

Studienwoche 2022

Kodierung

08. Juni 2023

Kodierung

1. Warum Kodierung
2. ASCII / ISO-8859-1 (Latin 1)
3. UTF-8
4. Base64

Studienwoche 2023

Warum Kodierung

- ```

0000h: 69 63 68 20 62 69 6E 20 65 69 6E 20 64 6F 6B 75 ich bin ein doku
0010h: 6D 65 6E 74 0A ment.

```

Studienwoche 2023

# ASCII / ISO-8859-1

# ASCII / ISO-8859-1

- ASCII ist die früher im Amerikanischen Sprachraum benutzte Kodierung
- Es gibt die Latin-1 Extensions, welche die Akzente die in Deutsch/Französisch und anderen West-Europäischen Sprachen vorkommen, kodieren
- Kodiert werden alle möglichen Zeichen mit maximal einem Byte (8 bits)
- Es sind also maximal 255 verschiedene Zeichen möglich
- Dies reicht natürlich nicht für alle Sprachen (Kyrillisch, Arabisch, Türkisch usw.)

# ASCII / ISO-8859-1

|    |    |    |     |    |   |     |    |   |     |    |   |
|----|----|----|-----|----|---|-----|----|---|-----|----|---|
| 34 | 22 | "  | 98  | 62 | b | 162 | A2 | ¢ | 226 | E2 | â |
| 35 | 23 | #  | 99  | 63 | c | 163 | A3 | £ | 227 | E3 | ã |
| 36 | 24 | \$ | 100 | 64 | d | 164 | A4 | ¤ | 228 | E4 | ä |
| 37 | 25 | %  | 101 | 65 | e | 165 | A5 | ¥ | 229 | E5 | å |
| 38 | 26 | &  | 102 | 66 | f | 166 | A6 | ¦ | 230 | E6 | æ |
| 39 | 27 | '  | 103 | 67 | g | 167 | A7 | § | 231 | E7 | ç |
| 40 | 28 | (  | 104 | 68 | h | 168 | A8 | ¨ | 232 | E8 | è |
| 41 | 29 | )  | 105 | 69 | i | 169 | A9 | © | 233 | E9 | é |
| 42 | 2A | *  | 106 | 6A | j | 170 | AA | ª | 234 | EA | ê |
| 43 | 2B | +  | 107 | 6B | k | 171 | AB | « | 235 | EB | ë |
| 44 | 2C | ,  | 108 | 6C | l | 172 | AC | ¬ | 236 | EC | ì |
| 45 | 2D | -  | 109 | 6D | m | 173 | AD |   | 237 | ED | í |
| 46 | 2E | .  | 110 | 6E | n | 174 | AE | ® | 238 | EE | î |
| 47 | 2F | /  | 111 | 6F | o | 175 | AF | ¯ | 239 | EF | ï |
| 48 | 30 | 0  | 112 | 70 | p | 176 | B0 | ° | 240 | F0 | ð |
| 49 | 31 | 1  | 113 | 71 | q | 177 | B1 | ± | 241 | F1 | ñ |
| 50 | 32 | 2  | 114 | 72 | r | 178 | B2 | ² | 242 | F2 | ò |
| 51 | 33 | 3  | 115 | 73 | s | 179 | B3 | ³ | 243 | F3 | ó |

Studienwoche 2023

# UTF-8

# UTF-8

- Sprachen-Abhängige Kodierung funktionieren, solange man in einem Land bleibt
- Durch die Globalisierung und die rasante Ausbreitung des Internets führte das zu Problemen
- Texte wurden plötzlich falsch dargestellt (falsche Kodierung)
- Entsprechend wurde eine Kodierung entwickelt, die eine variable Länge an Bytes benutzen kann
- UTF-8 ist in den ersten 128 Zeichen identisch mit ASCII

# UTF-8

- UTF-8 kann bis zu 4 Bytes benutzen (also ca. 2 Mio Zeichen darstellen)
- Dadurch sind 😊, 漢字 und weitere Zeichen in der Gleichen Kodierung möglich
- Fängt das Byte mit 0b0xxxxxxx so ist es Teil von Ascii ( $2^7 = 128$ )
- Fängt das Byte mit 0b110xxxxx an, so ist es das erste Byte eines Multi-Byte-Zeichen
- Folge Bytes eines Multi-Byte-Zeichen fangen mit 0b10xxxxxx an
- Die Anzahl der 1-Bits vor der ersten 0 im Start-Byte sind die Gesamtzahl der Bytes für dieses Zeichen
- 0b1110xxxx 0b10xxxxxx 0b10xxxxxx

Studienwoche 2023

# Base64

# Base64


- Das Umgekehrte Problem stellt die Darstellung beliebiger Bytes als Alphanumerische Zeichenketten dar
- Dies ist Wertvoll, wenn Protokolle benutzt werden, wo z.B. nur Alphanumerische Zeichen erlaubt sind
- Will man z.B. ein Bild im HTML-Quellcode direkt hinterlegen, braucht man ein Verfahren, die Bytes (als Schriftzeichen) zu Kodieren

iVBORw0KGgoAAAANSUhEUgAAAUQAAAFECAMAAABoNLf0AAAABGdBTUEAALGPC/xhBQA[...]



# Base64

- Base64 benutzt ein Alphabet aus 64 Zeichen
- Buchstaben A-Z, a-z, 0-9 und \_ und -
- Drei Bytes ( $3 \cdot 8 = 24$ ) werden zu  $4 \cdot 6\text{bit}$  Blöcken ( $2^6 = 64$ ) aufgeteilt
- Entsprechend werden  $4/3$  Bytes gebraucht um den Gleichen Inhalt zu kodieren



Studienwoche 2023

# BigIntegers

# BigInt

- Für grosse Moduli in RSA brauchen wir sehr grosse Zahlen
- Das normale Limit sind 32bit resp. 64bit Zahlen
- Entsprechend gibt es sogenannte BigIntegers
- Diese kodieren eine beliebig grosse Zahl
- Dies geschieht, in dem die Bits in eine Liste von Bytes kodiert werden
- Das höchste Bit gibt jeweils das Vorzeichen an (1 => -1, 0 => +1)