

Элементы теории трансляции

Транслятор

позволяет преобразовать программу, написанную на ЯП, отличном от машинного языка, к виду, допускающему выполнение на ЭВМ.

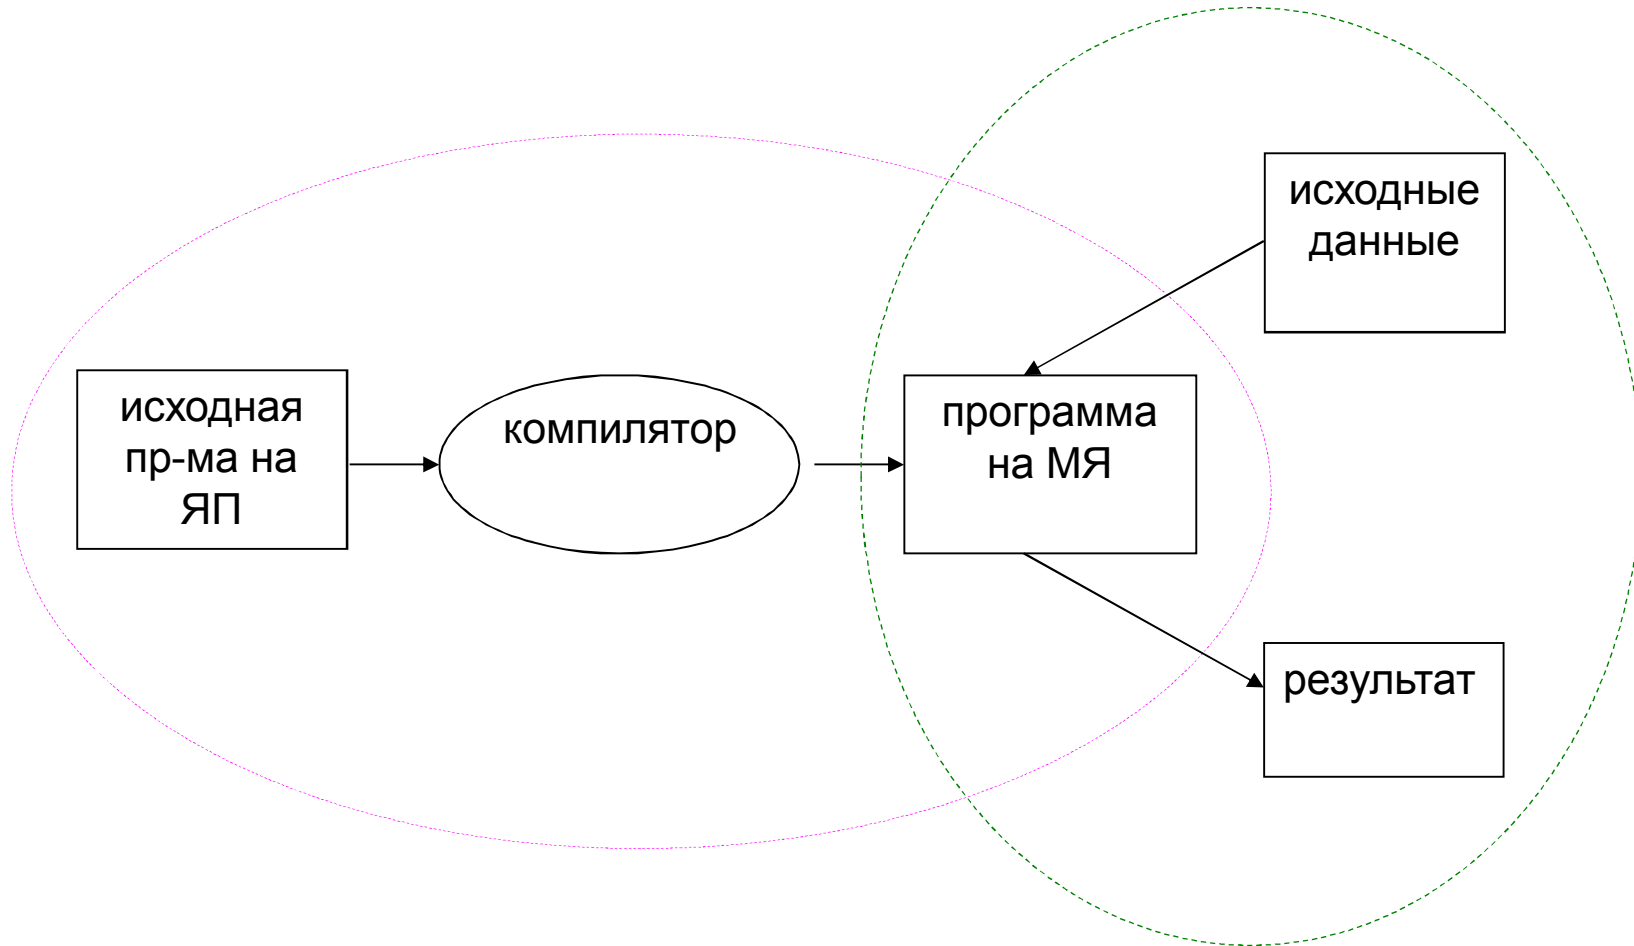
Компилятор

на вход получает программу на некотором ЯП (немашинном), а на выходе выдает объектный модуль (программу на машинном языке).

Интерпретатор

на вход получает программу на некотором ЯП (немашинном) и, считывая предложение за предложением исходной программы, анализирует их и тут же выполняет действия, указанные в этих предложениях.

Система программирования компилирующего типа




Примеры: MASM, Турбо Паскаль, gcc в UNIX

Система программирования интерпретирующего типа



Примеры: QBasic, командные интерпретаторы в UNIX -- bash, csh и др.


Смешанная стратегия



Примеры: 1) язык Java → байт-код → JVM (Java Virtual Machine)

2) Языки на технологии .NET (Basic, C#, C++) → промежуточный язык: CIL – Common Intermediate Language → JIT-компилятор (just-in-time)

Схема функционирования компилятора



Основные понятия теории формальных языков

Алфавит:

это конечное множество символов.

Пример: $V = \{a,b,c\}$

Цепочка символов в алфавите V :

любая конечная последовательность символов этого алфавита.

Пример: $V = \{a,b\}$. Цепочка: abbba

Пустая цепочка :

цепочка, которая не содержит ни одного символа.

Обозначение: ε

(иногда для этой цели используется символ Λ)

Конкатенация (сцепление) цепочек α и β :

цепочка, полученная приписыванием последовательности β справа к α

Обозначение: $\alpha \cdot \beta$ (или $\alpha\beta$)

Пример: если $\alpha = ab$ и $\beta = cd$, то

$$\alpha\beta = abcd.$$

- Для любой цепочки α верно $\alpha\varepsilon = \varepsilon\alpha = \alpha$.
(Аналог для чисел: $\forall x$ верно $1 \cdot x = x \cdot 1 = x$)
- Операция конкатенации ассоциативна: $(\alpha \cdot \beta) \cdot \gamma = \alpha \cdot (\beta \cdot \gamma)$ для любых α, β, γ .
- Операция конкатенации некоммутативна:
например, для $\alpha = ab$ и $\beta = cd$ $\alpha \cdot \beta \neq \beta \cdot \alpha$

Обращение (или *реверс*) цепочки α :

цепочка, символы которой записаны в обратном порядке.

Обозначение: α^R

Пример: если $\alpha = abcdef$, то $\alpha^R = fedcba$.

Для пустой цепочки: $\varepsilon = \varepsilon^R$.

Рекурсивное определение:

$$\alpha^R = \begin{cases} \varepsilon, & \text{если } \alpha = \varepsilon; \\ \beta^R s, & \text{если } \alpha = s \beta, \text{ где } s \text{ — символ алфавита} \end{cases}$$

***n*-я степень** цепочки α (обозначается α^n) :

конкатенация n цепочек α

$$\underbrace{\alpha \alpha \alpha \dots \alpha \alpha}_{n \text{ раз}} = \alpha^n$$

Рекурсивное определение:

$$\alpha^n = \begin{cases} \varepsilon, & \text{если } n=0; \\ \alpha^{n-1}\alpha, & \text{если } n>0 \end{cases}$$

Длина цепочки :

это число составляющих ее символов

Пример: если $\alpha = abcdefg$, то длина α равна 7.

Обозначение: $|\alpha|$

$$|\varepsilon| = 0$$

Рекурсивное определение:

$$|\alpha| = \begin{cases} 0, & \text{если } \alpha = \varepsilon; \\ |\beta| + 1, & \text{если } \alpha = \beta s, \text{ где } s \text{ — символ алфавита} \end{cases}$$

Обозначение $|\alpha|_s$ используется для числа вхождений символа s в цепочку α .

Язык в алфавите V :

подмножество цепочек конечной длины в этом алфавите.

V^* :

множество, содержащее все цепочки конечной длины в алфавите V , включая пустую цепочку ε .

Пример: $V = \{0,1\}$,

$V^* = \{\varepsilon, 0, 1, 00, 11, 01, 10, 000, 001, 011, \dots\}$.

V^+ :

множество, содержащее все цепочки конечной длины в алфавите V , исключая пустую цепочку ε .

- $V^* = V^+ \cup \{\varepsilon\}$
- Для любого языка $L \subseteq V^*$

способы описания языков

Явное перечисление:

$$L = \{ab, abb, ba, baa\}$$

Язык L — конечный

Формулы:

$$L = \{a^n b^n \mid n \geq 0\}$$

Цепочки языка L : $\varepsilon, ab, aabb, aaabbb, \dots$

Порождающие грамматики Хомского

Распознаватели (МТ, ЛОА, конечные автоматы, МП-автоматы)

Декартово произведение множеств A и B :

множество $\{ (a,b) \mid a \in A, b \in B \}$

Обозначение: $A \times B$

Порождающая грамматика G :

это четверка $\langle T, N, P, S \rangle$, где

- T – алфавит *терминальных символов (терминалов)*,
 - N – алфавит *нетерминальных символов (нетерминалов)*, не пересекающийся с T ,
 - P – конечное подмножество множества $(T \cup N)^+ \times (T \cup N)^*$;
элемент (α, β) множества P называется *правилом вывода* и записывается в виде $\alpha \rightarrow \beta$,
 α содержит хотя бы один нетерминал;
- S – *начальный символ (цель)* грамматики, $S \in N$.

правила

$\alpha \rightarrow \beta_1 \quad \alpha \rightarrow \beta_2 \quad \dots \quad \alpha \rightarrow \beta_n$

записываются сокращенно

$\alpha \rightarrow \beta_1 \mid \beta_2 \mid \dots \mid \beta_n$

β_i для $i = 1, 2, \dots, n$, - **альтернатива** правила

вывода из цепочки α .

Порождающая грамматика G :

это четверка $\langle T, N, P, S \rangle$, где

- T – алфавит *терминальных символов (терминалов)*,
- N – алфавит *нетерминальных символов (нетерминалов)*,
 $T \cap N = \emptyset$,
- P – конечное подмножество множества $(T \cup N)^+ \times (T \cup N)^*$;
элемент (α, β) множества P называется *правилом вывода* и записывается в виде $\alpha \rightarrow \beta$,
- S – *начальный символ (цель)* грамматики, $S \in N$.

Пример грамматики: $G_1 = \langle \{0,1\}, \{A, S\}, P, S \rangle$

P :

$S \rightarrow 0A1$

$0A \rightarrow 00A1$

$A \rightarrow \varepsilon$

Пусть $\beta \in (T \cup N)^*$ $\alpha \in (T \cup N)^+$

β **непосредственно выводима** из α

в грамматике $G = \langle T, N, P, S \rangle$,

если $\alpha = \xi_1 \gamma \xi_2$,

$\beta = \xi_1 \delta \xi_2$,

где $\xi_1, \xi_2, \delta \in (T \cup N)^*$, $\gamma \in (T \cup N)^+$ и $\gamma \rightarrow \delta \in P$.

Обозначение: $\alpha \rightarrow \beta$

Пример: $G_1 = \langle \{0,1\}, \{A, S\}, P, S \rangle$

P:

$S \rightarrow 0A1$

$0A \rightarrow 00A1$

$A \rightarrow \varepsilon$

Цепочка $00A11$ непосредственно выводима из $0A1$ в грамматике G_1 : $0A1$ \rightarrow $00A11$ (по правилу $0A \rightarrow 00A1$)

Цепочка $\beta \in (T \cup N)^*$ **выводима** из цепочки $\alpha \in (T \cup N)^+$
в грамматике $G = \langle T, N, P, S \rangle$,

если существуют цепочки $\gamma_0, \gamma_1, \dots, \gamma_n$ ($n \geq 0$), такие, что

$$\alpha = \gamma_0 \rightarrow \gamma_1 \rightarrow \dots \rightarrow \gamma_n = \beta.$$

Обозначение: $\alpha \Rightarrow \beta$

Вывод длины n :

последовательность $\gamma_0, \gamma_1, \dots, \gamma_n$

Любая цепочка выводится сама из себя за 0 шагов: $\alpha = \gamma_0 = \alpha$

$G_1 = \langle \{0, 1\}, \{A, S\}, P, S \rangle$

P:

$S \rightarrow 0A1$

$0A \rightarrow 00A1$

$A \rightarrow \varepsilon$

$S \Rightarrow 000A111$ в G_1 , т. к. \exists вывод $S \rightarrow 0A1 \rightarrow 00A11 \rightarrow 000A111$.

Длина вывода равна 3.

Сентенциальная форма в грамматике $G = \langle T, N, P, S \rangle$:
 $\alpha \in (T \cup N)^*$, для которой $S \Rightarrow \alpha$

Язык, порождаемый грамматикой $G = \langle T, N, P, S \rangle$:
множество $L(G) = \{\alpha \in T^* \mid S \Rightarrow \alpha\}$

Грамматика — это не алгоритм, а система правил подстановки, позволяющих строить выводы.

Язык, порождаемый грамматикой $G = \langle T, N, P, S \rangle$:

$$\text{множество } L(G) = \{ \alpha \in T^* \mid S \Rightarrow \alpha \}$$

Пример: $G_1 = \langle \{0,1\}, \{A,S\}, P, S \rangle$,

P:

$$(1) S \rightarrow 0A1$$

$$(2) 0A \rightarrow 00A1$$

$$(3) A \rightarrow \varepsilon$$

$$L(G) = ?$$

$$S \xrightarrow{(1)} 0A1 \xrightarrow{(3)} 01$$

$$S \xrightarrow{(1)} 0A1 \xrightarrow{(2)} 00A11 \xrightarrow{(3)} 0011$$

$$S \xrightarrow{(1)} 0A1 \xrightarrow{(2)} 00A11 \xrightarrow{(2)} 000A111 \xrightarrow{(3)} 000111$$

...

Предположительно: $L_1 = \{0^n 1^n \mid n > 0\}$

Язык, порождаемый грамматикой $G = \langle T, N, P, S \rangle$:
 множество $L(G) = \{ \alpha \in T^* \mid S \Rightarrow \alpha \}$

Пример: $G_1 = \langle \{0,1\}, \{A,S\}, P, S \rangle$,

P:

(1) $S \rightarrow 0A1$

(2) $0A \rightarrow 00A1$

(3) $A \rightarrow \varepsilon$

Предположительно: $L_1 = \{0^n 1^n \mid n > 0\}$

Требуется доказать: $L(G_1) = L_1$:

(1) $L_1 \subseteq L(G_1)$, т.е. $\forall x \in L_1 \Rightarrow x \in L(G_1)$ (индукция по n)

(2) $L(G_1) \subseteq L_1$, т.е. $\forall x \in L(G_1) \Rightarrow x \in L_1$ (индукция по длине вывода)

Эквивалентность грамматик G_1 и G_2 :

20

$$L(G_1) = L(G_2)$$

Пример:

$$G_1 = \langle \{0,1\}, \{A,S\}, P_1, S \rangle$$

и

$$G_2 = \langle \{0,1\}, \{S\}, P_2, S \rangle$$

$$P_1: S \rightarrow 0A1$$

$$P_2: S \rightarrow 0S1 \mid 01$$

$$0A \rightarrow 00A1$$

$$A \rightarrow \varepsilon$$

$$L(G_1) = L(G_2) = \{0^n 1^n \mid n > 0\}$$

Грамматика G_1 и G_2 **почти эквивалентны**,
если $L(G_1) \cup \{\varepsilon\} = L(G_2) \cup \{\varepsilon\}$.

Пример:

$$G_1 = \langle \{0,1\}, \{A,S\}, P_1, S \rangle$$

и

$$G_2' = \langle \{0,1\}, \{S\}, P_2', S \rangle$$

$$P_1: S \rightarrow 0A1$$

$$P_2': S \rightarrow 0S1 \mid \varepsilon$$

$$0A \rightarrow 00A1$$

$$A \rightarrow \varepsilon$$

$$L(G_1) = \{0^n 1^n \mid n > 0\}, \text{ а } L(G_2') = \{0^n 1^n \mid n \geq 0\}$$

$$\text{т.е. } L(G_2') = L(G_1) \cup \{\varepsilon\}$$

$$G_1 = (\{0,1\}, \{A,S\}, P_1, S)$$

$$P_1: S \rightarrow 0A1$$

$$0A \rightarrow 00A1$$

$$A \rightarrow \varepsilon$$

Рассмотрим

$$G_3 = (\{0,1\}, \{S\}, P, S), \text{ где } P:$$

$$(1) S \rightarrow 0S$$

$$(2) S \rightarrow 1S$$

$$(3) S \rightarrow \varepsilon$$

Любая цепочка вида $0^n 1^n$ порождается следующим способом:

-- n раз применить правило (1), затем

-- n раз применить правило (2)

-- и на последнем шаге применить правило (3).

Однако $L(G_3) \neq L(G_1)$,

$$\text{т.к. } S \rightarrow 1S \rightarrow 10S \rightarrow 10 \in L(G_3),$$

$$10 \notin L(G_1)$$