

# Tema 1. Codificación y sus usos

José A. Montenegro

Dpto. Lenguajes y Ciencias de la Computación  
ETSI Informática. Universidad de Málaga  
monte@lcc.uma.es 

26 de septiembre de 2013

## 1 Mensajes

- Definición Informal

## 2 Codificación

- Aproximación al problema
- Razones codificación mensajes

## 3 Definiciones Formales

- Alfabetos, Símbolos, Mensajes y Cadena
- Código, Palabra Codificada
- Concatenación
- Unívocamente Decodificable

## 4 Otros Alfabetos y Codificación

- Código Morse
- Código ASCII
- Codificación PEM
- Codificación de datos 2D
- Ejemplo Doble Codificación

# Mensajes

La primera tarea que debemos realizar es establecer el modelo matemático de un mensaje.

## Ejemplo 1

*Muchos mensajes están escritos en un lenguaje natural, como es el caso del Español.*

*Estos mensajes contienen símbolos y los símbolos forman palabras, los cuales constituyen frases.*

*Los mensajes pueden ser enviados de una persona a otra utilizando varios medios: una nota manuscrita, un correo electrónico, SMS, twitts, etc.*

## Ejemplo 2

*Dispositivos como los escáners y cámaras digitales producen mensajes utilizando impulsos electrónicos. Estos mensajes pueden ser enviados de un dispositivo a otro mediante cables, o mediante ondas de radio.*

Las definiciones formales basadas en estos ejemplos serán establecidas más adelante.

- Por ahora, estableceremos que un **mensaje** es una secuencia de símbolos, teniendo en cuenta que el orden de los símbolos es muy importante.
- La **principal función** de un mensaje es transportar información de un ente a otro.
- Los elementos de la comunicación deben estar de acuerdo en el mismo conjunto de símbolos, denominado **Alfabeto**.

### Ejemplo 3

Denotamos por  $\mathbb{A}$  el alfabeto que tiene 28 símbolos, las letras  $\{A, B, C, D, E, F, G, H, I, J, K, L, M, N, \tilde{N}, O, P, Q, R, S, T, U, V, W, X, Y, Z\}$  y un espacio, el cual es denotado por  $\sqcup$  (28 ó 0).

Utilizaremos el alfabeto  $\mathbb{A}$  para representar los mensajes escritos en Español.

Ignoramos elementos del idioma, distinción entre mayúsculas y minúscula, así como marcas de puntuación.

En un lugar de la Mancha ...

es reducido al siguiente mensaje utilizando el alfabeto  $\mathbb{A}$ .

EN  $\sqcup$  UN  $\sqcup$  LUGAR  $\sqcup$  DE  $\sqcup$  LA  $\sqcup$  MANCHA

## Ejemplo 4

*El alfabeto  $\mathbb{B}$  tiene dos símbolos, 0 y 1, determinados dígitos binarios o bits.*

*Bits 0 y 1 son implementados electrónicamente como estados APAGADO y ENCENDIDO.*

*En la práctica, los bits son combinados en grupos, como palabras de 32 bits.*

*Cualquier mensaje transmitido electrónicamente es esencialmente una secuencia de bits.*

# Codificación

- **Codificar** es definido como una regla que permite una sustitución de un mensaje por otro mensaje.
- Los mensajes no tienen que compartir los mismos alfabetos.

## Ejemplo 5

*Una simple regla para codificar un mensaje en el alfabeto  $\mathbb{A}$  utilizando el mismo alfabeto es: escribir cada palabra al revés. Por lo que el mensaje:*

NOS □ VEMOS □ PRONTO *sería* SON □ SOMEV □ OTNORP

## Ejemplo 6

*Una regla para codificar mensajes en  $\mathbb{A}$  utilizando el alfabeto  $\mathbb{B}$  es: reemplazar las vocales por ceros y las consonantes por unos. Por lo que el mensaje:*

NOS □ VEMOS □ PRONTO *sería* 10110101110110

Hasta ahora ejemplos mostrados son artificiales tienen un valor limitado.

Debemos mirar los propósitos de la codificación para acercarnos a la realidad.

Hay tres razones principales para codificar un mensaje:

- Económicas:** Situaciones es necesario utilizar un alfabeto menor que los lenguajes naturales. O es deseable el mensaje más pequeño, esto ha dado lugar al desarrollo de técnicas para la *Compresión de datos*.
- Fiabilidad:** El proceso de transmisión no está libre de “ruido” que proporciona alteraciones en los mensajes. Necesario desarrollar *Corrección de los Errores*.
- Seguridad:** Usualmente es necesaria la confidencialidad de los mensajes. Históricamente, desarrollada en las comunicaciones diplomáticas y militares, pero hoy en día juegan en todas las transacciones económicas. Este área de codificación es conocida como *Criptografía*.

- Otros usos como *Algoritmos de Predicción* en el caso de dispositivos de tamaño reducido.

## Ejercicio 1

*Los siguientes mensajes son versiones codificadas del Español. Determine las reglas de codificación utilizadas y encuentre el mensaje original.*

20 22 5 19 21 5

10100 10110 00101 10011 10101 00101

# Definiciones Formales

## Definición 1 (Alfabeto y Símbolos)

*Un Alfabeto es un conjunto finito  $S$ . Los miembros de  $S$  son denominados símbolos.*

## Definición 2 (Mensaje, cadena y palabra)

*Un mensaje en el alfabeto  $S$  es una secuencia finita de miembros de  $S$ :*

$$x_1x_2 \dots x_n (x_i \in S, 1 \leq i \leq n).$$

*Un mensaje es una cadena de miembros de  $S$ , o una palabra en  $S$ , donde  $n$  es la longitud del mensaje, cadena o palabra.*

El conjunto de todas las cadenas de longitud  $n$  es representado por  $S^n$ . Por ejemplo, cuando  $S = \mathbb{B}$  y  $n=3$ , el conjunto de  $\mathbb{B}^3$  está formado por las siguientes cadenas:

000 001 010 011 100 101 110 111

El conjunto de todas las cadenas en  $S$  es denotado como  $S^*$ :

$$S^* = S^0 \cup S^1 \cup S^2 \dots S^{n-1} \cup S^n$$

Aunque  $S^0$  consiste de la cadena con longitud cero, o la cadena sin símbolos.

### Definición 3 (Palabra Codificada)

Sean dos alfabetos  $S$  y  $T$  y una función  $c$  inyectiva  $c : S \rightarrow T^*$ .

Para cada símbolo  $s \in S$  la cadena  $c(s) \in T^*$  es denominada la **palabra codificada** para  $s$ .

### Definición 4 (Código)

El conjunto de todas las palabras codificadas,  $C = \{c(s) | s \in S\}$ , es denominada como **código**.

Cuando  $|T| = 2$  el código es denominado binario, en el caso que  $|T| = 3$  es ternario y en general cuando  $|T| = b$ , es  $b$ -nario.

Por ejemplo, sea  $S = \{x, y, z\}$ ,  $T = \mathbb{B}$ , y definimos

$$c(x) = 0, c(y) = 10, c(z) = 11.$$

Tenemos un código binario, y el conjunto de palabras codificadas es  $C = \{0, 10, 11\}$

- Un código  $c$  asigna a cada símbolo en  $S$  una cadena de símbolos en  $T$ , que pueden ser de distinta longitud.
  - ▶ Queremos construir un código para el alfabeto  $\mathbb{A}$  utilizando el alfabeto binario  $\mathbb{B}$ .
  - ▶ Si establecemos palabras codificadas de longitud 4, sería como sigue:
$$A \mapsto 0000 \quad B \mapsto 0001 \quad C \mapsto 0010 \dots$$
- $c$  debe ser un función inyectiva, para que  $c$  no asigne el mismo código a dos símbolos diferentes. En otras palabras, si  $c(s) = c(s')$  entonces  $s = s'$ .
  - ▶ En este caso solamente tenemos 16 cadenas de longitud 4 en  $\mathbb{B}$ , por lo que los 28 símbolos en  $\mathbb{A}$  no pueden ser asignados a símbolos diferentes.

Previamente solamente hemos considerado la codificación de símbolos individuales, aunque puede realizarse una extensión a mensajes (cadenas de símbolos).

### Definición 5 (Concatenación)

Si  $c : S \rightarrow T^*$  es un código, extendemos  $c$  a  $S^*$  como sigue. Dado una cadena  $x_1x_2 \dots x_n$  en  $S^*$ , definimos:

$$c(x_1x_2 \dots x_n) = c(x_1)c(x_2) \dots c(x_n)$$

Este proceso es conocido como concatenación, donde extendemos la función  $c : S^* \rightarrow T^*$

No siempre es posible recuperar la cadena original desde la versión codificada. Por ejemplo, sea  $S = \{x, y, z\}$ , y define  $c : S \rightarrow B^*$  como:

$$x \mapsto 0, y \mapsto 01, z \mapsto 10$$

Si tenemos la cadena codificada 010100, que es el resultado de codificar una cadena en  $S^*$  utilizando  $c$ . En una primera aproximación podemos obtener dos resultados:

$$xzzx \mapsto 010100, yyxx \mapsto 010100$$

Esta situación debe ser evitada siempre que sea posible.

## Definición 6 (Unívocamente Decodificable)

El código  $c : S \rightarrow T^*$  es unívocamente decodificable (UD) si la función extendida  $c : S^* \rightarrow T^*$  es una función inyectiva, por tanto cada cadena en  $T^*$  corresponde a un mensaje en  $S^*$

A lo largo del curso, mostraremos como la propiedad UD puede ser garantizada.

### Ejercicio 2

Un código binario es definido por las siguientes reglas:

$$s_1 \mapsto 10, s_2 \mapsto 010, s_3 \mapsto 100$$

Muestra mediante un ejemplo que el código no es unívocamente decodificable.

# Código Morse

<b>A</b>	.-	<b>M</b>	--	<b>Y</b>	-.--	<b>6</b>	-....
<b>B</b>	-...	<b>N</b>	-. .	<b>Z</b>	--..	<b>7</b>	--...
<b>C</b>	-.-.	<b>O</b>	---	<b>Ä</b>	.-.-	<b>8</b>	---..
<b>D</b>	-..	<b>P</b>	.-.	<b>Ö</b>	---.	<b>9</b>	----.
<b>E</b>	.	<b>Q</b>	--.-	<b>Ü</b>	..--	,	.-.-.-
<b>F</b>	..-.	<b>R</b>	.-.	<b>Ch</b>	----	?	---..
<b>G</b>	--.	<b>S</b>	...	<b>0</b>	-----	!	..-..
<b>H</b>	....	<b>T</b>	- .	<b>1</b>	.-----	:	---...
<b>I</b>	..	<b>U</b>	..-	<b>2</b>	..----	“	.-.-.
<b>J</b>	.----	<b>V</b>	...-	<b>3</b>	...--	‘	.-----.
<b>K</b>	-. -	<b>W</b>	.- -	<b>4</b>	....-	=	-...-
<b>L</b>	.-..	<b>X</b>	-.- -	<b>5</b>	.....		

# Código ASCII

DEC	HEX	CHAR									
0	00	NUL	32	20	SP	64	40	@	96	60	`
1	01	SOH	33	21	!	65	41	A	97	61	a
2	02	STX	34	22	"	66	42	B	98	62	b
3	03	ETX	35	23	#	67	43	C	99	63	c
4	04	EOT	36	24	\$	68	44	D	100	64	d
5	05	ENQ	37	25	%	69	45	E	101	65	e
6	06	ACK	38	26	&	70	46	F	102	66	f
7	07	BEL	39	27	'	71	47	G	103	67	g
8	08	BS	40	28	(	72	48	H	104	68	h
9	09	HT	41	29	)	73	49	I	105	69	i
10	0A	LF	42	2A	*	74	4A	J	106	6A	j
11	0B	VT	43	2B	+	75	4B	K	107	6B	k
12	0C	FF	44	2C	,	76	4C	L	108	6C	l
13	0D	CR	45	2D	-	77	4D	M	109	6D	m
14	0E	SO	46	2E	.	78	4E	N	110	6E	n
15	0F	SI	47	2F	/	79	4F	O	111	6F	o
16	10	DLE	48	30	0	80	50	P	112	70	p
17	11	DC1	49	31	1	81	51	Q	113	71	q
18	12	DC2	50	32	2	82	52	R	114	72	r
19	13	DC3	51	33	3	83	53	S	115	73	s
20	14	DC4	52	34	4	84	54	T	116	74	t
21	15	NAK	53	35	5	85	55	U	117	75	u
22	16	SYN	54	36	6	86	56	V	118	76	v
23	17	ETB	55	37	7	87	57	W	119	77	w
24	18	CAN	56	38	8	88	58	X	120	78	x
25	19	EM	57	39	9	89	59	Y	121	79	y
26	1A	SUB	58	3A	:	90	5A	Z	122	7A	z
27	1B	ESC	59	3B	;	91	5B	[	123	7B	{
28	1C	FS	60	3C	<	92	5C	\	124	7C	
29	1D	GS	61	3D	=	93	5D	]	125	7D	}
30	1E	RS	62	3E	>	94	5E	^	126	7E	~
31	1F	US	63	3F	?	95	5F	_	127	7F	DEL

# Codificación PEM



Figura 1 : Certificado Clave Pública. Windows

```
-----BEGIN CERTIFICATE-----
DwYDVQLEwEeHRvIEsDQzEOMAwGA1UEAxMFbW9udGUxHzAdBgkqhkiG9w0BCQEW
EG1vbmlRlQgYy51bWVhZXMwgZ8wDQYJKoZIhvcNAQEBBQADgY0AMIGJAoGBALJS
Ms+RrNOI55b5peRaLvNjwITCbWAZDBhMeL23qx44mLbXRrsf2Ji/kkVmk3psksY7
jekYaDntGVpsBydoWbsnMgmD/IK5yQ7iteAuFwT3fprHoG3oJ3RrIvXT7zTwDlrv
MT9fPxx6BpIPBYKWK0cMPLhgJfHwsMfPNYIb3pvhAgMBAAGgADANBgkqhkiG9w0B
AQQFAAOBgQBp2AMVHtow2SRqRenemrmyKzH8sYlothzPKcqSgC34bDecSuzIMJYw
WKILi0TqZnZvNskZEeDhq6rwhWcTGdGC19SaccKky02BfMrSR-WiwndOq8Rrz7J
6QXEBLdeVr4sR7WlwNSKZAxivHydS8MLbuRhZV3eQm7yEi0UJe22qA-----
-----END CERTIFICATE-----
```

Figura 2 : Certificado Clave Pública. PEM

# Codificación de datos 2D



Figura 3 : Datamatrix



Figura 4 : QRCode

# Ejemplo Doble Codificación

Num. Billete: 7233000159910  
Localizador: 95DUHK Tarifa IDA Y VUELTA

<b>Salida</b>	<b>MALAGA</b>	<b>26/02/2011</b>	<b>10:40</b>
<b>Llegada</b>	<b>SEVILLA SJ</b>	<b>26/02/2011</b>	<b>13:10</b>
<b>MD</b>	<b>13903</b>	<b>Turista</b>	
<b>Coche</b>	<b>1</b>	<b>Plaza: 033</b>	

**Total: 17,90 € IVA(8%) 1,33 €**

Transp.: 1071

Conservese para la vuelta. Validez de regreso 15 días  
En el viaje de vuelta es obligatorio presentar este billete y el billete de formalización de vuelta

11:45:54 23/02/2011

Figura 5 : Billete de IDA

723300015991054413510032602111390300103301695DUHK



**7233000159910 5441351003 260211 13903 001 033 016 95DUHK**

Num. Billete: 7233000159910

Fecha: 260211

MD: 13903

Coche: 001

Plaza: 033

Localizador: 95DUHK

Num. Billete: 7233000159936  
 Localizador: 95DUHK Tarifa FORMALIZACION IV **renfe** 

<b>Salida</b>	<b>SEVILLA SJ</b>	<b>28/02/2011</b>	<b>13:05</b>
<b>Llegada</b>	<b>MALAGA</b>	<b>28/02/2011</b>	<b>15:40</b>
<b>MD</b>	<b>13904</b>	<b>Turista</b>	
<b>Coche</b>	<b>1</b>	<b>Plaza: 030</b>	

**Total: 17,90 € IVA(8%) 1,33 €**

**Transp.: 1071**

Billete de ida: 7233000159910

11:45:54 23/02/2011 

Figura 6 : Billete de Vuelta

**7233000159910 5441351003 260211 13903 001 033 016 95DUHK**  
**7233000159936 5100354413 280211 13904 001 030 018 95DUHK**

**José A. Montenegro Montes**  
*Dpto. Lenguajes y Ciencias de la Computación*  
*ETSI Informática. Universidad de Málaga*  
**monte@lcc.uma.es**  
**twitter** 

