

Consiglio Nazionale delle Ricerche
ISTITUTO DI ELABORAZIONE DELLA INFORMAZIONE

SYNREC - L'ANALIZZATORE SINTATTICO
PER L'INTERPRETATORE PANON-1B.

L. Spanedda

Nota Interna B68-22

SYNREC - L'ANALIZZATORE SORDAPPIO PER LA PROGRAMMAZIONE

PATCH-13

L. Spadolini (es)

1. Introduzione

Il programma SYNREC è stato studiato e realizzato nell'ambito della definizione di un Interpretatore per un linguaggio per manipolazione di simboli basato su una esecuzione degli algoritmi generalizzati di Narkov: il PATCH-13 (Programming Language for Symbol Manipulation).

Questo linguaggio consiste essenzialmente di:

- 1) Un insieme di definizioni di classi, che definiscono un'Insieme Locale di Funzioni Libere e chiamate di funzioni.
- 2) Una sequenza di regole di trasformazione attivabili, che definiscono l'algoritmo.

Una regola di trasformazione attivabile è della forma

$$\varphi \rightarrow \varphi'$$

dove φ e φ' sono esprimenti due strutture di parole su $V_p \cup V_f$, dove V_p è un alfabeto base e V_f un insieme di simboli sovrapposti che denotano classi di parole su V_p . φ e φ' sono chiamati rispettivamente *proto* e *nuovo* membro delle regole di trasformazione.

L'interpretazione di un programma sintetico sarà rappresentata da: le proposizioni iniziali e loro conseguenze (informazioni chiuse o prototipi oggetto).

Una regola di trasformazione si dice che è applicabile ad una stringa oggetto, ad un certo punto t , se e soltanto se è possibile ottenere una corrispondenza tra le configurazioni definite da φ' ed un segmento della stringa oggetto.

Il problema di accettare l'esistenza di una tale corrispondenza è, ovviamente, il problema principale che un interprete deve risolvere. Il SYNREC, che è una delle parti principali dell'interprete PASCAL-1B, è un sottoprogramma che viene chiamato ogni qualvolta si dobbia decidere l'appartenenza di una sequenza di caratteri della stringa oggetto ad una certa classe del tipo libero o arbitraria di frase.

Esso viene inserito nell'interprete PASCAL-1B in base al diagramma illustrato nella fig. 1a.

Il ciclo interpretativo chiama successivamente una regola dopo l'altra, facendo esaminare il primo membro del decompositore sintattico. Se la regola risulta applicabile si esegue, diversamente si passa ad esaminare la successiva. Il decompositore sintattico esegue una serie di partizioni particolari della stringa oggetto in $k+2$ segmenti consecutivi (notionbrings), dove k è il numero dei termini del primo membro, e chiama il SYNREC a decidere, per ciascuna delle sottosequenze di punto uguale a quello di un nome di classe nelle regole, l'appartenenza a quella classe.

Il SYNREC è quindi un analizzatore sintattico per i termini liberi a struttura di frase.

2. Preliminari

Un vocabolario V è un insieme finito non vuoto di simboli. Una parola su V è una sequenza finita o nulla di elementi di V . La lunghezza di una parola è il numero di elementi che essa contiene. La parola di lunghezza zero è chiamata parola vuota.

Se indichiamo con V_T il vocabolario terminale, con V_N il vocabolario non terminale e con Λ l'insieme contenente come unico elemento la parola vuota, diciamo che

$$V = V_T \cup V_N \cup \Lambda$$

L'insieme di tutte le parole su un alfabeto V dicesi universo linguistico ed è indicato con V^* . Ogni sottoinsieme di V^* è chiamato un linguaggio su V . Chiamiamo produzione l'associazione di una certa parola $x \in V^*$ ad un elemento $Z \in V_N$. Una produzione si indica con la scrittura

$$Z \rightarrow^* x$$

dove Z e x sono chiamati, rispettivamente, primo membro e secondo membro della produzione. La lunghezza della parola x rappresenta la lunghezza della produzione.

Chiamiamo grammatica libera una quadrupla $G(V, V_T, P, S)$, dove:

- V è un insieme finito (vocabolario);
- V_T è un sottoinsieme di V (vocabolario terminale);
- P è un insieme finito di produzioni
 - (1) $Z \rightarrow^* x$ dove $Z \in V_N$, $x \in V^*$;
- S è un simbolo speciale di V_N (simbolo iniziale).

le S-derivazioni sono più di una, allora diremo che il linguaggio è ambiguo.

Data una grammatica G, chiamiamo ordine di un elemento $x \in V_N$ il numero di espressioni, o alternative, associate ad X in G.

Consideriamo la produzione

$$X \rightarrow x$$

diciamo che X è un elemento nullificante di V se è stato associato alla parola vuota, ovvero

$$x = \Delta$$

Se invece risulta $x \neq \Delta$, ma esiste una derivazione $X \Rightarrow \Delta$, allora diciamo che X è un elemento indirettamente nullificante.

Un elemento X si dice ciclico se esistono due parole x_1 e x_2 tali che

$$X \Rightarrow x_1 x_2$$

In particolare se risulta $x_1 = \Delta$ e $x_2 \neq \Delta$ si dice ciclico a sinistra, se, invece, risulta $x_1 \neq \Delta$ e $x_2 = \Delta$, si dice ciclico a destra.

3. L'Algoritmo generale

Un analizzatore sintattico è un algoritmo che, dato un linguaggio $L(G)$ ed una stringa arbitraria k , terminali rispetto a G , decide se k è o non è una stringa per un dato elemento sintattico X di G e, in caso affermativo, fornisce una λ -deriva-
zione di k , cioè la sua struttura sintattica.

Gli algoritmi generali di analisi sintattica si di-
stinguono in ascendenti e discendenti. Negli algoritmi ascendenti
si parte dalla stringa oggetto per ripalire al simbolo iniziale;
negli algoritmi discendenti, invece, si parte dal simbolo ini-
ziale per arrivare ai simboli della stringa oggetto.

Il STREO è basato su un algoritmo di tipo discenden-
te, descritto alla fine del paragrafo, che non richiede l'ordina-
mento delle grammatiche sulla quale deve operare (vedi l'esem-
pio più oltre); cioè non richiede l'introduzione di una ben de-
terminata gerarchia fra le produzioni. L'algoritmo presentato
è del tutto generale e consente di operare su grammatiche della
massima generalità senza alcuna restrizione. Infatti, non si
pongono restrizioni sulle produzioni cicliche, sulle produzioni
miliificanti, sul numero di produzioni con lo stesso primo mem-
bro, sulla lunghezza delle produzioni, ecc.

Consideriamo, ad esempio, la grammatica $G_1 = (V, V_T, P, S)$,
dove:

$$V = \{S, W, H, a, b, c, d\}$$

$$V_T = \{a, b, c\}$$

$$S = S$$

$$\begin{aligned} P = & \{S \rightarrow^* W, S \rightarrow^* a, S \rightarrow^* ab, S \rightarrow^* bSW, S \rightarrow^* H, \\ & W \rightarrow^* c, S \rightarrow^* SW, W \rightarrow^* aH, H \rightarrow^* AJ\} \end{aligned}$$

Le produzioni, opportunamente codificate, vengono memorizzate in due tabelline distinte chiamate CP1 e CPP (vedi fig. 10). La prima tabella (ad una dimensione) contiene i codici degli elementi dei secondi membri delle produzioni. La seconda tabellina (a quattro dimensioni) su una stessa linea e per ogni produzione, contiene le seguenti informazioni:

- il codice del nome di classe (primo membro della produzione);
- l'ordine del nome di classe;
- la lunghezza delle produzioni;
- la posizione nella tabellina CP1 del primo elemento dell'espressione assegnata al nome di classe.

Le due tabelline rappresentano la grammatica del linguaggio. La stringa da esaminare, anch'essa opportunamente codificata, viene memorizzata in una tabellina ad una dimensione, che indichiamo con TS. Se consideriamo una stringa di n elementi, allora TS(1) contiene il codice del primo elemento, TS(2) il codice del secondo, ed, infine TS(n) il codice dell'ultimo elemento della stringa.

Il SYNREC utilizza per la memorizzazione dei risultati parziali due stack, chiamati rispettivamente, stack operativo (nel seguito verrà indicato con SPO) e stack sintattico (SS). Nel primo le informazioni vengono memorizzate da destra verso sinistra, nel secondo, viceversa, da sinistra verso destra. Si ha così il vantaggio di sfruttare convenientemente la zona di memoria disponibile. Ogni qualvolta l'ausiliaria sintattica ha esito positivo, SS viene a contenere la struttura sintattica della stringa e, conseguentemente, SPO risulta vuota.

Indichiamo con K la posizione del simbolo della stringa, di lunghezza LS, che si sta esaminando ad un istante t_j ; con J la posizione che un elemento X occupa nello stack operativo; con P il numero di elementi non nullificanti alle destra di X in STO, simboli terminali compresi.

Se un elemento X viene trasferito dallo stack operativo nello stack sintattico, ad esso viene associata una quadrupla di informazioni che consentono, in caso di insuccesso parziale, di esaminare le altre alternative possibili. Questa quadrupla caratterizza l'elemento X in STS, ed è indicata con $X(N, J, K, P)$, dove N rappresenta l'ordine dell'elemento, cioè l'alternativa considerata nella costruzione dell'albero sintattico, e J, K, P sono stati precedentemente definiti. Se $X \in V_P^*$, si ha $N = 0$.

Def. 1 - Un elemento X sulla testa dello stack operativo, si dice accettabile se, essendo verificata la relazione $LS+1 \geq K+P$, si ha

$$STO(J) = TS(K) \text{ , oppure } STO(J) \in V_P^*$$

Def. 2 - Un elemento ciclico $X(N, J, K, P)$ sulla testa dello stack sintattico si dice accettabile per ogni $X'(N', J', K', P')$ se è verificata almeno una delle seguenti condizioni:

- a) $X \neq X'$;
- b) $X = X'$, ma $K \neq K'$;
- c) $X = X'$, $K = K'$, ma $P \neq P'$;
- d) $X = X'$, $K = K'$, $P = P'$, ma $J < J'$;
- e) il numero degli elementi per cui è $X = X'$, $K = K'$, $P = P'$, $J \geq J'$, è minore del numero ($LS-K$) dei caratteri della stringa ancora da esaminare.

Il diagramma dinamico semplificato del SYNREC è dato in fig. 2.

I vari blocchi del diagramma eseguono le seguenti operazioni:

- 1: Memorizza nello stack operativo il simbolo iniziale.
- 2: Trasferisce l'elemento di testa dello stack operativo nello stack sintattico; se tale elemento è cirlico va a 7, altrimenti continua su 3.
- 3: Trasforma nello stack operativo l'espressione associata all'elemento di testa dello stack sintattico.
- 4: Si distinguono i seguenti due casi fondamentali:
 - a) il primo elemento nello stack operativo è accettabile: se non è terminale si va a 2, altrimenti esso viene trasferito nello stack sintattico. In questo caso le eventualità sono due:
 - a.1) l'analisi è fermata ed ha dato esito positivo;
 - a.2) l'analisi non è fermata; si ripete a).
 - b) il primo elemento dello stack operativo non è accettabile: si procede su 5.
- 5: Esamina l'esistenza di una eventuale successiva espressione assegnata all'elemento di testa dello stack sintattico; se la trova va a 3, altrimenti continua su 6.
- 6: Ritrasferisce l'elemento di testa dello stack sintattico (nello operativo): se SIS risulta vuoto, l'analisi ha dato esito negativo, altrimenti torna a 3.
- 7: Se l'elemento di testa dello stack sintattico è accettabile, si va a 3, altrimenti si va a 6.

4. Schema generale del funzionamento del SYNTAC

1. Elenco dei simboli

1.1 - Celle di memoria con funzioni speciali

E = numeratore del simbolo in esame nella struttura

dello stack operativo

o = numeratore dello stack estraattivo

P = cella contenente il numero di elementi non nullificanti in SPO

SC = cella contenente il simbolo iniziale

LG = " " " la lunghezza delle stringhe

X, Y, V, L, R, S = celle auxiliarie

2. $z(R)$ = contenuto della cella R (con R qualsiasi).

$z(\emptyset)$ = celle avendo indirizzo relativo 0, dove 0 è un nome di zona di lavoro (ad es.: SPS), e \emptyset è una cella con funzioni speciali.

$z(T, n)$ = n^{mo} "campo" della cella $z(\emptyset)$, se per la cella Z sono previste delle partizioni le "campi".

$z(T, n_1, n_2)$ = "campo" della cella $z(T)$ simile alla unione dei campi n_1 , n_2 .

3. I funzionamenti dei simboli nullificanti

3.1 - $z(\emptyset) \rightarrow z(\emptyset) \quad \text{se} \quad z(\emptyset) \neq \emptyset$

3.2 - $z(\emptyset) \rightarrow z(\emptyset) \quad \text{se} \quad z(\emptyset) = \emptyset$

3.3 - $z(\emptyset) \rightarrow z(\emptyset) \quad \text{dalle produzioni}$

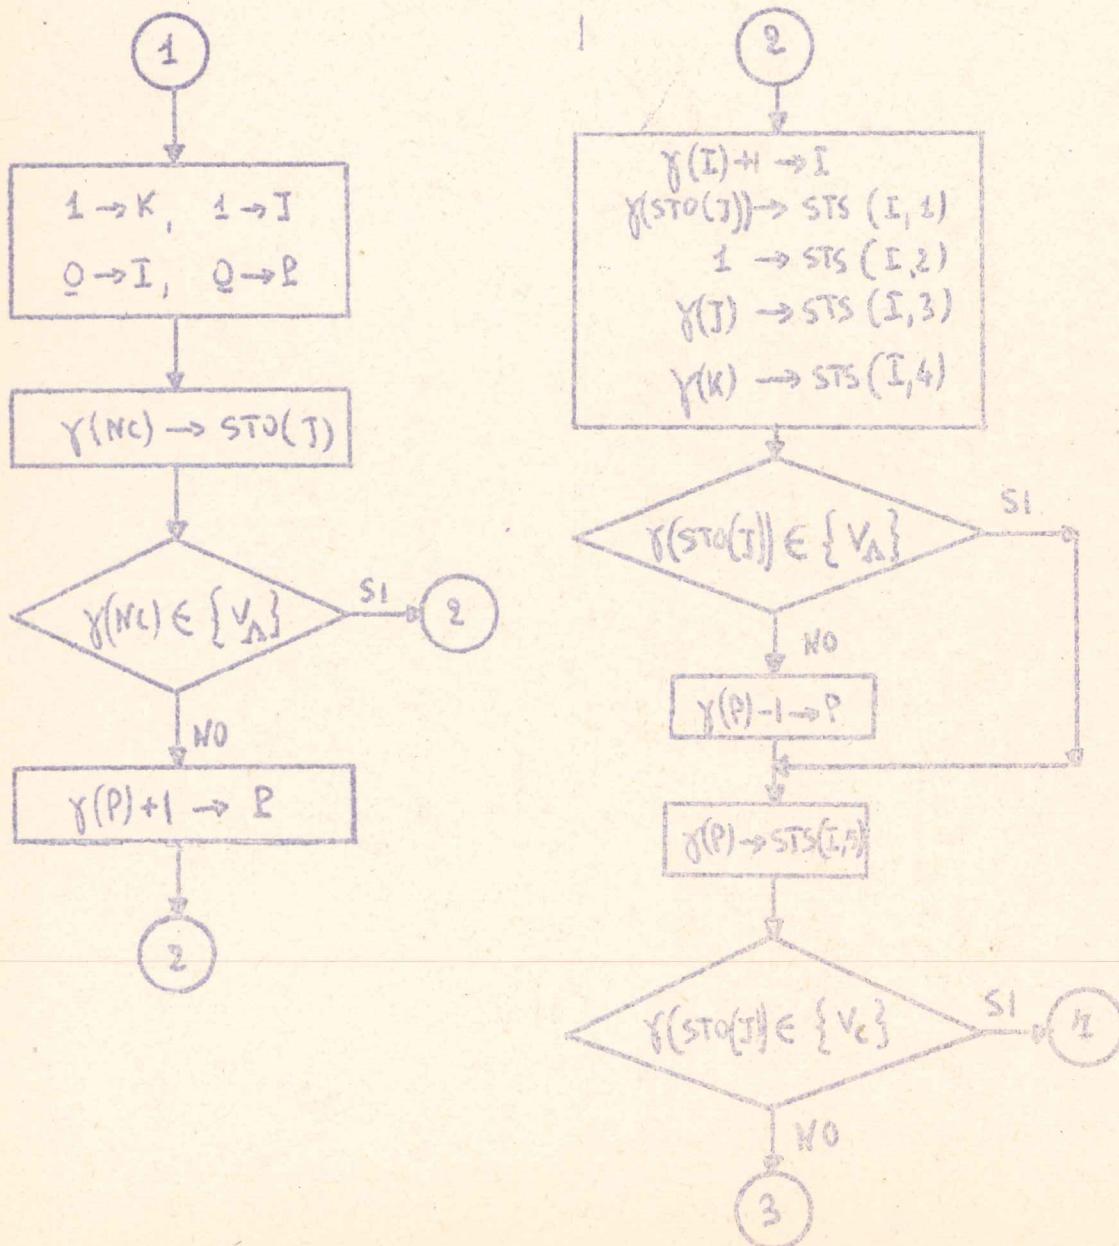
4 - STO = stack operativo

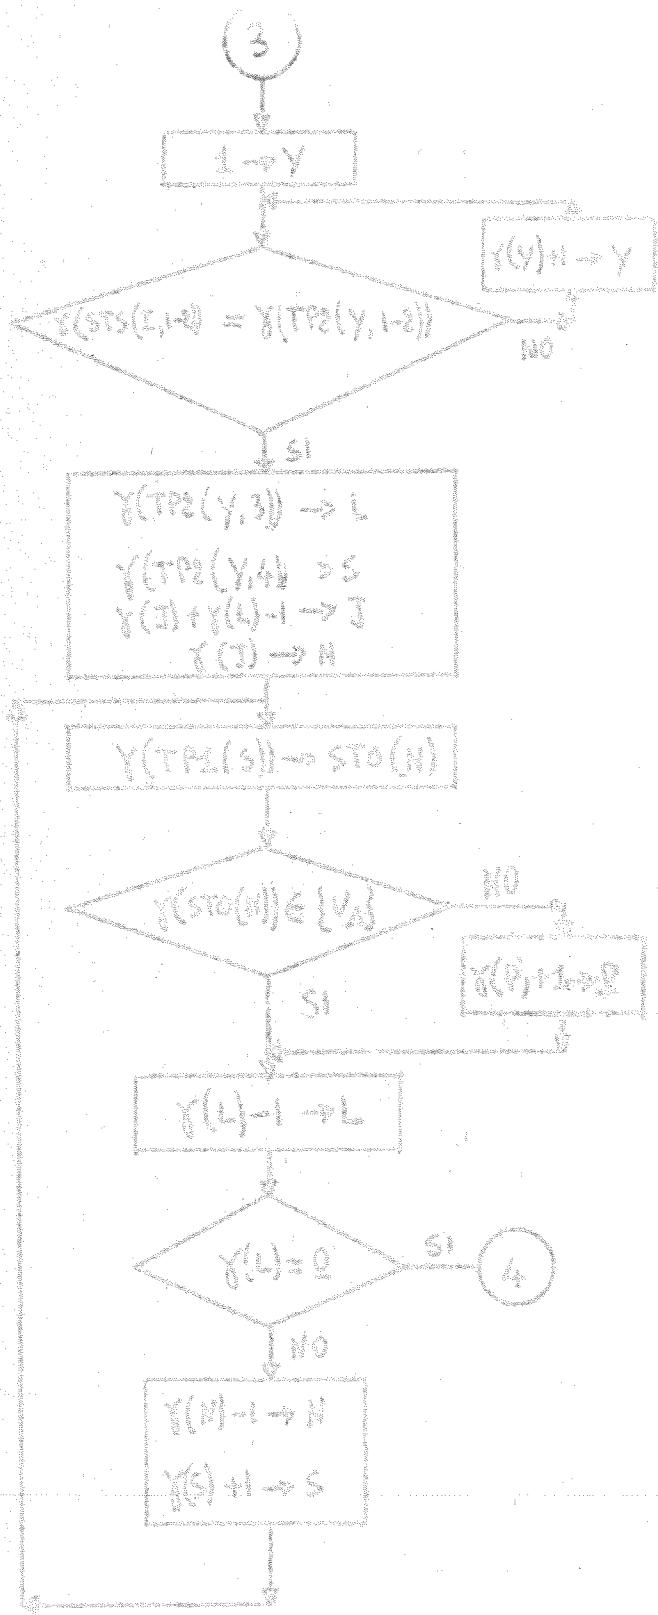
STS = stack sintattico

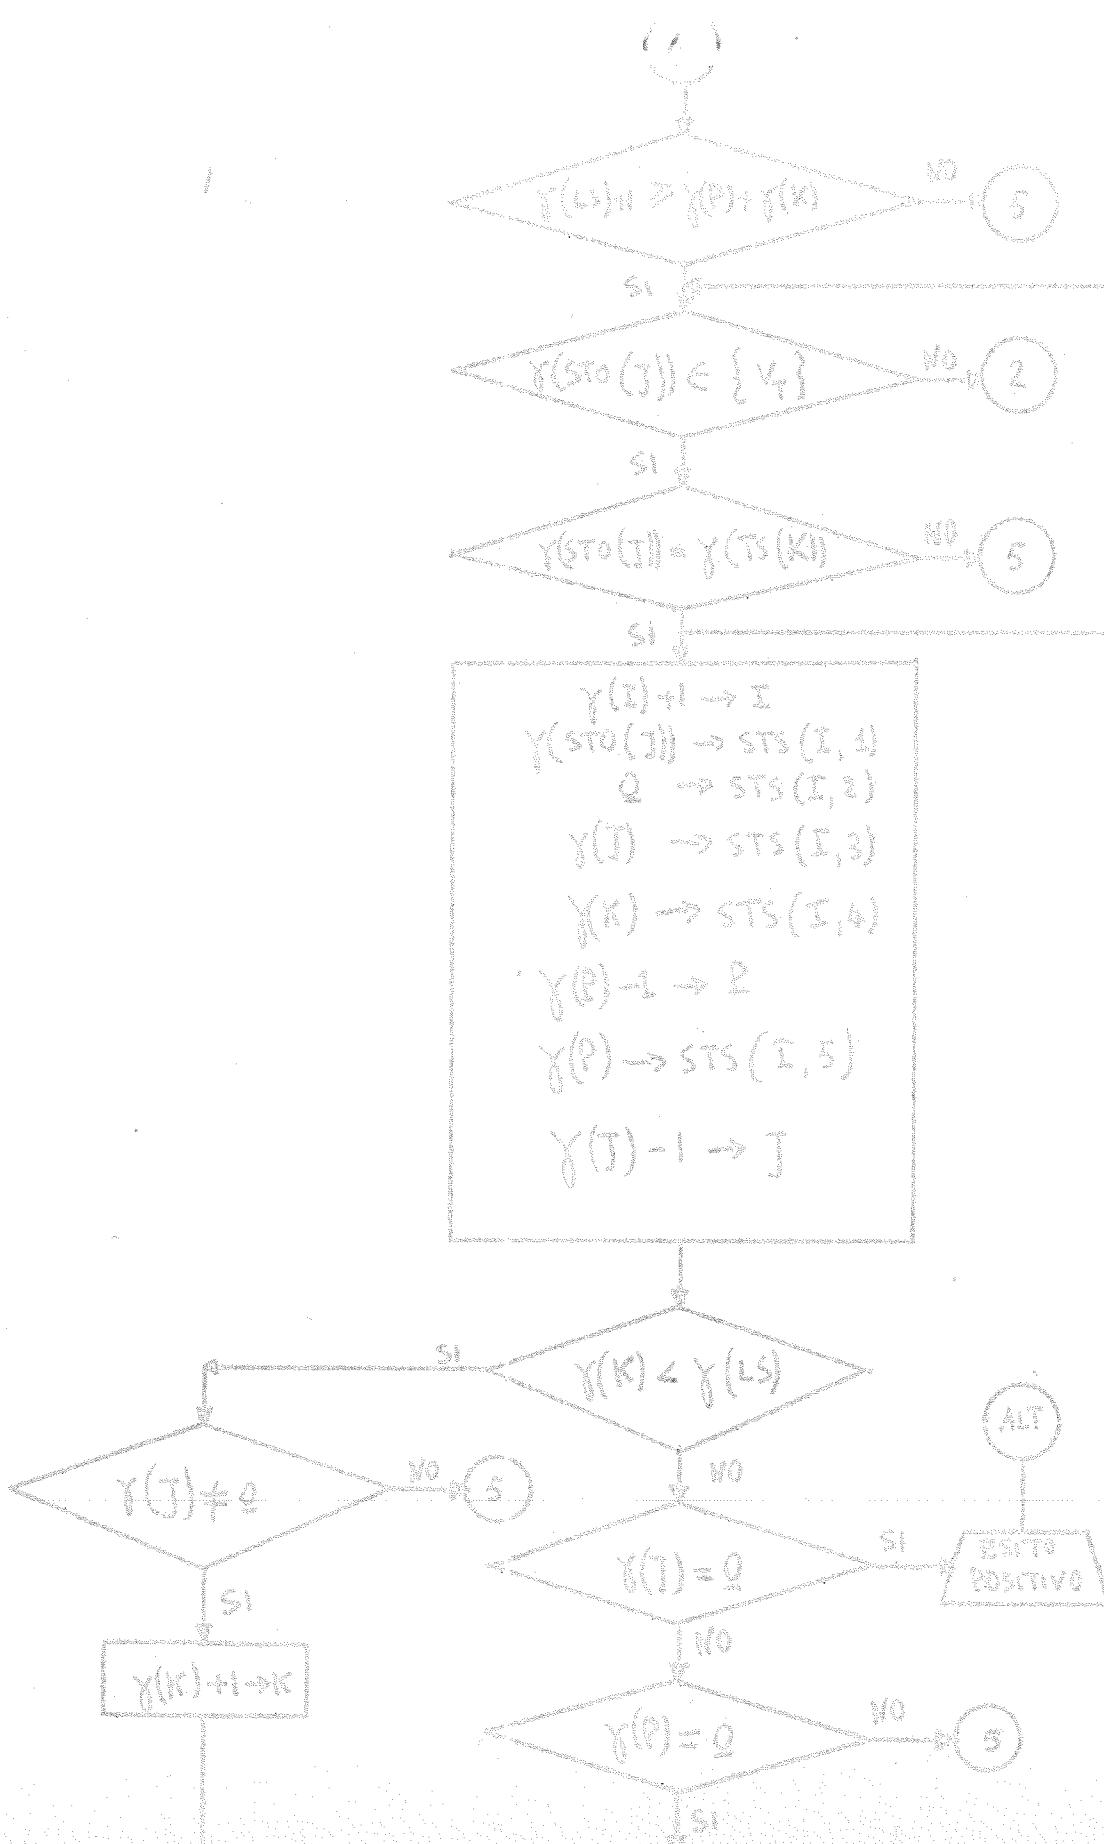
TP1 = tabella dei codici degli elementi che compaiono nei secondi membri delle produzioni.

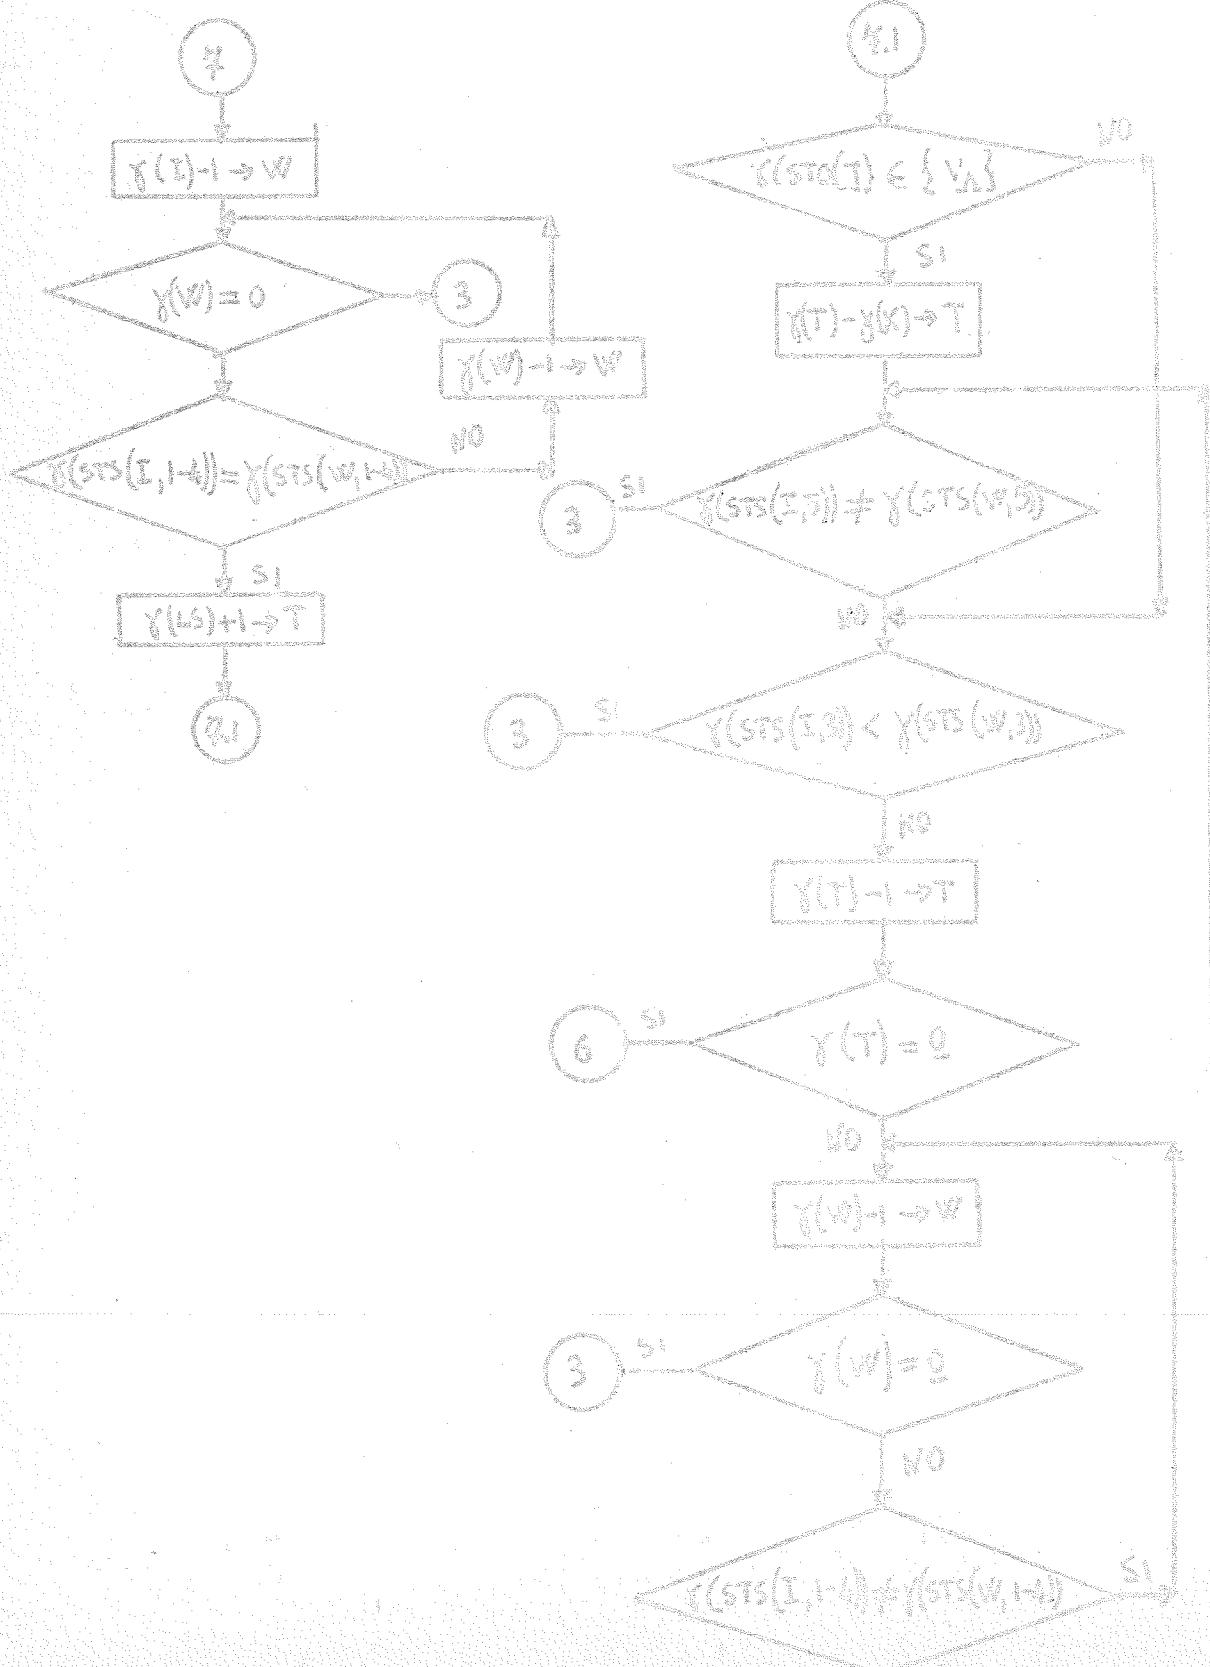
TP2 = tabella dei codici dei nomi di classe

Dettaglio dei blocchi del diagramma semplificato.









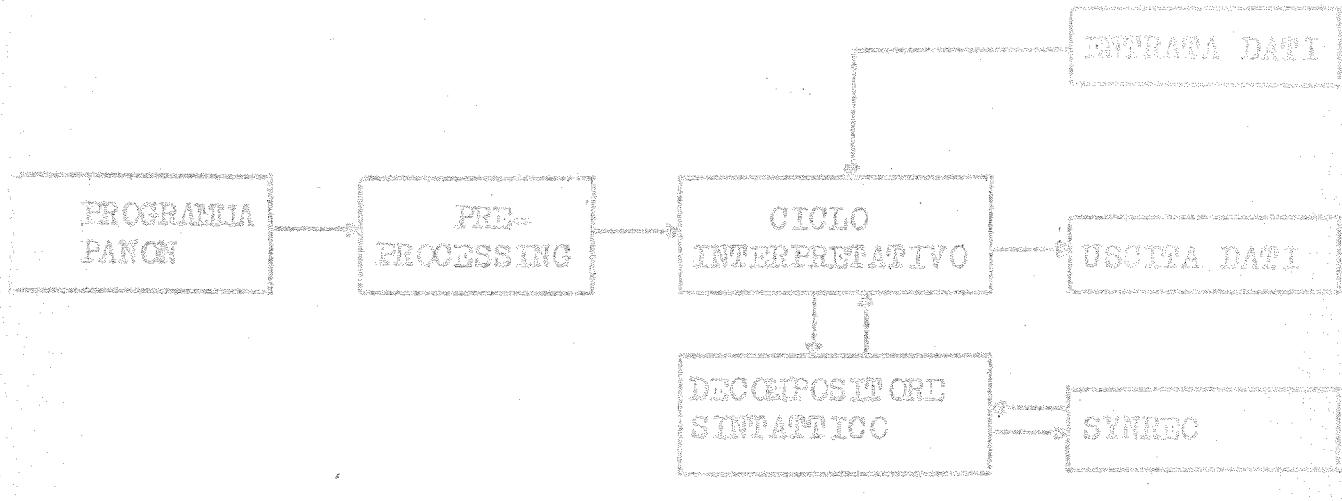


Fig. 10 - Diagramma dell'interpretazione sintattica

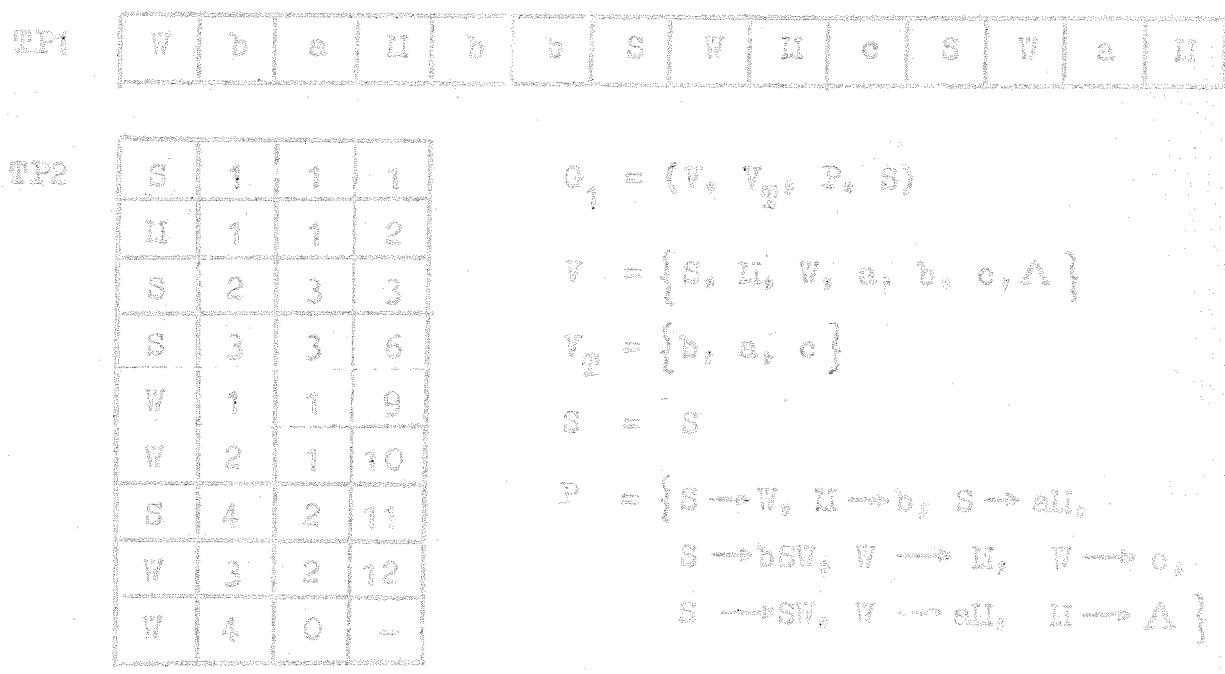


Fig. 10 - La grammatica G_p e le strutture corrispondenti

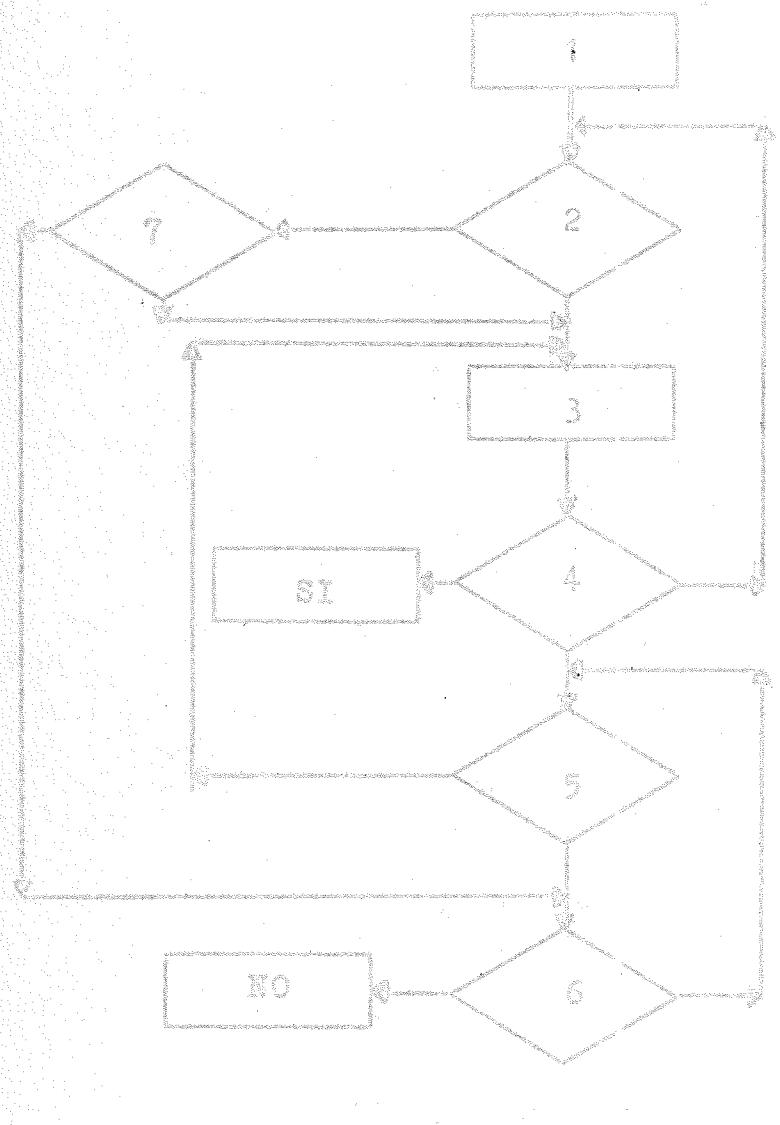


Fig. 2 - SIRIUS : diagramma dinamico semplificato.

BIBLIOGRAFIA

1. A. Caracciolo di Portno - Elementi di teoria formale dei linguaggi. Appunti al corso di Cibernetica presso la Facoltà di Scienze, Università di Pisa, 1964-65. Periodico Pisa, (1968).
2. N. Wolkenstein - Some remarks on the implementation of PANON-1B. SIC-SAM Bulletin 2, (July 1967).
3. J. Eickel, H. Paul, H.-L. Esuer, K. Samelton - A syntax-controlled generator of formal language processors. Comm. ACM, 8 (1965), 451-455.
4. R.W. Griffis, S.R. Petrick - On the efficiencies of context-free grammar recognisers. Comm. ACM, 8 (5) (1965).
5. A. Caracciolo di Portno, L. Spanedda, N. Wolkenstein - PANON-1B: A programming language for symbol manipulation. Calcolo, 3 (2) (1966), 245-265.
6. L. Spanedda, N. Wolkenstein - An interpreter for PANON-1B (in preparation).
7. D. Bolliet - Théorie des compilateurs. Chiffres, 9 (1) (1966), 47-73.
8. S. Ginsburg - The mathematical theory of context-free languages. New York, McGraw-Hill, (1966).
9. R.W. Floyd - The syntax of programming languages - A survey. IBM Transactions on Electronic Computers, (1964), 346-353.

10. P.G. Tandweber - Precision problems of phrase-structure grammars.
IBM Transactions on Electronic Computers, (1964),
354-362.
11. A. Carucciole di Parino, L. Spanedda - Analisi multiple per
linguaggi Context-Free e natura dell'insieme delle
strutture sintattiche.
(in preparazione).
12. H. Brasseur, J. Cohen - Algorithmes d'analyse syntaxique
pour langages "context-free".
Chiffres, 8 (2), (1965), 95-119.