

# COMSM1302 電腦架構概論

## IEEE 754 浮點數補充教材

32 位元單精度 (binary32) 與 64 位元雙精度 (binary64)

含 6 道練習題完整詳解

Week 2 補充教材 (數的表示法延伸)

2026 年 7 月

為什麼放在第 2 週? 第 2 週我們學了無號數、2 補數與二進位加減法——這些都是**整數**的世界。真實程式還需要  $3.14159$ 、 $6.02 \times 10^{23}$ 、 $0.001$  這類**實數**。本補充教材說明現代電腦 (從手機到超級電腦) 一致採用的實數表示標準: **IEEE 754**。模擬考的自訂 8 位元浮點格式題 (1 位符號、2 位指數、5 位尾數) 考的正是同一套原理, 只是欄位縮小; 把本教材讀通, 那類題目就是「換個參數再算一次」。

## 目錄

|     |                                                              |   |
|-----|--------------------------------------------------------------|---|
| 1   | 為什麼需要浮點數?                                                    | 3 |
| 2   | 二進位科學記號與正規化                                                  | 3 |
| 3   | binary32: 32 位元單精度格式                                         | 4 |
| 3.1 | 編碼流程 (十進位 $\rightarrow$ binary32 五步驟)                        | 4 |
| 4   | binary64: 64 位元雙精度格式                                         | 4 |
| 5   | 特殊值: 零、次正規數、無限大、NaN                                          | 5 |
| 6   | 捨入: 格子塞不下的時候                                                 | 6 |
| 7   | 常見陷阱 (寫程式必知)                                                 | 6 |
| 8   | 練習題 (6 題完整詳解)                                                | 7 |
| 8.1 | 練習 1: 十進位 $\rightarrow$ binary32—— $13.625$                  | 7 |
| 8.2 | 練習 2: binary32 $\rightarrow$ 十進位——解碼 <code>0xC1690000</code> | 7 |

|     |                                                        |    |
|-----|--------------------------------------------------------|----|
| 8.3 | 練習 3: 塞不下的 0.1——循環小數與捨入誤差 . . . . .                    | 8  |
| 8.4 | 練習 4: 十進位 $\rightarrow$ binary64—— $-2026.5$ . . . . . | 9  |
| 8.5 | 練習 5: 特殊值判讀——六個位元樣式 . . . . .                          | 10 |
| 8.6 | 練習 6: 整數的精度極限—— $2^{24} + 1$ 與安全整數 . . . . .           | 11 |
| 9   | 速查表                                                    | 12 |

## 1 為什麼需要浮點數?

用 16 位元表示數字時，若採**定點數** (fixed point)，例如規定「小數點固定在第 8 位」，我們得到：

$$\underbrace{b_{15} b_{14} \cdots b_8}_{\text{整數部分}} . \underbrace{b_7 b_6 \cdots b_0}_{\text{小數部分}}$$

最大約 255.996、解析度固定  $2^{-8} \approx 0.0039$ 。問題是：

- 想表示  $10^{20}$  (天文數字)? 整數位不夠。
- 想表示  $10^{-20}$  (原子尺度)? 小數位不夠。
- 兩者同時要? 定點數完全無解——位元預算被小數點的「固定位置」綁死。

解法借自科學記號： $6.02 \times 10^{23}$  用「**有效數字**」(6.02) 搭配「**指數**」(23)——小數點的位置變成一個**可調的欄位**，讓小數點「浮動」(floating)，同一格式就能同時涵蓋巨大與微小的數。代價是：**有效位數固定**，數字越大，相鄰可表示值的間距越大 (精度是「相對的」而非「絕對的」)。

### IEEE 754 標準

IEEE 754 (1985 年首版，最新修訂為 IEEE 754-2019) 規定了浮點數的**二進位格式**、**捨入規則**、**特殊值與運算行為**。兩種最重要的基本格式：**binary32** (單精度，C 的 float) 與 **binary64** (雙精度，C 的 double、Python 的 float、JavaScript 的 Number)。

## 2 二進位科學記號與正規化

十進位科學記號要求有效數字介於  $1 \sim 9.99\dots$ ；二進位的對應要求是有效數字介於  $1 \sim 1.11\dots_2$  (即  $[1, 2)$ )：

$$13.625_{10} = 1101.101_2 = \underbrace{1.101101_2}_{\text{有效數字 (significand)}} \times 2^{\overbrace{3}^{\text{指數}}}$$

把小數點移到「最高位的 1 之後」稱為**正規化** (normalisation)。

**關鍵觀察：隱藏位元 (hidden bit)**。正規化後，小數點前永遠是 **1** (二進位只有 0 和 1，最高有效位必是 1)。既然一定是 1，就不必儲存——IEEE 754 只存小數點後的部分 (fraction)，解碼時自動補回「1.」。這讓 23 位的欄位實際提供 **24 位** 的精度，白賺一個位元。

**小數轉二進位的兩把工具** (第 2.1 講的延伸)：

- 整數部分：反覆除以 2 取餘數 (由下往上讀)；
- 小數部分：反覆乘以 2 取整數位 (由上往下讀)。例： $0.625 \times 2 = 1.25$  (取 1)、 $0.25 \times 2 = 0.5$  (取 0)、 $0.5 \times 2 = 1.0$  (取 1)  $\Rightarrow 0.625 = 0.101_2$ 。



原理與 binary32 完全相同，只是欄位加寬。兩種格式對照（順帶列出 GPU / 機器學習常用的 binary16）：

|                           | binary16 (half)                      | binary32 (float)                      | binary64 (double)                      |
|---------------------------|--------------------------------------|---------------------------------------|----------------------------------------|
| 總位元數                      | 16                                   | 32                                    | 64                                     |
| 符號／指數／小數                  | 1/5/10                               | 1/8/23                                | 1/11/52                                |
| 偏移量 bias                  | 15                                   | 127                                   | 1023                                   |
| 實際指數範圍                    | -14 ~ 15                             | -126 ~ 127                            | -1022 ~ 1023                           |
| 有效精度（位）                   | 11                                   | 24                                    | 53                                     |
| 約當十進位有效位數                 | $\approx 3.3$                        | $\approx 7.2$                         | $\approx 15.9$                         |
| 最大正規數                     | 65504                                | $\approx 3.40 \times 10^{38}$         | $\approx 1.80 \times 10^{308}$         |
| 最小正規數                     | $\approx 6.1 \times 10^{-5}$         | $\approx 1.18 \times 10^{-38}$        | $\approx 2.23 \times 10^{-308}$        |
| 最小次正規數                    | $\approx 6.0 \times 10^{-8}$         | $\approx 1.40 \times 10^{-45}$        | $\approx 4.94 \times 10^{-324}$        |
| 機器 epsilon ( $2^{-p+1}$ ) | $2^{-10} \approx 9.8 \times 10^{-4}$ | $2^{-23} \approx 1.19 \times 10^{-7}$ | $2^{-52} \approx 2.22 \times 10^{-16}$ |

怎麼記偏移量？bias =  $2^k - 1$  ( $k$  為指數位數)：binary16 是  $2^4 - 1 = 15$ 、binary32 是  $2^7 - 1 = 127$ 、binary64 是  $2^{10} - 1 = 1023$ 。模擬考的 2 位指數自訂格式則是  $2^1 - 1 = 1$ ——同一條公式。

## 5 特殊值：零、次正規數、無限大、NaN

指數欄位「全 0」與「全 1」被保留，用來編碼四類特殊值（以 binary32 為例，binary64 把 255 換成 2047、-126 換成 -1022 即可）：

| 指數 $E$  | 小數 $F$   | 意義                                                             |
|---------|----------|----------------------------------------------------------------|
| 0       | = 0      | $\pm 0$ （正零與負零，比較時相等）                                          |
| 0       | $\neq 0$ | 次正規數： $(-1)^S \times 0.F_2 \times 2^{-126}$ （無隱藏位元）            |
| 1 ~ 254 | 任意       | 正規數： $(-1)^S \times 1.F_2 \times 2^{E-127}$                    |
| 255     | = 0      | $\pm \infty$ （如 $1/0 = +\infty$ 、 $-1/0 = -\infty$ ）           |
| 255     | $\neq 0$ | NaN (Not a Number, 如 $0/0$ 、 $\sqrt{-1}$ 、 $\infty - \infty$ ) |

- 為什麼需要次正規數 (subnormal)？最小正規數是  $1.00\dots 0 \times 2^{-126}$ 。若再小就直接跳到 0，會出現「 $x \neq y$  但  $x - y = 0$ 」的怪事。次正規數把隱藏位元改成 0 ( $0.F \times 2^{-126}$ )，讓數值以漸進方式滑向 0 (gradual underflow)，一路撐到  $2^{-149}$ ；代價是有效位數逐漸縮水。
- NaN 的傳染性：任何含 NaN 的運算結果都是 NaN，且 NaN 不等於任何值（包括它自己）——「 $x \neq x$ 」是判斷 NaN 的慣用寫法。

- **無限大會飽和**：超出最大正規數的運算（如  $10^{38} \times 100$ ）產生  $\pm\infty$ （溢位不繞回，與 2 補數整數溢位的行為完全不同）。

## 6 捨入：格子塞不下的時候

多數十進位小數（如 0.1）在二進位是**無限循環小數**，23 或 52 位的小數欄位塞不下，必須捨入。IEEE 754 預設採用：

**Round to nearest, ties to even（就近捨入、平手取偶）**

把真實值捨入到**最接近**的可表示浮點數；若恰好落在兩個可表示值的**正中間**（平手），取小數欄位最後一位為 **0（偶數）** 的那個。

操作面：看第 24 位（要被切掉的第一位，稱 round bit）——

- round bit = 0：直接截斷（往下捨）；
- round bit = 1 且後面還有 1：進位（往上入）；
- round bit = 1 且後面全 0（正中間）：往「尾位為偶」的方向捨入。

「平手取偶」避免了「一律四捨五入」造成的系統性偏大——統計上一半往上、一半往下，長期誤差互相抵消。

## 7 常見陷阱（寫程式必知）

**陷阱 1**： $0.1 + 0.2 \neq 0.3$ 。三個數在 binary64 中都不精確（見練習 3 的原理），儲存值分別約為 0.1000000000000000055...、0.2000000000000000111...、0.2999999999999999889...；相加再捨入後得 0.3000000000000000444...，比「0.3 的儲存值」大了一個最低有效位（ULP）。所以  $0.1 + 0.2 == 0.3$  在幾乎所有語言中都是 **false**。**正確做法**：比較用容差  $|x - y| < \varepsilon$ （ $\varepsilon$  依問題尺度選取），或改用十進位定點／有理數型別處理金額等精確需求。

**陷阱 2**：大數吃小數（swamping）。浮點加法要先**對齊指數**：小的數往右移位，移出 24（或 53）位視窗的部分直接消失。極端例子：binary32 中  $2^{24} + 1 = 2^{24}$ （見練習 6）。連鎖效應是**結合律失效**： $(a + b) + c \neq a + (b + c)$ ——累加一大串數字時，先加小的再加大的，誤差較小。

**陷阱 3**：可表示的數不是均勻分布。相鄰浮點數的間距  $= 2^e \times \varepsilon$ ，隨數字變大而變大：在  $[1, 2)$  區間 binary32 的格點間距是  $2^{-23}$ ，在  $[2^{24}, 2^{25})$  區間卻是 2。「數線越遠越稀疏」是理解一切精度問題的心智模型。

## 8 練習題 (6 題完整詳解)

### 8.1 練習 1: 十進位 $\rightarrow$ binary32——13.625

#### 題目

把 13.625 編碼成 IEEE 754 binary32, 分別寫出符號、指數、小數三個欄位, 並以十六進位表示完整的 32 位元。

#### 解答

第一步: 定符號。正數  $\Rightarrow S = 0$ 。

第二步: 轉二進位。整數部分  $13 = 1101_2$  ( $13 = 8 + 4 + 1$ ); 小數部分 0.625:

$$0.625 \times 2 = 1.25 \text{ (取1)}, \quad 0.25 \times 2 = 0.5 \text{ (取0)}, \quad 0.5 \times 2 = 1.0 \text{ (取1)} \Rightarrow 0.101_2$$

合併:  $13.625 = 1101.101_2$ 。

第三步: 正規化。小數點左移 3 位:

$$1101.101_2 = 1.101101_2 \times 2^3$$

第四步: 指數欄位。  $E = 3 + 127 = 130 = 1000\ 0010_2$ 。

第五步: 小數欄位。隱藏位元「1」不存, 取小數點後的 101101, 右邊補 0 到 23 位:

$$F = 1011\ 0100\ 0000\ 0000\ 0000\ 0000$$

組合並轉十六進位。

$$\underbrace{0}_S \underbrace{10000010}_E \underbrace{101101000000000000000000}_F$$

每 4 位一組: 0100 0001 0101 1010 0000 0000 0000 0000

$$13.625 = 0x415A0000$$

驗算(解碼回去):  $E = 130 \Rightarrow e = 3$ ;  $1.101101_2 \times 2^3 = 1101.101_2 = 8 + 4 + 1 + 0.5 + 0.125 = 13.625$

✓

### 8.2 練習 2: binary32 $\rightarrow$ 十進位——解碼 0xC1690000

#### 題目

某記憶體位置存放的 32 位元為 0xC1690000。把它視為 IEEE 754 binary32, 求它代表的十進位值。

#### 解答

第一步: 展開成二進位。

$$C1690000 = 1100\ 0001\ 0110\ 1001\ 0000\ 0000\ 0000\ 0000$$

第二步：切欄位。

$$\underbrace{1}_S \underbrace{10000010}_E \underbrace{110100100000000000000000}_F$$

(切法：第 1 位是  $S$ ；接下來 8 位是  $E$ ；剩下 23 位是  $F$ 。)

第三步：判斷類型。 $E = 1000\,0010_2 = 130$ ，不是 0 也不是 255  $\Rightarrow$  正規數，照公式解碼。

第四步：解碼。

- 符號： $S = 1 \Rightarrow$  負數；
- 實際指數： $e = 130 - 127 = 3$ ；
- 有效數字：補回隱藏位元  $\Rightarrow 1.1101001_2$ 。

$$1.1101001_2 \times 2^3 = 1110.1001_2 = 8 + 4 + 2 + 0.5 + 0.0625 = 14.5625$$

$$\boxed{\text{0xC1690000} = -14.5625}$$

驗算 (反向編碼)： $14.5625 = 14 + 0.5625$ ； $14 = 1110_2$ ； $0.5625 = 0.5 + 0.0625 = 0.1001_2$ ； $1110.1001_2 = 1.1101001 \times 2^3$ ； $E = 130$ 、 $S = 1$  ✓

解碼的第一件事永遠是「看指數欄位」： $E = 0$  (零或次正規) 與  $E = 255$  ( $\infty$  或 NaN) 不能套正規數公式。養成先分類再解碼的習慣，練習 5 會專門考這件事。

### 8.3 練習 3：塞不下的 0.1——循環小數與捨入誤差

#### 題目

- 證明 0.1 在二進位是無限循環小數，並寫出循環模式；
- 求 0.1 的 binary32 編碼 (十六進位)；
- 求儲存值與 0.1 的實際誤差，並說明誤差方向 (偏大或偏小)。

#### 解答

(a) 乘 2 取整，找循環。

$$0.1 \times 2 = 0.2 \quad \text{取0}$$

$$0.2 \times 2 = 0.4 \quad \text{取0}$$

$$0.4 \times 2 = 0.8 \quad \text{取0}$$

$$0.8 \times 2 = 1.6 \quad \text{取1}$$

$$0.6 \times 2 = 1.2 \quad \text{取1}$$

$$0.2 \times 2 = 0.4 \quad \text{取0} \quad \leftarrow \text{小數部分回到0.2，開始循環}$$

一旦「待乘的小數部分」重複出現 (0.2 再現)，輸出就永遠循環：

$$0.1_{10} = 0.0001\overline{1}_2 = 0.000110011001100110011\dots_2$$

分母  $10 = 2 \times 5$  含質因數 5 (不是 2 的冪次)，所以必然除不盡——這與  $1/3$  在十進位無限循環同理。

(b) 正規化、取 23 位、捨入。

$$0.1 = 1.10011001100110011001100 \underline{1100} \dots_2 \times 2^{-4}$$

小數欄位只能存 23 位 (上式底線前的部分)，被切掉的部分以 1100... 開頭: round bit = 1 且後面還有 1  $\Rightarrow$  往上進位:

$$F = 10011001100110011001100 + 1 = 1001100110011001101$$

指數欄位  $E = -4 + 127 = 123 = 0111\ 1011_2$ ,  $S = 0$ :

$$0\ 01111011\ 10011001100110011001101 = \boxed{0x3DCCCCD}$$

(c) 誤差計算。儲存的有效數字是  $1.10011001100110011001101_2$ ，即整數  $2^{23} + F = 13421773$  除以  $2^{23}$ ；乘上  $2^{-4}$ :

$$\text{儲存值} = \frac{13421773}{2^{27}} = 0.100000001490116119384765625$$

$$\text{誤差} = \text{儲存值} - 0.1 \approx +1.49 \times 10^{-9} \quad (\text{因為捨入時進位，誤差偏大})$$

相對誤差  $\approx 1.5 \times 10^{-8}$ ，符合單精度機器 epsilon ( $2^{-23} \approx 1.2 \times 10^{-7}$ ) 的量級。

**這就是  $0.1 + 0.2 \neq 0.3$  的根源：**每個十進位小數存進去時都各自帶了  $10^{-9}$  (float) 或  $10^{-17}$  (double) 級的小誤差，運算再把誤差組合、放大。double 版的 0.1 同理可得 **0x3FB999999999999A** (52 位小數、一樣要進位)。

#### 8.4 練習 4: 十進位 $\rightarrow$ binary64——-2026.5

##### 題目

把 -2026.5 編碼成 IEEE 754 binary64 (雙精度)，寫出各欄位並以十六進位表示完整的 64 位元。

##### 解答

第一步：定符號。負數  $\Rightarrow S = 1$ ，以下處理 2026.5。

第二步：轉二進位。

$$2026 = 1024 + 512 + 256 + 128 + 64 + 32 + 8 + 2 = 1111101010_2$$

(驗算:  $1024+512=1536$ 、 $+256=1792$ 、 $+128=1920$ 、 $+64=1984$ 、 $+32=2016$ 、 $+8=2024$ 、 $+2=2026$  ✓)

$$0.5 = 0.1_2 \Rightarrow 2026.5 = 1111101010.1_2$$

第三步：正規化。小數點左移 10 位:

$$1111101010.1_2 = 1.1111010101_2 \times 2^{10}$$

第四步：指數欄位 ( $\text{bias} = 1023$ )。

$$E = 10 + 1023 = 1033 = 10000001001_2 \quad (11 \text{ 位})$$

( $1033 = 1024 + 8 + 1$  ✓)

第五步：小數欄位。取小數點後的 11111010101 (11 位)，右邊補 41 個 0 湊滿 52 位。  
組合並轉十六進位。

$$\underbrace{1}_S \underbrace{10000001001}_E \underbrace{11111010101}_{F} \underbrace{0 \dots 0}_{41}$$

每 4 位一組：

$$1100\ 0000\ 1001\ 1111\ 1010\ 1010\ 0000 \dots 0000$$

$$\boxed{-2026.5 = 0xC09FAA0000000000}$$

驗算 (解碼)： $E = 10000001001_2 = 1033 \Rightarrow e = 10$ ； $1.11111010101_2 \times 2^{10} = 11111101010.1_2 = 2026.5$ ； $S = 1$  加負號 ✓

**binary32 與 binary64 的流程一字不差**，只是三個參數換掉：指數位數  $8 \rightarrow 11$ 、bias  $127 \rightarrow 1023$ 、小數位數  $23 \rightarrow 52$ 。考試時先在題目旁邊寫下這三個參數再動手，可避免中途混用。

## 8.5 練習 5：特殊值判讀——六個位元樣式

### 題目

把下列六個 32 位元樣式視為 binary32，判斷每一個是「正規數、次正規數、 $\pm 0$ 、 $\pm \infty$ 、NaN」中的哪一類，並求出 (可求的) 數值：

| 編號  | 位元樣式 (十六進位) |
|-----|-------------|
| (a) | 0x80000000  |
| (b) | 0x7F800000  |
| (c) | 0x7FC00000  |
| (d) | 0x00000001  |
| (e) | 0x00400000  |
| (f) | 0x7F7FFFFF  |

### 解答

先切欄位 ( $S | E | F$ )，再依「指數全 0 / 全 1」分類：

(a)  $0x80000000 = 1 | 00000000 | 00 \dots 0$ 。  $E = 0$  且  $F = 0 \Rightarrow$  負零  $-0$ 。(IEEE 754 規定  $-0 == +0$  比較為真，但  $1/-0 = -\infty$ ，符號仍有語義。)

(b)  $0x7F800000 = 0 | 11111111 | 00 \dots 0$ 。  $E = 255$  且  $F = 0 \Rightarrow +\infty$  (例如  $1.0/0.0$  的結果)。

(c)  $0x7FC00000 = 0 | 11111111 | 10 \dots 0$ 。  $E = 255$  且  $F \neq 0 \Rightarrow \text{NaN}$  (小數最高位為 1, 是 quiet NaN 的典型編碼;  $0/0$ 、 $\sqrt{-1}$  都產生它)。

(d)  $0x00000001 = 0 | 00000000 | 00 \dots 01$ 。  $E = 0$  且  $F \neq 0 \Rightarrow$  次正規數, 公式為  $0.F_2 \times 2^{-126}$  (沒有隱藏位元):

$$0.\underbrace{00 \dots 01}_{23 \text{ 位}} \times 2^{-126} = 2^{-23} \times 2^{-126} = 2^{-149} \approx 1.4 \times 10^{-45}$$

這是 binary32 最小的正數。

(e)  $0x00400000 = 0 | 00000000 | 10 \dots 0$ 。 同為次正規數:

$$0.1_2 \times 2^{-126} = 2^{-1} \times 2^{-126} = 2^{-127} \approx 5.9 \times 10^{-39}$$

(f)  $0x7FFFFFFF = 0 | 11111110 | 11 \dots 1$ 。  $E = 254$  (差一步就全 1)  $\Rightarrow$  正規數, 且是最大的有限值:

$$1.\underbrace{11 \dots 1}_{23} \times 2^{254-127} = (2 - 2^{-23}) \times 2^{127} \approx 3.4028 \times 10^{38}$$

再大一個 ULP 就變成 (b) 的  $+\infty$ 。

**記憶法:** 數線的兩端各有一段保留區。指數全 0 管「最靠近 0 的地帶」(零與次正規數), 指數全 1 管「超出範圍的地帶」(無限大與 NaN); 正規數住在中間  $E \in [1, 254]$ 。

## 8.6 練習 6: 整數的精度極限—— $2^{24} + 1$ 與安全整數

### 題目

- (a) 說明為什麼  $16\,777\,216 (= 2^{24})$  可以被 binary32 精確表示, 但  $16\,777\,217 (= 2^{24} + 1)$  不行;
- (b) 在 binary32 中計算  $16\,777\,216.0 + 1.0$ , 說明捨入過程與結果;
- (c) 由此推論: binary64 能精確表示的連續整數範圍是多少? 這與 JavaScript 的 `Number.MAX_SAFE_INTEGER` 有什麼關係?

### 解答

(a) 有效位數只有 24 位。binary32 的有效數字是「1 個隱藏位元 + 23 位小數」共 24 位。

$$2^{24} = 1.\underbrace{00 \dots 0}_{23} \times 2^{24} \quad (\text{小數全 0, 塞得下}) \quad \checkmark$$

$$2^{24} + 1 = 1\underbrace{00 \dots 0}_{23}1_2 = 1.\underbrace{00 \dots 0}_{23}1_2 \times 2^{24}$$

需要第 24 位小數才放得下最後那個 1——超出 23 位的欄位, 無法精確表示。✗

(b) 相加後捨入, 結果不變。真實總和  $16\,777\,217 = 1.\underbrace{0 \dots 0}_{23}1 \times 2^{24}$ , 夾在兩個可表示值中間:

$$16\,777\,216 = 1.\underbrace{0 \dots 0}_{22}00 \times 2^{24} \quad 16\,777\,218 = 1.\underbrace{0 \dots 0}_{22}10 \times 2^{24}$$

被切掉的部分恰是「1 後面全 0」——**正中間的平手局面**。依「平手取偶」規則，取小數最後一位為 0 的那個：16 777 216 的尾位是 0（偶）、16 777 218 的尾位是 1（奇），所以捨回 16 777 216：

$$16\,777\,216.0 + 1.0 = 16\,777\,216.0 \quad (\text{float 中})$$

加了等於沒加——迴圈計數器若用 `float`，數到  $2^{24}$  就永遠卡住，這是真實世界發生過的 bug 類型。

(c) **binary64 的安全整數**。同樣推理，53 位有效數字  $\Rightarrow [-2^{53}, 2^{53}]$  內的整數全部精確可表示，且  $2^{53} + 1$  是第一個表示不了的整數。JavaScript 的 `Number` 只有 binary64 一種數值型別，因此

$$\text{Number.MAX\_SAFE\_INTEGER} = 2^{53} - 1 = 9\,007\,199\,254\,740\,991$$

超過它，整數運算就開始「跳號」（如  $2^{53} + 1 == 2^{53}$  為 `true`）；需要更大的整數時得改用 `BigInt`。

**總結一句話：**浮點數是「用固定的有效位數換取巨大的動態範圍」。 $2^{24}$  (float) 與  $2^{53}$  (double) 是「每個整數都有格子」的分界線；越過去，格點間距變成 2、4、8……精度是相對的，不是絕對的。

## 9 速查表

|                  | binary32                      | binary64                       |
|------------------|-------------------------------|--------------------------------|
| 欄位 ( $S/E/F$ )   | 1/8/23                        | 1/11/52                        |
| 偏移量              | 127                           | 1023                           |
| 正規數公式            | $(-1)^S 1.F \times 2^{E-127}$ | $(-1)^S 1.F \times 2^{E-1023}$ |
| 次正規數公式 ( $E=0$ ) | $(-1)^S 0.F \times 2^{-126}$  | $(-1)^S 0.F \times 2^{-1022}$  |
| $\pm\infty$      | $E=255, F=0$                  | $E=2047, F=0$                  |
| NaN              | $E=255, F \neq 0$             | $E=2047, F \neq 0$             |
| 安全整數上限           | $2^{24}$                      | $2^{53}$                       |

**編碼五步驟：**定符號  $\rightarrow$  轉二進位  $\rightarrow$  正規化  $1.f \times 2^e \rightarrow E = e + \text{bias} \rightarrow$  填  $F$ （必要時就近捨入、平手取偶）。

**解碼三步驟：**切欄位  $\rightarrow$  看  $E$  分類（全 0 / 全 1 特殊處理） $\rightarrow$  套公式。