

بِسْمِ اللَّهِ الرَّحْمَنِ الرَّحِيمِ



اصول طراحی کامپایلر

درس ۴

تحلیل لغوی (۳)

Lexical Analysis (3)

کاظم فولادی قلعه
دانشکده مهندسی، پردیس فارابی
دانشگاه تهران

<http://courses.fouladi.ir/compiler>

تحلیل لغوی (۳)

۱

پیاده‌سازی
تحلیل‌گر
لغوی

پیاپی سازی تحلیل گر لغوی

وظیفه ی تحلیل گر لغوی

خواندن ورودی از چپ به راست

۱
بازشناسی
زیررشته ی
متناظر با لغت

نیاز به اضافه کردن
امکان بخش بندی به
آتوماتون متناهی


۲
برگرداندن زوج
<Token, Attributes>
برای لغت

نیاز به اضافه کردن
امکان اجرای یک کنش
در آتوماتون متناهی



خواندن ورودی

تکنیک بافر بندی

در ابتدا هر دو اشاره گر به نخستین کاراکتر لغت مورد بررسی اشاره می کنند.




این اشاره گر به جلو حرکت می کند تا اینکه لغت بازشناسی شود.




وقتی یک لغت به طور موفق پردازش شد، هر دو اشاره گر به کاراکتر بلافاصله بعد از آن لغت اشاره می کنند.

- تحلیل لغوی تنها مرحله از کامپایلر است که باید ورودی را بخواند.
- خواندن ورودی می تواند زمان گیر باشد.
- تکنیک بافر بندی برای بهبود کارایی لازم است.

از عبارت منظم تا تحلیل‌گر لغوی



ساختار بازشناسی کننده ی توکن ها بر اساس اتوماتون متناهی



- اگر با دنبال کردن یک اتوماتون شکست خوردیم، اشاره گر **forward** را به عقب برمی گردانیم و اتوماتون بعدی را آزمایش می کنیم.
- اگر همه ی اتوماتون ها شکست خوردند، یک **خطای لغوی** آشکار می شود.
- در هنگام بازشناسی یک لغت، یک کنش (action) می تواند اجرا شود. مثلاً درج رکورد شناسه در جدول نمادها و ...

انواع ابهام در تحلیل لغوی

تطابق
بخشی از یک لغت با
یک عبارت منظم

تطابق
یک لغت با
چند عبارت منظم

برخورد با ابهام «تطابق یک لغت با چند عبارت منظم»

$$R_1 \rightarrow abb$$

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

مثال: لغت abb هم با عبارت منظم R_1 و هم با عبارت منظم id تطابق می‌یابد.

قاعده

اگر یک لغت با چند عبارت منظم تطابق یافت،
اولویت با عبارت منظمی است که در لیست زودتر دیده می‌شود.

* پیاده‌سازی با ترتیب آتوماتون‌ها

برخورد با ابهام «تطابق بخشی از یک لغت با یک عبارت منظم»

رشته‌ی `position`

و عبارت منظم

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

لغت‌های زیر همگی با `id` تطابق می‌یابند:

`p`

`po`

`pos`

...

`position`

استراتژی حداکثر طول

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


قاعده

* پیاده‌سازی با دو روش: (۱) استفاده از `lookahead` و (۲) تغییر پاسخ اتوماتون به عدم پذیرش

برخورد با ابهام «تطابق بخشی از یک لغت با یک عبارت منظم»

استراتژی حداکثر طول: پیاده‌سازی اول: استفاده از آتوماتون با lookahead

استفاده از آتوماتون با lookahead




برخورد با ابهام «تطابق بخشی از یک لغت با یک عبارت منظم»

استراتژی حداکثر طول: پیاده‌سازی دوم: تغییر پاسخ اتوماتون به عدم پذیرش

تغییر پاسخ اتوماتون به عدم پذیرش

با رسیدن به حالت پذیرش، توقف نمی‌کنیم و همچنان ادامه می‌دهیم.
هر گاه به شکست برخوردیم، به آخرین حالت پذیرش برمی‌گردیم.

مثال: اتوماتون اعداد (61.23Express)




یک ملاحظه برای بهبود کارایی

در پیاده‌سازی، ترتیب آتوماتون‌ها اهمیت دارد
(آتوماتون‌ها یکی پس از دیگری در یک دنباله آزمایش می‌شوند):


اول آتوماتون‌هایی را قرار می‌دهیم که
متناظر با **پر رخدادترین** توکن‌ها هستند
(مثل فواصل خالی)

فرآیند ساخت بازشناسی‌کننده‌ی هر توکن




مثال: ساخت بازشناسی کننده برای چهار توکن

NFA




مثال: ساخت بازشناسی کننده برای چهار توکن

تکمیل NFA



مثال: ساخت بازشناسی کننده برای چهار توکن

تبدیل NFA به DFA و می نیم سازی DFA



مسائل خاص برای تحلیل‌گر لغوی

لزوم خواندن کاراکترهای اضافی از ورودی

تحلیل‌گر لغوی برای بازشناسی یک توکن

گاهی مجبور می‌شود که چند کاراکتر اضافی را نیز از ورودی بخواند.

کاراکترهای اضافی خوانده شده، باید پس از بازشناسی توکن به بافر ورودی برگردانده شوند.

مثال:

رزرو شده نبودن کلیدواژه‌ها در برخی زبان‌ها

بی‌اهمیت بودن فاصله‌های خالی در برخی زبان‌ها

پردازش ثابت‌های رشته‌ای

محدودیت در طول شناسه‌ها (بستار متناهی)

مسائل خاص برای تحلیل‌گر لغوی

لزوم خواندن کاراکترهای اضافی از ورودی: (۱) رزرو شده نبودن کلیدواژه‌ها در برخی زبان‌ها

رزرو شده نبودن کلیدواژه‌ها در برخی زبان‌ها

مانند زبان PL/1

مثال:

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

مسائل خاص برای تحلیل‌گر لغوی

لزوم خواندن کاراکترهای اضافی از ورودی: (۲) بی‌اهمیت بودن فاصله‌های خالی در برخی زبان‌ها

بی‌اهمیت بودن فاصله‌های خالی در برخی زبان‌ها

مانند زبان FORTRAN و Algol68

فاصله‌های خالی نادیده گرفته می‌شوند.

مثال:

do 10 i = 1,25 حلقه با شمارنده‌ی i ←

do 10 i = 1.25 انتساب به متغیر $do10i$ ←

مسائل خاص برای تحلیل‌گر لغوی

لزوم خواندن کاراکترهای اضافی از ورودی: (۳) پردازش ثابت‌های رشته‌ای

پردازش ثابت‌های رشته‌ای

کاراکترهای خاص در ثابت‌های رشته‌ای باید به گونه‌ی دیگری تفسیر شوند.

مثال:

کاراکتر خط جدید \n

کاراکتر تب \t

نمادهای نقل قول " "

جداکننده‌ی توضیحات /* */ (comment delimiter)

مسائل خاص برای تحلیل‌گر لغوی

لزوم خواندن کاراکترهای اضافی از ورودی: (۴) محدودیت در طول شناسه‌ها (بستار متناهی)

محدودیت در طول شناسه‌ها (بستار متناهی)

در برخی زبان‌ها، طول شناسه‌ها محدودیت دارد:
مثلاً FORTRAN 66 (حداکثر ۶ کاراکتر برای هر شناسه)

خطای لغوی

محل رخداد خطا	نام خطا	مثال
تحلیل لغوی	خطای لغوی (lexical error)	شروع کردن یک شناسه با عدد
تحلیل نحوی	خطای نحوی (syntax error)	عدم تطابق پرانترها در یک عبارت ریاضی
تحلیل معنایی	خطای معنایی (semantic error)	انتساب یک مقدار اعشاری به متغیر صحیح
تولید کد میانی		کمبود حافظه بر روی دیسک
بهینه‌سازی کد میانی		کمبود حافظه بر روی دیسک
تولید کد نهایی		کمبود حافظه بر روی دیسک

خطای لغوی: خطایی که در سطح تحلیل لغوی شناسایی می‌شود.

- * هرگاه یک لغت با الگوی هیچ توکنی تطبیق پیدا نکند، خطای لغوی رخ داده است.
- * تعداد کمی از خطاها در سطح تحلیل لغوی قابل تشخیص است (به دلیل دید محلی).


استراتژی‌های عبور از خطاهای لغوی

از ورودی مابقی کاراکترها را یکی یکی حذف می‌کنیم تا زمانی که تحلیل‌گر قادر به یافتن یک توکن جدید شود.	استراتژی حالت وحشت (Panic Mode)
- حذف یک کاراکتر بیگانه - درج یک کاراکتر جا افتاده - جایگزینی یک کاراکتر غلط با کاراکتر صحیح - تغییر مکان دو کاراکتر همسایه تبدیل $=$ به $=\$ تبدیل $:$ به $::$ تبدیل fi به if	استراتژی‌های تک‌کاراکتری
محاسبه‌ی حداقل تعداد تغییر برای تبدیل برنامه‌ی خطا به یک برنامه‌ی صحیح * صرفاً برای داشتن یک معیار نظری است و به دلیل هزینه‌ی بالا پیاده‌سازی نمی‌شود.	استراتژی کم‌ترین فاصله

تحلیل لغوی (۳)

۲

منابع



A. V. Aho, M. S. Lam, R. Sethi, J. D. Ullman,
Compilers: Principles, Techniques and Tools,
Second Edition, Addison-Wesley, 2007.

Chapter 3