

# الفصل الأول

## تمثيل الأعداد ومفهوم الاستقرارية في التحليل العددي

- § 1. تمثيل بطريقة النقطة العائمة
- § 2. معيار IEEE في تمثيل الأعداد
- § 3. تدوير الأعداد في نظام IEEE المعياري
- § 4. الحالات الخاصة في نظام IEEE المعياري
- § 5. الأخطاء من وجهة النظر العددية
- § 6. مفهوم الاستقرارية في التحليل العددي
- § 7. استقرارية الطرائق العددية
- § 8. مسائل وتمارين

كان مصنيع الأجهزة الحاسوبية، في أعوام السبعينيات والثمانينيات، يطورون -كل على طريقته- نظام تمثيل الأعداد بالنقطة العائمة مما جعل توافقية البرمجيات مع هذه الأجهزة أمراً عسيراً. فعلى سبيل المثال، كانت معظم الآلات الحاسوبية تعتمد النظام الثنائي في تمثيل الأعداد في حين كانت حواسيب IBM 360/370 (والتي كانت شائعة في تلك الفترة) تعتمد النظام ست عشرى hexadecimal وفيما كانت أنظمة حاسوبية أخرى مثل أنظمة HP الحاسوبية تعتمد النظام العشري.

ساهمت جهود العديد من اختصاصي الأجهزة الحاسوبية، في بداية أواخر الثمانينيات من أمثال W. Kahan في وضع نظام قياسي لتمثيل الأعداد بالنقطة العائمة وتلى ذلك دفع كبير لهذا النظام بتبني كل من شركة Intel وشركة Motorola لهذا المعيار في تمثيل الأعداد. عُرف هذا النظام القياسي في التمثيل باسم معيار IEEE في تمثيل الأعداد بالنقطة العائمة وكان ذلك منذ أن بدأ بتطويره فريق متخصص من معهد الهندسة الكهربائية والالكترونية Institute for Electrical and Electronics Engineers.

### 1. تمثيل بطريقة النقطة العائمة

ليكن  $N \leq \beta^2$  عددًا طبيعيًا نسميه الأساس (غالبًا ما يكون زوجيًا)، عندئذ، أيًا كان العدد الحقيقي  $x \in \mathbb{R} \setminus \{0\}$  فإنه يوجد عدد صحيح  $e \in \mathbb{Z}$  بحيث يكون  $|\beta^e| < |x| \leq \beta^{e+1}$  وهذا يعني أنه يوجد عددٌ وحيد  $\lambda \in [0, 1)$  بحيث يكون

$$|x| = (1 - \lambda) \cdot \beta^e + \lambda \cdot \beta^{e+1} = (1 + \lambda \cdot (\beta - 1)) \cdot \beta^e$$

أي أن العدد  $x$  يكتب بطريقة وحيدة بالشكل

$$x = \pm m \times \beta^e, \quad 1 \leq m < \beta, \quad e \in \mathbb{Z}.$$

نسمى العدد  $m$  دليل العدد  $x$ .

تعتمد طريقة التمثيل بالنقطة العائمة على اختيار عدد صحيح  $p \leq 1$  يسمى دقة التمثيل precision إضافة إلى عددين آخرين  $e_{\max}$  و  $e_{\min}$  يحدّدان مجال تغيير الأس  $e$  بحيث نستطيع بهذه الطريقة تمثيل الأعداد التالية

$$(1) \quad \underbrace{\pm \left( d_0 + d_1 \cdot \beta^{-1} + \cdots + d_{p-1} \cdot \beta^{-(p-1)} \right)}_m \times \beta^e, \quad 0 \leq d_i < \beta$$

يعبر المصطلح عدد النقطة العائمة floating-point number عن العدد الحقيقي الذي يكتب بالشكل (1). لتخزين عدد النقطة العائمة تقسم وحدة الذاكرة computer word المخصصة لذلك إلى ثلاثة حقول تمثل على الترتيب الإشارة  $s$ ، الأس  $e$  ومن ثم الدليل  $m$ . فمثلاً في نظام حاسوبي يعتمد وحدة ذاكرة قياسها 32 bit – يمكن توزيع هذه الحقول كالتالي: 1 bit لتمثيل الإشارة، 8 bits لتمثيل الأس و 23 bits لتمثيل الدليل.

هناك حالتان لا يمكن فيها تمثيل عدد حقيقي تمثيلاً تماماً كعدد من أعداد النقطة العائمة. الحالة الأولى، وهي الأكثر شيوعاً، يمكن إيضاحها بالعدد العشري 0.1. فهذا العدد يمثل تمثيلاً عشرياً متھماً ( $\beta = 10$ ):

$$0.1 = +1.0 \times 10^{-1}$$

وفي النظام الثنائي ( $\beta = 2$ ) يقع هذا العدد تماماً بين عددي نقطة عائمة وذلك لكونه لا يقبل تمثيلاً متهماً:

$$0.1 = 1.10011001100\dots \times 2^{-4}$$

والحالة الثانية، وهي أقل حدوثاً وتعلق بالأعداد الواقعة خارج مجال التمثيل، أي أن تكون القيمة المطلقة للعدد أكبر من القيمة  $\beta \times \beta^{e_{\min}}$  أو أصغر من القيمة  $\beta^{e_{\max}}$ .

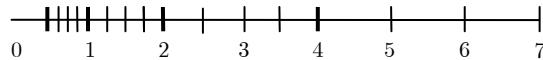
إن تمثيل الأعداد بطريقة النقطة العائمة ليس وحيداً، فعلى سبيل المثال، كلاً من الكتابتين:  $0.01 \times 10^1$  و  $1.00 \times 10^{-1}$  تمثل العدد 0.1. لكي نجعل تمثيل الأعداد الحقيقية بطريقة النقطة العائمة وحيداً نشرط في هذا التمثيل أن يكون الرقم الأول من يسار دليل العدد  $d_0$  غير معروف وعندئذ يأخذ تمثيل العدد الشكل التالي:

$$(2) \quad \pm d_0 \cdot d_1 d_2 \cdots d_{p-1} \times \beta^e, \quad 0 \leq d_i < \beta, \quad d_0 > 0.$$

نسمى طريقة التمثيل (2) طريقة التمثيل بالنقطة العائمة القياسية Normalized floating-point ، كما نسمى الأعداد التي تكتب وفق العبارة (2) أعداداً قياسية Normalized numbers. فعلى سبيل المثال الكتابة  $1.00 \times 10^{-1}$  هي قياسية في حين أن الكتابة  $0.01 \times 10^1$  ليست كذلك.

**مثال:**

في حالة 2 عدداً قياسياً موجباً (الإشارة +) لدينا 16 عدداً قياسياً موجباً (الإشارة +) :



الشكل 1: الأعداد القياسية الموجبة عندما  $p = 3$  ،  $\beta = 2$  ،  $e_{\max} = 2$  و  $e_{\min} = -1$

$$\cdot e_{\max} = 2 \text{ و } e_{\min} = -1$$

وهذه الأعداد هي:

$$\bigcup_{i=-1}^2 \left\{ 1.00 \times 2^i, 1.01 \times 2^i, 1.10 \times 2^i, 1.11 \times 2^i \right\}$$

لسوء الحظ، فإن الشرط الذي وضعناه ليصبح التمثيل بالنقطة العائمة قياسياً، لا يسمح بتمثيل الصفر! سترى في الفقرة التالية كيفية تمثيل الصفر وكذلك أعداداً أخرى لا يمكن كتابتها وفق العبارة (2).

## 2. معيار IEEE في تمثيل الأعداد

في عام 1985 ، حرى اعتماد معيار "IEEE 754" لتمثيل الأعداد بالنقطة العائمة. وهو نظام تمثيل يقوم حصراً على استخدام النظام الثنائي ( $\beta = 2$ ) في التعبير عن مكونات التمثيل: الأس exponent والدليل significand. بعد ذلك بأعوام قليلة، وفي عام 1987 حرى تعميم هذا المعيار إلى "IEEE 854" والذي يسمح باستخدام أحد الأساسين أو  $\beta = 10$  أو  $\beta = 2$  في التمثيل على حد سواء.

نناقش في هذا الفصل النموذج الحسابي الذي يحدد المعيار 1985-1985 ANSI/IEEE Standard 754 أو اختصاراً IEEE 754". نتوء هنا إلى أن جميع معالجات SPARC و x86 تستعمل نظام IEEE 754 الحسابي.

يشتمل معيار IEEE في تمثيل الأعداد على ثلاثة أنماط قياسية مصنفة تبعاً للدقة التي يتاحها كلّ نمط:

- نمط الدقة البسيطة single precision
- نمط الدقة المضاعفة double precision
- نمط الدقة الموسعة extended precision

### • أولاً: نمط الدقة البسيطة

تتألف هذه الصيغة من ثلاثة حقول: حقل مكون من 23-bit يمثل الجزء الكسري  $f < 0$ ؛ حقل مكون من 8-bit لتمثيل القيمة المنحازة للأس  $e$  وأخيراً، حقل مكون من 1-bit لتمثيل الإشارة  $s \in \{0,1\}$ . تخزن هذه الحقول متقاربةً في وحدة ذاكرة قياسها 32-bit كما في الشكل التالي.

msb	lsb	msb	lsb
S	e [30:23]	f [22:0]	
31 30	23 22		0

الشكل 2: صيغة التخزين البسيطة.

يبين الجدول التالي الحالات المختلفة للحقول الثلاثة  $s$  ،  $e$  و  $f$  وما يقابلها من قيم عدديّة تمثّلها صيغة التمثيل البسيطة.

صيغة التخزين البسيطة	القيمة العدديّة
$0 < e < 255$	$(-1)^s \times 1.f \times 2^{e-127}$ normal numbers
$e = 0; f \neq 0$	$(-1)^s \times 0.f \times 2^{-126}$ subnormal numbers
$e = 0; f = 0$	$(-1)^s \times 0.0$ (signed zero)
$s = 0; e = 255; f = 0$	+INF ( $+\infty$ )
$s = 1; e = 255; f = 0$	-INF ( $-\infty$ )
$e = 255; f \neq 0$	NaN (Not-a-Number)

الجدول 1: القيم العدديّة التي تمثلها نمط الدقة البسيطة في معيار IEEE القياسي.

نلاحظ هنا أنّ الدليل  $m$  للعدد الممثل بهذه الصيغة هو عددٌ مرّكب يساوي:

عديداً نظامياً •  $m = 1.f$  عندما  $e < 255 < 0$ . نسمّي العدد الذي تمثّله هذه الصيغة -في هذه الحالة-

▪ .normal number

عديداً تحت •  $m = 0.f$  عندما  $e = 0$  و  $f \neq 0$ . نسمّي العدد الذي تمثّله هذه الصيغة -في هذه الحالة-

▪ .subnormal number نظامي

يبين لنا من ذلك أنّ دليل الصيغة البسيطة  $m$  يمثل جزءٍ كسريٍّ قيمته  $0.f$  وجزءٍ صحيحٍ قيمته 1 في حالة الأعداد النظامية، و 0 في حالة الأعداد تحت النظامية.

يبين الجدول التالي بعض صيغ التمثيل البسيطة المأمة وقيمها بالنظام العشري.

الاسم الشائع	صيغة التخزين (Hex)	القيمة العدديّة العشرية
+0	00000000	0.0
-0	80000000	-0.0
1	3F800000	1.0
2	40000000	2.0
maximum normal number	7F7FFFFFFF	3.40282347e+38
minimum positive normal number	00800000	1.17549435e-38
maximum subnormal number	007FFFFFFF	1.17549421e-38
minimum positive subnormal number	00000001	1.40129846e-45
+∞	7F800000	Infinity
-∞	FF800000	-Infinity
Not-a-Number	7FC00000	NaN

الجدول 2: بعض صيغ التمثيل بالدقة البسيطة وقيمها العدديّة.

## • ثانياً: نمط الدقة المضاعفة

تتألف هذه الصيغة من ثلاثة حقول: حقل مكون من 1-bit يمثل الجزء الكسري  $f < 0$ ؛ حقل مكون من 11-bit لتمثيل القيمة المنحازة للأس  $e$  وأخيراً، حقل مكون من 1-bit لتمثيل الإشارة  $s \in \{0,1\}$ . تخزن هذه الحقول متجاوِرةً في وحدة ذاكرة قياسها 64-bit كما في الشكل التالي.

msb	lsb	msb	lsb
S	e [62:52]	f [51:0]	0
63 62	52 51		

الشكل 3: صيغة التخزين المضاعفة.

يبين الجدول التالي الحالات المختلفة للحقول الثلاثة  $s$  ،  $e$  و  $f$  وما يقابلها من قيمٍ عدديّة تمثلها صيغة التمثيل المضاعفة.

صيغة التخزين المضاعفة	القيمة العددية
$0 < e < 2047$	$(-1)^s \times 1.f \times 2^{e-1023}$ normal numbers
$e = 0; f \neq 0$	$(-1)^s \times 0.f \times 2^{-1022}$ subnormal numbers
$e = 0; f = 0$	$(-1)^s \times 0.0$ (signed zero)
$s = 0; e = 2047; f = 0$	$+ INF (+\infty)$
$s = 1; e = 2047; f = 0$	$- INF (-\infty)$
$e = 2047; f \neq 0$	$NaN$ (Not-a-Number)

الجدول 3: القيم العددية التي تمثلها نمط الدقة المضاعفة في معيار IEEE القياسي.

نلاحظ هنا - أيضاً - أنَّ الدليل  $m$  للعدد الممثل بـ هذه الصيغة هو عددٌ مرَكَب يساوي:

عندما  $m = 1.f$  •  
عندما  $m = 0.f$  .normal number  
نسمى العدد الذي تمثله هذه الصيغة - في هذه الحالة - **عُدداً نظامياً**

عندما  $e = 0$  و  $f \neq 0$ . نسمى العدد الذي تمثله هذه الصيغة - في هذه الحالة - **عُدداً تحت**  
.subnormal number •  
**نظامي**

يبين لنا من ذلك أنَّ دليل الصيغة المضاعفة  $m$  يمثل بجزءٍ كسري قيمته  $0.f$  وجزءٍ صحيح قيمته 1 في حالة **الأعداد النظامية**، و 0 في حالة **الأعداد تحت النظامية**.

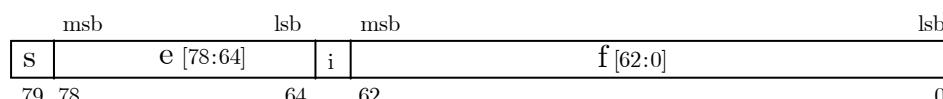
يبين الجدول التالي بعض صيغ التمثيل المضاعفة الهامة وقيمها بالنظام العشري.

الاسم الشائع	صيغة التخزين (Hex)	القيمة العددية العشرية
+0	00000000 00000000	0.0
-0	80000000 00000000	-0.0
1	3FF00000 00000000	1.0
2	40000000 00000000	2.0
maximum normal number	7FEFFFFF FFFFFF	1.7976931348623157e+308
minimum positive normal number	00100000 00000000	2.2250738585072014e-308
maximum subnormal number	000FFFFF FFFFFF	2.2250738585072009e-308
minimum positive subnormal number	00000000 00000001	4.9406564584124654e-324
+∞	7FF00000 00000000	Infinity
-∞	FFF00000 00000000	-Infinity
Not-a-Number	7FF80000 00000000	NaN

الجدول 4: بعض صيغ التمثيل بالدقة المضاعفة وقيمها العددية.

### • ثالثاً: نمط الدقة الموسعة

تتألف هذه الصيغة من أربعة حقول: حقل مكون من 63-bit يمثل **الجزء الكسري**  $f < 1 \leq f$ ؛ حقل مكون من 1-bit يمثل **الجزء الصحيح** من دليل العدد  $i \in \{0,1\}$ ؛ حقل مكون من 15-bit لتمثيل **القيمة المنحازة للأس**  $e$  وأخيراً، حقل مكون من 1-bit لتمثيل **الإشارة**  $s \in \{0,1\}$ . تخزن هذه الحقول متباورة في وحدة ذاكرة قياسها 80-bit كما في الشكل التالي.



الشكل 4: صيغة التخزين الموسعة.

يبين الجدول التالي الحالات المختلفة للحقول الأربع  $s$  ،  $e$  ،  $i$  و  $f$  وما يقابلها من قيم عدديّة تمثلها صيغة التمثيل المضاعفة.

صيغة التخزين الموسعة	القيمة العددية
$0 < e < 32767; i=0$	Unsupported
$0 < e < 32767; i=1$	$(-1)^s \times 1.f \times 2^{e-16383}$ normal numbers
$e = 0; i = 0; f \neq 0$	$(-1)^s \times 0.f \times 2^{-16382}$ subnormal numbers
$e = 0; i = 1$	$(-1)^s \times 1.f \times 2^{-16382}$ pseudo-denormal numbers
$e = 0; i = 0; f = 0$	$(-1)^s \times 0.0$ (signed zero)
$s = 0; e = 32767; i = 1; f = 0$	+INF ( $+\infty$ )
$s = 1; e = 32767; i = 1; f = 0$	-INF ( $-\infty$ )
$e = 32767; f \neq 0$	NaN (Not-a-Number)

الجدول 5: القيم العددية التي يمثلها نمط الدقة الموسعة في معيار IEEE القياسي.

يبين الجدول التالي بعض صيغ تمثيل المضاعفة الهامة وقيمها بالنظام العشري.

الاسم الشائع	صيغة التخزين x86 (Hex)	القيمة العددية العشرية
+0	0000 00000000 00000000	0.0
-0	8000 00000000 00000000	-0.0
1	3FFF 80000000 00000000	1.0
2	4000 80000000 00000000	2.0
maximum normal number	7FFE FFFFFFFFFF FFFFFFFFFF	1.18973149535723176505e+4932
minimum positive normal number	0001 80000000 00000000	3.36210314311209350626e-4932
maximum subnormal number	0000 7FFFFFFF FFFFFFFF	3.36210314311209350608e-4932
minimum positive subnormal number	0000 0000000 00000001	3.64519953188247460253e-4951
$+\infty$	7FFF 80000000 00000000	Infinity
$-\infty$	FFFF 80000000 00000000	-Infinity
Not-a-Number	7FFF FFFFFFFFFF FFFFFFFFFF	NaN

### 3. تدوير الأعداد في نظام IEEE المعياري

يحسب ، في نظام IEEE المعياري، ناتج أي عملية حسابية بدقة ومن ثم يجري تدوير الناتج (أي اختيار ممثل له من بين أعداد الآلة).

بوجه عام، يقصد بعملية تدوير عدد حقيقي  $x \in \mathbb{R}$  اختيار أقرب أعداد الآلة إليه يتطلب نظام IEEE المعياري تعريف ثلاثة أنماط أخرى من عمليات التدوير:

- التدوير باتجاه الصفر Round toward 0،
- التدوير باتجاه  $+\infty$ ،
- التدوير باتجاه  $-\infty$ .

يشتمل نظام IEEE المعياري على مجموعة من المؤشرات التي تدل على الحالات الاستثنائية في الحساب العددي منها:

- ظاهرة نقص الأس underflow،
- ظاهرة زيادة الأس overflow،
- القسمة على الصفر division by zero،
- العمليات الحسابية غير الصحيحة invalid operation.

عما أن تدوير الأعداد يدخل في صميم الحساب بالنقطة العائمة فإنه من المهم لنا ايجاد طريقة لقياس خطأ التدوير عند تنفيذ عملية حسابية ما. فعلى سبيل المثال، عندما نستخدم نظام تمثيل فيه  $p = 3$  ،  $\beta = 10$  و كانت نتيجة عملية حسابية ممثلة بهذا النظام  $3.12 \times 10^{-2}$  وكان الناتج عندما بحري العملية بدقة لا نهائية مساوياً  $0.0314$ ، يكون من الواضح أن هناك خطأ بقدر وحدتين من **مرتبة آخر رقم** (هنا  $10^{-4}$ ) من أرقام تمثيل الناتج بهذا النظام. بشكل مشابه، يمثل العدد الحقيقي  $0.0314159$  في هذا النظام بالعدد  $3.14 \times 10^{-2}$  وعندما يكون خطأ التمثيل مساوياً  $0.159$  وحدة من **مرتبة آخر رقم** (هنا  $10^{-4}$ ).

بوجه عام، إذا كان التمثيل بالنقطة العائمة للعدد الحقيقي  $x$  فإن الخطأ المرتكب في هذا التمثيل يساوي

$$\left| d_0.d_1 \dots d_{p-1} - x / \beta^e \right| \cdot \beta^{p-1}$$

وحدة من **مرتبة آخر رقم** (هنا  $\beta^{e-(p-1)}$ ).

يستعمل عادةً مصطلح **وحدة آخر رقم** ulp unit in the last place . فمثلاً: في نظام التمثيل المبين بالشكل 1 لدينا

$$ulp(1.11 \times 2^{-1}) = 2^{-1-2} = 1/8, \quad ulp(1.00 \times 2^0) = 2^{-2} = 1/4,$$

$$ulp(1.10 \times 2^1) = 2^{1-2} = 1/2, \quad ulp(1.01 \times 2^2) = 2^{2-2} = 1.$$

#### 4. الحالات الخاصة في نظام IEEE المعياري

رأينا سابقاً أنّ نظام IEEE 754 المعياري يشتمل على مجموعة من القيم الخاصة (انظر الجدول التالي) التي تحتاجها تمثيل الناتج عند إجراء العمليات الحسابية. تمتلك جميع هذه القيم تمثيلاً تكون فيه قيمة الأس مساوية لإحدى القيمتين  $e_{\max} + 1$  أو  $e_{\min} - 1$

<i>Exponent</i>	<i>Fraction</i>	<i>Represents</i>
$e = e_{\min} - 1$	$f = 0$	$\pm 0$
$e = e_{\min} - 1$	$f \neq 0$	$0.f \times 2^{e_{\min}}$
$e_{\min} \leq e \leq e_{\max}$	—	$1.f \times 2^e$
$e = e_{\max} + 1$	$f = 0$	$\infty$
$e = e_{\max} + 1$	$f \neq 0$	NaN

القيم الخاصة في نظام IEEE 754

• القيمة NaN

جرت العادة عند حساب النسبة  $0 / 0$  أو المدار  $\sqrt{-1}$  أنْ يوقف الحساب بخطأ غير قابل للمعالجة. لكن، هناك العديد من الحالات التي يكون فيها متابعة الحساب مفيدة. يمكن تجنب هذه المشكلة بتعريف قيمة خاصة تسمى NaN واعتبار ناتج كلّ من العمليتين  $0 / 0$  و  $\sqrt{-1}$  مساوياً NaN بدلاً من التوقف. يلخص الجدول التالي عدداً من الحالات التي يكون الناتج فيها NaN:

<i>Operation</i>	<i>Nan Produced By</i>
+	$\infty + (-\infty)$
$\times$	$0 \times \infty$
/	$0 / 0$ , $\infty / \infty$
$\sqrt{ }$	$\sqrt{x}$ , when $x < 0$

• القيمة  $\infty$  أو  $-\infty$

يسمح تعريف القيمة  $\infty$  بمتابعة الحساب عند حدوث زيادة في الأس overflow. يعتبر هذا الخيار أفضل من إرجاع القيمة الموافقة لأكبر عدد قابل للتمثيل. فمثلاً على سبيل المثال، عند حساب قيمة المدار  $\sqrt{x^2 + y^2}$  في نظام تمثيل للأعداد فيه

$$\beta = 10, \quad p = 3, \quad e_{\max} = 98.$$

إذا كان  $x = 3 \times 10^{70}$  و  $y = 4 \times 10^{70}$  فإنّ حساب قيمة  $x^2 + y^2$  سوف تحدث زيادة في الأس ولنفترض أنّ الناتج قد استبدل بالقيمة العظمى في هذا النظام وهي  $9.99 \times 10^{98}$ . يوجه مشابه تحدث زيادة في الأس عند حساب  $y^2$ . وكذلك

تحدث زيادةً في الأس عند حساب المجموع  $x^2 + y^2$  ومن ثم يكون الناتج أيضاً  $9.99 \times 10^{98}$ . وأخيراً، تكون نتيجة حساب المقدار متساويةً  $\sqrt{x^2 + y^2}$

$$\sqrt{9.99 \times 10^{98}} = 3.16 \times 10^{49}$$

ومن الواضح أن الخطأ في هذه النتيجة فظيع جداً !!! والجواب الصحيح هو وضوحاً  $5.00 \times 10^{70}$ .

في نظام IEEE الحسابي تكون نتيجة حساب  $x^2$  متساويةً للقيمة  $\infty$  وكذلك الأمر بالنسبة لنتيجة حساب  $y^2$  و  $\sqrt{x^2 + y^2}$ . ومن ثم تكون النتيجة النهائية  $\infty$ . من الواضح أن إعطاء هذه القيمة لنتيجة الحساب آمن من سابقتها.

من الأمثلة على الحالات التي يكون الناتج فيها متساوياً  $\infty$  ما يلي:

$$1/0 = \infty, \quad -1/0 = -\infty, \quad \sqrt{\infty} = \infty.$$

### • الصفر مع الإشارة ±0

يمثل الصفر في نظام IEEE بجزءٍ كسري معدوم  $0 \equiv f$  وأسٍ قيمته  $e_{\min} - 1$ . وبما أن إشارة التمثيل sign يمكن أن تأخذ قيمتين فإنه يكون هناك تمثيلين للصفر  $+0$  و  $-0$ . في مثل هذا الوضع يجب الحذر من طريقة التعامل مع هذا التمثيل، فمثلاً اختبار المقارنة  $(x = 0) \neq f$  يعتمد على إشارة  $x$  ولا يمكن في هذه الحالة إعطاء نتيجة دون وضع قاعدة توضح العلاقة بين تمثيلي الصفر. فنظام IEEE المعياري يعرف المقارنة بحيث يكون  $-0 = +0 < +0$ .

من جهة أخرى، يمكن للمرء أن يفكّر بإهمال الإشارة عند تمثيل الصفر، ولكن هذا أيضاً ينطوي على إشكالات، ونظام IEEE المعياري لا يفعل ذلك، لأن إشارة الصفر تفيد في تحديد إشارة ناتج حساب المقادير العددية. فمثلاً، تبطل صلاحية المطابقة  $x = 1/x$  عندما  $\infty = \pm x$ . والسبب في ذلك يعود إلى كون ناتج كل من  $\infty - 1$  و  $1/\infty$  هو الصفر وناتج  $1/0$  هو  $+\infty$ . وبذا تضيع معلومة إشارة الناتج.

مثالاً آخر على فائدة إشارة الصفر في حالة نقص الأس underflow والتواتر التي لها انقطاع عند الصفر مثل التابع اللوغاريتمي  $\log$ . في نظام IEEE المعياري، يعرف  $\log 0 = -\infty$  و  $\log x = \text{NaN}$  عندما  $x < 0$ . لنفترض  $x$  يمثل عدداً سالباً صغيراً بما يكفي ليحدث نقصاً في الأس فيدور إلى الصفر. عندها وحسن الحظ أن إشارة  $x$  سالبة ويكون ناتج حساب قيمة التابع اللوغاريتمي  $\text{NaN}$ .

### • الأعداد تحت النظامية Subnormal

لتنظر في حالة العددان  $x = 6.87 \times 10^{-97}$  و  $y = 6.0 \times 10^{-99}$  في نظام تمثيل بالنقطة العائمة وسطاً له:  $p = 3$ ،  $\beta = 10$ ،  $e_{\min} = -98$ . من الواضح أن هذين العددان نظاميين تماماً وكلّ منهما يكبر أصغر الأعداد النظامية الممثلة بهذا النظام  $1.00 \times 10^{-98}$ . مع ذلك، نلاحظ وجود ظاهرة غريبة يتمتع بها هذان العددان:  $x - y = 0$  في حين أن  $y \neq 0$ . والسبب في ذلك يعود إلى كون  $6.0 \times 10^{-99} = 0.06 \times 10^{-97} = x - y$  وهذا الفرق يمثل عدداً صغيراً لا يمكن تمثيله بعد نظامي normal number ولهذا يدور هذا الفرق إلى الصفر.

يبين من ذلك أهمية أن يحافظ نظام التمثيل على صحة الخاصة التالية

$$(3) \quad x = y \Leftrightarrow x - y = 0$$

يضمن نظام التمثيل المعياري IEEE 754 وكذلك IEEE 854 الخاصة (3) إضافةً إلى العديد من الخواص الأخرى من خلال توسيع مجموعة الأعداد النظامية الممثلة بهذا النظام لتشمل أعداداً واقعة بين الصفر وأصغر الأعداد النظامية. تسمى هذه الأعداد denormalized numbers وأعيد تسميتها في نظام IEEE 854 لتصبح .subnormal

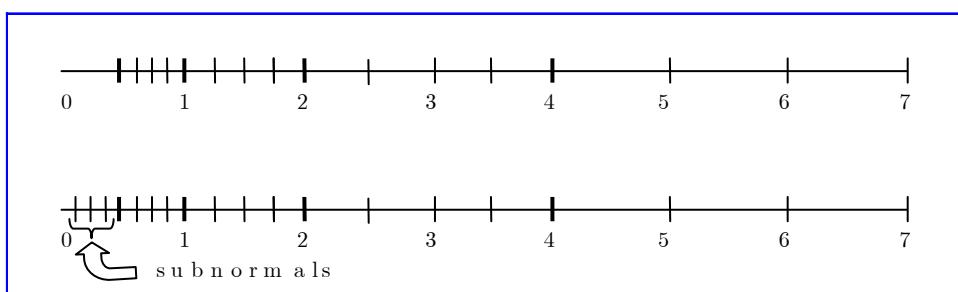
**مثال:** في حالة نظام تمثيل بالنقطة العائمة القياسية وسطاوه  $e_{\max} = 2$  ،  $e_{\min} = -1$  ،  $p = 3$  ،  $\beta = 2$  ولدينا (انظر الشكل 5) :

- مجموعة الأعداد النظامية: وتشمل

$$\mathcal{N} = \bigcup_{i=-1}^2 \left\{ 1.00 \times 2^i, 1.01 \times 2^i, 1.10 \times 2^i, 1.11 \times 2^i \right\}$$

- مجموعة الأعداد تحت النظامية وهي

$$\mathcal{S} = \left\{ 0.01 \times 2^{-1}, 0.10 \times 2^{-1}, 0.11 \times 2^{-1} \right\}$$



الشكل 5: الأعداد القياسية الموجبة: النظامية وتحت النظامية في حالة نظام التمثيل المعياري الموافق للوسطاء

$$. e_{\max} = 2 \quad e_{\min} = -1 \quad , p = 3 \quad , \beta = 2$$

## 5. الأخطاء من وجهة النظر العددية

تعتبر دراسة الخطأ موضوعاً جوهرياً في التحليل العددي، ذلك أنّ معظم الطائق العددي توفر حلولاً تقريرية للحل المنشود، ومن المهم هنا أن نستطيع تقدير الخطأ الناشئ عن اعتماد هذه الحلول، وأن نحصره ضمن حدود معينة. نصنف في

هذه الفقرة الأخطاء المتعلقة بمسألة معينة، كما نقدم عرضاً موجزاً لنتائج أولية تتعلق بانتشار الأخطاء في أنواع مختلفةٍ من الحسابات العددية.

نعرف الخطأ في تقرير لقيمة عدد ما بأنه الفرق بين قيمته الحقيقية والقيمة التقريرية. نرمز بـ  $x_T$  إلى القيمة الحقيقية وبـ  $x_A$  إلى القيمة التقريرية، ونضع

$$(4) \quad \text{Err}(x_A) = x_T - x_A$$

وفي حالة  $x_T \neq 0$  نعرف الخطأ النسبي بالعلاقة

$$(5) \quad \text{Rel}(x_A) = \frac{x_T - x_A}{x_T}$$

**مثال:** إذا كان

$$\begin{cases} x_T = e = 2.7182818\cdots \\ x_A = \frac{19}{7} = 2.7142857\cdots \end{cases}$$

فإن

$$\begin{cases} \text{Err}(x_A) = 0.03996 \\ \text{Rel}(x_A) = 0.00147 \end{cases}$$

## 1.5 مصادر الأخطاء

تصنّف مصادر الأخطاء الأساسية كما يلي:

### • أولاً: أخطاء ناجمة عن المذجة الرياضية للمسائل الفيزيائية:

يعتبر النموذج الرياضي لظاهرة فيزيائية محاولة لإبراز علاقة رياضية بين بعض المقادير الفيزيائية المتعلقة بهذه الظاهرة. وبسبب تعقيد الواقع الفيزيائي، نعمد إلى استخدام فرضيات تبسيطية، بغية الحصول على نموذج رياضي بسيط يحكم الظاهرة الفيزيائية. وبحكم التبسيط فإن النموذج الرياضي الموضوع سيكون محدود الدقة، وقد تكون هذه المحدودية في بعض الحالات عائقاً دون الاستفادة منه، وقد يعطي النموذج نتائج مقبولة في حالات أخرى ، وهذا يتعلق باستخدامات النموذج. وفي الحالة التي يكون فيها النموذج غير دقيق فإن الحل العددي للنموذج لا يمكنه أن يحسن من نقص الدقة في النموذج.

### • ثانياً: أخطاء ناجمة عن عدم الدقة في المعطيات الفيزيائية:

تشتمل معظم المعطيات في المسائل الفيزيائية على أخطاء، وهذا ما يؤثّر في دقة الحسابات التي تُجرى على هذه المعطيات، ومن ثم تحدّ من دقة النتائج التي نحصل عليها.

### • ثالثاً: أخطاء ناجمة عن تدوير الأعداد:

إنّ تمثيل الأعداد في الأنظمة الحاسوبية بعدد محدود من الأرقام، يجعل عملية تقرير الأعداد الحقيقية بأعداد الآلة أمراً لا بدّ منه، للتمكن من تمثيل الأعداد والتعامل معها في الحسابات. إنّ دقة التقرير في تمثيل الأعداد في النظام الحاسوبي، تتعلق

كما رأينا بالمواصفات التي يتسم بها النظام الحاسوبي للتعامل مع الأعداد. في حالة التمثيل بالنقطة العائمة، رأينا أن الدقة في التمثيل تتعلق بعدد الأرقام  $p$  المستخدمة في التعبير عن الجزء الكسري وبطبيعة الحال بأساس نظام التمثيل  $\beta$  المستخدم.

## 2.5 انتشار الأخطاء

ندرس في هذه الفقرة، الآثار الناجمة عن العمليات الحسابية على أعداد تشوهاً أخطاء. لهذا نرمز بـ  $w$  إلى عملية حسابية أساسية مثل  $+$  ،  $-$  ،  $\times$  ،  $/$ ؛ ونرمز بـ  $w^*$  إلى العملية الحسابية المقابلة في النظام الحاسوبي، والتي غالباً ما تتضمن عملية تدوير rounding نرمز إليها بالتطبيق  $A \rightarrow \mathbb{R}$ : حيث تمثل  $A$  مجموعة الأعداد القابلة للتمثيل في النظام الحاسوبي.

ليكن  $x_A$  و  $y_A$  العددين اللذين ستحرجى عليهما العملية الحسابية  $w$ ، ونفترض أنهما مشوبان بخطأ مقداره  $\varepsilon$  و  $\eta$  على الترتيب، أي أن القيم الصحيحة هي:

$$x_T = x_A + \varepsilon, \quad y_T = y_A + \eta.$$

عندما يكون  $y_A \cdot w \cdot x_A$  هو العدد الناتج من إجراء العملية  $w^*$ ، ويكون الخطأ المرتكب في النتيجة:

$$(6) \quad x_T \cdot w \cdot y_T - x_A \cdot w^* \cdot y_A = (x_T \cdot w \cdot y_T - x_A \cdot w \cdot y_A) + \\ (x_A \cdot w \cdot y_A - x_A \cdot w^* \cdot y_A).$$

نسمّي المقدار

$$(x_T \cdot w \cdot y_T - x_A \cdot w \cdot y_A)$$

**خطاً الانتشار** ، وبالمثل نسمّي المقدار

$$(x_A \cdot w \cdot y_A - x_A \cdot w^* \cdot y_A)$$

**خطاً التدوير**. وفيما يخص خطأ التدوير فإنه غالباً ما يكون:

$$(7) \quad x_A \cdot w^* \cdot y_A = \text{rd}(x_A \cdot w \cdot y_A).$$

وهذا يعني أن المقدار  $y_A \cdot w \cdot x_A$  يحسب تماماً ومن ثم يجري تدوير الناتج. ويتبين من ذلك أن خطأ التدوير يحقق المترادفة:

$$(8) \quad |x_A \cdot w \cdot y_A - x_A \cdot w^* \cdot y_A| \leq \frac{\beta}{2} \cdot |x_A \cdot w \cdot y_A| \cdot \beta^{-p}$$

وفيما يخص انتشار الأخطاء، نتفحص الحالات الخاصة التالية:

### حالات عملية الضرب ☒

$$\begin{aligned} x_T \cdot y_T - x_A \cdot y_A &= x_T \cdot y_T - (x_T - \varepsilon) \cdot (y_T - \eta) \\ &= x_T \cdot \eta + y_T \cdot \varepsilon - \varepsilon \cdot \eta \end{aligned}$$

ويكون الخطأ النسبي:

$$\text{Rel}(x_A \cdot y_A) = \frac{x_T y_T - x_A y_A}{x_T y_T} = \frac{\eta}{y_T} + \frac{\varepsilon}{x_T} - \frac{\varepsilon}{x_T} \cdot \frac{\eta}{y_T}$$

ومنه

$$(9) \quad \text{Rel}(x_A \cdot y_A) = \text{Rel}(x_A) + \text{Rel}(y_A) - \text{Rel}(x_A) \cdot \text{Rel}(y_A)$$

وفي حالة كون  $1 \ll \text{Rel}(y_A) \ll |\text{Rel}(x_A)|$

$$(10) \quad \text{Rel}(x_A \cdot y_A) \approx \text{Rel}(x_A) + \text{Rel}(y_A)$$

الرمز  $\ll$  يعني "أصغر بكثير من".

### حالات عملية القسمة ☒

طريقة مشابهة للحالة السابقة نحصل على:

$$(11) \quad \text{Rel}(x_A / y_A) = \frac{\text{Rel}(x_A) - \text{Rel}(y_A)}{1 - \text{Rel}(y_A)}$$

عندما يكون  $|\text{Rel}(y_A)| \ll 1$

$$(12) \quad \text{Rel}(x_A / y_A) \approx \text{Rel}(x_A) - \text{Rel}(y_A)$$

نلاحظ في عملية الضرب والقسمة، أن الأخطاء النسبية لا تنتشر بسرعة.

### حالات عملية الجمع والطرح ☒

لدينا هنا

$$(x_T \pm y_T) - (x_A \pm y_A) = (x_T - x_A) \pm (y_T - y_A) = \varepsilon \pm \eta$$

ومنه

$$(13) \quad \text{Err}(x_A \pm y_A) = \text{Err}(x_A) \pm \text{Err}(y_A)$$

### حالات حساب القيمة العددية لتابع ☒

لتكن  $f(x_A)$  القيمة التقريرية لقيمة التابع  $f(x_T)$  عند النقطة  $x_T$ . باستخدام مبرهنة القيمة الوسطية نكتب

$$(14) \quad f(x_T) - f(x_A) \approx f'(x_T) \cdot (x_T - x_A)$$

وذلك بفرض أن  $x_A$  و  $x_T$  عدادان قرييان نسبياً وأن  $f'(x)$  لا يتغير كثيراً بين العددين  $x_A$  و  $x_T$ . على سبيل المثال:

$$\begin{aligned}\sin(\pi/5) - \sin(0.628) &\approx \cos(\pi/5) \cdot (\pi/5 - 0.628) \\ &\approx 0.00026\end{aligned}$$

وهذا تقريب ممتاز للخطأ.

### ☒ حالة حساب مجموع

لندرس حساب مجموع من النمط

$$(15) \quad S = \sum_{i=1}^m x_i$$

باستخدام نظام حاسوبي تمثل فيه الأعداد  $x_1, \dots, x_m$  مجموعة من أعداد الآلة، أي إن  $(x_i)_{i \in \{1, \dots, m\}}$  كان

$$S_2 = \text{rd}(x_1 + x_2) = (x_1 + x_2) \cdot (1 + \varepsilon_2)$$

حيث

$$|\varepsilon_2| \leq \frac{\beta}{2} \beta^{-p}$$

نعرف بالتدريج، المجموع

$$S_{r+1} = \text{rd}(S_r + x_{r+1}), \quad 1 \leq r \leq m-1.$$

عندما يكون

$$S_{r+1} = (S_r + x_{r+1}) \cdot (1 + \varepsilon_{r+1}), \quad |\varepsilon_{r+1}| \leq \frac{\beta}{2} \beta^{-p}.$$

ونحصل أخيراً على

$$S_2 - (x_1 + x_2) = (x_1 + x_2) \cdot \varepsilon_2$$

$$\begin{aligned}S_3 - (x_1 + x_2 + x_3) &= (x_1 + x_2) \cdot \varepsilon_2 + (x_1 + x_2) \cdot (1 + \varepsilon_2) \cdot \varepsilon_3 + x_3 \cdot \varepsilon_3 \\ &\approx (x_1 + x_2) \cdot \varepsilon_2 + (x_1 + x_2 + x_3) \cdot \varepsilon_3\end{aligned}$$

$$\begin{aligned}S_4 - (x_1 + x_2 + x_3 + x_4) &\approx (x_1 + x_2) \cdot \varepsilon_2 + (x_1 + x_2 + x_3) \cdot \varepsilon_3 + \\ &\quad (x_1 + x_2 + x_3 + x_4) \cdot \varepsilon_4\end{aligned}$$

ومن ثم، فإن

$$\begin{aligned}(16) \quad S_m - \sum_{i=1}^m x_i &\approx (x_1 + x_2) \cdot \varepsilon_2 + \dots + (x_1 + \dots + x_m) \cdot \varepsilon_m \\ &= x_1 \cdot (\varepsilon_2 + \dots + \varepsilon_m) + x_2 \cdot (\varepsilon_2 + \dots + \varepsilon_m) + \\ &\quad x_3 \cdot (\varepsilon_3 + \dots + \varepsilon_m) + \dots + x_m \cdot \varepsilon_m\end{aligned}$$

من هذه العلاقة نستنتج أن أفضل استراتيجية لجمع الأعداد هي أن يجري الجمع من الأصغر إلى الأكبر.

### ☒ تأثير المعطيات غير الدقيقة

إنّ المعطيات ذات المصدر التجاري (ناتجة عن قياسات فيزيائية) غالباً ما تكون ذات **دقة محدودة**، لنقل إنّها مقادير مقيسة بدقة  $r$  رقمًا. إنّ الأخطاء المرتكبة في القياس (نتيجة نقص الدقة في أجهزة القياس) سوف تنتشر بالحسابات التي تجرى على هذه المعطيات، ومن ثم تتسرب في الحصول على نتائج حسابية لها عدد من أرقام الدقة يقل عن  $r$  رقمًا. فمثلاً، لننظر في مسألة حساب المجموع

$$\sum_{i=1}^m x_i \cdot y_i$$

الأعداد  $x_i$  و  $y_i$  تقع في المجال  $[0.1, 1]$  وتتمتع بدقة  $r$  رقمًا. باستخدام الحسابات العشرية ( $\beta = 10$ )، نحسب المجموع بطريقتين ونخلل الخطأ. في الحالتين تمثل  $X_i$  و  $Y_i$  القيم الصحيحة:

$$\left. \begin{aligned} X_i &= x_i + \varepsilon_i \\ Y_i &= y_i + \eta_i \end{aligned} \right\}, \quad |\varepsilon_i|, \quad |\eta_i| \leq 5 \times 10^{-(r+1)}.$$

**حالة أولى:** نكون الجداء  $x_i \cdot y_i$  وندور إلى  $r$  رقمًا ثم نجمع. إن الخطأ المرتكب في المجموع هو

$$\begin{aligned} E_1 &= \sum_{i=1}^m X_i Y_i - \text{Computed value of} \left( \sum_{i=1}^m x_i y_i \right) \\ &= \sum_{i=1}^m X_i Y_i - \sum_{i=1}^m [(X_i - \varepsilon_i) \cdot (Y_i - \eta_i) + \gamma_i] \end{aligned}$$

حيث  $\gamma_i$  هو خطأ التدوير في الجداء  $x_i \cdot y_i$ . لدينا في هذه الحالة

$$E_1 \approx \sum_{i=1}^m [\varepsilon_i \cdot Y_i + \eta_i \cdot X_i - \gamma_i]$$

ومنه نجد

$$(17) \quad |E_1| \leq 3m \left( 5 \times 10^{-(r+1)} \right)$$

**حالة ثانية:** نكون الجداءات  $x_i \cdot y_i$  بدقة  $2r$  ونحري عملية جمعها محتفظين بكل أرقام الدقة. ثم نقوم بتدوير ناتج الجمع الأخير إلى  $r$  رقمًا. عندها يعطى الخطأ المرتكب في هذه الحالة

$$\begin{aligned} E_2 &= \sum_{i=1}^m X_i Y_i - \text{Computed value of} \left( \sum_{i=1}^m x_i y_i \right) \\ &= \sum_{i=1}^m X_i Y_i - \left\{ \sum_{i=1}^m [(X_i - \varepsilon_i) \cdot (Y_i - \eta_i)] + \gamma \right\} \\ &\approx \left( \sum_{i=1}^m [\varepsilon_i \cdot X_i + \eta_i \cdot Y_i] \right) - \gamma \end{aligned}$$

حيث  $|\gamma| \leq 5 \times 10^{-(r+1)}$ . ومنه نستنتج

$$(18) \quad |E_2| \leq (2m + 1) \left( 5 \times 10^{-(r+1)} \right)$$

من الواضح أن تحديد الخطأ في المراجحة (15) أفضل مما هو عليه في المراجحة (14). إن الخطأ  $E_2$  ناتج من انتشار أخطاء المعطيات الأصلية ؛ في حين يشمل  $E_1$ ، إضافة إلى ذلك أخطاء تدوير النتائج المتوسطة إلى  $x$  رقمًا. ومن ثم تبيّن أهمية إجراء الحسابات بدقة تتجاوز  $x$  رقمًا لتجنب حدوث انتشار أوسع للأخطاء.

## 6. مفهوم الاستقرارية في التحليل العددي

تتأثر حلول العديد من المسائل الرياضية بدرجة ملحوظة بعض الأخطاء الحسابية مثل أخطاء التدوير. ولكي نستطيع دراسة وتحليل مثل هذه الظواهر، نشرح مفهوم "الاستقرارية" **Stability** ومفهوم "الحساسية" **Sensitivity**. إن حساسية مسألة ما مرتبطة إلى حد بعيد بالدقة العظمى التي يمكننا الوصول إليها في حل هذه المسألة، عندما نستخدم نظام تمثيل منه للأعداد ونجزي العمليات الحسابية فيه لإيجاد الحل. نوسع في مرحلة لاحقة هذه المفاهيم لتشمل الطائق العددي المستخدمة في حل المسائل الرياضية على أنواعها. وبوجه عام، نعتمد الطائق العددي التي لا تتمتع بحساسية عالية للأخطاء الصغيرة التي قد تшوب معطيات المسألة، أو قد تنجم عن أخطاء تمثيل الأعداد وأخطاء التدوير عند إجراء الحسابات.

لتبسيط العرض، نقتصر في نقاشنا على دراسة المسائل التي لها شكل المعادلة:

$$(19) \quad F(x, y) = 0$$

حيث يمثل المتحول  $x$  مجھول المسألة الذي نود تعبينه بحل هذه المعادلة، ويتمثل المتحول  $y$  المعطيات التي تتعلق بها نتيجة الحل. إن شكل المعادلة (19) يمكن أن يمثل العديد من المسائل الرياضية. فعلى سبيل المثال:

◀ تابع حقيقي متحول حقيقي  $x$  ومتاحول شعاعي  $y$  ، تساهم مركباته في تعريف العلاقة التابعية  $F$  ؛

◀ المعادلة (19) يمكن أن تكون معادلة تكاملية أو معادلة تفاضلية يمثل فيها  $x$  التابع المجهول ويتمثل  $y$  تابعًا معطى أو قيمًا محاطية معطاة.

نقول عن المسألة (19) إنها **مستقرة** **Stable** إذا كان الحل  $x$  يتعلق باستمرار بالمتاحول  $y$ . معنى أنه إذا كانت  $\{y_n\}$  متتالية من القيم التي تقارب قيمة  $y$  بمعنى من المعاني، فإن متتالية الحلول الموافقة  $\{x_n\}$  يجب أن تقارب الحل  $x$  على نحو موافق. نسمى أيضًا المسائل المستقرة، مسائل **جيّدة الطرح well-posed problems** كما نسمى المسائل غير المستقرة **ill-posed problems**، مسائل **سيئة الطرح Unstable**.

**أمثلة:**

❶ لنظر في مسألة حل المعادلة الجبرية

$$ax^2 + bx + c = 0, \quad a \neq 0.$$

المعطيات هنا هي الثلاثية  $(a, b, c) = y$ . نعلم أنه في حالة تحقق الشرط  $0 - 4ac \geq b^2$  تقبل هذه المعادلة حلولاً حقيقية تعطى بالقانون:

$$x = \frac{-b \pm \sqrt{b^2 - 4ac}}{2a}$$

ومن الواضح أن هذين الحللين مستمران كتابع بالتحولات  $a$ ،  $b$  و  $c$ .

**2** لتكن المعادلة التكاملية التالية:

$$(20) \quad \int_0^1 \frac{0.75 x(t) dt}{1.25 - \cos[2\pi(s+t)]} = y(s), \quad 0 \leq s \leq 1.$$

إن هذه المسألة غير مستقرة. لأنّه توجد متتالية من التشويشات  $\{\delta_n\}_{n \in \mathbb{N}}$ :

$$n \in \mathbb{N}, \quad \delta_n(s) = y_n(s) - y(s)$$

تحقق

$$(21) \quad \lim_{n \rightarrow \infty} \max_{0 \leq s \leq 1} |\delta_n(s)| = 0.$$

وتحقق متتالية الحلول المواتفة  $\{x_n\}_{n \in \mathbb{N}}$  الشرط:

$$(22) \quad \forall n \in \mathbb{N}, \quad \max_{0 \leq s \leq 1} |x_n(s) - x(s)| = 1.$$

فعلى سبيل المثال، نعرف  $y_n(s) = y(s) + \delta_n(s)$  حيث

$$\forall n \in \mathbb{N}, \quad \delta_n(s) = \frac{1}{2^n} \cos(2n\pi s), \quad 0 \leq s \leq 1.$$

ويكون في هذه الحالة

$$x_n(s) - x(s) = \cos(2n\pi s).$$

وهذا يتحقق الشرط (19).

إذا كانت مسألة من النمط (19) غير مستقرة، فستواجهنا صعوبات جدية إذا ما حاولنا حلّها. ومن غير الممكن عادةً أن نحلّ مثل هذه المسائل بدون محاولتنا فهم جوانب عديدة تتعلق بخصائص الحل. وهذا الجانب من المعالجة، للمسائل غير المستقرة هو مجال بحث حيث في الرياضيات التطبيقية عموماً، وفي مسائل التحليل العددي بوجهٍ خاص.

في الواقع العملي، هناك العديد من المسائل المستقرة بالمعنى الذي أوردناه آنفًا، ولكن تبقى هناك صعوبات وعوائق تترجم عن الحسابات العددية المتعلقة بطرائق حل هذه المسائل. ولكي نستطيع التعامل مع هذه الصعوبات، نستخدم مفهوماً لقياس استقرارية المسألة نسميه "عدد الحساسية" ويعادل هذه التسمية المصطلح اللاتيني **Condition number**.

نحاول بواسطة عدد الحساسية أن نقيس أسوأ آثار المسألة (19) في الخل  $x$ ، عندما يتعرض المتحول  $y$  لتشويش بمقدار بسيط. ليكن  $\delta y$  التشويش الذي يتعرض له المتحول  $y$  وليكن  $x + \delta x$  هو حل المعادلة المشوّشة:

$$(23) \quad F(x + \delta x, y + \delta y) = 0$$

$$(24) \quad \kappa(x) = \sup_{\delta y} \frac{\|\delta x\|/\|x\|}{\|\delta y\|/\|y\|} \quad \text{نعرف}$$

نستخدم هنا الرمز  $\|\cdot\|$  لندل على قياس المقدار الموضوع داخله. يحسب الحد الأعلى  $\sup$  في العبارة (24) على مجموعة التشویشات الصغيرة  $\delta y$  التي تكون المسألة (23) عندها ذات معنى، أي قابلة للحل. وبطبيعة الحال فإن المسائل غير المستقرة تقودنا إلى  $\kappa(x) = \infty$ .

إن عدد الحساسية  $\kappa(x)$  للمسألة (19) يقيس حساسية الحل  $x$  للتغيرات الصغيرة في المعطيات  $y$ . فإذا كان  $\kappa(x)$  كبيراً نسبياً، فإن هذا يعني وجود تغيير صغير نسبياً  $\delta y$  للمعطيات  $y$  يحدث تغييراً كبيراً نسبياً  $\delta x$  في الحل  $x$ . ولكن إذا كان  $\kappa(x)$  صغيراً، ولنقل  $\leq 10$ ، عندها لا يكون للتغيرات الصغيرة في المعطيات  $\delta y$  الأثر الكبير في تغيير الحل  $\delta x$ .

فالتغيرات الصغيرة نسبياً في  $y$  تقودنا إلى تغيرات صغيرة نسبياً في الحل  $x$ . ولما كانت الحسابات العددية يشوهها عادةً أخطاء صغيرة ناجمة عن التدوير وتقريب الأعداد، فإننا لا نرغب أن يكون **عدد الحساسية** لمسألة نود حلها بالطريق العددية كبيراً. إن مسألة كهذه نسميها **سيئة الحساسية ill-conditioned** (ذات حساسية عالية)، وتكون غالباً صعبة الحل بدقة.

### أمثلة:

لنطرح مسألة إيجاد حل للمعادلة ①

$$(25) \quad x - a^y = 0, \quad a > 0$$

نشوش  $y$  بـ  $\delta y$  فنحصل على

$$\frac{\delta x}{x} = \frac{a^{y+\delta y} - a^y}{a^y} = a^{\delta y} - 1$$

ومنه نجد عبارة عدد الحساسية

$$\kappa(x) = \sup_{\delta y} \left| \frac{\delta x/x}{\delta y/y} \right| = \sup_{\delta y} \left| y \left( \frac{a^{\delta y} - 1}{\delta y} \right) \right|$$

إذا كان المقدار  $\delta y$  صغيراً نحصل على

$$(26) \quad \kappa(x) \approx |y \ln a|$$

وبصرف النظر عن طريقة حساب  $x$  في المعادلة (25)، إذا كان  $\kappa(x)$  كبيراً فإن تغيرات صغيرة في  $y$  تؤدي إلى تغيرات أكبر بكثير نسبياً في الحل  $x$ . فإذا كان  $\kappa(x) = 10^4$  وكان الخطأ النسبي في قيمة  $y$  المستخدمة هو  $10^{-7}$  وهو

خطأ ناجم عن التمثيل بدقة منتهية في النظام الحاسوبي، عندما توقع أن يكون الخطأ النسبي في قيمة  $x$  الناتجة قرابة  $10^{-3}$ . ويمثل هذا هبوطاً كبيراً في الدقة.

لتكون المعادلة ②

$$\begin{pmatrix} 0.780 & 0.563 \\ 0.913 & 0.659 \end{pmatrix} \cdot \begin{pmatrix} x_1 \\ x_2 \end{pmatrix} = \begin{pmatrix} 0.217 \\ 0.254 \end{pmatrix}$$

التي تكتب بالشكل

$$(27) \quad A \cdot x = b$$

حيث

$$A = \begin{pmatrix} 0.780 & 0.563 \\ 0.913 & 0.659 \end{pmatrix}, \quad b = \begin{pmatrix} 0.217 \\ 0.254 \end{pmatrix}, \quad x = \begin{pmatrix} x_1 \\ x_2 \end{pmatrix}.$$

وهذه مسألة من النمط (19) معطياتها  $y$  والمصفوفة  $A$  والشاع  $b$ . نبحث عن الحل  $x$  الذي يحقق الشرط (27). تتمتع هذه المسألة بحساسية عالية، فأيّ تغيير بسيط في المعطيات، أي عناصر المصفوفة  $A$  وعناصر الشاع  $b$ ، يتبع عنه تغيير كبير في الحل. تقبل المعادلة (27) حلّاً وحيداً هو

$$x = \begin{pmatrix} 1 \\ -1 \end{pmatrix}$$

فإذا أجرينا تغييراً بسيطاً في عناصر الشاع  $b$  ولتكن  $\Delta b = \begin{pmatrix} 10^{-3} \\ -10^{-3} \end{pmatrix}$  حصلنا على المعادلة المشوهة

$$(28) \quad A \cdot \tilde{x} = b + \Delta b$$

تقيل هذه المعادلة حلّاً هو

$$\tilde{x} = A^{-1} \cdot \tilde{b} = \begin{pmatrix} 659000 & -563000 \\ -913000 & 780000 \end{pmatrix} \cdot \begin{pmatrix} 0.218 \\ 0.253 \end{pmatrix} = \begin{pmatrix} 1223 \\ -1694 \end{pmatrix}.$$

نلاحظ هنا أنّ

$$\|\delta x\|_\infty = 1693,$$

$$\|x\|_\infty = 1,$$

$$\|\delta b\|_\infty = 10^{-3},$$

$$\|b\|_\infty = 0.254.$$

وهذا ما يبرر **السلوك الحساس** جداً لهذه الجملة الخطية.

## 7. استقرارية طرائق العددي

نقول عن طريقة عددية حل مسألة رياضية إنها مستقرة إذا كانت حساسية ناتجها العددي للمعطيات لا تزيد عن حساسية المسألة الرياضية الأصلية. يعالج المثال التالي مسألة حساب تكامل محدود باتباع طرائق عددية، وبه نوضح مفهوم الاستقرارية لهذا.

ليكن

$$(29) \quad E_n = \int_0^1 x^n e^{x-1} dx, \quad n \in \mathbb{N}.$$

إذا كان  $n \geq 1$  فإن

$$(x^n e^{x-1})' = n \cdot x^{n-1} e^{x-1} + x^n e^{x-1}.$$

متكاملة الطرفين على المجال  $[0, 1]$  نجد

$$\int_0^1 x^n e^{x-1} dx = [x^n e^{x-1}]_0^1 - n \int_0^1 x^{n-1} e^{x-1} dx.$$

ومنه نحصل على علاقة التدرج

$$(30) \quad \begin{cases} E_n = 1 - n \cdot E_{n-1}, & n \geq 1 \\ E_0 = \int_0^1 e^{x-1} dx = 1 - e^{-1} \end{cases}$$

باستخدام نظام تمثيل حاسوبي فيه  $n = 6$  و  $\beta = 10$  يمكننا حساب قيم تقريرية  $E_n$  عندما  $n = 1, 2, \dots, 9$  فنجد:

$E_1 \cong 0.367879$	$E_6 \cong 0.127120$
$E_2 \cong 0.264242$	$E_7 \cong 0.110160$
$E_3 \cong 0.207274$	$E_8 \cong 0.118720$
$E_4 \cong 0.170904$	$E_9 \cong -0.068480 < 0$
$E_5 \cong 0.145480$	

نلاحظ هنا أن القيمة العددية التي نحصل عليها بهذه الطريقة كقيمة تقريرية للا całkowity للتكامل  $E_9$  هي قيمة سالبة، على حين يجب أن يكون تكامل التابع  $x^9 e^{x-1}$  على المجال  $[0, 1]$  موجباً، مما هو سبب هذه المشكلة؟

في الواقع، إذا أردنا تحليل ما حدث ومعرفة مصدر الخطأ الذي تسبب في هذه النتيجة، فخلل الأخطاء الحاصلة في النواتج العددية للتكمalamات  $E_1, E_2, \dots, E_9$  فنجد:

في حساب  $E_1 = 1 - E_0 = e^{-1}$  نرتكب خطأ تقرير من مرتبة دقة الآلة مقداره  $4.412 \times 10^{-7}$ . هذا الخطأ ينتشر في حساب  $E_2$  ليصبح  $(-2) \times 4.412 \times 10^{-7}$  ، وهكذا يكون خطأ التقرير الناتج في حساب  $E_9$  من مرتبة  $(-2)(-3)\dots(-9) \times 4.412 \times 10^{-7} = 9! \times 4.412 \times 10^{-7} \approx 0.1601$ .

إن القيمة الدقيقة لـ  $E_9$  في هذه الحالة (بدقة ثلاثة أرقام) هي:

$$-0.06848 + 0.1601 = 0.0916.$$

وهنا نطرح التساؤل عن وجود طريقة أخرى تخلّي مشكلة عدم الاستقرار هذا؟ في الواقع، إذا أعدنا كتابة علاقة التدريج (30) بالشكل:

$$(31) \quad E_{n-1} = \frac{1 - E_n}{n}, \quad n \geq 1$$

وإذا كنّا نعرف قيمةً تقريريةً لـ  $E_n$  فإن استخدام العلاقة (31) لحساب  $E_{n-1}$  يسمح لنا بالحصول على قيمةً تقريريةً يتافق فيها خطأ التقرير  $n$  مرّةً عمّا هو عليه في  $E_n$ .

لتكن  $n \gg 1$ ، لدينا

$$E_n = \int_0^1 x^n e^{x-1} dx \leq \int_0^1 x^n dx = \frac{x^{n+1}}{n+1} \Big|_0^1 = \frac{1}{n+1}.$$

نستنتج من ذلك أن  $\lim_{n \rightarrow \infty} E_n = 0$ .

فعلى سبيل المثال، يمكننا اعتبار القيمة 0 تقريرياً لـ  $E_{20}$  ونكون في هذه الحالة قد ارتكبنا خطأ لا يتجاوز  $\frac{1}{21}$ .

وباستخدام العلاقة (28) يمكننا حساب قيمة تقريرية لـ  $E_{19}$  يكون الخطأ فيها محدوداً بـ

$$\frac{1}{20} \times \frac{1}{21} \cong 0.0024.$$

تسمح علاقة التدريج (31) تدريجياً، بإيجاد قيمةً تقريريةً لـ  $E_{15}$  بخطأ لا يتجاوز  $4 \times 10^{-8}$  وهذا الخطأ أقل من دقة الآلة التي نجري بها الحسابات (هنا  $eps = 5 \times 10^{-6}$ ). باستخدام هذه الطريقة نحصل على القيم التقريرية التالية:

$E_{20} \cong 0.0$	$E_{14} \cong 0.0627322$
$E_{19} \cong 0.0500000$	$E_{13} \cong 0.0669477$
$E_{18} \cong 0.0500000$	$E_{12} \cong 0.0717733$
$E_{17} \cong 0.0527778$	$E_{11} \cong 0.0773523$
$E_{16} \cong 0.0557190$	$E_{10} \cong 0.0838771$
$E_{15} \cong 0.0590176$	$E_9 \cong 0.0916123$

نلاحظ هنا أن الخطأ الابتدائي المركب في تقييم قيمة التكامل  $E_{20}$  قد اختفى نهائياً اعتباراً من الحد  $E_{15}$  ؛ وهذا يعود إلى استقرارية هذه الطريقة، ومن ثم تكون قد حصلنا على قيم تقريرية للتكمالات  $E_{15}, E_9, \dots$  بدقة تفوق دقة الآلة التي بحري بها الحسابات، ومن هذا نستنتج أن جميع أرقام الجزء الكسري في تمثيل القيم  $E_{15}, E_9, \dots$  هي أرقام معنوية significant digit باستثناء الرقم الأخير الذي يمكن أن يكون مدوراً.

## 8 مسائل ومقارن

**1.8.** يعتمد تمثيل النقطة العائمة القياسية في نظام حاسوبي الموصفات

$$e_{\max} = 9, e_{\min} = -9, p = 3, \beta = 10$$

كم يبلغ عدد الأعداد القياسية Normalized number في هذه النظام؟

**2.8.** ليكن نظام التمثيل بالنقطة العائمة القياسية المحدد بالوسطاء  $10 = 3, \beta = 3, p = 3$ . ما هو الخطأ النسبي المركب في حساب ناتج العمليات الحاسوبية التالية:

$$(3.28 \cdot 10^{-2}) \times^* (6.98 \cdot 10^3) \\ [(3.28 \cdot 10^{-2}) \times^* (6.98 \cdot 10^3)] /* (4.82 \cdot 10^{-8})$$

إذا كان هذا النظام يعتمد التدوير إلى الأقرب في تمثيل النواتج.

**3.8.** بين أنه إذا كان  $x$  عدداً حقيقياً صغيراً بالقدر الكافي فإن حساب القيمة العددية للمقدار

$$1 - \cos x$$

يكون مصحوباً بخطأً كبيراً ناجماً عن عملية الطرح. اقترح صيغة مكافحة لحساب هذه القيمة بحيث تتجنب هذا الخطأ.

**4.8.** نعلم أن أحد جذور المعادلة  $0 = a \cdot x^2 + b \cdot x + c$  يعطى بالعلاقة

$$r_1 = \frac{-b + \sqrt{b^2 - 4ac}}{2a}$$

(a) عين قيمة  $r_1$  بأكبر دقة ممكنة وذلك في حالة الأمثل  $a = 1, b = 111.11, c = 1.2121$

(b) احسب قيمة هذا الجذر مستخدماً نظام تمثيل بخمسة أرقام  $p = 5$ . ما هو تعليقك على النتيجة؟

(c) اقترح صيغة مكافحة أكثر ملائمة للحساب في نظام تمثيل بخمسة أرقام.

**5.8.** نجد في الكتب التي تعرض جداول تكاملية علاقة التدريج التالية

$$\int \frac{dx}{x(a+x^2)^{m+1}} = \frac{1}{2am(a+x^2)^m} + \frac{1}{a} \int \frac{dx}{x(a+x^2)^m} \quad (m \neq 0)$$

(a) نعرف

$$f(m) = \int_1^2 \frac{dx}{x(a+x^2)^m}$$

استخدم علاقة التدريج السابقة في تعين المقدار  $c_m$  الذي يحقق العلاقة

$$(M) \quad f(m+1) = c_m + \frac{1}{a} f(m)$$

(b) ادرس استقرارية الطريقة .

**6.8.** لتكن المتتالية

$$a_0 = 11/2,$$

$$a_1 = 61/11,$$

$$a_{n+1} = 111 - \frac{1130}{a_n} + \frac{3000}{a_n a_{n-1}}, \quad n \geq 1.$$

(a) ادرس تجريبياً تقارب هذه المتتالية مستخدماً نظام تمثيل الأعداد في برنامج مثل Maple أو Mathmatica و ذلك بإجراء الحسابات بالدقة البسيط (ثمانية أرقام عشرية) وبالدقة المضاعفة (ست عشرة رقمًا عشرىًّا) بما في ذلك القيم الابتدائية  $\hat{a}_1 = \text{rd}(a_1)$  و  $\hat{a}_0 = \text{rd}(a_0)$ .

(b) ادرس التقارب النظري لهذه المتتالية بمساعدة أحد البرنامجين Maple أو Mathmatica. ماذا تلاحظ؟

**7.8.** ليكن  $x_A = 0.937$  قيمة تقريرية بثلاثة أرقام معنوية للقيمة الحقيقية  $x_T$ .

أولاً: عين تحديداً من الأعلى للخط النسبي في القيمة التقريرية  $x_A$ .

ثانياً: ليكن التابع  $f(x) = \sqrt{1-x}$ .

عين تحديداً من الأعلى للخط النسبي في حساب القيمة التقريرية  $f(x_A)$  بالمقارنة مع القيمة الافتراضية  $f(x_T)$ .

**8.8.** لتكن المعادلة

$$x^2 - 40 - x + 1 = 0$$

أوجد جذور هذه المعادلة بدقة خمسة أرقام، علماً أن  $\sqrt{399} \approx 19.975$  هو تقرير ناجم عن تدوير القيمة الصحيحة للجذر التربيعي  $\sqrt{399}$  إلى خمسة أرقام.

**9.8.** ليكن التابع  $f$  المعروف بالعلاقة

$$x \mapsto f(x) = \frac{\ln(1-x) + x \cdot e^{x/2}}{x^3}$$

- .1. احسب قيم التابع  $f(x)$  عند النقاط  $\left\{ x = 10^{-m} : m = 1, \dots, 7 \right\}$
- .2. ماهي القيمة المتوقعة (بمقتضى الدراسة النظرية) للنهاية  $\lim_{x \rightarrow 0} f(x)$  ؟
- .3. عندما تكون  $x$  قريبة من الصفر، ماهي أفضل طريقة لحساب  $f(x)$  ؟  
(توجيه: استخدم منشور تايلور بجوار الصفر).

**10.8.** نريد أن نستخدم المتسلسلة الصحيحة  $e^x = \sum_{n=0}^{\infty} x^n / n!$  لحساب قيمة تقريرية للعدد  $e^{-5}$ . ما هو عدد حدود

التقرير  $! n$  لكي نحصل على قيمة تقريرية بخطأ نسي لا يتجاوز  $10^{-3}$  ؟

