

**СООБЩЕНИЯ
ОБЪЕДИНЕННОГО
ИНСТИТУТА
ЯДЕРНЫХ
ИССЛЕДОВАНИЙ
ДУБНА**

Ш 951

P11-88-720

В.Шуберт, Э.В.Шарапова

**ОПЕРАЦИИ ДЛЯ ОБРАБОТКИ
ПОСЛЕДОВАТЕЛЬНОСТИ СИМВОЛОВ
В ФОРТРАНООРИЕНТИРОВАННЫХ ПРОГРАММАХ**

1988

I. Введение

Описывается система программ, которая обеспечивает обработку последовательностей символов (ПС) в фортраноориентированных программах. Система программ написана на диалекте Фортрана СДФ^{1,2/} и может быть поставлена на всех ЭВМ, которые поддерживают фортраноориентированную технологию программирования (Ф-технологию)^{3,7/}.

Работа была выполнена в ЛВТА ОИЯИ.

I.1. Краткие сведения об Ф-технологии


Ф-технология^{1-3,7/} является системой методических, лингвистических и программных средств для создания познаваемого, переносимого и пластичного программного обеспечения.

Ф-технология была разработана в ЛВТА ОИЯИ и поддерживается на базовых ЭВМ центрального вычислительного комплекса ОИЯИ (БЭСМ-6, срс-6500 и ЕС ЭВМ). Средства Ф-технологии поддерживают создание, отладку, использование и техническое обслуживание программного обеспечения. К средствам лингвистической поддержки Ф-технологии относятся определенные диалекты базовых языков (Фортран, Паскаль), языки для проектирования программного обеспечения (Ф-псевдокод) и для представления текстовых структур.

Средством программной поддержки Ф-технологии являются прекомпиляторы, которые переводят диалекты базовых языков в базовые языки, программы для автоматического преобразования текстов к виду программной документации и др.

I.2. Обработка последовательности символов (ПС) в СДФ

Язык СДФ является диалектом Фортрана. Он позволяет программировать в соответствии с требованиями структурного программирования, что связано с разделением текста на дерево пошагового уточнения. В СДФ, однако, отсутствует возможность непосредственной обработки последовательности символов, если базовым языком является Фортран IV. В Фортран IV мы имеем дело с единичными символами, как с индексированными элементами массива. Между тем, в процессе обработки информации, поддерживаемом ЭВМ, в интерфейсе между человеком и ЭВМ в качестве носителя информации естественно выступают последовательности символов. Оказывается полезным рассматривать последовательность символов как



некоторую автономную структурную единицу и иметь возможность различных действий над этими структурами. Такие возможности обеспечиваются разработанной системой программ, которая реализует тип данных с нар соответственно семантике языка PL/1 /4/, что обеспечивает создание, изменение и уничтожение ПС с любой длиной. Из набора функций PL/1 для обработки ПС было реализовано представительное подмножество.

2. Цель обработки последовательности символов (ПС)

В процессе обработки информации, поддерживаемом ЭВМ, ПС, как носители информации, возникают в интерфейсе между человеком и ЭВМ. Для того чтобы ЭВМ могла обрабатывать ПС, они должны быть преобразованы в нужную форму. И обратно, при выводе ПС из ЭВМ, внутреннее представление информации должно быть заменено соответствующим внешним представлением. Этой цели служат операции ввода-вывода в языках программирования, а также ряд операций для обработки ПС, описываемых ниже.

2.1. Операции для обработки ПС

Типичными операциями для обработки ПС являются:

- вычисление длины ПС (LENGTH)
- вычисление частного ПС (SUBSTR)
- связывание частных ПС (JOIN)
- определение позиции частного ПС (INDEX)
- сравнение двух ПС (SNCOMP)
 - а) по длине,
 - б) по внутреннему представлению.

Характерным при обработке ПС является создание и уничтожение ПС. Отсюда следует, что память для ПС должна быть динамически управляемой. На языке PL/1 существуют для этого некоторые языковые средства (ALLOCATE, FREE, EMPTU).

Базисными средствами для динамического управления ПС являются:

- инициализация памяти для ПС (INITIA)
- определение пустого ПС (NEW)
- преобразование массива символов в ПС (CHWRIT)
- перезапись ПС из массива символов (REWRIT)
- уничтожение ПС (DELETE)
- преобразование ПС в массив символов (CHREAD)
- вычисление длины свободной памяти (FREEM)
- вычисление длины рабочей памяти. (LENWRK)

Кроме того, имеются более сложные операции:

- уничтожение частного ПС (IMPAND)
- вставка частной ПС в ПС (INSERT)
- перепись части ПС в ПС (OVRWRT)

Подробное описание операций дано в главе 3.4. Операции для обработки последовательности символов можно использовать вызовом SUBROUTINE с параметрами или FUNCTION в каждой фортраноориентированной программе. Некоторые другие полезные возможности обработки ПС, такие как

- преобразование массива символов в представление других типов данных и обратно,
- преобразование массива символов реализованы в самой операционной системе ЭВМ.

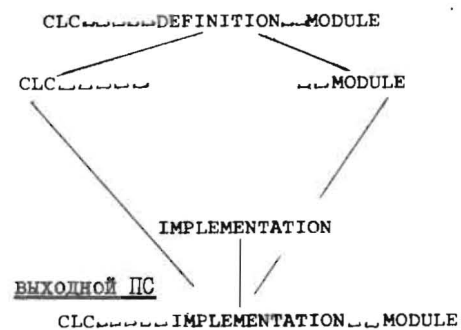
2.2. Примеры обработки ПС

2.2.1. Примеры ПС

moskva длина ПС=6
 A+B-C*3 длина ПС=7
 CLCDEFDEFINITION...MODULE длина ПС=26

2.2.2. Создание и связывание ПС

Входной ПС



вычисление частных ПС

Выходной ПС

связывание ПС

2.2.3. Поиск и сравнение ПС

Входной ПС	Искомый ПС	Исчисляемая позиция
moskva	KV	4
сравнение		результат сравнения
moskva	KV	больше ("moskva" длиннее, чем "kv").
A+B-C*3	A-B-C*3	меньше (внутреннее представление символа "-" больше, чем символа "+", в коде ДКОИ).

2.2.4. Конструирование ПС

- уничтожение частного ПС

входной ПС: операция:
A+B-с*3 уничтожение с 3-го до 5-го знака

выходной ПС:

A+*3

- вставка ПС

входной ПС: операция:
A+*3 вставка ПС "A+B" за 2-ой позицией

выходной ПС:

A+A+B*3

Программная реализация примеров приведена в 4.

3. Проектирование системы программ

3.1. Выбранная архитектура

Система программ, реализующая возможности обработки ПС, имеет трехуровневую структуру. Каждый уровень представляет собой коробку данных, т.е. соединяет в себе функции и данные. Уровни находятся друг к другу в отношении обобщения, подобно концепции уровней операционной системы multis /5/. Функции каждого уровня реализуются посредством функций более нижнего уровня и программного кода. С данными каждого уровня работают только функции соответствующего уровня.

Рассмотрим подробнее уровни, соответствующие функции и внутренние данные.

УРОВЕНЬ	ФУНКЦИЯ (см.2.1)	ВНУТРЕННИЕ ДАННЫЕ
1. Управление ПС	INITIA	- управляющая таблица для ПС (POINT)
	NEW	
	CHWRIT	- длина управляющей таблицы для ПС
	REWRIT	(LPOINT)
	DELETE	- массив строк символов (CHAR)
	CHREAD	
	FREEM	- максимальная длина строк символов (CHRBLK)
	LENGTH	
	LENWRK	
	2. Анализ ПС	SUBSTR
JOIN		
INDEX		- длина рабочего массива для ПС (LWORK)
CHCOMP		
3. Синтез ПС	IMPAND	
	INSERT	
	OVRWRT	

Номера уровней увеличиваются с уровнем обобщения. Программы каждого уровня структурированы на модули. Модули переводятся отдельно и связаны с редактором связи.

3.2. Спецификация модулей

Спецификация модулей следует из определения модульного интерфейса. Форма написания соответствует построению DEFINITION MODULE в MODULA2 /6/. DEFINITION MODULE - это определение внешнего вида модуля (наименование). IMPORT - определяет, какие программные объекты модуль требует для своей работы из внешнего мира. EXPORT - определяет, какие программные объекты модуль содержит и можно использовать в других модулях. Дополнительно пишется высказывание "содержит следующие частные модули" - PARTS .

Ниже приводятся примеры уровней декомпозирования:

- целый модуль

```
DEFINITION MODULE STR
IMPORT;
EXPORT INITIA,NEW,CHWRIT,REWRIT,DELETE,CHREAD,FREEM,LENGTH,
LENWRK,SUBSTR,JOIN,INDEX,CHCOMP,IMPAND,
INSERT,OVRWRT;
PARTS STR2,STR4,STR5;
```

- управление ПС

```
DEFINITION MODULE STR2
IMPORT;
EXPORT INITIA, NEW,CHWRIT,REWRIT,DELETE,CHREAD,FREEM,
LENGTH,LENWRK;
```

- управление памятью

```
DEFINITION MODULE STR21
IMPORT POINT, LPOINT, CHRBLK, CHAR;
EXPORT INITIA, NEW, DELETE, LENGTH, FREEM,
POINT, LPOINT, CHRBLK, CHAR;
PARTS;
```

- чтение и запись ПС

```
DEFINITION MODULE STR22
IMPORT NEW, FREEM, POINT,LPOINT,CHRBLK, CHAR;
EXPORT CHWRIT, REWRIT, CHREAD,POINT,LPOINT,CHRBLK,CHAR;
PARTS;
```

- анализ ПС

```
DEFINITION MODULE STR4
FROM STR2 IMPORT LENGTH, FREEM,CHWRIT,CHREAD;
EXPORT SUBSTR, JOIN, INDEX, CHCOMP, LENWRK;
PARTS STR43,STR44;
```

- анализ ПС (часть 1)

```
DEFINITION MODULE STR43
IMPORT LENGTH, FREEM, CHWRIT, CHREAD, LWORK, WORK;
EXPORT SUBSTR, JOIN, LWORK, WORK;
```

- анализ ПС (часть 2)

```
DEFINITION MODULE STR44
IMPORT LENGTH, CHREAD, LWORK, WORK;
EXPORT INDEX, CHCOMP, LENWRK, LWORK, WORK;
```

PARTS;

```
DEFINITION MODULE STR5
```

```
FROM STR2 IMPORT DELETE, LENGTH, FREEM;
```

```
FROM STR4 IMPORT SUBSTR, JOIN;
```

```
EXPORT IMPAND, INSERT, OVRWRT;
```

PARTS;

3.3. Проектирование уровня внутренних данных

Описывание уровня внутренних данных ведется соответственно MODULA2 и разделено в определении типов и декларации переменных и констант.

- определение типов:

управляющая таблица для ПС

```
TYPE CONTROLTABLE = ARRAY[1...LPOINT, 1...3]
OF INTEGER
```

массив строк символов

```
TYPE CHARACTERSTORAGE = ARRAY[1...LPOINT, 1...CHRBLK]
OF LOGICAL * 1
```

рабочий массив для ПС

```
TYPE WORKAREA = ARRAY[1...LWORK] OF LOGICAL * 1
```

Замечание: данные базовые типы (INTEGER, LOGICAL * 1) входят в состав FORTRANa.

- декларация переменных

```
VAR POINT: CONTROLTABLE,
CHAR: CHARACTERSTORAGE,
WORK: WORKAREA;
```

- декларация констант

```
CONST LPOINT = 500 - максимальное число ПС,
CHRBLK = 160 - размер блока для ПС,
LWORK = 65536 - максимальное число символов рабочего массива.
```

Каждой строке в CONTROLTABLE соответствует одна строка в CHARACTERSTORAGE (равный индекс). Одна строка в CONTROLTABLE предназначена для хранения следующей информации:

1 позиция: тип соответственной строки в CHARACTERSTORAGE

0 свободно

1 занято

2 временно занято

3 постоянно занято

4 постоянно занято (разрешается только чтение)

2 позиция: индекс строки продолжения

0 - если продолжения не существует

3 позиция: число хранящихся символов в строке.

3.4. Проектирование функциональных возможностей

3.4.1. Операции и их параметры

Ниже приводятся операции и их параметры. Дается пояснение семантики параметров.

INITIA(RC) - инициализация памяти для ПС

RC - код выполнения операции (Кво)

всегда 0.

NEW(TYPE, POINT, RC) -

- определение пустого ПС

TYPE тип ПС

2 временное хранение

3 постоянное хранение

4 постоянное хранение констант.

POINT численный идентификатор ПС (ЧИПС)

RC Кво

0 без ошибок

2 память недостаточна

16 тип ПС не разрешается.

DELETE(POINT, RC)

- уничтожение ПС

POINT ЧИПС

RC Кво

0 без ошибок

4 ЧИПС идентифицирует частный ПС

8 ЧИПС не идентифицирует ПС.

LENGTH(POINT, TYPE, LEN, RC)

- вычисление длины ПС

POINT ЧИПС

TYPE тип ПС

LEN длина ПС

RC Кво

0 без ошибок

8 ЧИПС не идентифицирует ПС.

FREEM (LEN, RC) - вычисление длины свободной памяти
 LEN длина
 RC Кво
 всегда 0.

CHWRIT (TYPE, STRING, LEN, POINT, RC) - преобразование массива символов в ПС
 TYPE тип ПС
 STRING массив символов
 LEN длина массива
 POINT ЧИПС
 RC Кво
 см. NEW

REWRIT (POINT, STRING, LEN, RC) - перезапись ПС из массива символов
 POINT ЧИПС
 STRING массив символов
 LEN длина массива
 RC Кво
 0 без ошибок
 2 память недостаточна
 8 ЧИПС не идентифицирует ПС

CHREAD (POINT, TYPE, STRING, LEN, RC) - преобразование ПС в массив символов
 POINT ЧИПС
 TYPE тип ПС
 STRING массив символов
 LEN число символов
 RC Кво
 см. DELETE

SUBSTR (POINT1, POS, LEN, POINT2, RC) - вычисление частного ПС.
 POINT1 ЧИПС, входной
 POS начальная позиция во входном ПС
 LEN длина частного ПС
 POINT2 ЧИПС, выходной
 RC Кво
 см. CHREAD, CHWRIT

JOIN (POINT1, POINT2, POINT3, RC) - связывание частных ПС
 POINT1 ЧИПС, 1. входной
 POINT2 ЧИПС, 2. входной
 POINT3 ЧИПС, выходной
 RC Кво
 см. CHREAD, CHWRIT

INDEX (POINT1, POS1, POINT2, LEN2, POS2, RC) - определение позиции частного ПС
 POINT1 ЧИПС, входной
 POS1 начальная позиция для поиска
 POINT2 ЧИПС, ПС сравнения
 LEN длина ПС сравнения
 POS2 найденная позиция
 RC Кво
 см. CHREAD

CHCOMP (POINT1, POINT2, C) - сравнение двух ПС
 POINT1 ЧИПС, ПС
 POINT2 ЧИПС, ПС
 C код сравнения
 0 равно
 1 меньше
 2 больше
 8 ЧИПС не идентифицирует ПС.

LENWRK (RC) - вычисление длины рабочей памяти
 RC Кво
 всегда 0.

IMPAND (POINT, POS, LEN, RC) - уничтожение частного ПС.
 POINT ЧИПС
 POS последняя, неизменяемая позиция
 LEN число уничтоженных символов
 RC Кво
 см. CHREAD, CHWRIT

INSERT (POINT1, POS, POINT2, RC) - вставка частного ПС в ПС.
 POINT1 ЧИПС, базовый ПС
 POS последняя, неизменяемая позиция
 POINT2 вставляемый ПС
 RC Кво
 см. CHREAD, CHWRIT

OVRWRT (POINT1, POS, POINT2, RC)

- переписывание части ПС с ПС

POINT1	ЧИПС, базовый ПС
POS	последняя, неизменяемая позиция
POINT2	переписываемый ПС
RC	Кво
	см. CHREAD, CHWRIT

3.4.2. Функции и их атрибуты.

Атрибутом функции является:

Имя функции (атрибут I. параметра, ..., атрибут m. параметра)

Атрибутом параметра является:

. свойство. может быть: входным (> ..)
 входным и выходным (> .. >)
 выходным (.. >)

. тип параметра

Примеры для типов данных - это "целое число" (i) и "массив данных" (s).

Функции уровня (кроме I-ого) базируются на функциях нижних уровней.

номер функции	атрибут функции	номера вызываемых функций
1.	INITIA (> I >)	
2.	NEW (> I, > I >, > I >)	
3.	DELETE (> I, > I >)	
4.	LENGTH (> I, > I >, > I >, > I >)	
5.	FREEM (> I >, > I >)	
6.	CHWRIT (> I, > S, > I >, > I >, > I >)	2, 5
7.	REWRIT (> I, > S, > I >, > I >)	4
8.	CHREAD (> I, > I >, > S >, > I >, > I >)	
9.	SUBSTR (> I, > I, > I, > I >, > I >)	4, 5, 6, 8
10.	JOIN (> I, > I, > I >, > I >)	4, 5, 6, 8
11.	INDEX (> I, > I, > I, > I, > I >, > I >)	4, 8
12.	CHCOMP (> I, > I, > I >)	4, 8
13.	LENWRK (> I >)	
14.	IMPAND (> I >, > I, > I, > I >)	3, 4, 5, 9, 10
15.	INSERT (> I >, > I, > I, > I >)	3, 4, 5, 9, 10
16.	OVRWRT (> I >, > I, > I, > I >)	3, 4, 5, 9, 10

4. Примеры использования

Операции для обработки последовательности символов (ПС) можно использовать вызовом SUBROUTINE или FUNCTION (LENWRK) в каждой фортраноориентированной программе. С помощью примеров из части 2.2 будет показана возможность их использования

4.1. Определение исходных ПС

Предполагаем, что существуют следующие массивы символов:

Имя	значение
VEC1	MOSKVA
VEC2	A+B-C*3
VEC3	CLC DEFINITION MODULE
VEC4	IMPLEMENTATION

из этих массивов символов мы сгенерируем ПС с именами S1, S2, S3 и S4

CALL CHWRIT (2, VEC1, 6, S1, RC1)	S1 => MOSKVA
CALL CHWRIT (2, VEC2, 7, S2, RC2)	S2 => A+B-C*3
CALL CHWRIT (2, VEC3, 26, S3, RC3)	S3 => CLC DEFINITION MODULE
CALL CHWRIT (2, VEC4, 14, S4, RC4)	S4 => IMPLEMENTATION

Выбор типа "2" для хранения ПС был взят для примера. (Тип "3" или "4" также возможен).

S1...S4 являются переменными типа INTEGER, предназначенными для хранения числовых идентификаторов последовательностей символов (ЧИПС), сгенерированных ПС.

4.2. Создание и связывание ПС

CALL SUBSTR (S3, 1, 8, S5, RC5)	S5 => CLC
CALL SUBSTR (S3, 19, 8, S6, RC6)	S6 => MODULE
CALL JOIN (S5, S4, S7, RC7)	S7 => CLC IMPLEMENTATION
CALL DELETE (S5, RC5)	S5 =>
CALL JOIN (S7, S6, S8, RC8)	S8 => CLC IMPLEMENTATION
CALL DELETE (S6, RC6)	MODULE
CALL DELETE (S7, RC7)	S6 =>
CALL CHREAD (S8, T8, VECTOR, L8, RC8)	S7 =>

Здесь

Имя	значение
T8	2
VECTOR	CLC...IMPLEMENTATION_MODULE
L8	30

CALL DELETE (S8, RC8)

Операции DELETE в последовательности вызовов можно опускать. Они служат для экономии памяти.

4.3. Поиск и сравнение ПС

-ПОИСК

CALL SUBSTR (S1, 4, 2, S5, RC5)	S5 => KV
CALL INDEX (S1, 1, S5, 2, P5, RC5)	

значение P5: 4
 т.е. "KV" начинается на позиции 4 в ПС S1 .

- сравнение

а) CALL CHCOMP (S1,S5,C5)
CALL DELETE (S5,RC5) значение C5 : 2 (больше)

б) CALL SUBSTR(S2,1,1;S5,RC5) S5⇒A
CALL SUBSTR(S2,4,1;S6,RC6) S6⇒ -
CALL SUBSTR(S2,3,5;S7,RC7) S7⇒ B-C*3
CALL JOIN(S5,S6,S8,RC8) S8⇒A -
CALL JOIN(S8,S7,S9,RC9) S9⇒A-B-C*3
CALL CHCOMP(S2,S9,C9)
CALL DELETE(S5,RC5) значение C9:1 (меньше)

4.4. Конструирование ПС

- уничтожение частного ПС

CALL SUBSTR(S2,1,3;S5,RC5) S5⇒A+B
CALL IMPAND(S2,2,3;RC2) S2⇒A+*3
CALL CHREAD(S2,T2,VECTOR,L2,RC2)
здесь ИМЯ значение
T2 2
VECTOR A+*3
L2 4

- вставка ПС

CALL INSERT(S2,2,S5,RC2) S2⇒A+A+B*3
CALL CHREAD(S2,T2,VECTOR,L2,RC2)
здесь ИМЯ значение
T2 2
VECTOR A+A+B*3
L2 7

5. Заключение

Операции для обработки ПС принимались как базовые функции в программах, расширяющих инструментальный комплекс Ф-технологии. Показано, что применение операций для обработки ПС полезно, если массивы или текстовые файлы не строго форматированы.

Преимущество разработанных операций для ПС, по сравнению с теми же операциями в Фортран-77, состоит в большей гибкости. Возможно динамически генерировать и уничтожать ПС практически любой длины.

В настоящее время операции для обработки ПС реализуют функции управления базами данных в разрабатываемой системе для объектно-ориентированного программирования. Кроме того, разработанный инструмент был использован для контроля соответствия модульной спецификации реализации модуля в разработанных системах программ.

ЛИТЕРАТУРА

1. Корнейчук А.А. ОИЯИ, II-80-382, Дубна, 1980.
2. Железнова К.М., Корнейчук А.А., Шарапова Э.В. ОИЯИ, 5-83-226, Дубна, 1983.
3. Железнова К.М., Корнейчук А.А., Шарапова Э.В. ОИЯИ, II-85-805, Дубна, 1985.
4. Фролов Г.Д., Олжнин В.Ю. Практический курс программирования на языке PL/1. М.: Наука, 1983.
5. Organick E.I.: The Multics System: An examination of its structure MIT Press, Cambridge, Mass, 1972.
6. Вирт Н. Программирование на языке МОДУЛА-2. М.: Мир, 1987.
7. Корнейчук А.А., Шарапова Э.В. Фортраноориентированная технология программирования. В сб.: 2 Всесоюзная конференция "Технология программирования", тезисы докладов, ч. I, Киев, ИК АН УССР, 1986, с. II7-II8.
8. Meyer B. Object - oriented design, First European software Engineering Conference, Strasbourg, 8-11, September, 1987.

Рукопись поступила в издательский отдел
30 сентября 1988 года.