


СТРОКИ




ПРОВЕРЬ ЗАПИСЬ




ПРАВИЛА ЗАНЯТИЯ

1. вопросы в чате можно задавать
в любое время
2. вопросы голосом задаем
по поднятой руке в Zoom
3. ответы на вопросы будут
в запланированных местах



ПЛАН ЛЕКЦИИ

1. Кодировки
2. Виды строк
3. Тонкости строк в Go



Terminal: deep_golang × + ∨



СТРОКА

Тип данных, значениями которого является
произвольная последовательность символов алфавита

**КАК РЕАЛИЗОВАТЬ
СТРОКУ?**

EXAMPLE

String implementation

Чтобы одни и те же числа отображались на разных компьютерах
одинаково – нужен стандарт по кодированию этих символов

ASCII TABLE

Decimal	Hex	Char	Decimal	Hex	Char	Decimal	Hex	Char	Decimal	Hex	Char
0	0	[NULL]	32	20	[SPACE]	64	40	@	96	60	`
1	1	[START OF HEADING]	33	21	!	65	41	A	97	61	a
2	2	[START OF TEXT]	34	22	"	66	42	B	98	62	b
3	3	[END OF TEXT]	35	23	#	67	43	C	99	63	c
4	4	[END OF TRANSMISSION]	36	24	\$	68	44	D	100	64	d
5	5	[ENQUIRY]	37	25	%	69	45	E	101	65	e
6	6	[ACKNOWLEDGE]	38	26	&	70	46	F	102	66	f
7	7	[BELL]	39	27	'	71	47	G	103	67	g
8	8	[BACKSPACE]	40	28	(	72	48	H	104	68	h
9	9	[HORIZONTAL TAB]	41	29	)	73	49	I	105	69	i
10	A	[LINE FEED]	42	2A	*	74	4A	J	106	6A	j
11	B	[VERTICAL TAB]	43	2B	+	75	4B	K	107	6B	k
12	C	[FORM FEED]	44	2C	,	76	4C	L	108	6C	l
13	D	[CARRIAGE RETURN]	45	2D	-	77	4D	M	109	6D	m
14	E	[SHIFT OUT]	46	2E	.	78	4E	N	110	6E	n
15	F	[SHIFT IN]	47	2F	/	79	4F	O	111	6F	o
16	10	[DATA LINK ESCAPE]	48	30	0	80	50	P	112	70	p
17	11	[DEVICE CONTROL 1]	49	31	1	81	51	Q	113	71	q
18	12	[DEVICE CONTROL 2]	50	32	2	82	52	R	114	72	r
19	13	[DEVICE CONTROL 3]	51	33	3	83	53	S	115	73	s
20	14	[DEVICE CONTROL 4]	52	34	4	84	54	T	116	74	t
21	15	[NEGATIVE ACKNOWLEDGE]	53	35	5	85	55	U	117	75	u
22	16	[SYNCHRONOUS IDLE]	54	36	6	86	56	V	118	76	v
23	17	[END OF TRANS. BLOCK]	55	37	7	87	57	W	119	77	w
24	18	[CANCEL]	56	38	8	88	58	X	120	78	x
25	19	[END OF MEDIUM]	57	39	9	89	59	Y	121	79	y
26	1A	[SUBSTITUTE]	58	3A	:	90	5A	Z	122	7A	z
27	1B	[ESCAPE]	59	3B	;	91	5B	[	123	7B	{
28	1C	[FILE SEPARATOR]	60	3C	<	92	5C	\	124	7C	
29	1D	[GROUP SEPARATOR]	61	3D	=	93	5D	]	125	7D	}
30	1E	[RECORD SEPARATOR]	62	3E	>	94	5E	^	126	7E	~
31	1F	[UNIT SEPARATOR]	63	3F	?	95	5F	_	127	7F	[DEL]

American Standart Code for Information Interchange

- от **0** до **127** (128 значений)
- с **0** до **31** – управляющие символы (нечитаемые)
- с **31** до конца символы, имеющие внешний вид
- **128** свободных значений (пустой старший бит)

0	1	1	1	1	1	1	1
---	---	---	---	---	---	---	---

EXAMPLE

Letter order

EXAMPLE

Letter frequencies

**КАК БЫТЬ ЕСЛИ
В АЛФАВИТЕ МНОГО
СИМВОЛОВ?**



0	1	1	1	1	1	1	1
---	---	---	---	---	---	---	---

Решили расширить **ASCII**, введя кодовые страницы. **Кодовая страница** – набор из **256** символов для конкретного языка (первые 128 символов символов совпадают с ASCII, а остальные 128 символов для конкретного языка)

256 СИМВОЛОВ НЕ ХВАТАЛО, ЧТОБЫ ОХВАТИТЬ
ВСЕ ВОЗМОЖНЫЕ ЯЗЫКИ!

UNICODE

- Первые 128 символов одинаковые с ASCII
- В первой версии два байта для хранения (65 536 значений)



КАКИЕ ПОЯВИЛИСЬ ПРОБЛЕМЫ


когда решили кодировать символы двумя байтам?

ПРОБЛЕМА №1

Излишнее потребление памяти


4 байта

"HI" (Unicode)



2 байта

"HI" (ASCII)



ПРОБЛЕМА №2

Порядок следования байтов

4 байта

"HI" (Big Endian)

00	68
----	----

00	69
----	----

4 байта

"HI" (Little Endian)

68	00
----	----



69	00
----	----

UCS-2

Добавилось два дополнительных байта
BOM (Unicode byte order mask)

“H”

“I”



Big Endian



Little Endian

Terminal: deep_golang × + ∨



UTF-8

Новая кодировка, которая стала доминирующей в интернете. Идея заключалась в том, чтобы сделать коды символов не фиксированной, а переменной длины от 1 до 4 байт – первые 128 символов юникода совпадают с символами ASCII

1 байт (от 0 до 7 бит)



2 байта (от 8 до 11 бит)



3 байта (от 12 до 16 бит)



4 байта (от 17 до 21 бита)



Вместо BOM используются маски кодов – если BigEndian, то первый байт будет начинаться с 0, 110, 1110 или 11110, а если LittleEndian то первый байт будет начинаться с 10

**КАКИЕ ПОЯВИЛИСЬ
ПРОБЛЕМЫ У UTF-8?**

Переменная длина символов увеличила время обработки строк,
так как каждый символ нужно было проверять на его длину,
поэтому код стал работать медленнее, из-за этого некоторые
языки программирования стали использовать другие кодировки

Terminal: deep_golang × + ∨



UTF-16

Один из способов кодирования символов
в виде последовательности 16-битных слов

Terminal: deep_golang × + ∨



UTF-32


Один из способов кодирования символов,
использующий для кодирования любого
символа ровно 32 бита

СРАВНЕНИЕ

	Размер	ВОМ	Скорость обработки
UTF-8	От 1 до 4 байт	Нет	Медленная
UTF-16	2 или 4 байта	Да	Средняя
UTF-32	4 байта	Да	Быстрая

FAQ

Строки




ВИДЫ СТРОК

КАК МОЖНО
РЕАЛИЗОВАТЬ СТРОКУ?

НУЛЬ–ТЕРМИНИРОВАННЫЕ СТРОКИ

Идея заключается в использовании завершающего байта – как правило, символ с кодом 0 выбирается в качестве признака конца строки, и строка хранится как последовательность байтов от начала до конца (пример – язык C)



**КАКИЕ ПРОБЛЕМЫ У НУЛЬ–
ТЕРМИНИРОВАННЫХ СТРОК?**

PASCAL СТРОКИ

Идея заключается в использовании отдельного места в памяти для хранения размера строки


str



**МОЖНО ЛИ МЕНЯТЬ
СИМВОЛЫ В СТРОКАХ?**



НЕИЗМЕНЯЕМЫЕ СТРОКИ

Идея заключается в том, что строку **нельзя изменить** — как правило, конкатенация строк возвращает новую строку (пример — язык Go, Java, C#, JavaScript)




ИЗМЕНЯЕМЫЕ СТРОКИ

Идея заключается в том, что строку **можно изменить** – как правило, растёт по такому же сценарию, как и срез (пример – язык C++)



**КАКИЕ ПРЕИМУЩЕСТВА
И НЕДОСТАТКИ У НЕИЗМЕНЯЕМЫХ
И ИЗМЕНЯЕМЫХ СТРОК?**

Какую оптимизацию можно придумать по работе с маленькими строками?



SSO

Small String Optimization





ЧТО ДЕЛАТЬ

когда нужно удалять символы из разных мест строки
и добавлять символы в разные места строки?

СПИСКИ СИМВОЛОВ



Идея заключается в том, что строку можно
представить в виде СВЯЗНОГО СПИСКА СИМВОЛОВ
(пример – язык Erlang и Haskell)



Есть еще интересные виды строк...

COW СТРОКИ

Copy-on-Write – идея заключается в том, что при чтении строки используется общая память, в случае изменения – создается копия




ИНТЕРНИРОВАНИЕ СТРОК

Идея заключается в том, чтобы хранить в памяти только один экземпляр типа строки для идентичных строк



FAQ

Виды строк



ТОНКОСТИ СТРОК В GO

СТРОКА В GO

Последовательность байт
и ничего более



```
1 type _string struct {  
2     elements *byte // underlying bytes  
3     len      int    // number of bytes  
4 }
```


Некоторые считают, что строки в **Go** всегда имеют кодировку **UTF-8**, но это не так – строки представляют собой последовательность произвольных байтов (например, при чтении файла – мы можем прочитать содержимое в абсолютно любой кодировке).

Но исходный код представлен в **UTF-8**, то есть все строковые литеры кодируются в последовательность байтов с использованием **UTF-8**

Terminal: deep_golang × + ∨



RUNE

Кодовые точки представлены в Go как значения рун,
в **Go rune** — это не что иное, алиас типа `int32`

EXAMPLE

Encodings

EXAMPLE

Interpreted and raw strings


СТРОКИ В GO

- строки используются, как константы (неизменяемые)
- строки можно конкатенировать с использованием операторов `+` и `+=`




```
1 str1 := "test"  
2 str2 := "-pro"  
3 str  := str1 + str2
```

str1



str2



str



EXAMPLE

Speed concatenation

String concatenations with the + operator are specially optimized so that only one memory allocation is made in each of such concatenations, no matter how many strings are concatenated in a $s_0 + s_1 + \dots + s_n$ expression

**КАК ДЕЛАТЬ КОНКАТЕНАЦИЮ
СТРОК БЫСТРЕЕ?**

ПЕРЕРЫВ 5 МИНУТ

EXAMPLE

String Builder

**КАК РЕАЛИЗОВАТЬ
STRINGS.BUILDER?**

EXAMPLE

String Builder implementation

EXAMPLE

String Builder copy

СТРОКИ В GO

Строки можно сравнивать между собой
с использованием операторов `!=`, `==`, `<`, `>`, `<=` и `>=`
(строки сравниваются друг с другом байт за байтом)

Сравнение строк на равенство реализовано таким образом,
что сначала проверяются размеры строк, затем адреса
указателей и только потом итерация по каждому байту

EXAMPLE

Speed comparison

СТРОКИ В GO

- можно узнать длину строки с использованием функции `len(x)`
- можно обратиться к n-ому байту строки с использованием оператора `[x]`
- можно получить подстроку с использованием оператора слайсинга `[x:x]`
- нельзя взять указатель на один из байт строки

**ЧТО ВОЗВРАЩАЕТ
ФУНКЦИЯ LEN() ДЛЯ СТРОКИ?**

EXAMPLE

String len

Функция `len()` возвращает количество байт – если нужно
получить количество рун, то можно использовать
`utf8.RuneCountInString()` (но она работает за линию)

Вызов функции `len()` для константной строки
вычисляется на этапе компиляции, а не в рантайме




```
1 const str = "hello world"  
2 length = len(str) // => 11
```

**КАК ПОЛУЧИТЬ ПОДСТРОКУ
ИЗ СТРОКИ?**

В результате получается строка, а не срез



```
1 str := "test"  
2 substr := str[1:3]
```



EXAMPLE

Substring

**ПОЧЕМУ НЕЛЬЗЯ ВЗЯТЬ УКАЗАТЕЛЬ
НА ОДИН ИЗ БАЙТОВ СТРОКИ?**

EXAMPLE


Byte address

EXAMPLE

Mutate string 1

EXAMPLE

Mutate string 2



EXAMPLE

`const strings`

СТРОКИ В GO


- можно конвертировать в `[]byte` и наоборот
- можно конвертировать в `[]rune` и наоборот

При конвертации будет
аллокация памяти - так как
строки неизменяемые в отличии
от срезов, поэтому они не
должны разделять данные



```
1 str := "test"  
2 slice := []byte(str)
```

str



slice



EXAMPLE

Byte slice to string

EXAMPLE

String to byte slice

EXAMPLE

Conversion deprecated

EXAMPLE

Rune to bytes test

ОПТИМИЗАЦИИ КОМПИЛЯТОРА

- преобразование из строки в байтовый срез, которое происходит внутри range
- преобразование из среза байт в строку, которое используется в качестве ключа словаря во время чтения из словаря
- преобразование из среза байт в строку, которое используется при сравнении
- преобразование из среза байт в строку, которое используется при конкатенации строк (по крайней мере одно из значений объединенной строки должно являться непустой строковой константой)

EXAMPLE

Conversion optimizations

Нельзя конвертировать `[]rune` в `[]byte` и наоборот

EXAMPLE

Runes to bytes

EXAMPLE

Rune to bytes test

**КАК МОЖНО ИТЕРИРОВАТЬСЯ
ПО СТРОКЕ?**

EXAMPLE

Strings range

ЕСТЬ ЛИ РАЗНИЦА

в производительности при итерации
по срезу байт и строке?

EXAMPLE


Range ASCII vs UTF-8

**ЧТО ПРОИСХОДИТ, КОГДА СТРОКА
ПЕРЕДАЕТСЯ В ФУНКЦИЮ?**




```
1 func process(temp string) {  
2     ...  
3 }  
4  
5 func main() {  
6     str := "test"  
7     process(str)  
8 }
```

str



temp



ГДЕ АЛЛОЦИРУЮТСЯ СТРОКИ?

EXAMPLE

BCE optimization

Строковые литералы могут храниться в TEXT (read only)
или DATA сегментах, а строки, созданные динамически во
время выполнения, хранятся либо в STACK, либо в HEAP –
в зависимости от использования

<> Documentation

Overview

The unique package provides facilities for canonicalizing ("interning") comparable values.

Index

type `Handle`

`func Make[T comparable](value T) Handle[T]`

`func (h Handle[T]) Value() T`

EXAMPLE

Unique

EXAMPLE

String operations

EXAMPLE

Append and copy

EXAMPLE

Leak with string

Предотвращение утечки



```
1 str := string([]byte(data[i+2 : i+22]))
```

EXAMPLE

BCE optimization

EXAMPLE

Trim right and trim suffix

<> Documentation

Overview

The unique package provides facilities for canonicalizing ("interning") comparable values.

Index

type `Handle`

`func Make[T comparable](value T) Handle[T]`


`func (h Handle[T]) Value() T`

EXAMPLE

Unique

FAQ

Тонкости строк в Go



ПОЖАЛУЙСТА, ЗАПОЛНИ ОПРОС О ЗАНЯТИИ

Ссылка в чате и в группе участников

