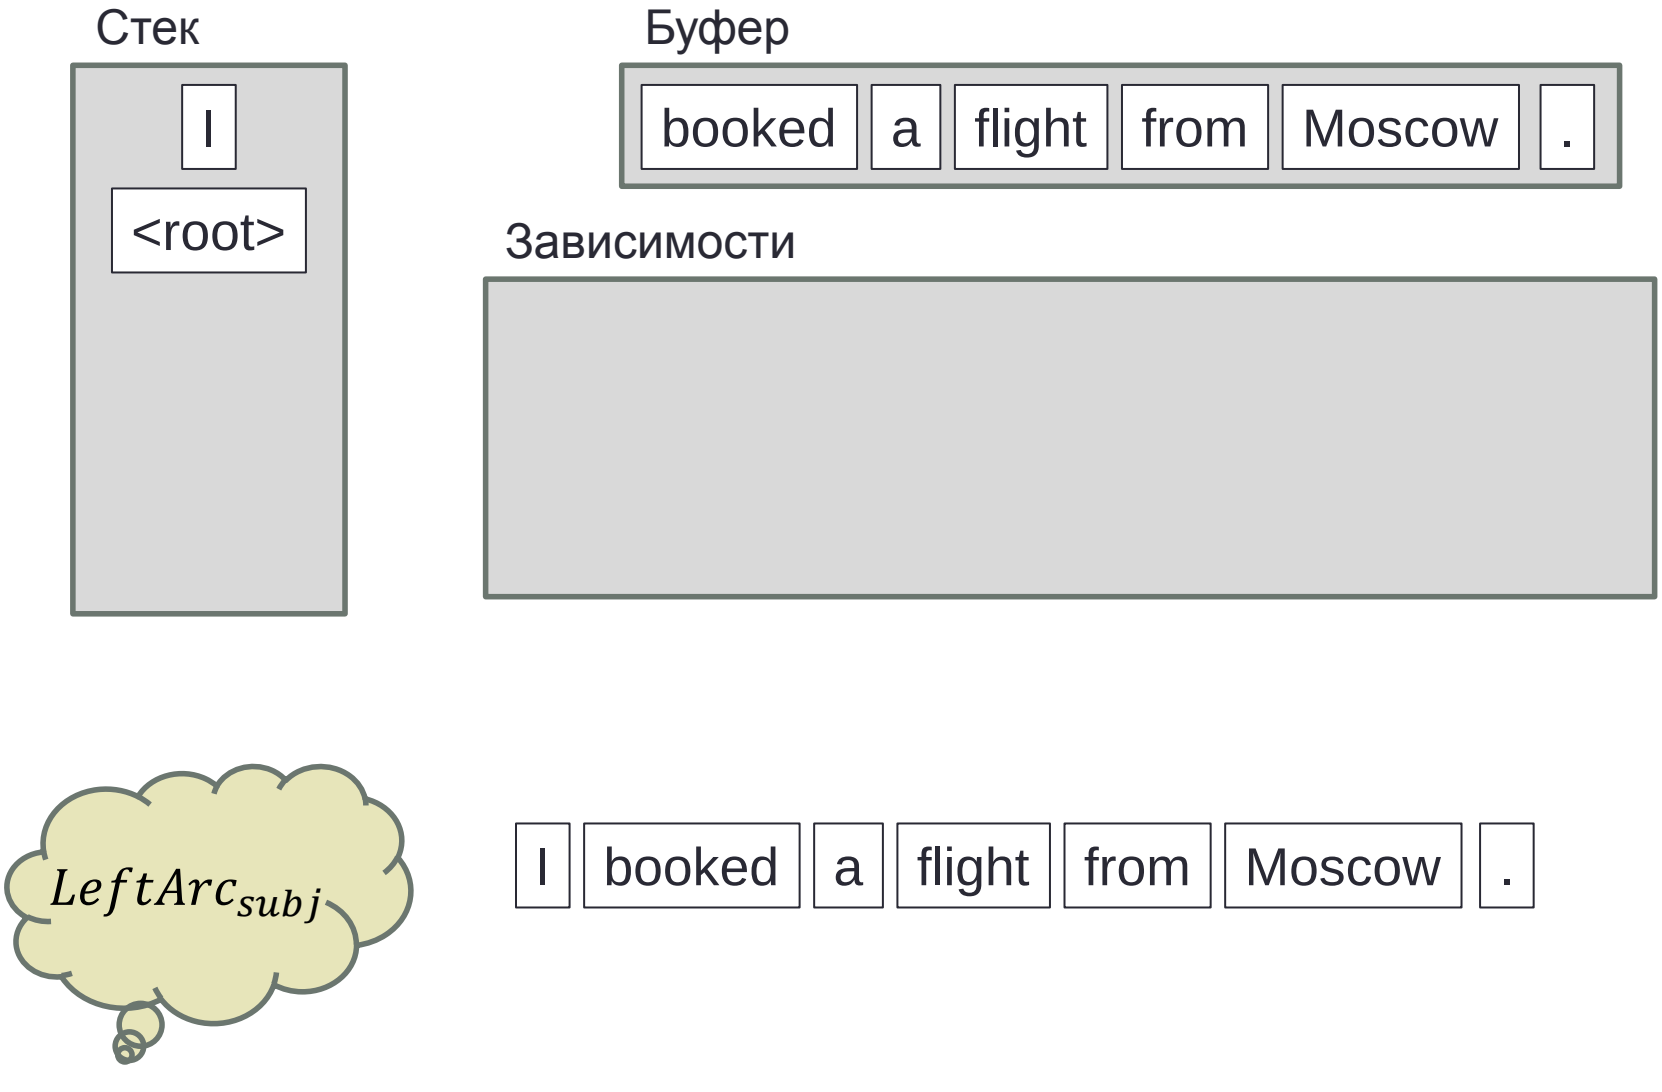
Стек
I
<root>
Буфер
booked
a
flight
from
Moscow
.
Зависимости
$LeftArc_{subj}$
I
booked
a
flight
from
Moscow
.

Arc-eager

Стек

<root>

Буфер

booked | a | flight | from | Moscow | .

Зависимости

$(booked, subj, I)$

Arc-eager

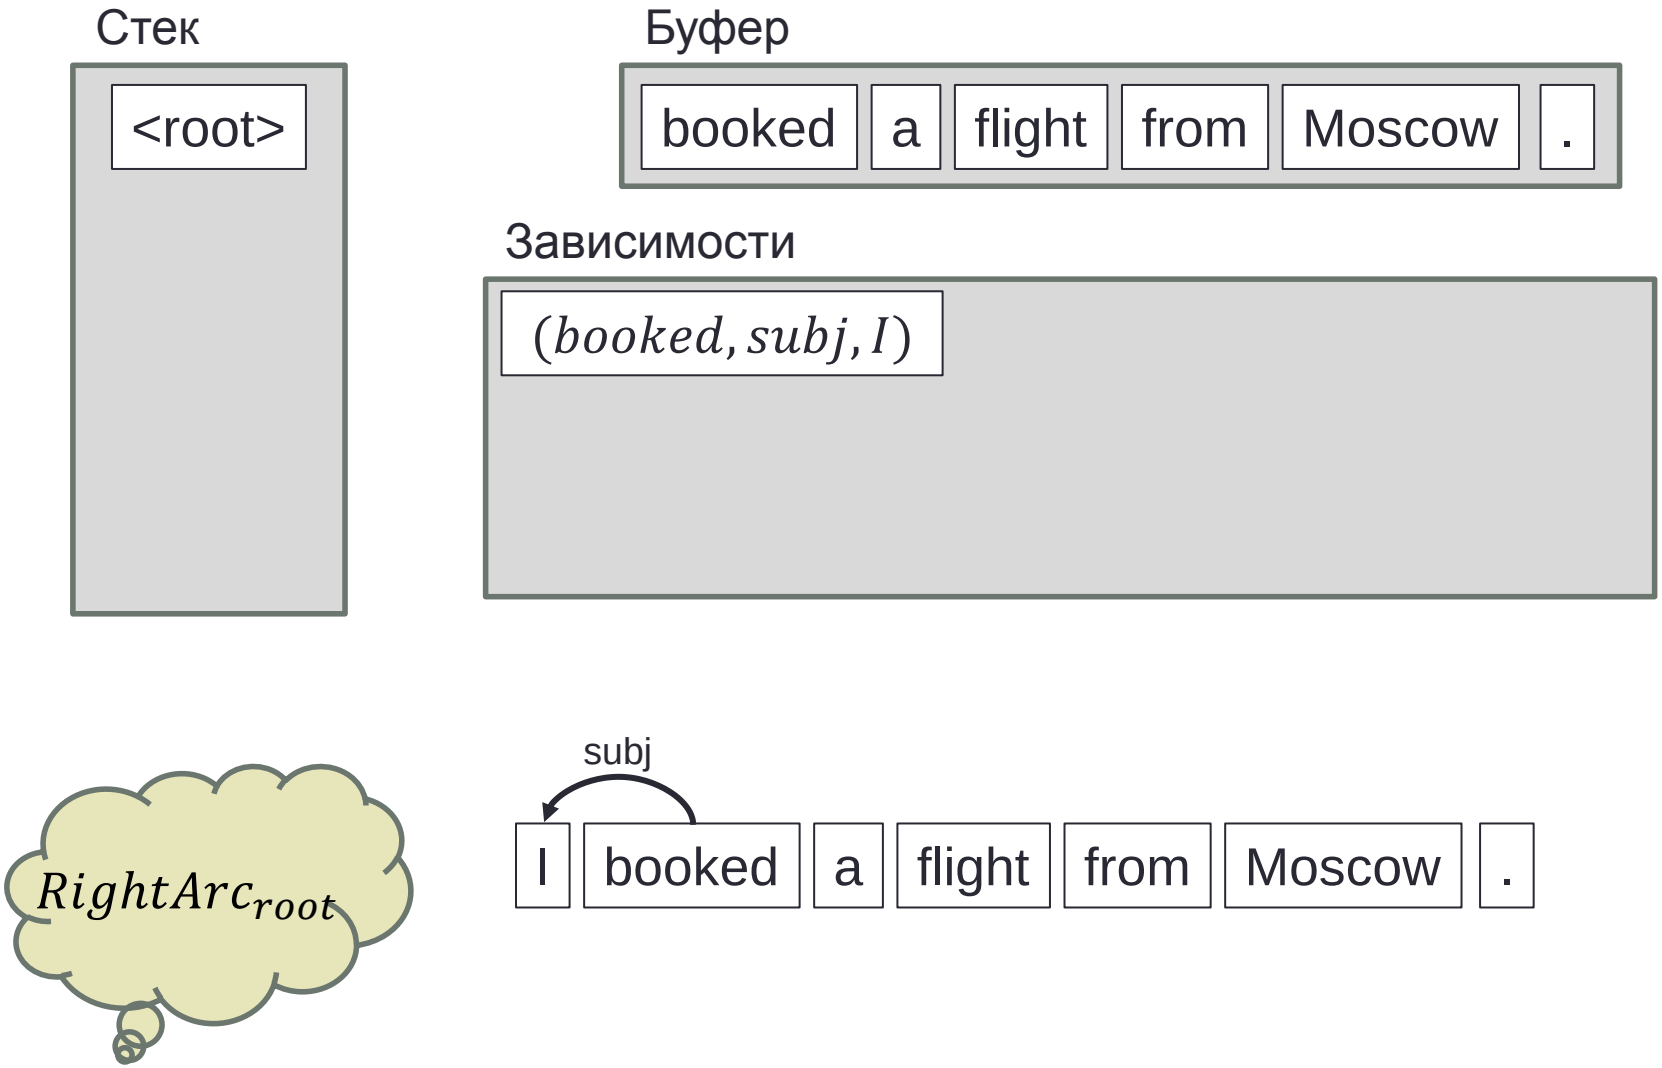
Стек
<root>
Буфер
booked
a
flight
from
Moscow
.
Зависимости
$(booked, subj, I)$
$RightArc_{root}$
subj
I
booked
a
flight
from
Moscow
.

Arc-eager

Стек

booked

<root>

Буфер

a | flight | from | Moscow | .

Зависимости

$(booked, subj, I)$ $(root, root, booked)$

Arc-eager

Стек

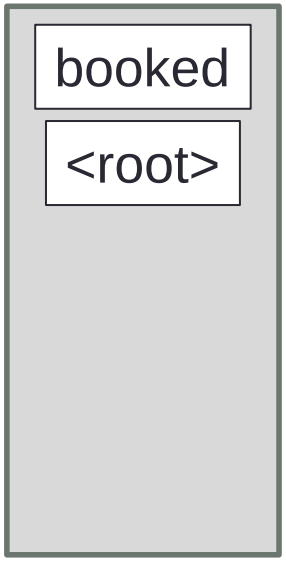

Буфер

Зависимости

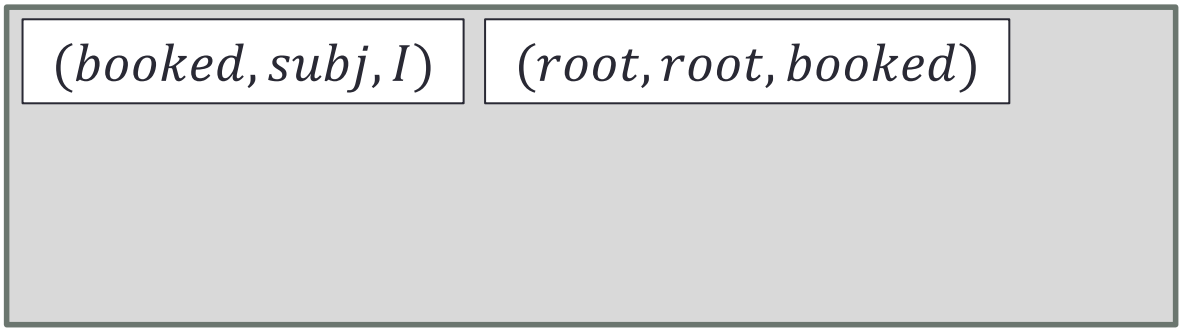

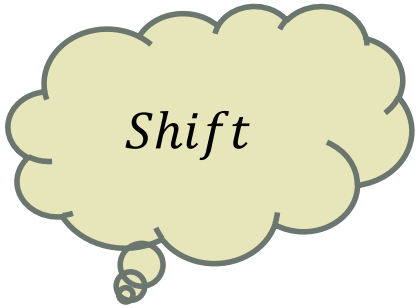

Arc-eager

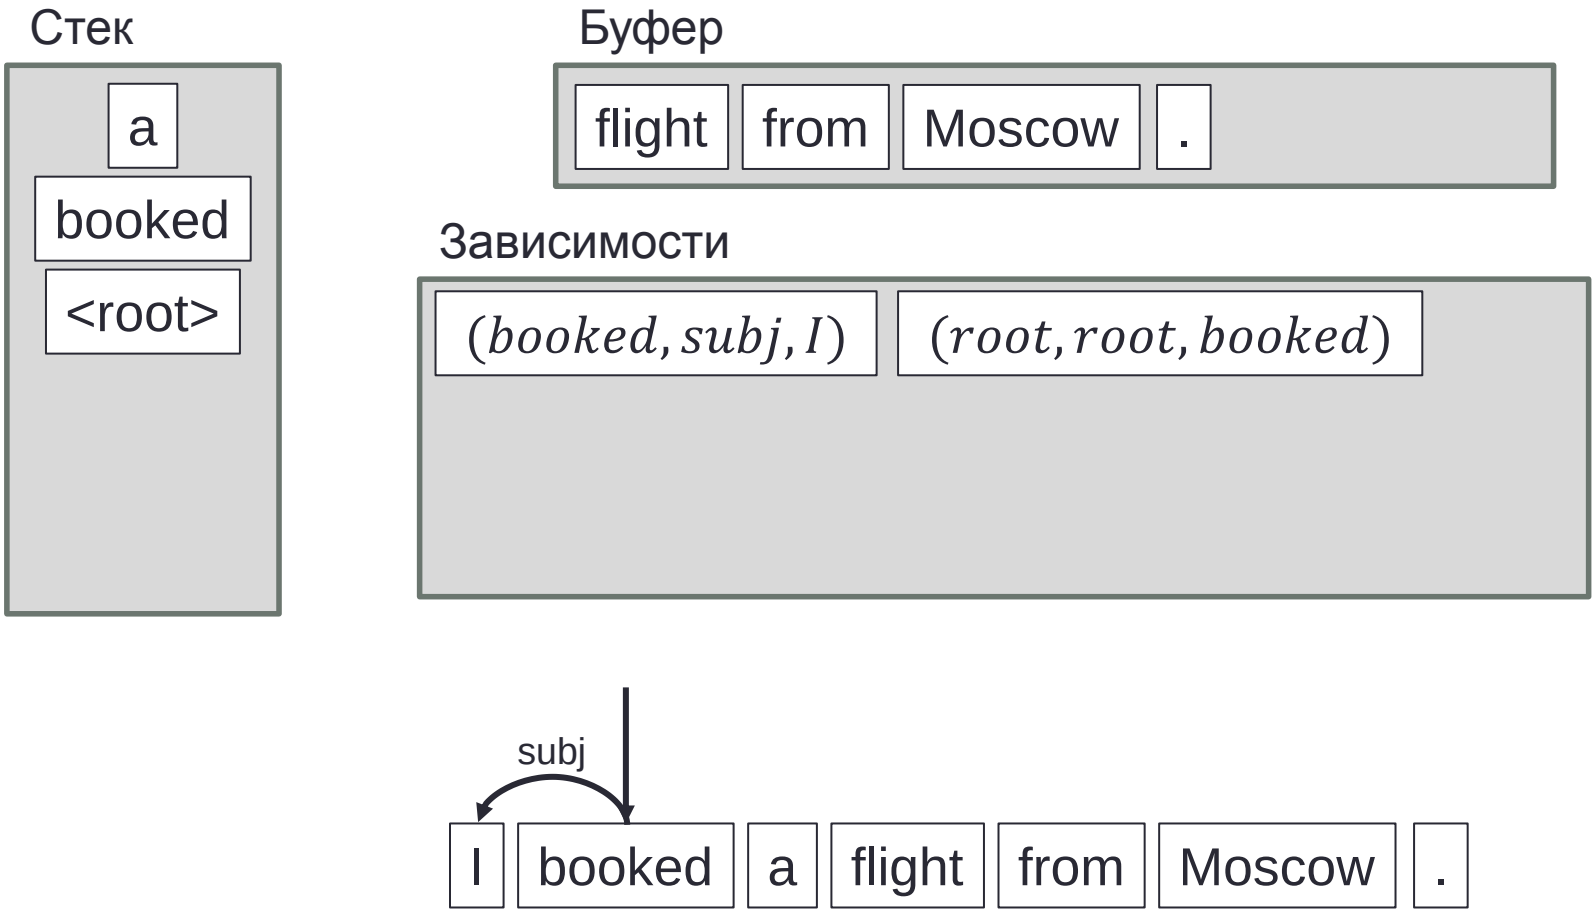
Стек
a
booked
<root>
Буфер
flight
from
Moscow
.
Зависимости
$(booked, subj, I)$
$(root, root, booked)$
subj
I
booked
a
flight
from
Moscow
.

Arc-eager

Стек

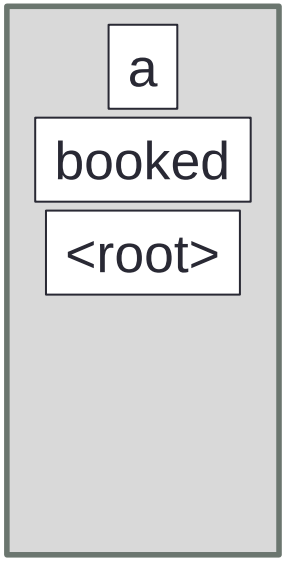

Буфер

Зависимости

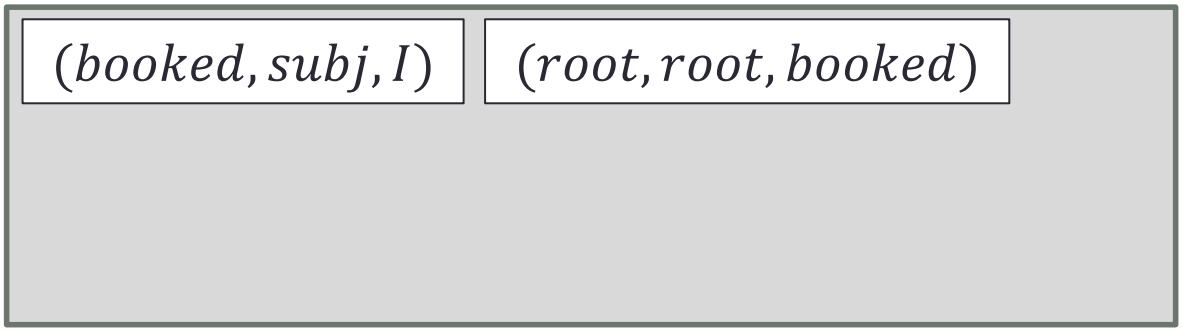

Arc-eager

Стек

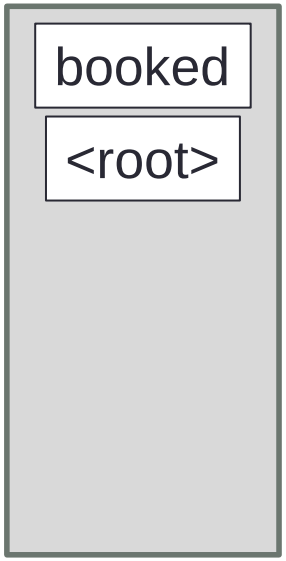

Буфер

Зависимости

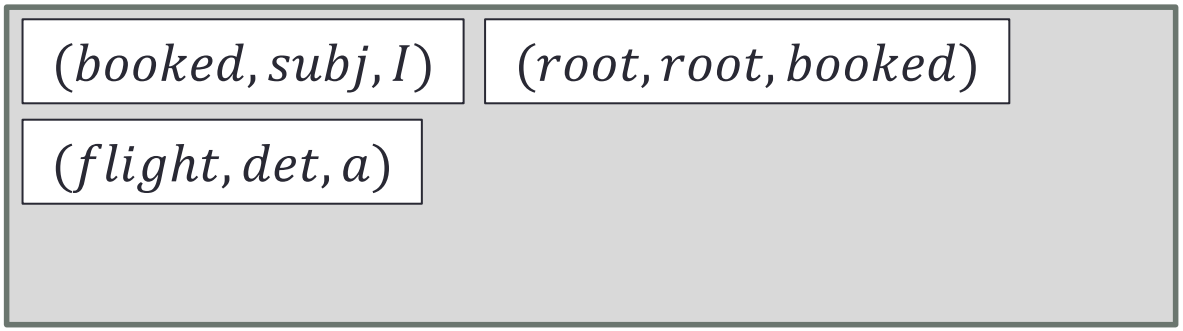

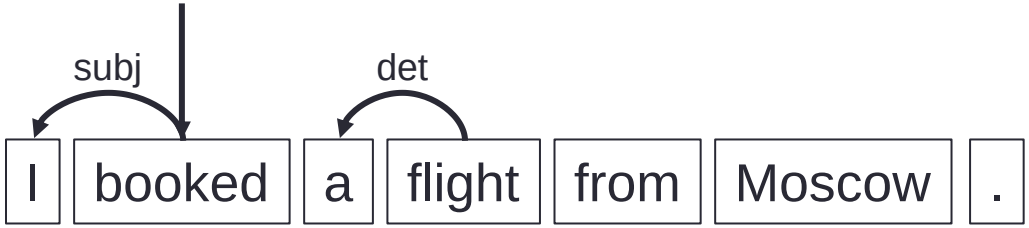

Arc-eager

Стек

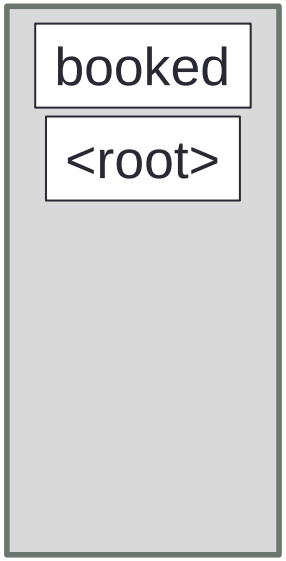

Буфер

Зависимости

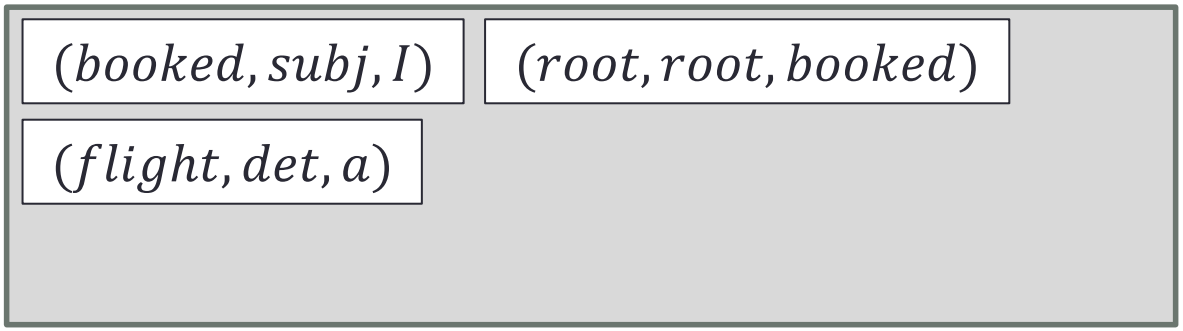

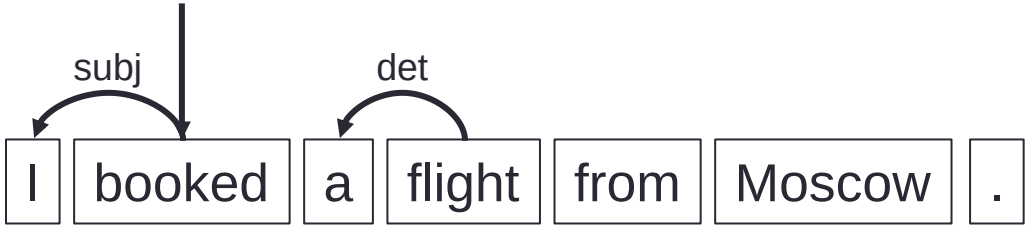

Arc-eager

Стек

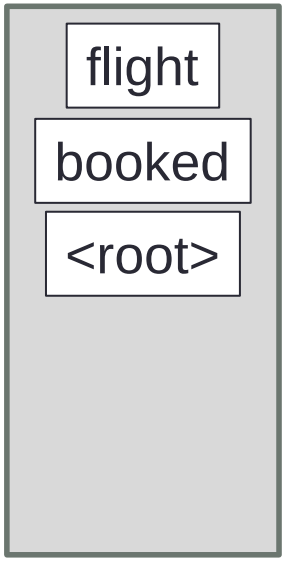

Буфер

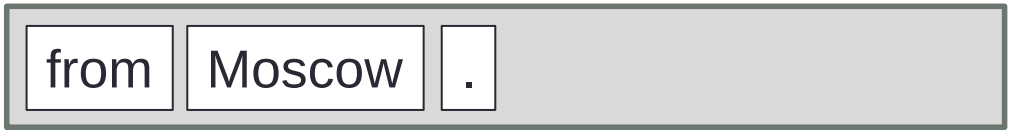

Зависимости

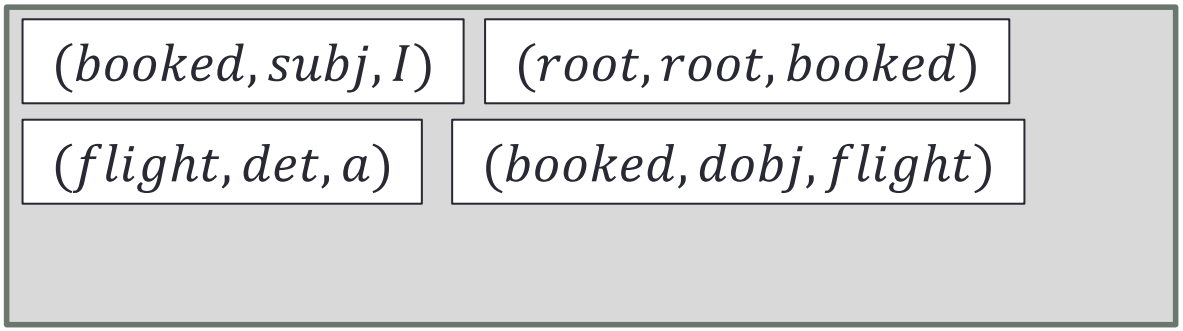

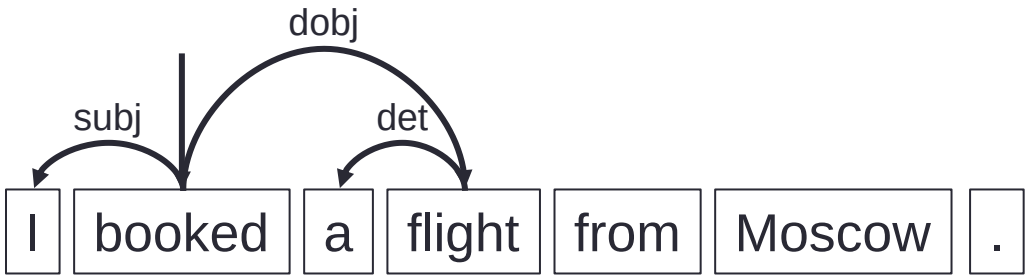

Arc-eager

Стек

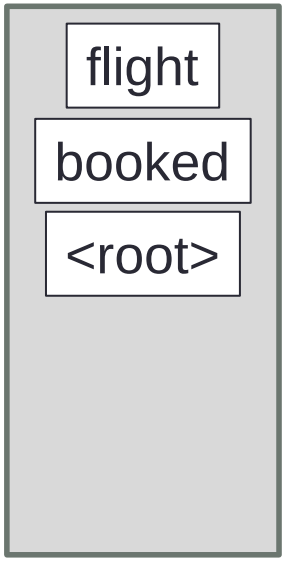

Буфер

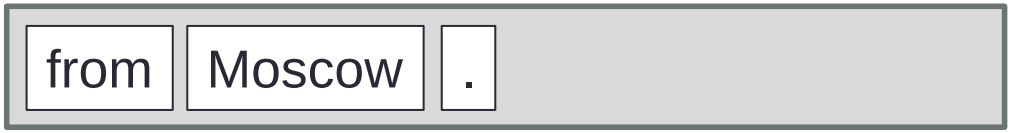

Зависимости

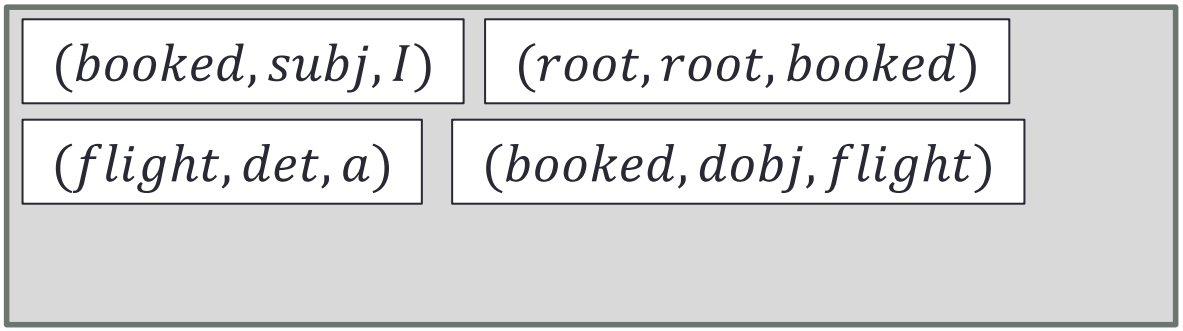

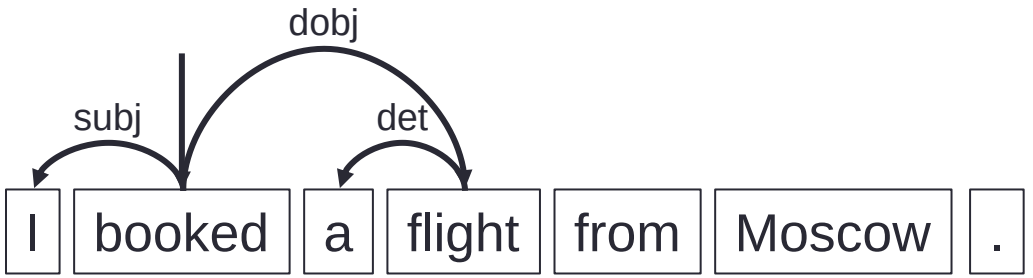

Arc-eager

Стек

- from
- flight
- booked
- <root>

Буфер

Moscow | .

Зависимости

$(booked, subj, I)$

$(root, root, booked)$

$(flight, det, a)$

$(booked, dobj, flight)$

$(flight, pmod, from)$

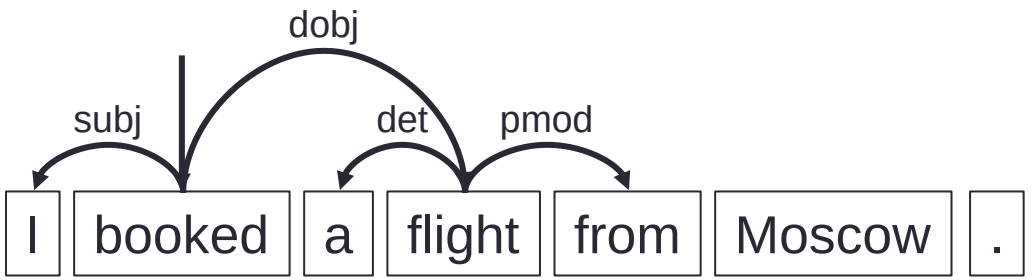

Arc-eager

Стек

- from
- flight
- booked
- <root>

Буфер

Moscow .

Зависимости

$(booked, subj, I)$

$(root, root, booked)$

$(flight, det, a)$

$(booked, dobj, flight)$

$(flight, pmod, from)$

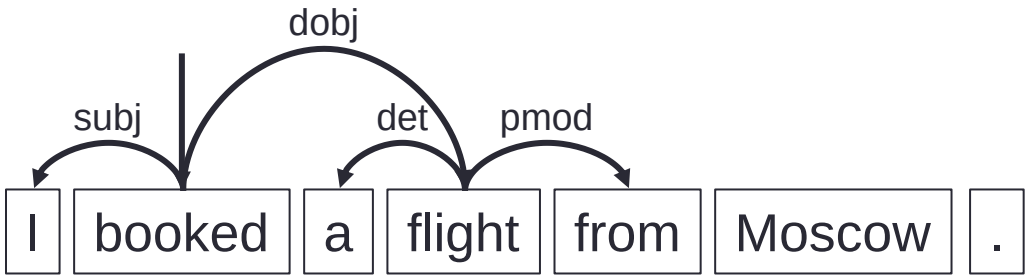

$RightArc_{prep}$

Arc-eager

Стек

- Moscow
- from
- flight
- booked
- <root>

Буфер

- .

Зависимости

- $(booked, subj, I)$
- $(root, root, booked)$
- $(flight, det, a)$
- $(booked, dobj, flight)$
- $(flight, pmod, from)$
- $(from, prep, Moscow)$

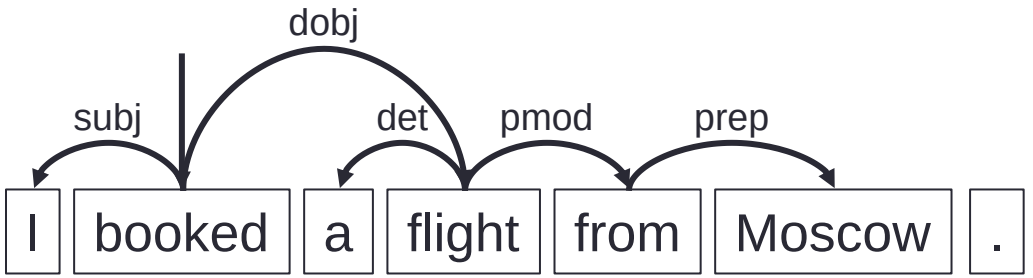

Arc-eager

Стек

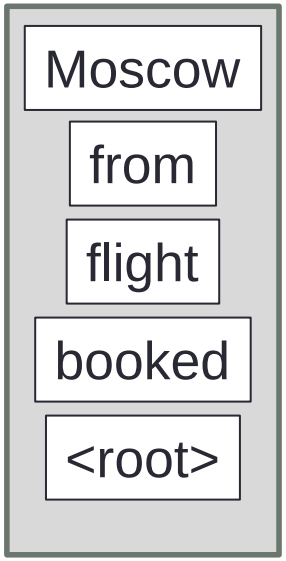

Буфер

Зависимости

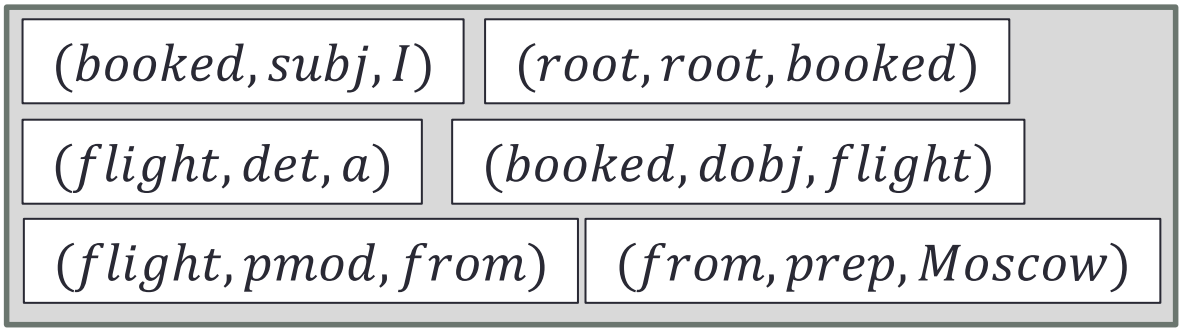

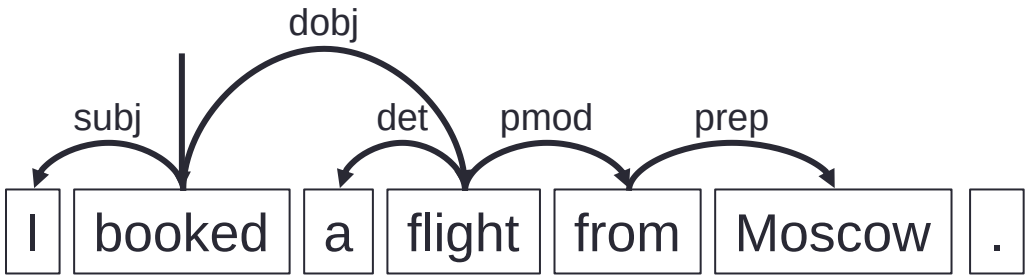

Arc-eager

Стек

- from
- flight
- booked
- <root>

Буфер

- .

Зависимости

- $(booked, subj, I)$
- $(root, root, booked)$
- $(flight, det, a)$
- $(booked, dobj, flight)$
- $(flight, pmod, from)$
- $(from, prep, Moscow)$

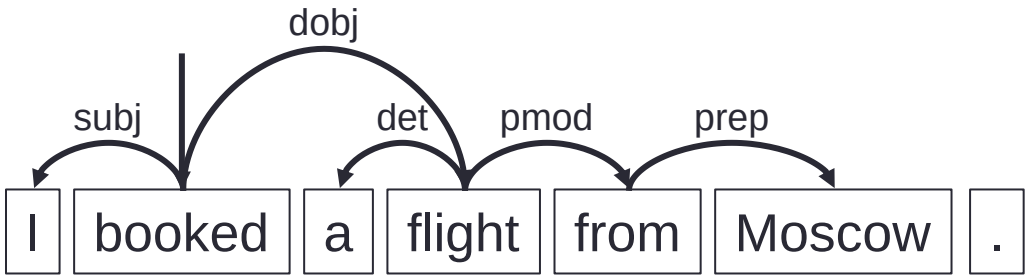

Arc-eager

Стек

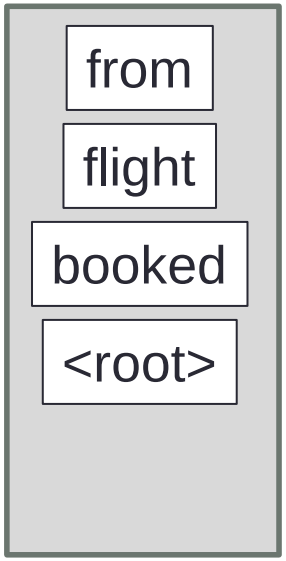

Буфер

Зависимости

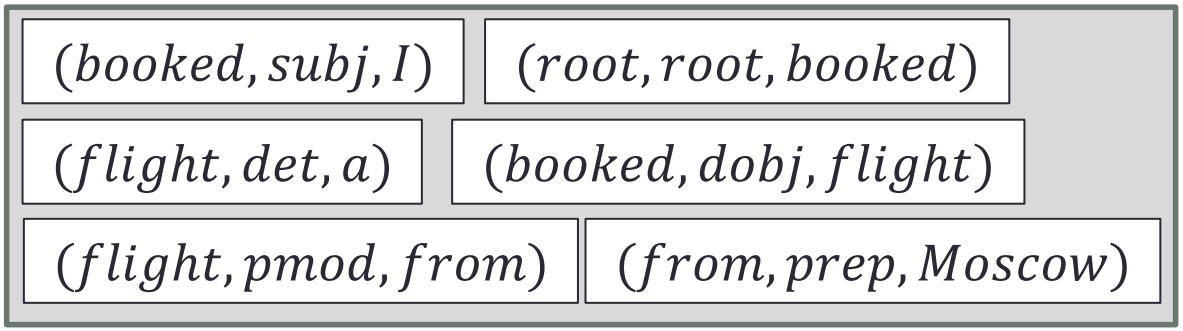

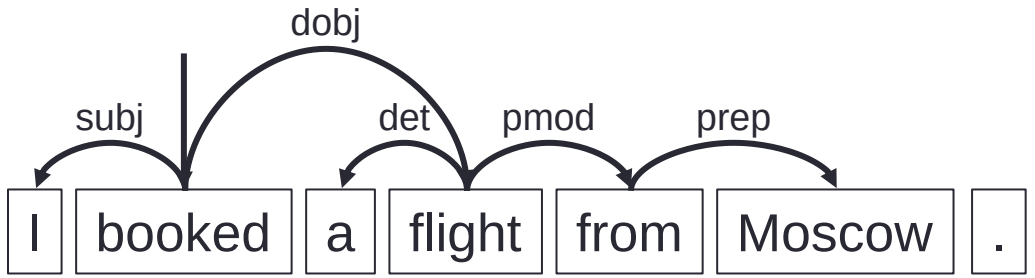

Arc-eager

Стек

flight

booked

<root>

Буфер

.

Зависимости

$(booked, subj, I)$ $(root, root, booked)$

$(flight, det, a)$ $(booked, dobj, flight)$

$(flight, pmod, from)$ $(from, prep, Moscow)$

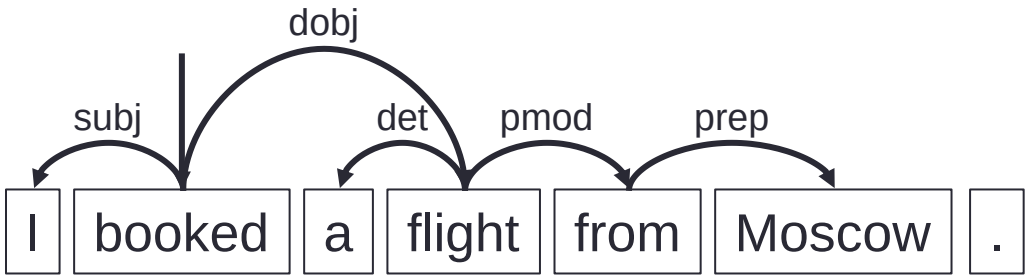

Arc-eager

Стек

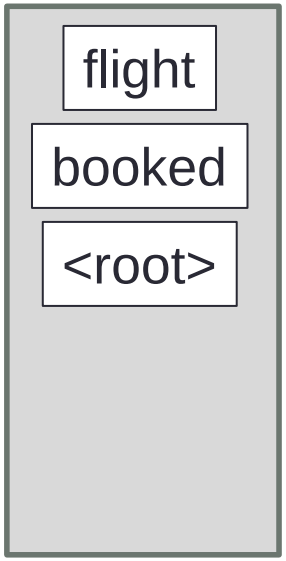

Буфер

Зависимости

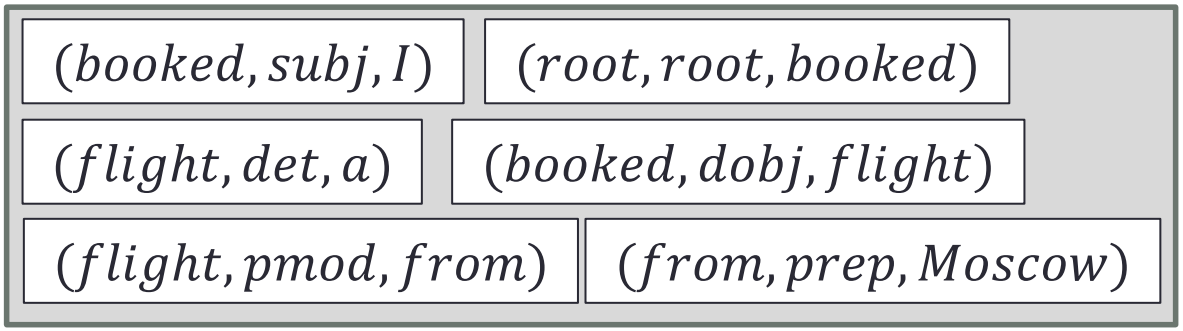

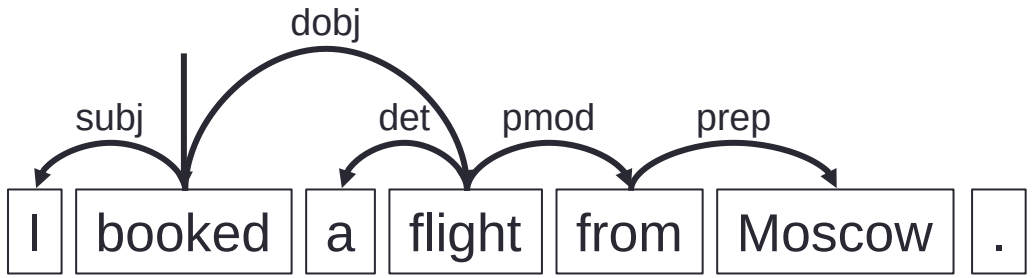

Arc-eager

Стек

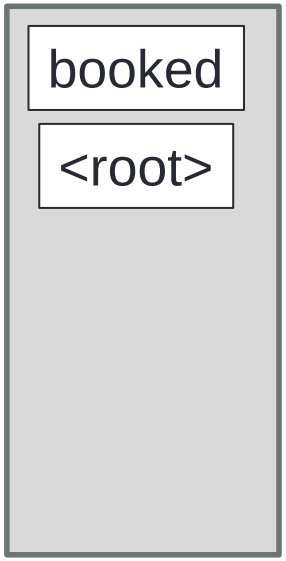

Буфер

Зависимости

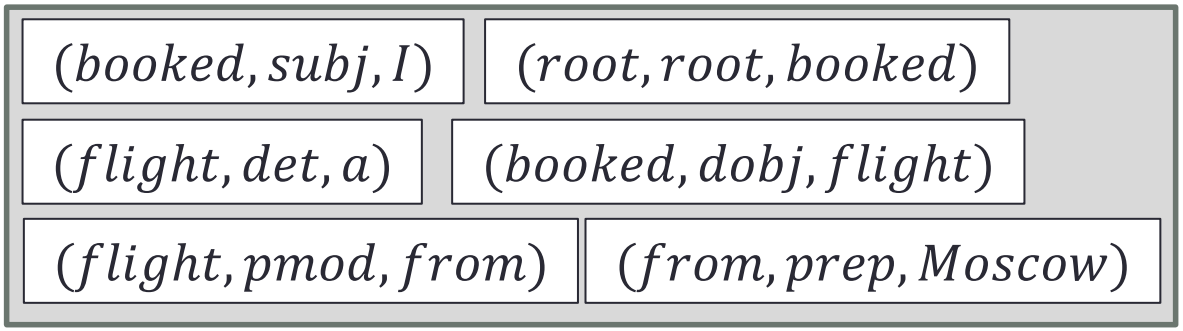

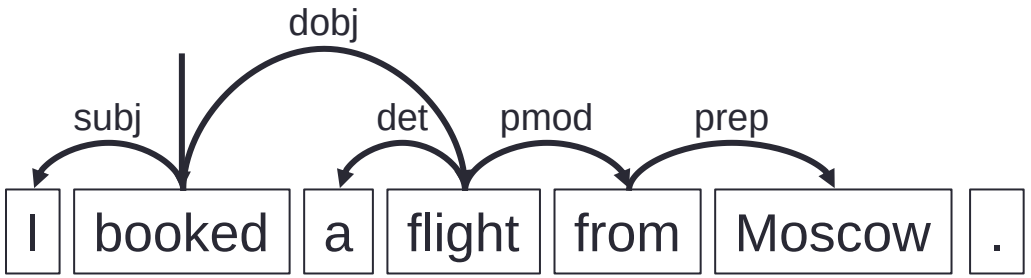

Arc-eager

Стек

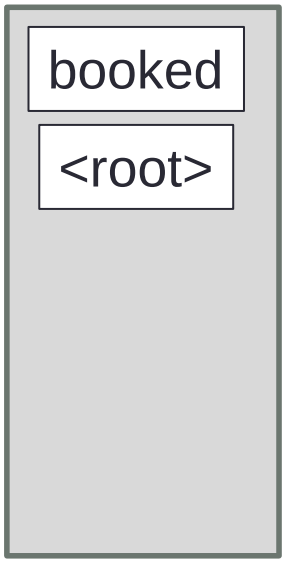

Буфер

Зависимости

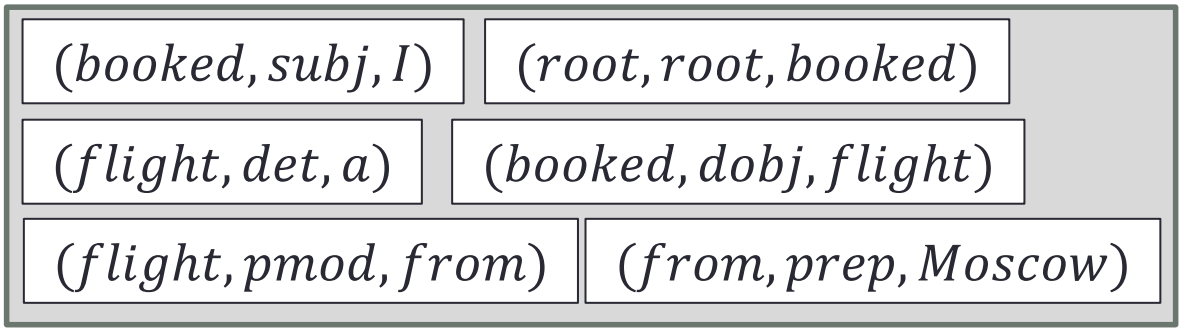

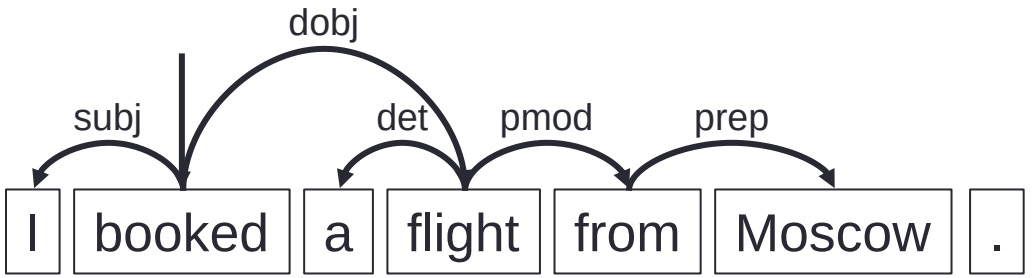

Arc-eager

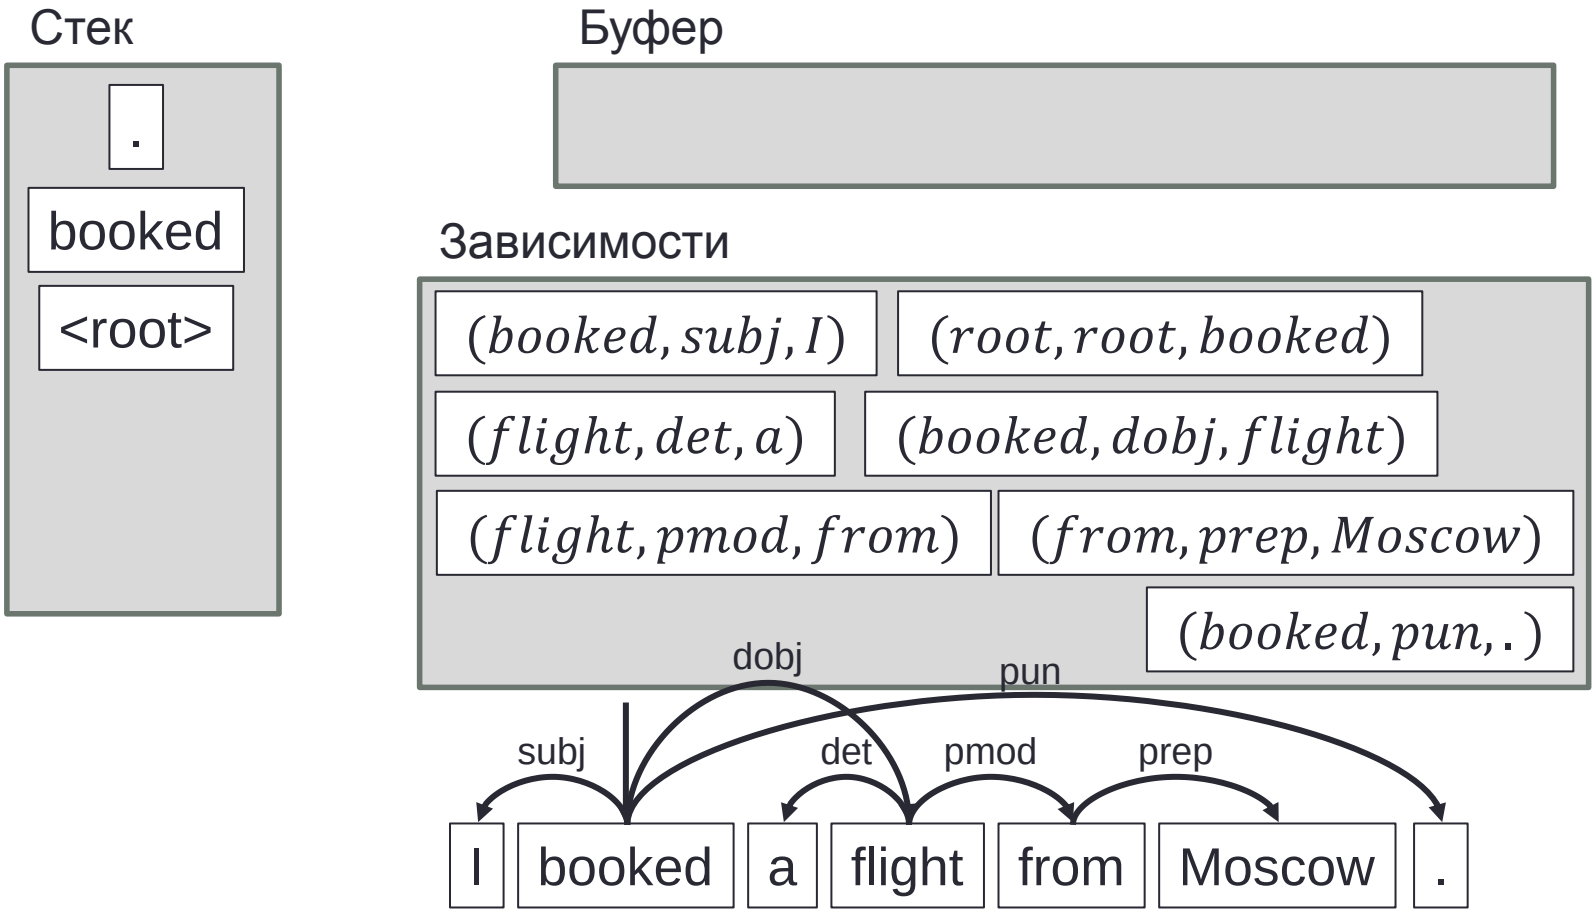
Стек
.
booked
<root>
Буфер
Зависимости
$(booked, subj, I)$
$(root, root, booked)$
$(flight, det, a)$
$(booked, dobj, flight)$
$(flight, pmod, from)$
$(from, prep, Moscow)$
$(booked, pun, .)$
dobj
pun
subj
det
pmod
prep
I
booked
a
flight
from
Moscow
.

Arc-eager

Стек

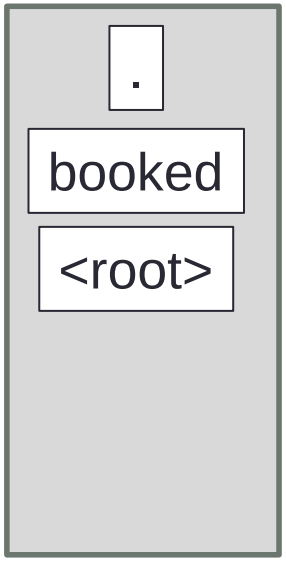

Буфер

Зависимости

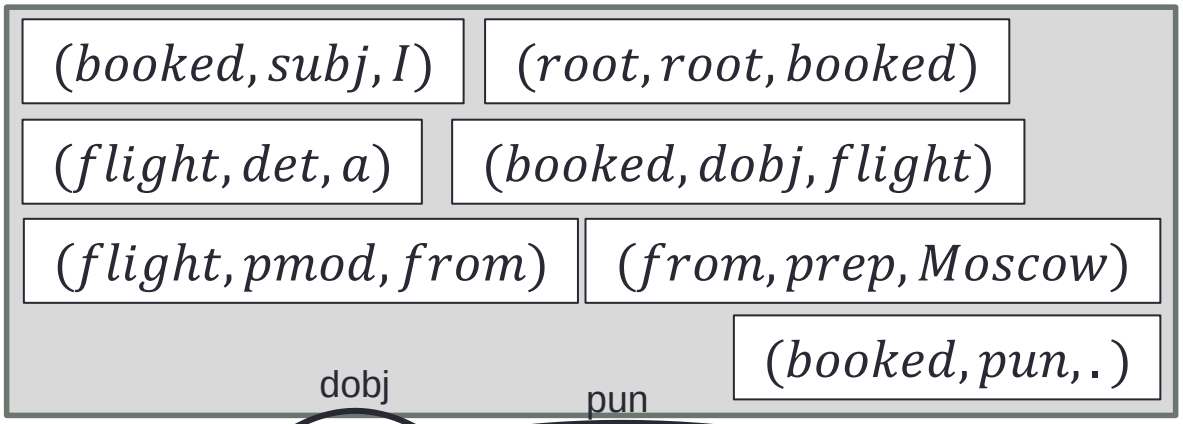

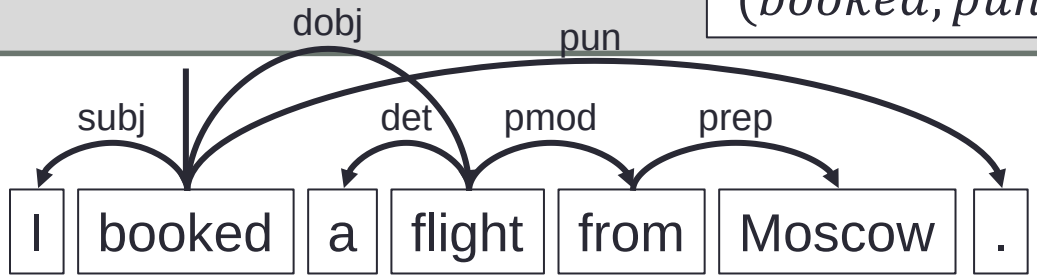

Проективное синтаксическое дерево

- Дерево зависимостей является проективным, если
  - Для каждой дуги в дереве существует направленный путь от главного слова до каждого из слов, расположенных между главным и зависимым словом этой дуги
  - $(i, l, j) \Rightarrow \forall k \in [\min(i, j), \max(i, j)], i \rightarrow^* k$

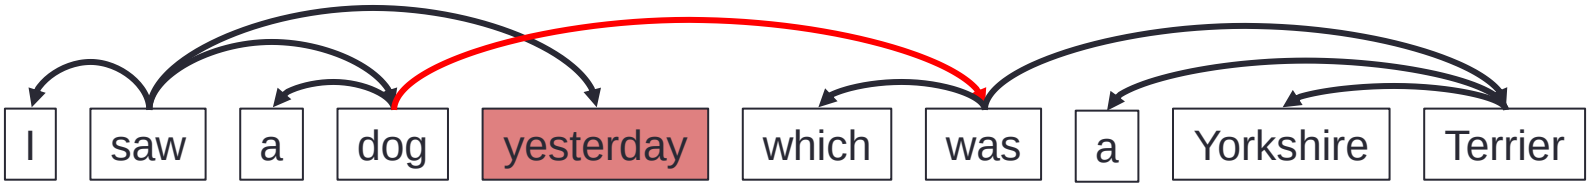

Non-projective Transition-based Parsing. Attardi's system

- Инициализация
  - $c_s(x = x_1 \dots x_n) = ([0], [1, \dots, n], \emptyset)$
- Конечное состояние
  - $C_t = \{c \in C | c = ([0], [\,], A)\}$
- Переходы (для левых зависимостей требуется $i \neq 0$)
  - $(Shift)$ $(\sigma, [i|\beta], A) \rightarrow ([\sigma|i], \beta, A)$
  - $(LeftArc_l)$ $([\sigma|i|j], B, A) \rightarrow ([\sigma|j], B, A \cup \{(j, l, i)\})$
  - $(RightArc_l)$ $([\sigma|i|j], B, A) \rightarrow ([\sigma|i], B, A \cup \{(i, l, j)\})$
  - $(LeftArc2_l)$ $([\sigma|i|k|j], B, A) \rightarrow ([\sigma|k|j], B, A \cup \{(j, l, i)\})$
  - $(RightArc2_l)$ $([\sigma|i|k|j], B, A) \rightarrow ([\sigma|i|k], B, A \cup \{(i, l, j)\})$
  - $(LeftArc3_l)$ $([\sigma|i|k_1|k_2|j], B, A) \rightarrow ([\sigma|k_1|k_2|j], B, A \cup \{(j, l, i)\})$
  - $(RightArc3_l)$ $([\sigma|i|k_1|k_2|j], B, A) \rightarrow ([\sigma|i|k_1|k_2], B, A \cup \{(i, l, j)\})$

Non-projective Transition-based Parsing. Online reordering

- Инициализация
  - $c_s(x = x_1 \dots x_n) = ([0], [1, \dots, n], \emptyset)$
- Конечное состояние
  - $C_t = \{c \in C | c = ([0], [\,], A)\}$
- Переходы
  - $(Shift)$ $(\sigma, [i|\beta], A) \rightarrow ([\sigma|i], \beta, A)$
  - $(LeftArc_l)$ $([\sigma|i|j], B, A) \rightarrow ([\sigma|j], B, A \cup \{(j, l, i)\})$, если $i \neq 0$
  - $(RightArc_l)$ $([\sigma|i|j], B, A) \rightarrow ([\sigma|i], B, A \cup \{(i, l, j)\})$
  - $(Swap)$ $([\sigma|i|j], \beta, A) \rightarrow ([\sigma|j], [i|\beta], A)$, если $i \neq 0$ и $i < j$

Transition-based Parsing. Предсказание переходов

- Задача многоклассовой классификации
  - Объекты классификации: конфигурации парсера
  - Классы: правила перехода

- Методы:
  - Multiclass SVM
  - Naïve Bayes
  - Decision trees
  - Нейронные сети
  - …

Признаки классификации

- Признаки для элемента
  - Словоформа
  - Лемма
  - Часть речи
  - Граммемы
  - Тип отношения
- Элементы:
  - i-й элемент стека
  - i-й элемент буфера
  - Левое отношение элемента стека
  - Правое отношение элемента стека

Long Short-Term Memory

- $i_t = \sigma(W_{ix}x_t + W_{ih}h_{t-1} + W_{ic}c_{t-1} + b_i)$
- $f_t = \sigma\left(W_{fx}x_t + W_{fh}h_{t-1} + W_{fc}c_{t-1} + b_f\right)$
- $c_t = f_t \odot c_{t-1} i_t + \tanh \odot (W_{cx}x_t + W_{ch}h_{t-1} + b_c)$

- $o_t = \sigma(W_{ox}x_t + W_{oh}h_{t-1} + W_{oc}c_t + b_0)$
- $h_t = o_t \odot \tanh(c_t)$

- $y_t = g(h_t)$

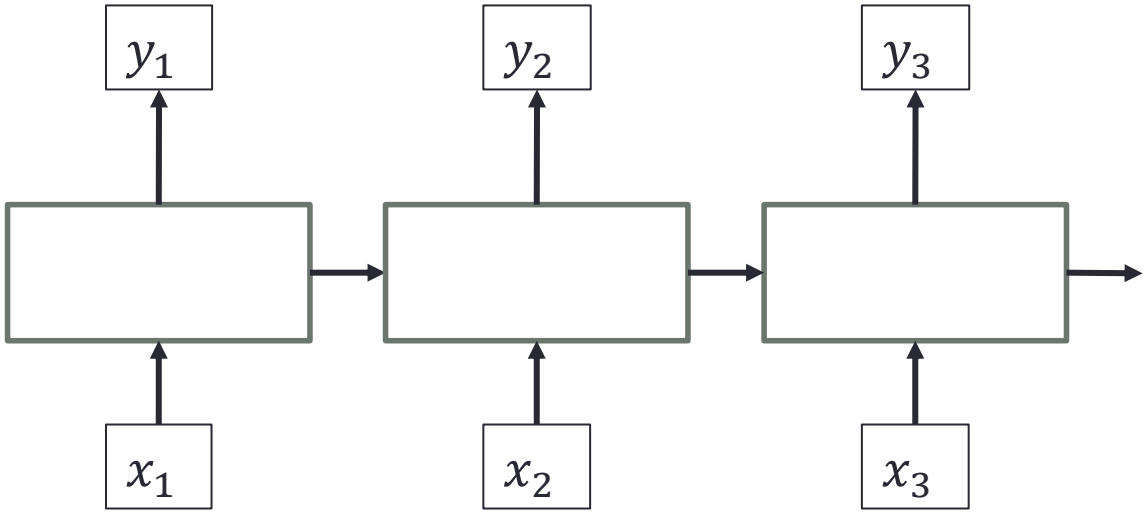

Stack Long Short-Term Memory

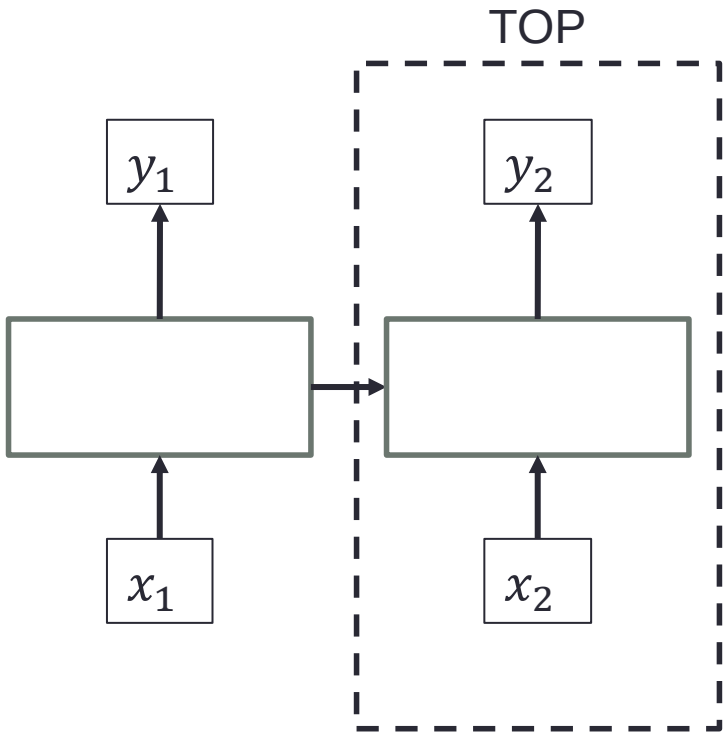

Stack Long Short-Term Memory

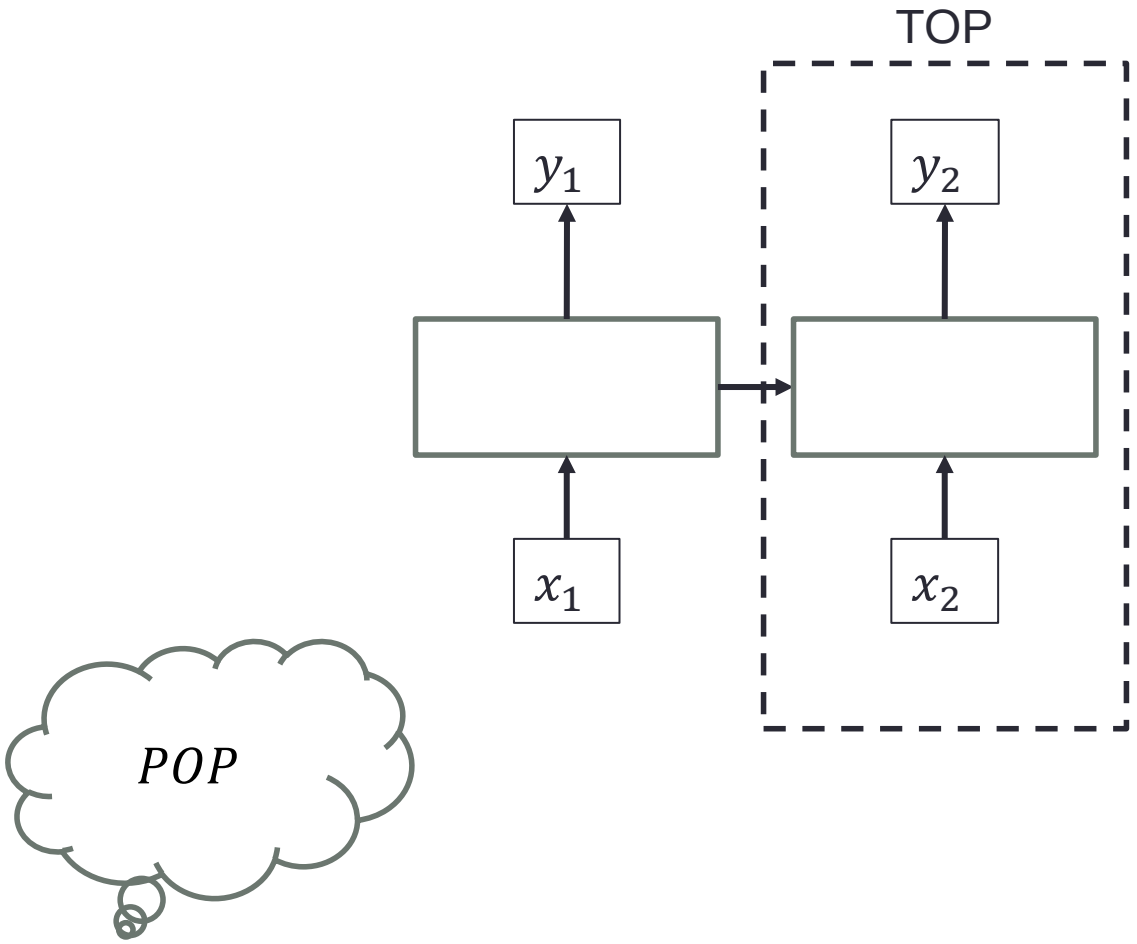

Stack Long Short-Term Memory

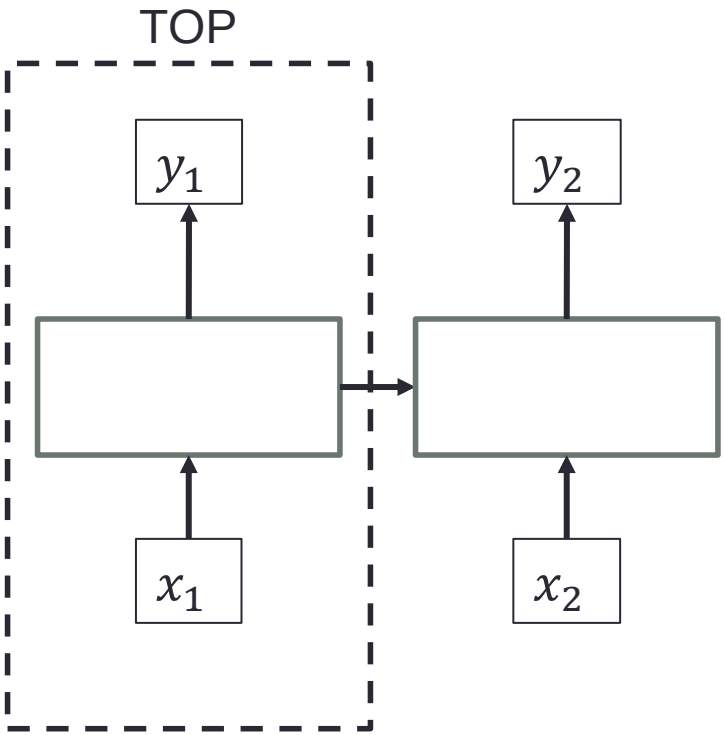

Stack Long Short-Term Memory

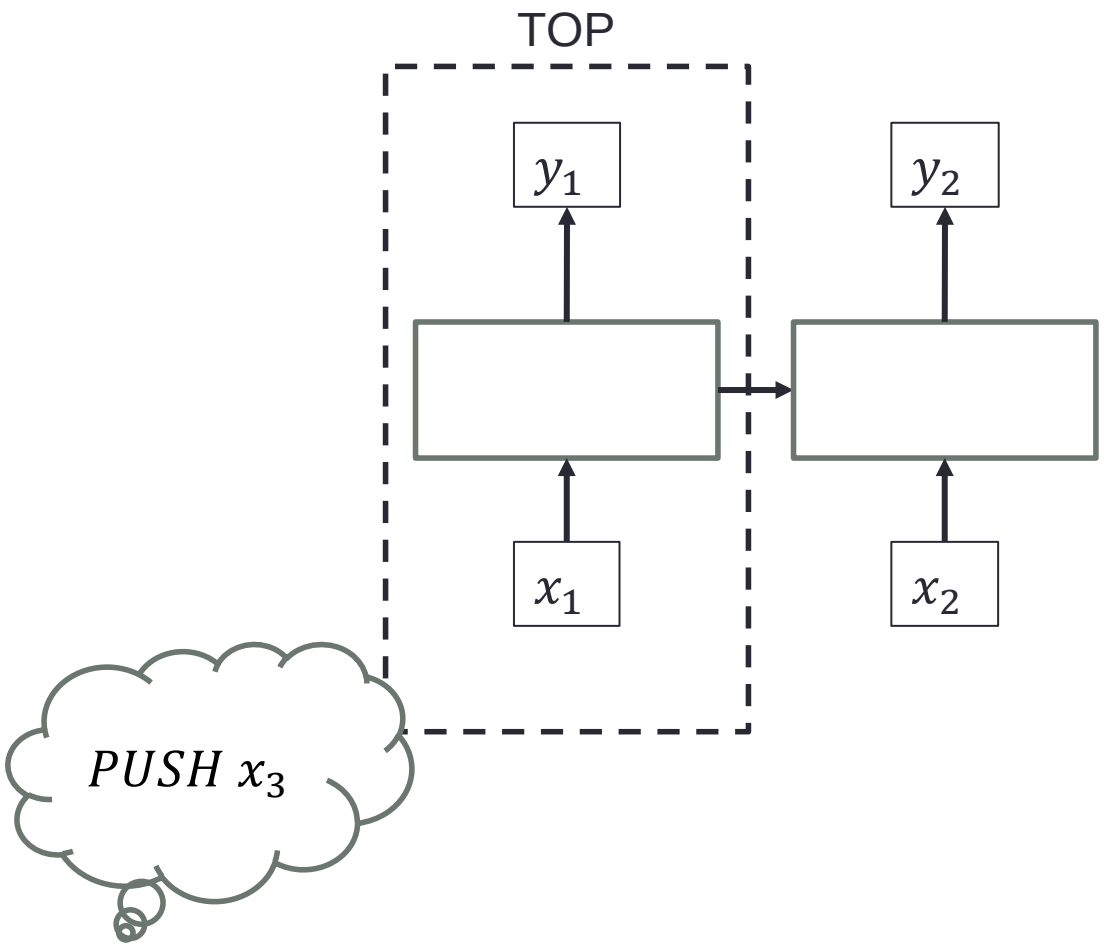

Stack Long Short-Term Memory

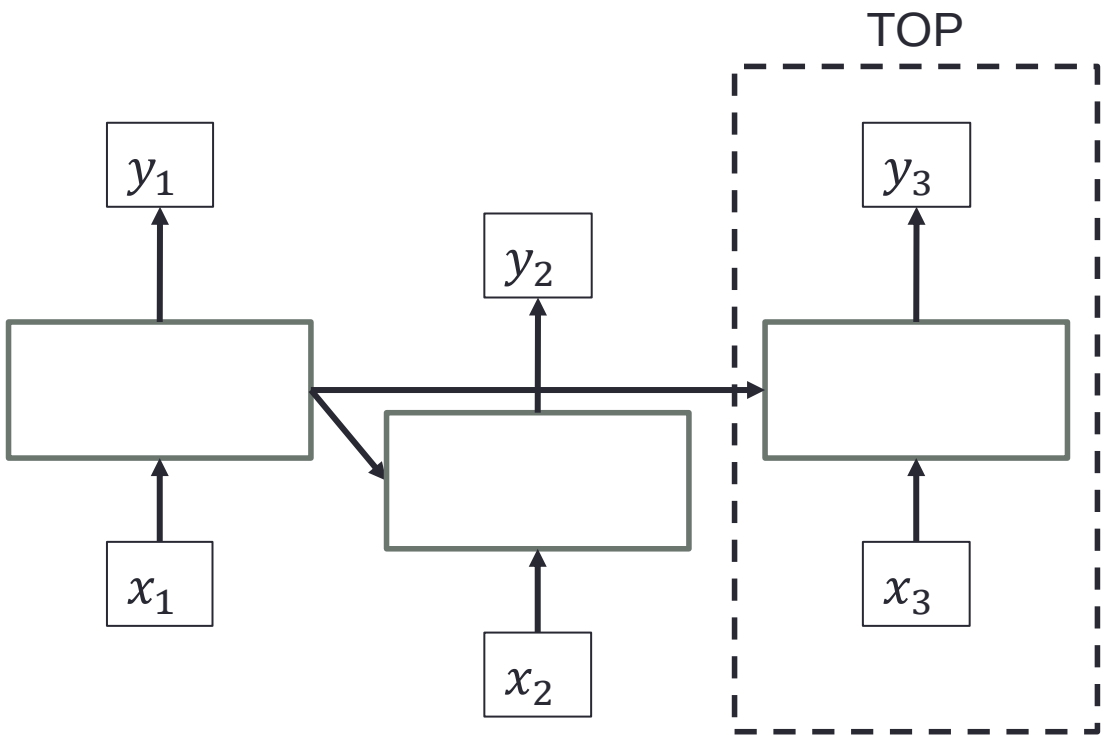

Stack LSTM Parser

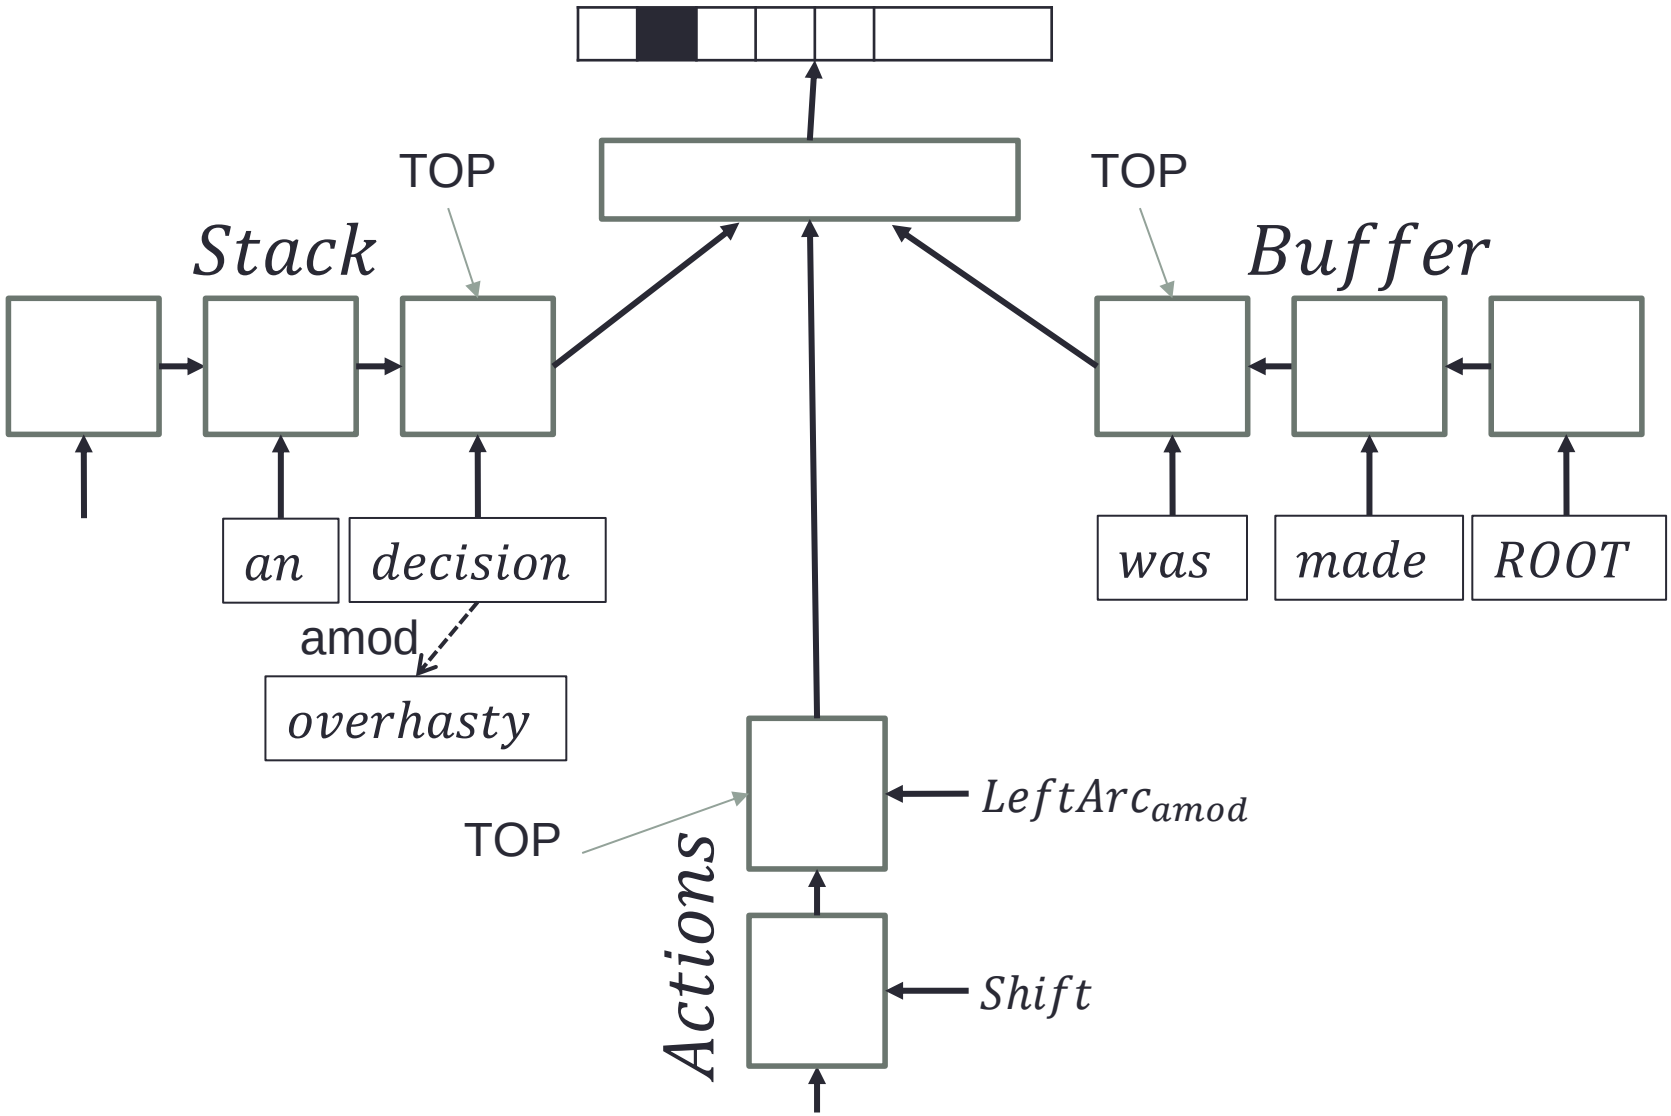

Stack LSTM Parser

- Переходы Arc-standard
  - $Shift$

$$(\sigma, [(v_i, i)|\beta], A) \rightarrow ([\sigma|(v_i, i)], \beta, A)$$

  - $LeftArc_r$

$$\left([\sigma|(v_i, i)|(v_j, j)], B, A\right) \rightarrow \left(\left[\sigma\middle|(g_r(v_i, v_j), j)\right], B, A \cup \{j \xrightarrow{r} i\}\right)$$

  - $RightArc_r$

$$\left([\sigma|(v_i, i)|(v_j, j)], B, A\right) \rightarrow \left(\left[\sigma\middle|(g_r(v_j, v_i), i)\right], B, A \cup \{i \xrightarrow{r} j\}\right)$$

Оценка качества

- Labeled attachment score (LAS):
  - Отношение количества правильно построенных дуг к общему количеству дуг
- Labeled exact match (LEM):
  - Отношение количества правильно построенных деревьев к общему количеству деревьев
- Unlabeled attachment score/exact match (UAS/UEM):
  - Те же метрики, но дуги рассматриваются без типов

Оценка качества

- Micro-averaged
  - Считаем отношение количества правильных дуг во всем корпусе к количеству дуг в этом корпусе
- Macro-averaged
  - Считаем метрику для каждого предложения и потом усредняем

Следующая лекция

- Машинный перевод

- Лектор: Сысоев Андрей Анатольевич