

اصول طراحی کامپیوتر

گروه کامپیوتر دانشگاه آزاد اسلامی واحد زنجان

مدرس: مهدی بازرگانی
آخرین بروز رسانی: پاییز ۱۳۹۲

Zau-93-94-2

فصل سوم

تحلیل گری لغوی

Zau-93-94-2

تحلیل گری لغوی (مثال)

به مثال زیر توجه کنید:

Program sample;
Var i=integer;
Begin
i:=i+2;
Write ln(i);
End.

[	r	o	g	r	a	M		[	s	a	m	p	l	E	;
/	p					]									
/	v	a	r		i	:	i	n	t	e	g	e	r	;	
/	n														
		B	e	g	i	n		i	:	=	i	+	2	;	/
														n	
w	r	i	t	e	l	n	(	i	)	;	/	e	n	d	.
										n					
/	z														

Zau-93-94-2

تحلیل گری لغوی (مثال)

در شکل بالا مشاهده میشود ویرایشگر در مکانهایی که برنامه نویس کلید Enter زده است، کاراکتر کنترل `/n` و برای نشان دادن آخر فایل کاراکتر کنترل `/z` را درج کرده است.

تحلیل گری لغوی برنامه مبدأ را بصورت جریانی از کاراکترها میخواند و لغات را استخراج میکند از آنجایی که `L.A` متن ورودی را پویش یا `scan` میکند بر `L.A` پویشگر یا `scanner` نیز گفته میشود.

Zau-93-94-2

تعاریف

❖ (نشانه) Token:

دنباله ای از کاراکترها در ورودی که با یک ارتباط منطقی با هم دارند، توکن یا نشانه را تولید می کنند.

❖ (لغت) Lexeme:

دنباله ای از کاراکترها در ورودی که با یک الگو برای یک توکن منطبق شده است. آنچه در برنامه ما ظاهر می شود. Lexeme ها معمولاً مطابق با الگویی هستند که برای یک نشانه در نظر گرفته می شوند.

❖ (الگو) Pattern:

به شکل کلی که یک توکن می تواند داشته باشد الگوی آن توکن می گویند. به عبارت دیگر رشته ها و عبارتهای مختلفی در ورودی وجود دارد که برای همه آنها توکن یکسانی تشخیص داده می شود، به شکل کلی این رشته ها الگوی آن توکن می گوئیم.

Zau-93-94-2

یک نمونه برنامه جهت بیان تفاوتها

token	Lexme	Pattern
Const	Const	Const
If	If	If
Relation	<, >, ≤, ...	< or > or ...
Id	Pi	با حروف الفبا شروع و به دنبال آن حرف یا رقم می آید
Num	3.1416	هر ثابت عددی
literal	" Test"	هر رشته نویسه ای که بین دو علامت "" قرار گیرد

Zau-93-94-2

خطاهای واژه ای (Lexical Error)

❖ خطاهای بسیار کمی را در فاز تحلیل لغوی می توان تشخیص داد.

❖ تحلیل گر لغوی دید وسیعی نسبت به ورودی ندارد و معمولاً چند کاراکتر جلو و عقب کاراکتر جاری را می تواند ببیند.

❖ در صورتی که پس از تشخیص یک واژه توسط تحلیل گر لغوی این واژه توسط هیچ یک از الگوهای موجود در زبان قابل تولید نباشد یک خطای لغوی رخ داده است.

✓ Var Temp: integer;
✓ Temp#:= 10;
✓ T=123.423.34;

❖ مواردی هم پیش خواهد آمد که تحلیل گر لغوی هیچ کاری نمی تواند انجام دهد. در اینگونه موارد خطاپرداز فراخوانی می شود تا به نحو مقتضی خطا را مدیریت نماید.

Zau-93-94-2

تکنیکهایی برای بالابردن کارایی اسکنر

۱- تکنیک استفاده از بافر ورودی (Input Buffering)

— استفاده از یک بافر به طول $2N$ کاراکتر

۲- تکنیک استفاده از نگهبانها (Sentinels)

— حالت توسعه یافته بافر ورودی برای اصلاح مشکلات آن

Zau-93-94-2

الگوریتم بافر ورودی (input Buffering)

❖ این شیوه برای تشخیص توکن هایی استفاده می شود که عمل تشخیص آنها نیاز به پیش نگری در رشته ورودی دارد.

❖ مانند: $\text{if } A \leq B$

Zau-93-94-2

الگوریتم بافر ورودی (input Buffering)

- در این روش بافری به طول N دوبخش کاراکتری در نظر گرفته می شود، بطوریکه N برابر تعداد کاراکترهایی است که بر روی هر بلاک حافظه قابلیت ذخیره سازی دارد.
- تفاوتی که در این وجود دارد با هربار عمل خواندن به جای یک کاراکتر، N کاراکتر از حافظه با یک دستور خوانده می شود و در بخش جای خالی بافر قرار می گیرد.

Zau-93-94-2

الگوریتم بافر ورودی (input Buffering)

- چنانچه تعداد کاراکترهای خوانده شده کمتر از N باشد، یک کاراکتر خاص (eof) به معنای انتهای ورودی قرار می گیرد.
- در این روش اذو اشاره گر استفاده می شود. (Lexeme Beginning و Forward)، رشته ای از کاراکترها که بین دو اشاره گر قرار می گیرد، لغت جاری خواهد بود.
- در ابتدا هردو اشاره گر به اولین کاراکتر از لغت بعدی اشاره می کنند، سپس اشاره گر پیشرو (forward) در صورتیکه به کاراکتر مورد نظر برسد، یک مکان به جلو حرکت می نماید تا اینکه بتواند طبق الگوریتم رشته ای از ورودی را جدا نماید.
- همینکه لغت بعدی تعیین شد forward به سمت راست ترین کاراکتر آن لغت اشاره می کند. پس از اینکه لغت پردازش گردید، هردو اشاره گر به سمت راست ترین کاراکتر آن لغت اشاره خواهند کرد.

Zau-93-94-2

Input buffering

- Sometimes lexical analyzer needs to look ahead some symbols to decide about the token to return
 - In C language: we need to look after -, = or < to decide what token to return
 - In Fortran: DO 5 I = 1.25
- We need to introduce a two buffer scheme to handle large look-aheads safely

E	=	M	*	C	**	2	eof
---	---	---	---	---	----	---	-----

Zau-93-94-2

الگوریتم بافر ورودی (input Buffering)

```

if forward at the end of first half then
  Begin
    Reload second half
    forward:=forward+1
  End;
Else if forward at the end of second half then
  Begin
    Reload first half
    move forward to Beginning of first half
  End;
Else forward:= forward+1;

```

Zau-93-94-2

الگوریتم بافر ورودی (input Buffering)

❖ نکته) این روش در اغلب موارد خوب عمل می کند، اما میزان پیش نگری در آن محدود به اندازه بافر هاست، با این محدودیت ممکن است که تشخیص توکن ها میسر نباشد، زیرا فاصله ای که forward باید بپیماید بیشتر از طول بافر است. نهایت پیشروی forward به اندازه $2N$ کاراکتر خواهد بود.

Zau-93-94-2

الگوریتم بهبود یافته بافر ورودی (استفاده از نگهبانها)

❖ برای هر بار جلو رفتن اشاره گر forward دو عمل مقایسه انجام میشود باندکی اصلاحات در دو قسمت بافر و الگوریتم اجرای عمل میتوان تعداد این مقایسه ها را کاهش داد.

❖ برای کاهش عمل مقایسه کافیت از یک کاراکتر نگهبان (sentinel) همانند eof که کاراکتر ویژه ایست و امکان حضور در رشته ورودی را ندارد، استفاده نماییم. در اینجا در انتهای هر یک از بخش های بافر یک کاراکتر eof قرار می دهیم.

Zau-93-94-2

Sentinels (C Code)

```

Switch (*forward++) {
  case eof:
    if (forward is at end of first buffer) {
      reload second buffer;
      forward = beginning of second buffer;
    }
    else if (forward is at end of second buffer) {
      reload first buffer;
      forward = beginning of first buffer;
    }
    else /* eof within a buffer marks the end of input */
      terminate lexical analysis;
    break;
  cases for the other characters;
}

```

E = M eof * C * * 2 eof eof

Zau-93-94-2

Sentinels(Pascal Code)

```

forward:= forward+1;
If forward↑=eof then
Begin
  if forward at the endof first half then
  Begin
    Reload second half
    forward:= forward+1;
  End;
Else if forward at the endof second half then
  Begin
    Reload first half
    forward:= forward+1;
  End;
Else
  Terminate lexical Analyzer;
End;

```

Zau-93-94-2

نکات الگوریتم استفاده از نگهبانها

❖ در این حالت در بیشتر موارد برای کنترل اینکه آیا اشاره گر پیشرو به eof رسیده یا خیر، به یک آزمون نیاز است، فقط هنگامیکه به انتهای نیمه بافریابه انتهای فایل ورودی می رسد، آزمون های بیشتری صورت می گیرد. چون N کاراکتر ورودی بین eof ها قرار دارند، متوسط تعداد شرطها (آزمون ها) برای هر کاراکتر ورودی بسیار نزدیک به یک می باشد.

❖ نکته) اگر N را خیلی کوچک بگیریم، عمل خواندن بیشتر می شود، تا بافر پر شود و اگر N را بزرگتر از حد مجاز بگیریم، نیمه اول بافر با یکبار Reload پر نمی شود. آنوقت الگوریتم اول کارایی ندارد. باید N با اندازه بلاک مطابق باشد.

❖ نکته) برای تشخیص الگوی تکن ها در بسیاری از زبانها از عبارات منظم استفاده می شود. در این میان برخی از الگوها توسط گرامرها و عبارات مستقل از متن قابل توصیف هستند.

Zau-93-94-2


تشخیص توکن ها در تحلیلگر لغوی

- ❖ ابزار اصلی تشخیص توکنها، نمودارهای گذار (Transition Diagram) می باشند.
- ❖ برنامه نویسی در تحلیلگر لغوی در ابتدا براساس توکن های موجود نمودارهای گذار؛ برای تشخیص توکنها رسم می شود.
- ❖ در اصل نمودار گذار عملی را نشان می دهد که توسط تحلیلگر لغوی برای انجام توکن بعدی انجام می شود.
- ❖ نمودار گذار مانند یک ماشین متناهی (FSA) می باشد. مکان ها در این نمودار به صورت دایره ترسیم می شوند و حالت نامیده می شود.
- ❖ حالتها توسط خطوط جهتداری به هم وصل می شوند که پال گفته می شوند.

Zau-93-94-2

دیاگرام حالت


➤ Transition diagram for relop



Zau-93-94-2

دیاگرام حالت ۲-


➤ Transition diagram for reserved words and identifiers



Zau-93-94-2

دیاگرام حالت ۳-

➤ Transition diagram for unsigned numbers



Zau-93-94-2

دیاگرام حالت ۴ -

• Transition diagram for whitespace




Zau-93-94-2

معماری تحلیلگر لغوی برپایه دیاگرام حالت

```
TOKEN getRelop()
{
    TOKEN retToken = new (RELOP)
    while (1) { /* repeat character processing until a
                return or failure occurs */
        switch(state) {
            case 0: c= nextchar();
                    if (c == '<') state = 1;
                    else if (c == '=') state = 5;
                    else if (c == '>') state = 6;
                    else fail(); /* lexeme is not a relop */
                    break;
            case 1: ...
            ...
            case 8: retract();
                    retToken.attribute = GT;
                    return(retToken);
        }
    }
```


Zau-93-94-2

یک نمودار انتقال



Zau-93-94-2

نمودار انتقال



Zau-93-94-2

قسمتی از کد اسکنر

```
class Scanner {
    InputStream _in;
    char _la; // The lookahead character
    char[] _window; // lexeme window
    Token nextToken() {
        startLexeme(); // reset window at start
        while(true){
            switch(_state){
                case 0: {
                    _la = getChar();
                    if (_la == '<') _state = 1;
                    else if (_la == '=') _state = 5;
                    else if (_la == '>') _state = 6;
                    else failure(state);
                }break;
                case 6: {
                    _la = getChar();
                    if (_la == '=') _state = 7;
                    else _state = 8;
                }break;
                case 7: {
                    return new Token(GEQUAL);
                }break;
                case 8: {
                    pushBack(_la);
                    return new Token(GREATER);
                }
            }
        }
    }
}
```

Zau-93-94-2

نکات تحلیلگر لغوی

- ❖ کلمات کلیدی مانند شناسه ها تشخیص داده می شوند یعنی ابتدا توسط ماشین مربوط به پذیرنده شناسه ها تشخیص داده شده و سپس با لیست کلمات کلیدی مقایسه می شوند در صورت تطبیق به عنوان کلمه کلیدی وگرنه به عنوان شناسه تشخیص داده می شوند.
- ❖ کلمات کلیدی را نیز می توان توسط ماشینهای جداگانه تشخیص داد.
- ❖ ماشین زیر کلمه کلیدی while را در زبان پاسکال نشان می دهد :



Zau-93-94-2

دیاگرام حالت

- ❖ یکی از ابزارهای پیاده سازی دستی برای اسکنر، دیاگرام انتقال حالت می باشد . یک دیاگرام یک گراف جهت دار است که هریک از گره های آن معرف یک وضعیت می باشد. یکی از وضعیت ها به عنوان وضعیت شروع و یکی یا چند تا از وضعیت ها بعنوان وضعیت خاتمه تلقی می شود. برچسب هایی روی لبه های گراف قرارداده می شود که مشخص می کند در چه صورتی می توانیم از یک وضعیت به وضعیت دیگر برویم . هر دیاگرام انتقال معرف یک زبان می باشد.
- ❖ با خواندن کاراکترهای یک رشته و تطبیق آنها با برچسب های دیاگرام انتقال معرف یک زبان و پیمایش آن دیاگرام می توان مشخص نمود که آیا آن رشته متعلق به زبان مورد نظر است یا خیر.

Zau-93-94-2