



اصول طراحی کامپایلر

۲

درس نامه‌ی

کاظم فولادی

<http://kazim.fouladi.ir>

ویراست اول: ۱۳۸۸

ویراست دوم: ۱۳۹۳


فهرست مطالب

۱	۲ تحلیل لغوی
۱	۱-۲ مقدمه
۲	۲-۲ توکن، لغت و الگو
۲	۱-۲-۲ خصیصه‌های یک توکن
۳	۲-۲-۲ تمایز کلیدواژه‌ها و شناسه‌ها
۳	۳-۲ الفبا، رشته و زبان
۳	۱-۳-۲ رشته‌ها
۳	عملیات روی رشته‌ها
۴	ترمینولوژی اجزای رشته‌ها: پیشوند، پسوند و زیررشته
۴	۲-۳-۲ زبان‌ها
۵	عملیات روی زبان‌ها
۵	۴-۲ مؤلفه‌های تحلیل‌گر لغوی
۵	۵-۲ عبارت‌های منظم: ابزاری برای تعریف الگوی توکن‌ها
۶	۱-۵-۲ عبارت منظم
۶	۲-۵-۲ زبان توصیف شده بایک عبارت منظم

۳-۵-۲	کوتاه‌نوشت‌هایی برای عبارت‌های منظم	۷
۴-۵-۲	تقدم عملگرها برای عبارت‌های منظم	۸
۵-۵-۲	تعریف‌های منظم	۸
۶-۵-۲	گرامرهای منظم به جای عبارت‌های منظم	۹
۶-۲	آتوماتای متناهی: مکانیزمی برای بازشناسی توکن‌ها	۹
۱-۶-۲	آتوماتون متناهی قطعی (DFA)	۹
۹	تابع گذر حالت تعمیم‌یافته برای آتوماتون متناهی قطعی	۹
۱۰	رشته‌های پذیرفته شده توسط یک DFA داده شده	۱۰
۱۰	گراف گذر حالت برای بازنمایی آتوماتون متناهی	۱۰
۱۱	جدول گذر حالت برای بازنمایی آتوماتون متناهی	۱۱
۲-۶-۲	آتوماتون متناهی غیر قطعی (NFA)	۱۱
۱۱	تابع گذر حالت تعمیم‌یافته برای آتوماتون متناهی غیرقطعی	۱۱
۱۲	رشته‌های پذیرفته شده توسط یک NFA داده شده	۱۲
۱۲	مقایسه‌ی آتوماتون‌های قطعی و غیرقطعی	۱۲
۳-۶-۲	ساخت NFA متناظر با یک عبارت منظم	۱۲
۴-۶-۲	ساخت یک DFA متناظر با یک NFA داده شده	۱۳
۵-۶-۲	می‌نیمم سازی تعداد حالات یک DFA داده شده	۱۵
۷-۲	پیاده‌سازی تحلیل‌گر لغوی	۱۵
۱-۷-۲	خواندن ورودی	۱۶
۲-۷-۲	از عبارت‌های منظم تا تحلیل‌گر لغوی	۱۶
۱۶	برخورد با ابهام‌ها	۱۶
۳-۷-۲	فرآیند ساخت بازشناس توکن‌ها	۱۸
۸-۲	مسایل خاص برای تحلیل‌گر لغوی	۲۰
۱-۸-۲	کلمات کلیدی	۲۰
۲-۸-۲	فاصله‌های خالی بااهمیت	۲۰
۳-۸-۲	ثوابت رشته‌ای	۲۰
۴-۸-۲	بستار متناهی	۲۱
۹-۲	خطاهای لغوی	۲۱
۱-۹-۲	عبور از خطاهای لغوی: استراتژی حالت وحشت (Mode Panic)	۲۱
۲-۹-۲	عبور از خطاهای لغوی: استراتژی‌های تک کاراکنتری	۲۱
۳-۹-۲	عبور از خطاهای لغوی: استراتژی کم‌ترین فاصله	۲۱
۲۱	* تمرین	۲۱

۱-۲ مقدمه

تحلیل لغوی، نخستین مرحله‌ی فرآیند کامپایل است.



شکل ۱-۲: تحلیل لغوی به عنوان نخستین مرحله‌ی فرآیند کامپایل

- در تحلیل لغوی به کد منبع به عنوان یک دنباله‌ی واحد از کاراکترها نگاه می‌شود.
- تحلیل‌گر لغوی کد منبع را می‌خواند و دنباله‌ی کاراکترها را در توکن‌ها گروه‌بندی می‌کند.



شکل ۲-۲: مرحله‌ی تحلیل لغوی

۲-۲ توکن، لغت و الگو

- توکن (Token): کوچکترین واحد معنادار که توسط تجزیه‌گر لغوی شناسایی می‌شود.
 - لغت (Lexeme): دنباله‌ای از کاراکترها که یک توکن را تشکیل می‌دهد.
 - الگو (Pattern): قاعده‌ای که چگونگی ساخت توکن را مشخص می‌کند.
- تعریف توکن و تعریف لغت به عهده‌ی تعریف زبان منبع است.

مثال

در جدول زیر نمونه‌هایی از توکن‌ها و لغت‌ها با توصیف آنها را مشاهده می‌کنید:

TOKEN	LEXEME	DESCRIPTION
const	const	language keyword
if	if	language keyword
relation	<, <=, =, <>, >, >=	comparison operators
id	position, A1, x	sequence of letters and digits
num	3.14, 14, 6.02E23	numeric constant

۱-۲-۲ خصیصه‌های یک توکن


خصیصه‌های یک توکن (Attributes): اطلاعات مرتبط با آن توکن

$\langle Token, Attributes \rangle$

- از خصیصه‌های یک توکن در مرحله‌ی تحلیل نحوی و ترجمه استفاده می‌شود.
- اگر توکن مشخص‌کننده‌ی یک لغت واحد باشد، خصیصه‌ی آن خالی خواهد بود.

مثال

مثالی ساده از تحلیل لغوی:



۲-۲-۲ تمایز کلیدواژه‌ها و شناسه‌ها

- زبان‌های برنامه‌سازی از رشته‌های ثابتی برای شناسایی کلیدواژه‌ها (Keywords) استفاده می‌کنند، مانند: `if`، `then`، `else`، ...
- از آنجا که الگوی کلیدواژه‌ها دقیقاً همان الگوی شناسه‌هاست، تحلیل‌گر لغوی باید بین آنها تمایز قایل شود.
- اگر کلیدواژه‌ها رزرو شده (Reserved) باشند، می‌توانیم آنها را در ابتدای جدول نمادها قرار دهیم و آنها را با عنوان Keyword مشخص کنیم.
- در این صورت، یک رشته به عنوان یک شناسه (Identifier) شناسایی می‌شود، اگر در جدول نمادها به عنوان کلیدواژه علامت‌گذاری نشده باشد.

۳-۲ الفبا، رشته و زبان

- الفبا (Alphabet): مجموعه‌ای متناهی و ناتهی از نمادهای تجزیه‌ناپذیر (Σ)
- رشته (String): دنباله‌ای متناهی از نمادهای یک الفبا
- زبان (Language): مجموعه‌ای از رشته‌های یک الفبا

۱-۳-۲ رشته‌ها

- طول رشته: تعداد نمادهای الفبا در رشته
- رشته‌ی تهی: رشته‌ای با طول صفر ϵ

عملیات روی رشته‌ها

الحاق (Concatenation):

- اگر x و y دو رشته باشند، رشته‌ی حاصل از الحاق آنها xy خواهد بود.
- ϵ عضو خنثای عمل الحاق می‌باشد:

$$x \epsilon = \epsilon x = x$$

مثال

x	y	xy
key	word	keyword
java	script	javascript

توان یک رشته:

$$x^0 = \epsilon$$

$$x^{i+1} = x^i x$$

ترمینولوژی اجزای رشته‌ها: پیشوند، پسوند و زیررشته

TERM	DEFINITION
prefix of s	a string obtained by removing 0 or more trailing symbols of s
suffix of s	a string obtained by removing 0 or more leading symbols of s
substring of s	a string obtained by deleting a prefix and a suffix from s
proper prefix suffix, substring of s	Any nonempty string x that is, respectively, a prefix, suffix or substring of s such that $s \neq x$

زبان‌ها ۲-۳-۲

مثال

- $\Sigma = \{0, 1\}$ – **a string is an instruction**
 - The set of M68K instructions
 - The set of Pentium instructions
 - The set of MIPS instructions
- Σ = the ASCII set – **a string is a program**
 - the set of Haskell programs
 - the set of C programs
 - the set of VC programs

عملیات روی زبان‌ها

$L_1 L_2 = \{x_1 x_2 : x_1 \in L_1, x_2 \in L_2\}$	Concatenation	الحاق
$L^\circ = \{\epsilon\}$		توان صفر
$L^i = L^{i-1} L$		توان
$L_1 \cup L_2 = \{x : x \in L_1, x \in L_2\}$	Union	اجتماع
$L^* = \bigcup_{i=0}^{\infty} L^i$	Star Closure	بستار ستاره‌ای
$L^+ = \bigcup_{i=1}^{\infty} L^i$	Positive Closure	بستار مثبت

$$L^* = L^+ \cup \{\epsilon\}$$

مثال

مثال‌هایی از عملیات روی زبان‌ها

- $L = \{a, \dots, z, A, \dots, Z, _\}$
- $D = \{0, \dots, 9\}$

EXAMPLE	LANGUAGE
$L \cup D$	letters and digits
LD	strings consisting of a letter followed by a digit
L^3	all 3-letter strings
L^*	all strings of letters, including the empty string ϵ
$L(L \cup D)^*$	all strings of letters and digits beginning with a letter
D^+	all strings of one or more digits

۴-۲ مؤلفه‌های تحلیل‌گر لغوی

برای یک تحلیل‌گر لغوی می‌توان سه مؤلفه‌ی زیر را در نظر گرفت:

- زبان مشخص‌سازی تحلیل‌گر لغوی: برای بیان الگوی توکن
 - مکانیزم تحلیل‌گر لغوی: نحوه‌ی تطبیق لغت‌ها با الگوها
 - پیاده‌سازی تحلیل‌گر لغوی: نحوه‌ی کدگذاری و پیاده‌سازی تحلیل‌گر لغوی
- در قسمت‌های بعدی این فصل به تشریح موارد فوق می‌پردازیم.

۵-۲ عبارت‌های منظم: ابزاری برای تعریف الگوی توکن‌ها

عبارت منظم برای توصیف الگوی توکن شناسه:

`letter(letter|digit)*`

۱-۵-۲ عبارت منظم (Regular Expression)

فرض می‌کنیم که Σ یک الفبای داده شده باشد:

(۱) $\epsilon, \emptyset$ و $a \in \Sigma$ عبارت‌های منظم هستند (عبارت منظم ابتدایی).

(۲) اگر r_1 و r_2 دو عبارت منظم باشند، در این صورت

$$r_1 | r_2$$

$$r_1 . r_2$$

$$r_1^*$$

$$(r_1)$$

هم عبارت منظم هستند.

(۳) یک رشته عبارت منظم است، اگر و فقط اگر بتوان آن را از ترکیب عبارت منظم ابتدایی با بکارگیری قانون ۲ به تعداد متناهی به دست آورد.

۲-۵-۲ زبان توصیف شده بایک عبارت منظم

اگر r یک عبارت منظم باشد، $L(r)$ زبان مرتبط با r است و مطابق جدول زیر تعریف می‌شود:

$L(\emptyset) = \emptyset$
$L(\epsilon) = \{\epsilon\}$
$L(a) = \{a\}$, $a \in \Sigma$
$L(r_1 r_2) = L(r_1) \cup L(r_2)$
$L(r_1 . r_2) = L(r_1) . L(r_2)$
$L((r)) = L(r)$
$L(r^*) = (L(r))^*$

مثال

نمونه‌هایی از عبارت‌های منظم:

$$\Sigma = \{a, b\}$$

Regular Expression	Language
$a b$	$\{a, b\}$
$(a b)(a b)$	$\{aa, ab, ba, bb\}$
a^*	$\{\epsilon, a, aa, aaa, \dots\}$
$(a b)^*$	Σ^*

مثال

نمونه‌ای از محاسبه‌ی زبان یک عبارت منظم:

- Alphabet: $\Sigma = \{0, 1\}$
- RE: $0(0|1)^*$
- Question: What is the language defined by the RE?
- Answer:

$$\begin{aligned}
 L(0(0|1)^*) &= L(0)L((0|1)^*) \\
 &= \{0\}L(0|1)^* \\
 &= \{0\}(L(0) \cup L(1))^* \\
 &= \{0\}(\{0\} \cup \{1\})^* \\
 &= \{0\}\{0, 1\}^* \\
 &= \{0\}\{\epsilon, 0, 1, 00, 01, 10, 11, \dots\} \\
 &= \{0, 00, 01, 000, 001, 010, 011, \dots\}
 \end{aligned}$$

The RE describes the set of strings of 0's and 1's beginning with a 0.

مثال

چند عبارت منظم و زبان متناظر با آنها:

RE	LANGUAGE
1	$\{1\}$
$0 1$	$\{0, 1\}$
1^*	$\{\epsilon, 1, 11, 111, \dots\}$
1^*1	$\{1, 11, 111, \dots\}$
$0 0^*1$	the set containing 0 and all strings consisting of zero or more 0's followed by a 1.

۳-۵-۲ کوتاه‌نوشت‌هایی برای عبارت‌های منظم

بستار مثبت

$$r^+ = r.r^*$$

نماد وجود

$$r^? = r \mid \epsilon$$

طبقه‌های کاراکتر (character class):

$$[\backslash, \text{۳}, \text{۵}] = \backslash \mid \text{۳} \mid \text{۵}$$

$$[a-z] = a \mid b \mid \dots \mid z$$

۴-۵-۲ تقدم عملگرها برای عبارت‌های منظم

برای اجتناب از پراختزگذاری‌های زیاد، از تقدم عملگرها استفاده می‌کنیم

↓ کاهش تقدم	*	بستار ستاره‌ای
	.	الحاق
		اجتماع

بالاترین تقدم مربوط به بستار ستاره‌ای و پس از آن به الحاق و سپس اجتماع می‌باشد.

۵-۵-۲ تعریف‌های منظم (Regular Definitions)

از تعریف‌های منظم برای نامگذاری عبارت‌های منظم استفاده می‌کنیم:

عبارت منظم $\rightarrow$ نام عبارت منظم

در یک تعریف منظم، می‌توان دنباله‌ای از تعاریف فوق را استفاده نمود و نام هر یک از عبارت‌های منظم را در تعریف دیگری به کار برد.

مثال

تعریف منظم برای شناسه:

$$letter \rightarrow A | B | \dots | Z | a | b | \dots | z$$

$$digit \rightarrow 0 | 1 | \dots | 9$$

$$id \rightarrow letter(letter | digit)^*$$

به طور معادل (با استفاده از طبقه کاراکترها)

$$id \rightarrow [A - Z a - z][A - Z a - z^0 - 9]^*$$

مثال

تعریف منظم برای اعداد:

$$5230, \quad 3.14, \quad 6.45E4, \quad 1.84E-4$$

$$digit \rightarrow 0 | 1 | \dots | 9$$

$$sign \rightarrow + | - | \epsilon$$

$$digits \rightarrow digit^+$$

$$fraction \rightarrow (.digits)^?$$

$$exponent \rightarrow (E sign^? digits)^?$$

$$num \rightarrow sign digits fraction exponent$$


۶-۵-۲ گرامرهای منظم به جای عبارت‌های منظم

گرامرهای منظم یا گرامرهای نوع سه

- هر عبارت منظم با یک گرامر منظم متناظر است و برعکس
- عبارت‌های منظم نسبت به گرامرهای منظم شکل فشرده‌تری دارند و خواندن آنها ساده‌تر است.

۶-۲ اتوماتای متناهی: مکانیزمی برای بازشناسی توکن‌ها

اتوماتون متناهی برای بازشناسی توکن شناسه:



۱-۶-۲ اتوماتون متناهی قطعی (DFA)

اتوماتون متناهی حالت قطعی (DFA) Deterministic Finite Automata، یک پنج‌تایی مرتب به صورت

$$M = (Q, \Sigma, \delta, q_0, F)$$

است که در آن

Q مجموعه‌ی حالات: مجموعه‌ی متناهی و ناتهی از حالت‌های داخلی (internal states)

Σ مجموعه‌ی الفبای ورودی (alphabet)

δ تابع گذر حالت به صورت $\delta : Q \times \Sigma \rightarrow Q$ که حالت بعدی اتوماتون را بر اساس حالت فعلی و نماد ورودی جاری تعیین می‌کند (state transition function)

$q_0 \in Q$ حالت آغازین (initial state)

$F \subseteq Q$ مجموعه‌ی حالات نهایی (final states)

تابع گذر حالت تعمیم‌یافته برای اتوماتون متناهی قطعی

$$\delta^* : Q \times \Sigma^* \rightarrow Q$$

$$\delta^*(q, \epsilon) = q$$

$$\delta^*(q, xa) = \delta(\delta^*(q, x), a), \quad x \in \Sigma^*, a \in \Sigma$$

رشته‌های پذیرفته شده توسط یک DFA داده شده

DFA رشته‌ی ورودی x را می‌پذیرد، اگر با شروع از حالت آغازین پس از مصرف x در یکی از حالت‌های نهایی توقف کند.

$$\delta^*(q_0, x) = q_f, \quad q_f \in F$$

گراف گذر حالت برای بازنمایی آتوماتون متناهی


گراف گذر حالت:

• گره‌ها: حالت‌های آتوماتون

– حالت آغازین: با یک پیکان ورودی به آن


– حالت‌های نهایی: با دو دایره

• یال‌ها: تابع گذر میان حالت‌ها



مثال


نمونه‌ای از گراف گذر حالت برای بازنمایی آتوماتون متناهی: یک DFA برای پذیرش رشته‌های زبان $L((a \mid b)^*abb)$



جدول گذر حالت برای بازنمایی اتوماتون متناهی

تابع گذر حالت را با جدول نیز می‌توان نمایش داد.

مثال



q	$\delta(q, a)$	$\delta(q, b)$
0	1	0
1	1	2
2	1	3
3	1	0

۲-۶-۲ اتوماتون متناهی غیر قطعی (NFA)

اتوماتون متناهی حالت غیر قطعی (NFA) Non-deterministic Finite Automata, یک پنج‌تایی مرتب به صورت

$$M = (Q, \Sigma, \delta, q_0, F)$$

است که در آن

Q مجموعه‌ی حالات: مجموعه‌ی متناهی و ناتهی از حالت‌های داخلی (internal states)

Σ مجموعه‌ی الفبای ورودی (alphabet)

δ تابع گذر حالت به صورت $\delta : Q \times (\Sigma \cup \{\epsilon\}) \rightarrow 2^Q$ که حالت بعدی اتوماتون را براساس حالت فعلی و نماد ورودی جاری تعیین می‌کند (state transition function)

$q_0 \in Q$ حالت اولیه (initial state)

$F \subseteq Q$ مجموعه‌ی حالات نهایی (final states)

تابع گذر حالت تعمیم‌یافته برای اتوماتون متناهی غیر قطعی

$$\delta^* : Q \times \Sigma^* \rightarrow 2^Q$$

$$\delta^*(q, \epsilon) = \{q\}$$

$$\delta^*(q, xa) = \bigcup_{q_i \in \delta^*(q, x)} \delta(q_i, a), \quad x \in \Sigma^*, a \in \Sigma$$

با داشتن یک رشته و یک NFA، در حالت کلی بیش از یک مسیر می‌تواند برای پیمودن وجود داشته باشد.


رشته‌های پذیرفته شده توسط یک NFA داده شده

NFA رشته‌ی ورودی x را می‌پذیرد، اگر با شروع از حالت آغازین حداقل یک مسیر منتهی به یک حالت نهایی وجود داشته باشد:

$$\exists q_f, q_f \in \delta^*(q_0, x), \quad q_f \in F$$

مثال

یک NFA برای پذیرش رشته‌های زبان $L((a | b)^*abb)$



مثال: پذیرش رشته‌ی $aaabb$


مقایسه‌ی آتوماتون‌های قطعی و غیرقطعی


- هم DFA و هم NFA قابلیت پذیرش همه‌ی عبارت‌های منظم را دارند.
- معمولاً اجرای DFA روی یک رشته سریع‌تر از اجرای NFA روی همان رشته است. (عدم وجود Backtracking در پیاده‌سازی DFA روی ماشین‌های ترتیبی)
- تعداد حالت‌های DFA معمولاً به طور نمایی بیشتر از NFA است.

۳-۶-۲ ساخت NFA متناظر با یک عبارت منظم

Thompson's Construction برای ساخت NFAی پذیرنده‌ی یک عبارت منظم:
NFAی حاصل:

- دقیقاً یک حالت نهایی دارد.
 - هیچ یالی به حالت آغازین آن وارد نمی‌شود.
 - هیچ یالی از حالت نهایی خارج نمی‌شود.
- اگر r یک عبارت منظم باشد، $N(r)$ پذیرنده‌ی متناهی غیرقطعی متناظر با آن خواهد بود.






مثال

نمونه‌ی ساخت NFA متناظر با یک عبارت منظم:

$$(0 \mid 10^*1)^*10^*$$




۴-۶-۲ ساخت یک DFA متناظر با یک NFA داده شده

Subset Construction

- حالت‌های DFA را به عنوان زیرمجموعه‌های حالت‌های NFA در نظر می‌گیریم.
- حالت شروع، حالت $\delta^*(q_0, \epsilon)$ خواهد بود.
- حالت‌های نهایی DFA حالت‌هایی هستند که در آنها حداقل یکی از حالت‌های نهایی NFA وجود داشته باشد.
- تابع‌گذر حالت DFA برای هر حالت و هر نماد الفبا، اجتماع مقادیر تابع‌گذر NFA برای حالت‌های موجود در آن حالت DFA با آن نماد الفباست.


مثال


نمونه‌ی ساخت یک DFA متناظر با یک NFA



مثال

نمونه‌ای دیگر از ساخت یک DFA متناظر با یک NFA






۵-۶-۲ می نیمم سازی تعداد حالات یک DFA داده شده

- برای هر DFA یک DFA می معادل با حداقل تعداد حالات وجود دارد.

مثال



۷-۲ پیاده سازی تحلیل گر لغوی

- تحلیل گر لغوی باید قادر به انجام دو چیز باشد:

- (۱) بازشناسی زیررشته های متناظر با لغت ها
- (۲) برگرداندن زوج $\langle Token, Attribute \rangle$ برای هر لغت

- در مقایسه ی این روال با آتوماتا

- (۱) آتوماتا یک رشته را می پذیرد یا رد می کند، اما آن را بخش بندی نمی کند؛


۲) $\Leftarrow$ بنابراین باید کاری بیشتر از پیاده‌سازی یک اتوماتون ساده انجام شود.

• دو پیامد مهم:

- ۱) هدف بخش‌بندی برنامه‌ی منبع است:
این کار با خواندن کد از چپ به راست و بازشناسی یک توکن در هر مرحله انجام می‌شود.
- ۲) برخورد با ابهام‌ها: برای مثال، pos یا position به عنوان شناسه؟

۱-۷-۲ خواندن ورودی

- تحلیل لغوی، تنها مرحله از کامپایل است که باید ورودی را بخواند.
- خواندن ورودی می‌تواند زمان‌گیر باشد. برای بهبود کارایی، ضروری است که تکنیک‌های بافر بندی مناسب مورد استفاده قرار گیرد.
- از دو اشاره‌گر به بافر ورودی استفاده می‌کنیم:
 - ۱) در ابتدا هر دو اشاره‌گر به نخستین کاراکتر لغتی که باید پیدا شود، اشاره می‌کنند.
 - ۲) اشاره‌گر forward به جلو حرکت می‌کند تا اینکه لغت بازشناسی شود.
 - ۳) اگر این لغت به طور موفق پردازش شد، هر دو اشاره‌گر به کاراکتر بلافاصله بعد از آن لغت اشاره خواهند کرد.



۲-۷-۲ از عبارتهای منظم تا تحلیل‌گر لغوی

- ۱) برای الگوی هر توکن، عبارت منظم متناظر با آن را می‌نویسیم.
- ۲) برای هر عبارت منظم، اتوماتون متناظر با آن را می‌سازیم.
- ۳) ورودی را می‌خوانیم و با آزمودن اتوماتون‌های مختلف، لغت‌ها را با توکن‌ها متناظر می‌سازیم:
 - اگر با دنبال کردن یک اتوماتون شکست خوردیم، اشاره‌گر forward را به عقب برمی‌گردانیم (با استفاده از اشاره‌گر دوم) و اتوماتون بعدی را آزمایش می‌کنیم؛
 - اگر همه‌ی اتوماتون‌ها شکست خوردند، در این صورت یک **خطای لغوی** آشکار می‌شود؛
 - در هنگام بازشناسی یک لغت، یک کنش (action) می‌تواند اجرا شود (مانند درج کردن رکورد یک شناسه در جدول نمادها و ...).

برخورد با ابهام‌ها

در تحلیل لغوی، دو دسته ابهام ممکن است:

- ۱) یک لغت واحد توسط دو یا چند عبارت منظم مختلف بازشناسی شود.
- ۲) یک عبارت منظم واحد بتواند بخشی از یک لغت را نیز بازشناسی کند.

برخورد با ابهام‌ها (۱) دو عبارت منظم زیر را در نظر بگیرید:

$$R_1 \rightarrow abb$$

$$id \rightarrow letter(letter \mid digit)^*$$

لغت abb هم با R_1 و هم با id تطابق می‌یابد.

قاعده:

اگر یک لغت توسط چند عبارت منظم بازشناسی می‌شود، عبارت منظمی که در لیست جلوتر قرار گرفته است، در نظر گرفته می‌شود.

برخورد با ابهام‌ها (۲) عبارت منظم مربوط به شناسه‌ها و رشته‌ی $position$ را در نظر بگیرید:

$$id \rightarrow letter(letter \mid digit)^*$$

لغت‌های زیر، همگی با id تطابق می‌یابند:

p •

po •

$\dots$ •

$position$ •

قاعده: (استراتژی حداکثر طول)


لغت مربوط به یک توکن آن است که بیشترین طول ممکن را دارد.

برای پیاده‌سازی استراتژی حداکثر طول، دو راه وجود دارد:

(۱) پیاده‌سازی اول: استفاده از اتوماتا با Lookahead (نماد پیش‌بینی)

مثال

آتوماتون شناسه‌ها




- منظور از برچسب other هر کاراکتری است که یال‌های ترک‌کننده‌ی آن گره با آن علامت‌گذاری نشده باشد.
- منظور از * این است که یک کاراکتر اضافی خوانده شده است و باید اشاره‌گر forward را یک واحد به عقب برگردانیم.

(۲) پیاده‌سازی دوم: تغییر پاسخ اتوماتون به عدم پذیرش

- با رسیدن به حالت پذیرش، توقف نمی‌کنیم؛
- وقتی به شکست برخوردیم، به آخرین حالت پذیرش برمی‌گردیم.

مثال


اتوماتون اعداد (61.23Express)



نکته


ترتیب اتوماتون‌ها اهمیت دارد (به خاطر بیاورید که اتوماتون‌ها یکی پس از دیگری در یک دنباله آزمایش می‌شوند): اولین اتوماتون‌ها را آنهایی قرار دهید که پر رخدادترین توکن‌ها هستند (مانند فواصل خالی).

۳-۷-۲ فرآیند ساخت بازشناس توکن‌ها




مثال


NFA برای بازشناسی چهار توکن if، <، <= و id



تکمیل NFA



تبدیل NFA به DFA و می نیم سازی DFA



۸-۲ مسایل خاص برای تحلیل‌گر لغوی

تحلیل‌گر لغوی برای تشخیص یک توکن، گاهی مجبور می‌شود که چند کاراکتر اضافی را نیز از ورودی بخواند. کاراکترهای اضافی خوانده شده پس از تشخیص توکن باید به بافر ورودی برگردانده شوند. در قسمت‌های زیر به مواردی چند از این موضوع اشاره می‌کنیم.

۱-۸-۲ کلمات کلیدی

در برخی زبان‌های برنامه‌سازی، کلمات کلیدی رزرو شده نیستند (مانند PL/1).

مثال

جملات زیر در زبان PL/1 معتبر هستند. در اینجا کلمات کلیدی مربوط به ساختار شرطی برای متغیرها نیز استفاده شده‌اند!

```
if then then then = else;
else else = then;
```

۲-۸-۲ فاصله‌های خالی بااهمیت

در برخی زبان‌های برنامه‌سازی، فواصل خالی نادیده گرفته می‌شوند (مانند FORTRAN و Algol68).

مثال

در دو جمله‌ی زیر از زبان FORTRAN تا زمانی که به کاراکتر کاما نرسیم مشخص نیست که این دستور یک حلقه را مشخص می‌کند که برای متغیر i از 1 تا 25 اجرا می‌شود یا انتساب مقدار 1.25 به متغیر do10i می‌باشد!

```
do 10 i = 1,25
do 10 i = 1.25
```

۳-۸-۲ ثوابت رشته‌ای

کاراکترهای خاص در ثابت‌های رشته‌ای باید به گونه‌ای دیگر تفسیر شوند، مانند:

- کاراکتر خط جدید
- tab
- علامت نقل قول ‘ ’
- جداکننده‌های توضیحات (comment delimiter)

۴-۸-۲ بستار متناهی

در برخی زبان‌های برنامه‌سازی، طول شناسه‌ها محدودیت دارد؛ بنابراین، علاوه بر الگوی توکن که با آتوماتون متناهی بازشناسی می‌شود، باید از مکانیزم مکملی برای تشخیص طول لغت نیز استفاده کرد. (مانند FORTRAN 66: حداکثر ۶ کاراکتر برای هر شناسه)

۹-۲ خطاهای لغوی

خطای لغوی، خطایی است که در سطح تحلیل لغوی شناسایی می‌شود.

- هرگاه یک لغت با الگوی هیچ توکنی مطابقت نکند، خطای لغوی رخ داده است.
- تعداد کمی از خطاها را می‌توان در سطح لغوی تشخیص داد (به دلیل دید محلی).

۱-۹-۲ عبور از خطاهای لغوی: استراتژی حالت وحشت (Panic Mode)

Panic Mode یک استراتژی ساده برای عبور از خطای لغوی:

از ورودی باقیمانده کاراکترها را به ترتیب حذف می‌کنیم تا زمانی که تحلیل‌گر قادر به یافتن یک توکن جدید شود.

۲-۹-۲ عبور از خطاهای لغوی: استراتژی‌های تک کاراکتری

در این استراتژی‌ها، سعی می‌کنیم با درج، حذف یا تغییر یک کاراکتر، از خطا عبور کنیم.

حذف یک کاراکتر بیگانه	تبدیل \$= به =:
درج یک کاراکتر جا افتاده	تبدیل : به =:
جایگزینی یک کاراکتر ناصحیح با کاراکتر صحیح	تبدیل :: به =:
تغییر مکان دو کاراکتر همسایه	تبدیل == به =: یا تبدیل fi به if

۳-۹-۲ عبور از خطاهای لغوی: استراتژی کم‌ترین فاصله

یک راه برای عبور از خطا در برنامه، محاسبه‌ی حداقل تعداد تغییر شکل رفع خطا برای تبدیل برنامه‌ی خطا به یک برنامه‌ی صحیح است.

رفع خطا با استراتژی کم‌ترین فاصله، به عنوان یک قاعده به منظور داشتن معیاری نظری است و اغلب پیاده‌سازی نمی‌شود؛ زیرا هزینه‌ی پیاده‌سازی آن بالاست.

تمرین

۱. زبانی که توسط هر یک از عبارت‌های منظم زیر توصیف می‌شود را مشخص کنید.

$$(a|b)^*a$$

$$(a|b)^*(a|b)^*$$

پ) $(0|1)^*(0|1)(0|1)$

ت) $0^*10^*10^*10^*$

۲. برای هر یک از مجموعه رشته‌های زیر یک تعریف منظم بنویسید.

آ) تمامی رشته‌های متشکل از حروف زبان انگلیسی که حروف آنها به ترتیب الفبایی قرار گرفته باشند.

ب) تمامی رشته‌های اعداد که دارای رقم تکراری نیستند.

پ) تمامی رشته‌های متشکل از ۰ و ۱ که حاوی زیررشته‌ی ۱۱۰ نیستند.

ت) تمامی رشته‌های متشکل از ۰ و ۱ که شامل تعداد زوجی ۰ و تعداد فردی ۱ باشد.

۳. برای مجموعه رشته‌های شامل یک b و حداقل سه a روی الفبای $\Sigma = \{a, b\}$

آ) یک عبارت منظم بنویسید.

ب) از روی عبارت منظم، NFA پذیرنده‌ی آن را رسم کنید.

پ) یک DFA با حداقل تعداد حالت‌ها معادل با NFA قسمت قبل ایجاد کنید.

۴. یک DFA برای بازشناسی توکن‌های زیر طراحی کنید:

$=, -, *, +, =, ==, >, <, <=$

۵. یک اتوماتون متناهی برای پذیرش آدرس‌های ایمیل یا آدرس‌های وب طراحی کنید. دقت کنید که دامنه‌ها می‌توانند مرتبه‌ی دوم (مثل .ac.ir) و یا مرتبه بالاتر (مثل .ut.ac.ir) باشد. (راهنمایی: از استراتژی حداکثر طول استفاده کنید).

۶. توضیح دهید که چرا برای زبان‌های زیر، نمی‌توان یک عبارت منظم برای توصیف الگوی رشته‌ها پیدا کرد:

آ) رشته‌های متشکل از a و b که تعداد a های آن بیشتر از تعداد b ها باشد.

ب) رشته‌های متشکل از a و b که متقارن هستند.

۷. برای زبان‌های زیر عبارت منظم بنویسید:

آ) تمامی اعداد دودویی که مضرب ۵ هستند.

ب) تمامی اعداد دودویی که بزرگ‌تر از ۱۰۱۰۰ هستند.

۸. رشته زیر را در نظر بگیرید:

$AcaacbBbAabaAAabbaAacBbABBBBc$

که تحلیل‌گر لغوی به ازای آن لغت‌های زیر را شناسایی کرده است:

$Ac \quad aacbBb \quad Aaba.A \quad Aabba.A \quad acBb \quad ABBBBc$

عبارت‌های منظمی را برای تحلیل‌گر لغوی بنویسید که قادر به شناسایی دنباله‌ی لغت‌های بالا برای رشته ورودی ذکر شده باشد. عبارت‌های منظم نوشته شده فقط باید شامل عملگرهای بستار و الحاق باشند.

۹. خطاهای لغوی موجود در تکه کد زیر که به زبان C نوشته شده است را مشخص کنید و چگونگی برخورد با هر یک از آنها را بیان کنید:

```
1 @include <iostream>
2
3 int main(int argc, char* argv[]){
4     int a;
5     if(argc == 1)
6         a = 12.01;
7     else argv[1] = 'salam';
8
9     int 12num = 3;
10    return 1;
11    /*What?
12 }
```