

Дискретная математика

# Контекстно-свободные языки

Константин Чухарев

Осень 2026

# Грамматика

*Бесцветные зелёные идеи яростно спят.*

— Ноам Хомский

# КС-грамматика

Регулярные языки — простейшая ступень. КС-грамматики снимают ограничение.

## Определение 1 (КС-грамматика (*context-free grammar*))

Четвёрка  $G = (V, \Sigma, P, S)$ :

- $V$  — нетерминалы.
- $\Sigma$  — терминалы.
- $P$  — правила  $A \rightarrow \alpha$ , где  $A \in V$  — один нетерминал, а  $\alpha \in (V \cup \Sigma)^*$  — строка из терминалов и нетерминалов.
- $S$  — стартовый нетерминал.

$$L(G) = \{w \in \Sigma^* \mid S \xrightarrow{*} w\}.$$

# Порождение

Грамматика описывает язык порождением.

Правила конечны, слова — бесконечно много.

$a^n b^n$

### Пример

$$S \rightarrow aSb \mid \varepsilon.$$

Вывод:  $S \rightarrow aSb \rightarrow aaSbb \rightarrow aaaSbbb \rightarrow a^3b^3$ .

Не регулярен, но контекстно-свободен.

На каждом шаге вывода слева появляется одна  $a$ , а справа — одна  $b$ .

Нужна память о числе — конечному автомату не под силу.

## Язык Дика

### Пример

Сбалансированные скобки:

$$S \rightarrow (S)S \mid \varepsilon.$$

Слово  $((()))()$  выводится так: раскрываем пары скобок и завершаем правилом  $S \rightarrow \varepsilon$ .

Вложенность — всюду:

- программы,
- выражения,
- разметка.

Распознать конечным автоматом нельзя.

Нужна память о глубине.

# Грамматика предложений

## Пример

Правила над словами:

$$\begin{aligned} S &\rightarrow \text{NP VP}, \\ \text{NP} &\rightarrow \text{Det } N \mid N, \quad \text{VP} \rightarrow V \text{ NP} \mid V, \\ \text{Det} &\rightarrow \text{старый}, \quad N \rightarrow \text{кот} \mid \text{мышь}, \quad V \rightarrow \text{ловит} \mid \text{бежит}. \end{aligned}$$

Левый вывод:  $S \rightarrow \text{NP VP} \rightarrow \text{Det } N \text{ VP} \rightarrow \text{старый кот ловит мышь}$ .

Слово «кот старый» не выводится: определение стоит только перед именем.

Язык — не все строки над алфавитом, а фразы со структурой.

Структуру задают правила, и она наследуется выводом.

# **Автоматы с магазинной памятью**

# PDA

## Определение 2 (PDA (*pushdown automaton*))

Семёрка  $M = (Q, \Sigma, \Gamma, \delta, q_0, Z_0, F)$ :

- $Q$  — состояния,  $\Sigma$  — входной алфавит.
- $\Gamma$  — алфавит стека,  $Z_0 \in \Gamma$  — донный символ.
- $\delta : Q \times (\Sigma \cup \{\varepsilon\}) \times \Gamma \rightarrow \mathcal{P}(Q \times \Gamma^*)$ .
- $q_0$  — начальное,  $F \subseteq Q$  — принимающие.

Переход  $(q', \gamma) \in \delta(q, a, A)$ : из  $q$ , прочитав  $a$ , увидев  $A$  на вершине, перейти в  $q'$ , заменив  $A$  строкой  $\gamma$ .

Стек — память о глубине вложенности.

Недетерминизм — как в НКА: существует путь.

## Принятие слова

### Определение 3 (Конфигурация и принятие)

Конфигурация — тройка  $(q, w, \gamma)$ : состояние, остаток входа, стек.

- По принимающему состоянию: путь к  $(q, \varepsilon, \gamma)$  с  $q \in F$ .
- По пустому стеку: путь к  $(q, \varepsilon, \varepsilon)$ .

Оба критерия эквивалентны.

## Распознавание $a^n b^n$

### Пример

- Фаза  $q_0$ : на каждую  $a$  кладём  $A$  в стек.
- Первая  $b$ : фаза  $q_1$ , на каждую  $b$  снимаем  $A$ .
- Принятие по пустому стеку.

Прогон  $a a b b$  (дно —  $Z_0$ ):

$$\begin{aligned}(q_0, aabb, Z_0) &\rightarrow (q_0, abb, AZ_0) \rightarrow (q_0, bb, AAZ_0) \\ &\rightarrow (q_1, b, AZ_0) \rightarrow (q_1, \varepsilon, Z_0) \rightarrow (q_1, \varepsilon, \varepsilon).\end{aligned}$$

$aba$  отвергается: в фазе  $q_1$  символ  $a$  читать нельзя.

Глубина стека — сколько  $a$  ещё не нашли пару.

# КСГ и PDA равносильны

## Теорема 1 (КСГ и PDA)

Язык порождается КС-грамматикой тогда и только тогда, когда распознаётся МП-автоматом (PDA, автоматом с магазинной памятью).

## Доказательство

От грамматики к автомату: автомат имитирует левый вывод, храня непрочитанную часть вывода в стеке. Верхний символ стека — терминал: снимаем его и сверяем с входной буквой. Верхний символ — нетерминал  $A$ : выбираем правило  $A \rightarrow \beta$ , снимаем  $A$  и кладём  $\beta$ . Автомат принимает, когда стек пуст и вход прочитан, и допускаемые им слова ровно те, что выводятся грамматикой.

## КСГ и PDA: от автомата к грамматике

КСГ  $\rightarrow$  PDA: автомат имитирует левый вывод.

PDA  $\rightarrow$  КСГ: нетерминалы кодируют переходы со стеком.

### Доказательство

От автомата к грамматике: кодируем состояния и стек нетерминалами вида  $[pXq]$  — переместиться из  $p$  в  $q$ , удалив из стека  $X$ . Переход из  $p$  в  $r$ , снимающий  $X$  и кладущий  $Y_1 \dots Y_m$  при чтении  $a$ , даёт правило  $[pXq] \rightarrow a[rY_1q_1][q_1Y_2q_2] \dots [q_{m-1}Y_mq]$  со вспомогательными состояниями  $q_1, \dots, q_{m-1}$ . Индукцией по числу переходов показывается, что такой нетерминал выводит строку тогда и только тогда, когда автомат проходит соответствующий путь.

# Структура КС-языков

## Дерево разбора

### Определение 4 (Дерево разбора)

Корнем служит  $S$ , внутренние вершины помечены нетерминалами, а листья — терминалами.

Дети вершины  $A$  слева направо — правая часть применённого правила  $A \rightarrow \alpha$ .


Метки листьев слева направо дают слово  $w$ .

### Пример

Слово  $aabbb$  из  $S \rightarrow aSb \mid \varepsilon$ : корень  $S$  раскрывается в  $aSb$ , внутренний  $S$  — снова в  $aSb$ , самый внутренний — в  $\varepsilon$ .

Дерево показывает: первая  $a$  спарена с последней  $b$ , вторая — с предпоследней.

## Дерево: $a^3b^3$



Дерево растёт слева направо: корень  $S$  слева, листья — справа.

На каждой стрелке — применённое правило: три раскрытия  $S \rightarrow aSb$  и завершение  $S \rightarrow \varepsilon$ .

Пустой лист  $\varepsilon$  символов не даёт: листья  $a, a, a, \varepsilon, b, b, b$  складываются в слово  $a^3b^3$ .

## Видимая вложенность

---

Строка прячет, какая скобка закрывает какую.

Дерево разбора делает вложенность видимой.

# Неоднозначность

## Определение 5 (Неоднозначная грамматика)

Грамматика неоднозначна, если некоторое слово языка имеет более одного дерева разбора.

Два дерева — два смысла одной строки.

Неоднозначность приоритетов устраняют уровнями правил: слагаемые собираются из множителей.

## Пример: два дерева

### Пример

$$E \rightarrow E + E \mid E * E \mid (E) \mid \text{id}.$$

Слово  $\text{id} + \text{id} * \text{id}$  — два дерева:

- Склеить сначала  $\text{id} + \text{id}$ : чтение  $(\text{id} + \text{id}) * \text{id}$ .
- Склеить сначала  $\text{id} * \text{id}$ : чтение  $\text{id} + (\text{id} * \text{id})$ .

При числах значения расходятся:  $(2 + 3) \cdot 4 = 20$ , но  $2 + (3 \cdot 4) = 14$ .

## Лемма о накачке

### Теорема 2 (Лемма о накачке для КС-языков (*pumping lemma*))

Если  $L$  контекстно-свободен, то есть  $p \geq 1$ : любое  $w \in L$  длины  $|w| \geq p$  разбивается как  $w = uvxyz$ :

- $|vy| > 0$ ;
- $|vxy| \leq p$ ;
- $uv^i xy^i z \in L$  для всех  $i \geq 0$ .

Накачиваются две подстроки одновременно и симметрично.

Регулярный случай — одна подстрока (цикл). Здесь две (стек растёт и убывает).

## $a^n b^n c^n$ не КС

### Пример

Возьмём  $w = a^p b^p c^p$ .

Подстрока  $vxy$  длины  $\leq p$  не захватывает и  $a$ , и  $c$ : между ними стоят все  $b$ .

Так как  $vxy$  не содержит одновременно  $a$  и  $c$ , при  $i = 0$  или  $i = 2$  одна из букв перестаёт накачиваться, и равенство количеств нарушается.

Значит,  $a^n b^n c^n$  не контекстно-свободен.

Один стек — один счётчик.

Два независимых счётчика уводят за пределы класса.

**Разбор**

## Обратная задача

КС-грамматика задаёт язык порождением. Разбор — обратная задача: по строке найти её вывод.

### Определение 6 (Разбор)

Дана строка  $w$  и грамматика  $G$ . Определить, лежит ли  $w$  в  $L(G)$ , и если да — построить дерево разбора.

Именно это делает компилятор: текст программы превращается в синтаксическое дерево.

### Пример

Для  $S \rightarrow aSb \mid \varepsilon$  и строки  $aabb$ :  $S \rightarrow aSb \rightarrow aaSbb \rightarrow aabb$  — вывод, он же путь в дереве разбора.

## Направления разбора

- Нисходящий разбор начинает со стартового символа и раскрывает продукции.
- Восходящий разбор сворачивает правые части продукций к стартовому символу.

Трудность — выбор: какую продукцию применить, где и что свернуть.

# LL и LR

## Определение 7 (Классы $LL(k)$ и $LR(k)$ )

- Грамматика  $LL(k)$  разбирается нисходяще с подглядыванием на  $k$  символов вперёд.
- Грамматика  $LR(k)$  разбирается восходяще.
- Большинство грамматик языков программирования — LR (или их упрощение LALR).

Для LR-грамматик существуют генераторы парсеров:

- yacc,
- bison,
- ANTLR.

LL- и LR-языки — собственные подклассы КС-языков.

Недетерминизм — цена выразительности: не всякая КС-грамматика разбирается детерминированно.

# Рекурсивный спуск

## Определение 8 (Рекурсивный спуск)


Простейший нисходящий парсер состоит из одной функции на каждый нетерминал и пишется вручную.

Функция для  $A$  пробует правые части правил  $A \rightarrow \alpha$  по очереди.

Так устроены парсеры компиляторов, написанные вручную.

# Иерархия Хомского

# Ступени



- **Регулярные:** конечные автоматы.
- **Контекстно-свободные:** PDA.
- **Контекстно-зависимые:** линейно-ограниченные автоматы.
- **Рекурсивно перечислимые:** машины Тьюринга.

Каждая ступень строго больше:  $a^n b^n$  — КС, но не регулярный.

# Разрешимость

Подъём по иерархии оплачивается потерей алгоритмических гарантий.

- Для регулярных языков разрешимы все стандартные вопросы: эквивалентность, пустота, включение.
- Для КС-языков разрешима пустота, но эквивалентность — уже нет.
- Для рекурсивно перечислимых неразрешима даже пустота (следующая лекция).

## Контекстно-зависимые

### Определение 9 (КЗ-грамматика (*context-sensitive grammar*))

Правила вида  $\alpha A \beta \rightarrow \alpha \gamma \beta$ : нетерминал  $A$  заменяется на непустую  $\gamma$ , только если вокруг стоят  $\alpha$  и  $\beta$ .

Замена чувствительна к контексту — отсюда название.

### Пример

Грамматика для  $a^n b^n c^n$ :

$$\begin{aligned} S &\rightarrow aSBC \mid aBC, & CB &\rightarrow BC, \\ aB &\rightarrow ab, & bB &\rightarrow bb, & bC &\rightarrow bc, & cC &\rightarrow cc. \end{aligned}$$

- Правило  $CB \rightarrow BC$  переставляет соседние  $B$  и  $C$ .
- Остальные превращают их в  $b$  и  $c$ .

## Монотонность

КЗ-правило не укорачивает строку: правая часть длиннее левой на  $|\gamma| - 1 \geq 0$  символов.

В выводе слова  $w$  ни одна промежуточная строка не длиннее  $|w|$ . Строк подходящей длины над конечным алфавитом — конечное число.

Распознавание перебором заведомо завершается: кандидатов конечное число.

Монотонные грамматики (все правила  $\alpha \rightarrow \beta$  с  $|\beta| \geq |\alpha|$ ) порождают в точности контекстно-зависимые языки.

# Линейно-ограниченный автомат

Стек доступен только с вершины, а контекстно-зависимым языкам нужна память с произвольным доступом.

## Определение 10 (Линейно-ограниченный автомат)

Линейно-ограниченный автомат — машина Тьюринга, длина ленты которой ограничена линейной функцией от длины входа.

Распознаёт в точности контекстно-зависимые языки.

## Пример

ЛОА распознаёт  $a^n b^n c^n$ :

1. Стирает крайние  $a$  и  $c$  попарно.
2. Сверяет оставшиеся  $b$ , уместаясь на ленте длины  $O(n)$ .

## Мост к машине Тьюринга

Мост к следующей лекции: полная машина Тьюринга — та же лента без ограничения длины.

КЗ-языки разрешимы, но распознавание дороже: перебор растёт экспоненциально с длиной слова.

## КС-языки на практике

- КС-грамматики — синтаксис языков программирования.
- Парсеры строят деревья разбора.
- Язык Дика — вложенность скобок в коде.

Нотация Бэкуса–Наура (BNF) — синтаксическая запись КС-грамматик.

Парсеры — алгоритмы построения дерева разбора.

Иерархия Хомского — карта выразительности.

От регулярных к рекурсивно перечислимым.

## Что мы поняли?

- КС-грамматика описывает язык порождением: конечные правила дают бесконечно много слов.
- Стек — память о глубине вложенности. КС-языки — ровно те, что распознаются МП-автоматом (PDA).
- Дерево разбора делает вложенность видимой. Два дерева у одного слова — два смысла.
- Один стек — один счётчик:  $\{a^n b^n c^n\}$  требует двух независимых счётчиков и выходит за пределы КС.

## Вопросы для самопроверки

---

- Определите КС-грамматику.
- Запишите грамматику для  $\{a^n b^n\}$ .
- Что такое язык Дика?
- Почему  $a^n b^n$  распознаётся PDA, но не ДКА?
- Сформулируйте эквивалентность КСГ и PDA.
- Когда грамматика неоднозначна?
- Сформулируйте лемму о накачке для КС-языков.
- Почему  $\{a^n b^n c^n\}$  не контекстно-свободен?
- Опишите иерархию Хомского.