

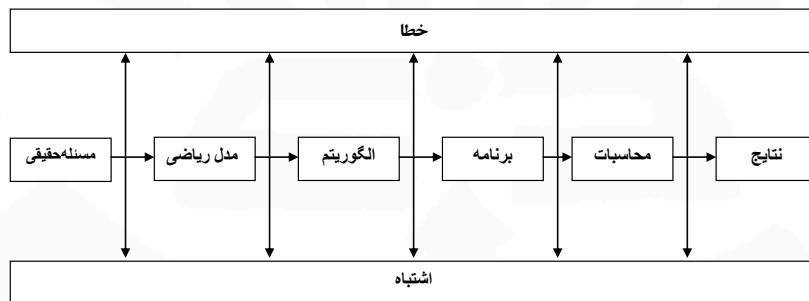
٢ فصل

خطاها

زمانی که به دست آوردن جواب واقعی یک مسئله غیرممکن است و یا مفروض به صرفه نیست، سعی می‌کنیم به کمک روش‌های عددی، یک جواب تقریبی برای مسئله پیدا کنیم. این فرایند منجر به تولید خطا می‌شود. در این فصل قصد داریم منابع تولید خطا و انواع خطا را شناسایی کرده و تا حدی از انتشار خطا جلوگیری کنیم.

١.٢ منابع توليد خطأ

بیشتر مواقع در عمل با یک مسئله حقیقی (فیزیکی) مواجه هستیم و بنا به دلایلی، جواب عددی یا تقریبی آن را جستجو می‌کنیم. مراحل یافتن جواب عددی چنین مسئله‌ای در روندnamای آمده در شکل ۱.۲ خلاصه می‌شود. این روندnamای مکان‌های احتمالی بروز خطأ و اشتباه را نیز نشان می‌دهد.



شكل ١.٢: فرایند تولید جواب عددی (تقریبی)

۱۰۲ تذکر در مدل سازی مسائل باید از بروز خطاهای ذاتی تا حد ممکن جلوگیری کرد در حالی که پرهیز از خطاهای محاسباتی و کنترل آنها، از وظایف متخصص آنالیز عددی است. تفاوت بین جواب واقعی و تقریبی از اشتباهات و خطاهای ناشی می شود. اشتباه را می توان برطرف کرد ولی خطا ممکن است اجتناب ناپذیر باشد. به عنوان مثال قرار دادن ۲۳۲۳ به جای ۲۳۳۲ یک اشتباه است حال آن که عدد π بسط ددهی نامختوم دارد و در وسایل محاسباتی باید یک بسط ددهی، مختوم برای آن در نظر گرفت که این موجب بروز خطأ می شود.

مراحل مختلف این روند را در مثال بعد دنبال می‌کنیم:

مثال ۱.۲ (مسئله حقیقی) می‌خواهیم دوره تناوب حرکت نوسانی و متناوب یک آونگ ساده به جرم m و طول l را به دست آوریم. فرض کنید $\theta(t)$ جابجایی زاویه‌ای آونگ در زمان t باشد. صرف نظر از مقاومت هوا و اصطکاک در لولا، مدل این مسئله به صورت $ml \frac{d^2\theta}{dt^2} = -mg \sin \theta$ یا

$$\frac{d^2\theta}{dt^2} = -\frac{g}{l} \sin \theta, \quad (1.2)$$

در می‌آید که یک معادله دیفرانسیل غیرخطی است. با فرض کوچک بودن θ یعنی

$$\theta = 6^\circ \simeq 0.1047 \text{ rad} \rightarrow \sin \theta \simeq 0.1045, \quad \theta = 15^\circ \simeq 0.262 \text{ rad} \rightarrow \sin \theta \simeq 0.259,$$

می‌توان فرض کرد $\sin \theta \simeq \theta^{\text{rad}}$ و معادله دیفرانسیل را به صورت $\frac{d^2\theta}{dt^2} + \omega^2 \theta = 0$ نوشت که در آن $\omega^2 = \frac{g}{l}$. این معادله دیفرانسیل خطی جوابی به صورت $\theta(t) = A \sin \omega t + B \cos \omega t$ دارد که از آن نتیجه می‌گیریم $T_L = 2\pi \sqrt{\frac{l}{g}}$ از طرف دیگر با حل معادله دیفرانسیل غیرخطی (۱.۲) خواهیم داشت

$$T_N = 2\pi \sqrt{\frac{l}{g}} \left(1 + \frac{1^2}{2^2} \sin^2 \frac{\theta_m}{2} + \frac{1^2 \times 3^2}{2^2 \times 4^2} \sin^4 \frac{\theta_m}{2} + \dots \right),$$

که در آن θ_m جابجایی زاویه‌ای ماکریم آونگ است. جالب است توجه داشته باشیم که T_L اولین جمله سری T_N است. در ادامه یک الگوریتم برای این مدل ریاضی طراحی می‌کنیم.

الگوریتم ۱.۲ الگوریتم یافتن دوره تناوب حرکت یک آونگ ساده.

• ورودی. θ_m و مرز خطای ϵ

• خروجی. مقدار T_N و اختلاف آنها

$$1) \text{ قرار دهید } 8/14 \text{ و } p = 3/14, g = 9/8$$

$$. T_2 = T_1 + C \text{ و } C = T_L \times M \times \sin^{1k} \frac{\theta_m}{2}, T_1 = T_L, M = (\frac{2k-1}{2k})^2, k = 1$$

۳) تا زمانی که $|C| < \epsilon$ را تکرار کنید.

$$. T_2 = T_1 + C \text{ و } C = T_L \times M \times \sin^{1k} \frac{\theta_m}{2}, T_1 = T_2, M = M \times (\frac{2k-1}{2k})^2, k = k + 1$$

۴) قرار دهید $T_N = T_2$ و $T_L = T_N - T_2$.

حال برای الگوریتم ۱.۲ یک برنامه با استفاده از بسته نرم‌افزاری Mathematica می‌نویسیم. پس از اجرای برنامه ۱.۲ در محیط Mathematica محاسبات شروع شده و به ازای 100° می‌توان نتایج گزارش شده در جدول ۱.۲ را تولید کرد. باید توجه داشت که برای $\theta_m < 15^\circ$ اختلاف T_L و T_N از 5% بیشتر نیست.

با توجه به روند نمای ارائه شده در شکل ۱.۲ و مثال ۱.۲، خطاهای از نظر منابع تولید به صورت زیر تقسیم‌بندی می‌شوند.

۱. خطای ذاتی

• خطای مدل (ناشی از صرف نظرها، چشم‌پوشی‌ها و ساده‌سازی‌ها مانند فرض $(\sin \theta \simeq \theta^{\text{rad}})$)

• خطای داده‌های مدل (ناشی از آزمایشات و اندازه‌گیری‌ها مانند l, g, θ_m)

۲. خطای محاسباتی

• خطای نمایش اعداد (مانند $\pi = ۳/۱۴$)

• خطای اعمال ریاضی (به عنوان مثال $(\frac{l}{g})^k$)

• خطای روش‌های (الگوریتم‌های) عددی (محاسباتی) (مانند خطای روش محاسبه $\sqrt{\frac{l}{g}}$)

$l = \text{Input}["طول آونگ را بر حسب متر وارد کنید"];$

$\theta_m = \text{Input}["جایجایی زاویه‌ای ماکزیمم را بر حسب درجه وارد کنید"];$

$\epsilon = \text{Input}["مقدار مجاز خطای روش محاسبه"];$

$st = \text{Sin}[\theta_m * Pi / 180];$

$g = ۹.۸; TL = ۲ * \pi * \sqrt{\frac{l}{g}}; k = ۱; M = (\frac{r_{k-1}}{r_k})^k;$

$CC = TL * M * st^{r_k}; T1 = TL; T2 = T1 + CC;$

$\text{While}[CC > \epsilon, \{$

$k++;$

$M* = (\frac{r_{k-1}}{r_k})^k;$

$T1 = T2;$

$CC = TL * M * st^{r_k};$

$T2 = T1 + CC;$

\};

$TN = T2;$

$\text{Print}[T_L = ", TL, " TN = ", TN, " TN - TL = ", TN - TL];$

برنامه ۱.۲: برنامه یافتن دوره تناوب حرکت یک آونگ ساده.

$l(cm)$	θ_m	T_L	T_N	$T_N - T_L$	$l(cm)$	θ_m	T_L	T_N	$T_N - T_L$
۱۰	۳	۰.۶۳۴۷۰	۰.۶۳۴۸۱	۰.۰۰۰۱۱	۱۰	۱۲	۰.۶۳۴۷۰	۰.۶۳۶۴۴	۰.۰۰۱۷۴
۲۰	۳	۰.۸۹۷۶۰	۰.۸۹۷۷۵	۰.۰۰۰۱۵	۲۰	۱۲	۰.۸۹۷۶۰	۰.۹۰۰۰۷	۰.۰۰۲۴۷
۳۰	۳	۱.۰۹۹۳۲	۱.۰۹۹۵۲	۰.۰۰۰۱۹	۳۰	۱۲	۱.۰۹۹۳۲	۱.۱۰۲۳۵	۰.۰۰۲۰۲
۱۰	۶	۰.۶۳۴۷۰	۰.۶۳۵۱۳	۰.۰۰۰۴۳	۱۰	۱۵	۰.۶۳۴۷۰	۰.۶۳۷۴۳	۰.۰۰۲۷۳
۲۰	۶	۰.۸۹۷۶۰	۰.۸۹۸۲۱	۰.۰۰۰۶۱	۲۰	۱۵	۰.۸۹۷۶۰	۰.۹۰۱۴۶	۰.۰۰۲۸۶
۳۰	۶	۱.۰۹۹۳۲	۱.۱۰۰۰۸	۰.۰۰۰۷۵	۳۰	۱۵	۱.۰۹۹۳۲	۱.۱۰۴۰۶	۰.۰۰۴۷۳
۱۰	۹	۰.۶۳۴۵۰	۰.۶۳۵۷۰	۰.۰۰۱۲۰	۱۰	۱۸	۰.۶۳۴۷۰	۰.۶۳۸۶۳	۰.۰۰۲۹۳
۲۰	۹	۰.۸۹۷۶۰	۰.۸۹۹۰۰	۰.۰۰۱۴۰	۲۰	۱۸	۰.۸۹۷۶۰	۰.۹۰۳۱۷	۰.۰۰۵۵۷
۳۰	۹	۱.۰۹۹۳۲	۱.۱۰۱۰۳	۰.۰۰۱۷۰	۳۰	۱۸	۱.۰۹۹۳۲	۱.۱۰۶۱۵	۰.۰۰۶۸۲

جدول ۱.۲: دوره تناوب آونگ ساده با طول‌های مختلف

۲۰۲ نمایش اعداد

در این بخش به بررسی نمایش اعداد حقیقی می‌پردازیم. اثبات برخی از قضایا را می‌توان در سایر مراجع یافت.

قضیه ۱.۲ هر عدد حقیقی مثبت x نمایشی به صورت

$$x = a_m \beta^m + a_{m-1} \beta^{m-1} + \cdots + a_1 \beta^1 + a_0 \beta^0 + a_{-1} \beta^{-1} + a_{-2} \beta^{-2} + \cdots \\ = (a_m a_{m-1} \dots a_1 a_0 / a_{-1} a_{-2} \dots)_{\beta}, \quad (\star\star)$$

دارد که در آن $m \in \mathbb{Z}$ و $\beta - 1 = a_0 + a_1 \cdot 1 + a_2 \cdot 2 + \dots + a_{\beta-1} \cdot \beta$. برای منحصر به فرد بودن این نمایش لازم است که $a_m \neq 0$ و عدد صحیح j چنان وجود داشته باشد که $a_{j-1} = a_j = \dots = a_0$ ، یا به ازای هر N به اندازه کافی بزرگ وجود داشته باشد $j^N \leq a_{j-1}$.

رابطه (۲.۲) به نمایش (بسط) عدد x در مبنای β معروف است. اگر $10 = \beta$ اختیار شود به (۲.۲) نمایش (بسط) ددهی (اعشاری) گویند که در زندگی روزمره با آن سروکار داریم. در حالتی که $2 = \beta$ در نظر گرفته شود، (۲.۲) به نمایش دودویی (باینری) عدد x معروف یوده و این مینا، اساس کار را پانه و وسائل دیجیتال است.

تذکر ۲.۲ شرط دوم منحصر به فرد بودن نمایش، لازم است چه در غیر این صورت به عنوان مثال می‌توان نوشت

یعنی بسط ددهی بیان شده را می توان برای دو عدد $\frac{3}{48}$ و $\frac{3}{47999} \dots$ در نظر گرفت.

قضیه ۲.۲ اگر پس ط دده‌ی یک عدد مختوم یا نامختوم متناوب باشد، آن عدد گویا است.

نتیجه ۱.۲.۲ بسط ددهی، یک عدد گنگ، نامختوم نامتناوب است.

میتا، ۲۰۲ به نمایش اعداد زیر توجه کنید.

$$\frac{2}{3} = 0.\overline{666\ldots} = 0.\bar{6} = (0/2)_2, \quad \frac{3}{8} = 0.\overline{375} = (0/011)_2, \quad \frac{1}{7} = 0.\overline{142857} = (0/1)_2,$$

$$\sqrt{2} = 1.\overline{414213\ldots}, \quad \pi = 3.\overline{141592\ldots}, \quad \exp(1) = e = 2.\overline{718281\ldots}$$

عدد ... ۱۹۱۹۱۹، گویا است ولی، اعداد ... ۱۰۲۰۰۳۰۰۰۴۰۰۰... و ... ۱۲۲۳۲۳۴۴۴۴ هستند. △

هنگام کار با رایانه (ماشین حساب) اعداد را در مبنای ۱۰ وارد کرده و انتظار داریم نتایج (خروجی) نیز در همین مبنای نمایش داده شود ولی این وسایل با مبنای دیگری مانند ۲، ۸ و ۱۶ کار می‌کنند. بنابراین مسئله تغییر مبنای مطرح می‌شود.

پیش‌شماره ۱۰.۲ مبنای ۲ در مقایسه با مبنای ۱۶ چه معایب و مزایایی دارد؟

مثال ۳.۲ در این مثال یک عدد در مبنای ۲ را به مبنای ۱۰ می‌بریم.

$$\begin{aligned}(1011001,111001)_2 &= 2^6 + 2^4 + 2^3 + 2^0 + 2^{-1} + 2^{-2} + 2^{-3} + 2^{-6} \\ &= 64 + 16 + 8 + 1 + 0,5 + 0,25 + 0,125 + 0,015625 = 89,890625\end{aligned}$$

بنابراین تغییر مبنای از مبنای ۲ به مبنای ۱۰ به کمک بسط به سادگی امکان‌پذیر است.

مثال ۴.۲ در این مثال یک عدد صحیح مثبت را از مبنای ۱۰ به مبنای ۲ می‌بریم.

$$23 = 11 \times 2 + 1, \quad 11 = 5 \times 2 + 1, \quad 5 = 2 \times 2 + 1, \quad 2 = 1 \times 2 + 0.$$

پس $(10111)_2 = 23$. بنابراین از تقسیم‌های متوالی بر ۲ استفاده می‌کنیم.

اگر عدد داده شده x در مبنای ۱۰ در فاصله $(1, 0)$ باشد و عدد متناظر در مبنای ۲ به صورت $(b_1 b_2 b_3 \dots)_2$ فرض شود آن‌گاه

$$x = b_1 \times 2^{-1} + b_2 \times 2^{-2} + b_3 \times 2^{-3} + \dots,$$

و در نتیجه $\dots + b_3 \times 2^{-3} + b_2 \times 2^{-2} + b_1 \times 2^{-1} + y = 2x$ با قرار دادن y خواهیم داشت

$$0 \leq y < 1 \times 2^{-1} + 1 \times 2^{-2} + \dots = \frac{2^{-1}}{1 - 2^{-1}} = 1.$$

پس $[y] = 0$. از طرف دیگر داریم $y = b_1 + b_2 \times 2^{-1} + b_3 \times 2^{-2} + \dots$ زیرا $b_1 = [2x]$ نتیجه می‌شود b_1 عددی صحیح است (b_1 یا صفر است یا یک). با قرار دادن $y = x$ و تکرار این روند می‌توان b_2, b_3, \dots و سایر رقم‌ها را به دست آورد. شرط توقف این روند تکراری زمانی است که x صفر شود یا تناوب به وجود آید و یا ممکن است بسط نامختوم نامتناوب باشد و پس از چند تکرار مجبور شویم روند را متوقف کنیم.

مثال ۵.۲ در این مثال این روند را برای حالت‌هایی دنبال می‌کنیم که عدد نمایشی مختوم یا نامختوم متناوب دارد. با توجه به جدول ۲.۲ می‌توان نوشت

$$0,578125 = (0,100101)_2, \quad 0,1 = (0,00\overline{11})_2.$$

با توجه به نتایج این مثال، نمایش یک عدد گویا در هر مبنایی یا مختوم است یا نامختوم متناوب [۱].

تمرین ۱.۲ برنامه‌ای بنویسید که عدد حقیقی x و عدد طبیعی n را از ورودی گرفته و نمایش دودویی عدد x را تولید کند و اگر نمایش نامختوم نامتناوب است حداکثر n رقم نمایش، چاپ شود.

i	x	$2x$	b_i
۱	$0/578125$	$1/15625$	۱
۲	$0/15625$	$0/3125$	۰
۳	$0/3125$	$0/625$	۰
۴	$0/625$	$1/25$	۱
۵	$0/25$	$0/5$	۰
۶	$0/5$	$1/0$	۱
	۰		

i	x	$2x$	b_i
۱	$0/1$	$0/2$	۰
۲	$0/2$	$0/4$	۰
۳	$0/4$	$0/8$	۰
۴	$0/8$	$1/6$	۱
۵	$0/6$	$1/2$	۱
۶	$0/2$	$0/4$	۰
	۰/۴		

جدول ۲.۲: نمایش دودویی اعداد کوچک ترازو واحد

۳.۲ نمایش اعداد در رایانه

برای نمایش اعداد در ماشین، ابتدا نمایشی به نام ممیز ثابت^۱ در نظر گرفته شد که در آن هر عدد حقیقی x به صورت زیر نمایش داده می‌شود

$$x = \pm(a_{n-1} \dots a_1 a_0 / a_{-1} a_{-2} \dots a_{-m})_\beta,$$

که در آن m و n اعداد مشخص و ثابتی هستند. در اصل در این نمایش مکان ممیز مشخص و ثابت است. برای نمایش اعداد بسیار بزرگ (کوچک) در این نمایش با مشکل مواجه می‌شویم و در نتیجه این نمایش برای محاسبات علمی مناسب نیست ولی برای بسیاری از کاربردها (مانند حسابداری) این نمایش سودمند است و هنوز هم ماشین‌هایی براین اساس ساخته می‌شوند.

یک روش جدید و متداول برای نمایش اعداد در رایانه، نمایش ممیز (نقطه) شناور (سیار)^۲ است که از بدوبیدایش مورد توجه سازندگان سخت‌افزار رایانه قرار گرفته است و چنین به نظر می‌رسد که تا حدودی به طور سلیقه‌ای با آن برخورد شده است. آنچه در ادامه درباره این نمایش خواهد آمد بر اساس استانداردی است که IEEE^۳ وضع کرده است.

۱.۳.۲ نمایش ۶۴-بیتی ممیز شناور

این نمایش پیش از این به دقت دو برابر (مضاعف)^۴ معروف بوده و متناظر با نوع double در زبان C است. در این نمایش برای ذخیره هر عدد در مبنای ۲، ابتدا یک ساختار به طول ۶۴ بیت در نظر گرفته می‌شود. اولین بیت به بیت علامت معروف است و با s نمایش داده می‌شود و بلافاصله بعد از آن ۱۱ بیت برای مشخصه^۵ در نظر گرفته می‌شود و با e نمایش داده می‌شود و ۵۲ بیت باقی مانده نیز برای ماتنیس کنار گذاشته می‌شود و آن را با f نشان می‌دهند. سپس برای هر عدد نمایشی به صورت $(1 + 0/f) \times 2^e \times 10^{s-1}$ در نظر گرفته می‌شود که در آن $e = c - 10^{23}$ توان (نمای) است. محدودیت $2^{11} - 1 = 2047 \leq c \leq 2^{11} - 1 = 2047$ و $0 \leq s \leq 10^{24}$ موجب می‌شود که $10^{23} \leq e \leq 10^{24}$. از

Fixed point^۱Floating point^۲IEEE standard 754-1985^۳Double precision^۴Characteristic^۵

طرف دیگر محدودیت $2 \leq f \leq 1/\underbrace{1\cdots 1}_{52\text{times}} \circ$ باعث می‌گردد که $2 < \underbrace{(1 + \circ/f)}_{52\text{times}} \leq 1 + 1$. بنابراین اگر کوچک‌ترین و بزرگ‌ترین عدد مثبت قابل نمایش را به ترتیب با $+MN$ و $+mN$ نشان دهیم آن‌گاه

$$+mN = 2^{-1022} \times 1/\circ \simeq 2/225074 \times 10^{-308}, \quad +MN = 2^{1024} \times 1/\circ \simeq 1/797693 \times 10^{308}.$$

همچنین برای نمایش صفر و بی‌نهایت می‌توان از قراردادهای زیر استفاده کرد

$$+\circ = (\underbrace{1/1\cdots 1}_{52\text{times}})_2 \times 2^{-1023}, \quad +\infty = (\underbrace{1/0\cdots 0}_{51\text{times}})_2 \times 2^{1024}.$$

تمرین ۲.۲ نمایش $-MN$, $-\circ$, $-\infty$ را بنویسید.

تعریف ۱.۲ در نمایش اعداد ماشینی، کوچک‌ترین عدد مثبت ماشینی که اگر به ۱ اضافه شود عددی بزرگ‌تر از ۱ به دست می‌آید به اپسیلون ماشین^۶ معروف است و با eps نمایش داده می‌شود. نصف eps ، به رُند واحد^۷ یا واحد گرد کردن^۸ یا دقت ماشین^۹ معروف است.

چون در نمایش 64 -بیتی بعد از ۱ عدد $\underbrace{1/0\cdots 0}_{51\text{times}}$ قرار می‌گیرد، پس

$$\text{eps} = (\underbrace{1/0\cdots 0}_{51\text{times}})_2 - 1 = (\underbrace{0/0\cdots 0}_{51\text{times}})_2 = 2^{-52} \simeq 2/220446 \times 10^{-16}.$$

در ادامه بزرگ‌ترین عدد صحیح مثبت M را تعیین می‌کیم که هر عدد صحیح x با شرط $x \leq M < \circ$ را بتوان به طور دقیق نمایش داد. با توجه به موارد بیان شده، تمام اعداد صحیح نامنفی که بزرگ‌تر از $2^{52} \times 1/1\cdots 1 = 1/1\cdots 1 - 2^{53}$ نباشند به طور دقیق قابل نمایش هستند و به علاوه 2^{53} نیز به صورت $2^{53} \times 1/0$ (قابل نمایش است. اما تعداد ارقام در مانتبس جهت نمایش $+1$ کافی نیست (53 رقم در مانتبس لازم است). بنابراین $10^{15} \simeq 9/007199 \times 10^{15}$ و در نتیجه تمام اعداد صحیح 15 رقمی و بسیاری از اعداد 16 رقمی در این نمایش به طور دقیق قابل نمایش هستند به بیان دیگر نمایش 64 -بیتی 15 الی 16 رقم دقت دارد. بنابراین اعدادی که بیشتر از 16 رقم داشته باشند به طور دقیق قابل نمایش نیستند.

تذکر ۳.۲ مجموعه اعداد با ممیز شناور را با \mathbb{F} نمایش می‌دهیم. محور اعداد با ممیز شناور برخلاف محور اعداد حقیقی، متناهی و گسسته است و برخلاف آنچه به نظر می‌رسد، نقاط روی این محور هم فاصله نیستند. اگر در هنگام انجام محاسبات، عددی در فاصله $(-\circ, +\circ)$ تولید شود پیام پاریز^{۱۰} و اگر عدد تولید شده از $-MN$ و $+MN$ بزرگ‌تریا از کوچک‌تر باشد پیام سرریز^{۱۱} صادر می‌شود. برنامه uoflow.nb را بینید.

تذکر ۴.۲ بعضی از نرم‌افزارها مانند Mathematica، محدودیتهای سخت‌افزار را از طریق برنامه‌های نرم‌افزاری برطرف می‌کنند و به اصطلاح دقت را بالا می‌برند که ممکن است تا حدودی سرعت محاسبات کاهش یابد.

Machine epsilon ^۶
Unit round ^۷
Roundoff unit ^۸
Machine precision ^۹
Underflow ^{۱۰}
Overflow ^{۱۱}

تمرین ۳.۲ در نمایش ۳۲-بیتی (دقت معمولی^{۱۲} متناظر با نوع float در زبان C) هشت بیت برای مشخصه منظور می‌شود. تمام کمیت‌های معرفی شده در این بخش را برای این نمایش تعیین کنید.

۲.۳.۲ اعداد ماشینی

به اعداد \mathbb{F} اعداد ماشینی نیز گفته می‌شود و برای سادگی، نمایشی به صورت $1 \times 10^b \pm a$ برای آن‌ها در نظر گرفته می‌شود. به عبارتی یک عدد ماشینی با زوج مرتب (a, b) نظیر می‌شود. در اینجا b توان (نما) است و به زیرمجموعه‌ای از \mathbb{Z} تعلق دارد. به بیان دقیق‌تر $L \leq b \leq U$ که در آن L و U با توجه به محدودیت‌های سخت‌افزاری و نرم‌افزاری تعیین می‌شوند. $a = 0/d_1 \dots d_k$ بیانگر ماتیس (جزء کسری) است و به ازای $k = 1, \dots, n$ داریم $i = \{0, 1, \dots, 9\}$ و برای یکتایی نمایش فرض می‌شود $a \neq 0$. بنابراین $1/a \leq 1/0$. این نمایش، به نمایش ممیز شناور ددهی نرمال شده نیز معروف است و چنین اعدادی را، اعداد ماشینی ددهی k -رقمی می‌نامند. ایده چنین نمایشی، از نمایش علمی نرمال شده اعداد ناشی شده است. در نمایش علمی نرمال شده، هر عدد حقیقی مخالف صفر x را می‌توان به صورت $x = \pm a \times 10^b$ نمایش داد که در آن $a = 0/d_1 \dots d_k d_{k+1} \dots 0$ که در آن به ازای $i = 1, 2, \dots, 9$ داریم $d_i \in \{0, 1, \dots, 9\}$ و $a \neq 0$. واضح است که برای نمایش x به صورت ممیز شناور ددهی نرمال شده باید k رقم از ماتیس آن را حفظ کرده و رقم‌های اضافی را به کمک یکی از روش‌های زیر کنار گذاشت

روش قطع کردن (برش)^{۱۳}، روش گرد کردن معمولی^{۱۴}، روش گرد کردن به زوج^{۱۵}.

در روش قطع کردن، k رقم از ماتیس حفظ و بقیه کنار گذاشته می‌شود در حالی که در روش گرد کردن معمولی، ابتدا روش قطع کردن اعمال شده، سپس اگر $5 \geq d_{k+1} \dots d_k$ یک واحد به d_k اضافه می‌گردد. اما در روش گرد کردن به زوج، ابتدا روش قطع کردن اعمال شده و در هر یک از حالت‌های زیر یک واحد به d_k اضافه می‌گردد

$$d_{k+1} > 5 \quad \bullet$$

$$d_{k+1} = 5 \quad \bullet \quad \text{و رقم مخالف صفری در سمت راست } d_{k+1} \text{ مشاهده شود}$$

$$d_{k+1} = 5 \quad \bullet \quad \text{و رقم مخالف صفری در سمت راست } d_{k+1} \text{ مشاهده نشود و } d_k \text{ فرد باشد.}$$

قضیه ۳.۲ اگر $x = 0/d_1 \dots d_k d_{k+1} \dots 0$ یک عدد حقیقی ناصفر در نمایش علمی نرمال شده باشد آن‌گاه $r(x) = 0/\delta_1 \dots \delta_k \times 10^m$ و $c(x) = 0/d_1 \dots d_k \times 10^n$ اعداد ماشینی k -رقمی متناظر با x هستند که به ترتیب از روش قطع کردن و گرد کردن معمولی به دست می‌آیند و خواهیم داشت

$$|x - c(x)| \leq 1 \times 10^{n-k}, \quad |x - r(x)| \leq 5 \times 10^{n-k-1} = 0/5 \times 10^{n-k}.$$

پرسش ۲.۲ تفاوت 47^{km} با 4700^m یا تفاوت $3/700$ با $3/70$ یا $3/700$ در چیست؟

Single precision^{۱۲}

Chopping^{۱۳}

Rounding^{۱۴}

Rounding to even^{۱۵}

x	۲۸,۶۴۲۴	۰,۰۰۵۷۶۷۱	۴,۹۸۵۰	-۲۱۷۵,۳۴۵۱۲
$\tilde{x}(۳S)$	۲۸,۶	۰,۰۰۵۷۷	۴,۹۹	-۲۱۸۰
$\tilde{x}(۳D)$	۲۸,۶۴۲	۰,۰۰۶	۴,۹۸۵	-۲۱۷۵,۳۴۵
$\hat{x}(۳S)$	۲۸,۶	۰,۰۰۵۷۶	۴,۹۸	-۲۱۷۰
$\hat{x}(۳D)$	۲۸,۶۴۲	۰,۰۰۵	۴,۹۸۵	-۲۱۷۵,۳۴۵

جدول ۳.۲: مثال‌هایی از گرد کردن و قطع کردن معمولی

تعریف ۲.۲ منظور از ارقام بامعنای یک عدد مخالف صفر، ارقام مخالف صفر، صفرهای بین دو رقم مخالف صفر و صفرهایی است که در سمت راست عدد به منظور نشان دادن نوعی دقت قرار داده می‌شوند (تمام ارقام مانتیس در نمایش علمی نرمال شده).

مثال ۶.۲ عدد $۰,۰۰۰۷۰۴۵۰۰$ حداقل ۴ رقم بامعنای و حداقل ۷ رقم بامعنای دارد.

قرارداد 1.2^{rd} یعنی r رقم اعشار و rS یعنی r رقم بامعنای ^{۱۶}.

مثال ۷.۲ در جدول ۳.۲، چند عدد و مقدارهای تقریبی متناظر با آنها با روش‌های قطع کردن (\hat{x}) و گرد کردن معمولی (\tilde{x}) با دقت $۳S$ و $۳D$ داده شده است.

تذکر ۵.۲ از این به بعد، همانند بسیاری از وسائل محاسباتی از گرد کردن معمولی استفاده می‌کنیم.

پرسش ۳.۲ در نظر بگیرید \hat{x} تقریبی از x باشد. آیا هر چه تعداد ارقام بامعنای \hat{x} بیشتر باشد، \hat{x} تقریب بهتری است؟

تعریف ۳.۲ فرض کنید $\hat{x} = d_m \times 10^m + \dots + d_{-k} \times 10^{-k} + d_{-1} \times 10^{-1} + \dots + d_0 \times 10^0$ که در آن $d_m \neq 0$ ، تقریبی برای x باشد (در اینجا m نشان‌دهنده با ارزش‌ترین مکان است). تعداد ارقام بامعنای درست \hat{x} نسبت به x ، بزرگ‌ترین عدد طبیعی n است که در نابرابری‌های زیر صدق کند.

$$|x - \hat{x}| \leq 5 \times 10^{m-n}, \quad n \leq m+k+1$$

به وضوح هر چه تعداد ارقام بامعنای درست \hat{x} نسبت به x بیشتر باشد، \hat{x} تقریب بهتری خواهد بود.

مثال ۸.۲ از اعداد $۹۹/۹۶$ و $۱۰۰/۷$ کدام یک تقریب بهتری برای $x = ۱۰۰$ است؟

$$\hat{x} = ۹۹/۹۶ \rightarrow m = ۱, |x - \hat{x}| = ۰,۰۴ \leq 5 \times 10^{1-n} \rightarrow n = ۳$$

$$\tilde{x} = ۱۰۰/۷ \rightarrow m = ۲, |x - \tilde{x}| = ۰,۷ \leq 5 \times 10^{2-n} \rightarrow n = ۲$$

بنابراین \hat{x} تقریب بهتری برای x است زیرا تعداد ارقام بامعنای درست بیشتری دارد.

مثال ۹.۲ تعداد ارقام بامعنای درست $\hat{x} = ۱۰۰/۳۱$ را نسبت به $x = ۱۰۰,۳۱۰۴$ مشخص کنید.

$$\hat{x} = ۱۰۰/۳۱ \rightarrow m = ۲, |x - \hat{x}| = ۰,۰۰۰۴ \leq 5 \times 10^{2-n} \rightarrow n = ۶$$

و چون \hat{x} فقط پنج رقم بامعنای دارد پس $n = 5$

۴.۲ انواع خط

تعريف ۴.۲ اگر \hat{x} تقریبی از x باشد $|\hat{x} - x| = \Delta x$ خطای مطلق \hat{x} نسبت به x نامیده می‌شود. Δx یکتا بوده و در عمل بیشتر موقع قابل تعیین نیست و به جای آن از هر عدد b_x استفاده می‌شود که از Δx کمتر نباشد. b_x یکتا نیست و به آن کران خطای مطلق گویند. بنابراین $b_x \leq \hat{x} - x \leq \hat{x} + b_x$ و در نتیجه $\Delta x \leq b_x$ می‌نویسیم.

مثال ۱۰.۲ برای $\hat{x} = 1/\sqrt{3} = 1/\sqrt{2} \approx 0.5774$ به عنوان تقریبی از $x = \sqrt{3}$ می‌توان نوشت

$$\Delta x = \left| \sqrt{3} - 1/\sqrt{3} \right| = 1/\sqrt{3} - 1/\sqrt{2} \approx 0.5774 - 0.5774 = 0.0000508075\dots$$

از طرفی می‌دانیم $b_x = 0.0001 < \sqrt{3} - 1/\sqrt{3} < 1/\sqrt{3} - 1/\sqrt{2} \approx 0.0001$ بنابراین $1/\sqrt{3}$ پس از Δ معیاری برای نزدیکی $1/\sqrt{3}$ است.

پرسش ۴.۲ آیا خطای مطلق معیار مناسبی برای مقایسه خطاهای است؟ پاسخ. خیر. به عنوان مثال خطای مطلق یک صندوق داربانک، تایپیست و دروازه‌بان را در نظر بگیرید.

تعريف ۵.۲ اگر \hat{x} تقریبی از x باشد $\delta x = \frac{|\hat{x} - x|}{|x|} = \frac{\Delta x}{|x|}$ خطای نسبی \hat{x} نسبت به x نامیده می‌شود و یکتا بوده و بیشتر موقع قابل تعیین نیست و از کران خطای نسبی استفاده می‌شود. δx به درصد خطا معروف است.

قضیه ۴.۲ اگر \hat{x} تقریبی از x باشد و b_x یک کران خطای مطلق برای این تقریب باشد آنگاه

$$\delta x \leq \frac{b_x}{|\hat{x}| - b_x}.$$

به علاوه اگر b_x نسبت به $|\hat{x}|$ خیلی کوچک باشد می‌توان نوشت $\delta x \leq \frac{b_x}{|\hat{x}|}$.

برهان. بنابر تعريف b_x و با استفاده از خواص نابرابری‌ها واضح است. \square

مثال ۱۱.۲ برای $\hat{x} = 1/\sqrt{3} = 1/\sqrt{2} \approx 0.5774$ به عنوان تقریبی از $x = \sqrt{3}$ می‌توان نوشت

$$\delta x = \frac{|\sqrt{3} - 1/\sqrt{3}|}{\sqrt{3}} = \frac{1/\sqrt{3} - 1/\sqrt{2} \approx 0.0000508075\dots}{1/\sqrt{3} \approx 0.5774} = \frac{0.0000508075\dots}{1/\sqrt{3} \approx 0.5774}.$$

پس 3 و با توجه به قضیه ۴.۲ $\delta x = 0.0000293337\dots < 0.00003$ خواهیم داشت

$$\delta x \leq \frac{0.0001}{1/\sqrt{3} - 0.0001} = \frac{0.0001}{1/\sqrt{3} \approx 0.5774} = 0.00005774005\dots < 0.00006$$

و یا

$$\delta x \leq \frac{0.0001}{1/\sqrt{3}} = 0.00005773672\dots < 0.00006.$$

قضیه ۵.۲ اگر \hat{x} تقریبی از x با n رقم بامعنای درست باشد و $\hat{y} = 10^t \times \hat{x}$ و $y = 10^t \times x$ که در آن t عددی صحیح است آن‌گاه \hat{y} نیز تقریبی از y با n رقم بامعنای درست بوده و خطای نسبی \hat{x} و \hat{y} برابر است.

قضیه ۶.۲ اگر \hat{x} گردشده x تا n رقم بامعنای باشد آن‌گاه \hat{x} دارای n رقم بامعنای درست است.

ارتباط خطای نسبی با تعداد ارقام بامعنای درست در قضیه بعدی مشخص می‌شود.

قضیه ۷.۲ اگر \hat{x} دارای n رقم بامعنای درست باشد، آن‌گاه $10^{-n} < \delta_x < 5 \times 10^{-n}$ به شرط آن که ارقام بامعنای درست \hat{x} یک رقم 1 و $1 - n$ رقم صفر جلوی آن نباشد. اگر $5 \times 10^{-n} \leq \delta_x < 10^{-n}$ آن‌گاه \hat{x} حداقل n رقم بامعنای درست دارد.

مثال ۱۲.۲ تقریبی از $\sqrt[3]{1/73205} = 1/7321$ ارائه دهید که خطای نسبی آن از 10^{-4} کمتر باشد.

بنابر قضیه ۷.۲ اگر \hat{x} تقریبی از $\sqrt[3]{1/73205}$ باشد که 5 رقم بامعنای درست داشته باشد آن‌گاه $10^{-4} < 10^{-5} < \delta_x < 5 \times 10^{-5}$. از این‌رو، با توجه به قضیه ۶.۲ کافی است \hat{x} گردشده $\sqrt[3]{1/7321}$ تا 5 رقم بامعنای باشد، یعنی $\hat{x} = 1/7321$.

۵.۲ خطای محاسبات

فرض کنید $z = f(x_1, \dots, x_n)$ تابعی باشد که می‌خواهیم آن را در نقطه (x_1, \dots, x_n) ارزیابی کنیم و که در آن \hat{x}_i مقدار تقریبی x_i است. پس می‌توان نوشت

$$z = f(x_1, \dots, x_n) = f(\hat{x}_1 + \Delta x_1, \dots, \hat{x}_n + \Delta x_n).$$

بنابر بسط تیلور توابع n متغیره داریم

$$z = f(\hat{x}_1, \dots, \hat{x}_n) + \left(\Delta x_1 \frac{\partial f}{\partial x_1} + \dots + \Delta x_n \frac{\partial f}{\partial x_n} \right) (\hat{x}_1, \dots, \hat{x}_n) + R,$$

که در آن R جمله خطای بوده و شامل حاصل ضربها و توان‌های Δx_i است و چون Δx_i ها کوچک هستند از R چشم‌پوشی کرده، خواهیم داشت

$$f(x_1, \dots, x_n) - f(\hat{x}_1, \dots, \hat{x}_n) \simeq \left(\Delta x_1 \frac{\partial f}{\partial x_1} + \dots + \Delta x_n \frac{\partial f}{\partial x_n} \right) (\hat{x}_1, \dots, \hat{x}_n),$$

و اگر $\hat{z} = f(\hat{x}_1, \dots, \hat{x}_n)$ آن‌گاه

$$\Delta z = |z - \hat{z}| \simeq \left| \left(\Delta x_1 \frac{\partial f}{\partial x_1} + \dots + \Delta x_n \frac{\partial f}{\partial x_n} \right) (\hat{x}_1, \dots, \hat{x}_n) \right|,$$

و بللافاصله داریم

$$\delta z = \frac{\Delta z}{|z|} \simeq \left| \frac{\left(\Delta x_1 \frac{\partial f}{\partial x_1} + \dots + \Delta x_n \frac{\partial f}{\partial x_n} \right) (\hat{x}_1, \dots, \hat{x}_n)}{f(\hat{x}_1, \dots, \hat{x}_n)} \right|.$$

تذکر ۶.۲ اگر می خواهیم جوابی از یک مسئله را با دقت rD به دست آوریم، باید محاسبات میانی را با دقت $(r+1)D$ و حتی بیشتر انجام دهیم و نتیجه نهایی را با دقت rD گرد کنیم. اگر محاسبات میانی با دقت rD انجام شود، به دلیل اثرات خطای گرد کردن اعتباری به رقم (ارقام) سمت راست جواب نیست. به طور مشابه، هنگام کار با دقت rS باید ملاحظاتی را در نظر گرفت.

مثال ۱۳.۲ (مستقیم) یک استوانه به شعاع قاعده $\frac{4}{\pi}$ و ارتفاع $\sqrt{2}$ را در نظر بگیرید. اگر شعاع و ارتفاع استوانه و عدد π را با دقت $4D$ وارد محاسبات کنیم، حجم این استوانه با چه خطایی به دست می آید؟ می دانیم حجم یک استوانه از قاعده $\pi r^2 h$ تعیین می شود که در آن r شعاع قاعده و h ارتفاع استوانه است. اگر تعریف کنیم $z = V(p, r, h) = pr^2 h$ آنگاه باید V به ازای $p = \pi$ و $r = \frac{4}{\pi}$ و $h = \sqrt{2}$ ارزیابی شود. محاسبات میانی را با دقت $4D$ دنبال می کنیم (ماشین حساب را به صورت MODE FIX 4 تنظیم می کنیم). بنابراین

$$p = \pi \rightarrow \hat{p} = 3,1416, \quad r = \frac{4}{\pi} \rightarrow \hat{r} = 1,27323, \quad h = \sqrt{2} \rightarrow \hat{h} = 1,4142.$$

به طوری که $\Delta p, \Delta r, \Delta h \leq 0,5 \times 10^{-4}$. بنابراین

$$\hat{z} = V(\hat{p}, \hat{r}, \hat{h}) = 3,1416 \times 1,27323 \times 1,4142 = 7,8980.$$

از طرفی

$$\Delta z \simeq \Delta p \hat{r} \hat{h} + 2 \Delta r \hat{p} \hat{h} + \Delta h \hat{p} \hat{r} \leq (\hat{r} \hat{h} + 2 \hat{p} \hat{h} + \hat{p} \hat{r}) \times 0,5 \times 10^{-4} \simeq 9,9731 \times 10^{-4}.$$

در نتیجه حجم استوانه با دقت $3D$ برابر است با $7,898$ و حداقل خطای مرتبک شده عبارت است از

$$\Delta z + 0,5 \times 10^{-4} \lesssim 0,0010.$$

به کمک یک ماشین حساب 10 رقمی نتیجه $z = 7,898458555$ به دست می آید و بنابراین

$$e(z) = |z - \hat{z}| = 4,585554 \times 10^{-4} < 0,0010.$$

△

تمرین ۴.۲ (معکوس) یک استوانه به شعاع قاعده $\frac{4}{\pi}$ و ارتفاع $\sqrt{2}$ در نظر بگیرید. اگر بخواهیم حجم این استوانه را با دقت $3D$ به دست آوریم، شعاع قاعده و ارتفاع استوانه و حتی عدد π را با چه دقیقی وارد محاسبات کنیم؟

مثال ۱۴.۲ (معکوس) اعداد $x = \sqrt{5}$ و $y = \frac{\pi}{11}$ را با چه دقیقی در نظر بگیریم تا مقدار $f(x, y) = 6x^2(\ln x + \sin 2y)$ با دقت $2D$ حساب شود.

اگر فرض کنیم $z = f(x, y) = 6x^2(\ln x + \sin 2y)$ آنگاه

$$\frac{\partial f}{\partial x} = 12x(\ln x + \sin 2y) + 6x, \quad \frac{\partial f}{\partial y} = 12x^2 \cos 2y,$$

و درنتیجه با فرض $x = 2/2$ و $y = 0/3$ را با دقت $1S$ یا $2S$ درنظر می‌گیریم) داریم

$$\Delta z \simeq \left| \Delta x \frac{\partial f(2/2, 0/3)}{\partial x} + \Delta y \frac{\partial f(2/2, 0/3)}{\partial y} \right| \simeq |48/9 \Delta x + 47/9 \Delta y|,$$

و برای برقراری نابرابری $|48/9 \Delta x + 47/9 \Delta y| \leq 0/5 \times 10^{-2}$ باید داشته باشیم این نامعادله عبارت است از

$$\Delta x \leq 0/5 \times 10^{-4}, \quad \Delta y \leq 0/5 \times 10^{-4}.$$

بنابراین برای رسیدن به نتیجه مطلوب، می‌توان x و y را با دقت $4D$ درنظر گرفت.

△

۱.۵.۲ خطای اعمال ریاضی

هنگام کار با اعداد ماشینی (ممیز شناور) باید توجه داشت که بعضی از اصول میدان \mathbb{R} نظیر شرکت‌پذیری، یکتایی عضو خنثی و غیره برقرار نیست. به طور کلی، عبارت‌هایی که از نظر ریاضی معادل هستند ممکن است از نظر محاسباتی معادل نباشند. علت اصلی بروز این مشکلات، خطای گرد کردن است.

تعريف ۶.۲ فرض کنید x و y دو عدد حقیقی، \hat{x} و \hat{y} تقریب‌هایی از آن‌ها و \otimes بیانگر یک عمل دوتایی باشد. متناظر با $x \otimes y$ در ماشین عمل $\hat{x} \hat{\otimes} \hat{y}$ انجام می‌شود و می‌توان نوشت

$$|x \otimes y - \hat{x} \hat{\otimes} \hat{y}| = |(x \otimes y - \hat{x} \otimes \hat{y}) + (\hat{x} \otimes \hat{y} - \hat{x} \hat{\otimes} \hat{y})| \leq |x \otimes y - \hat{x} \otimes \hat{y}| + |\hat{x} \otimes \hat{y} - \hat{x} \hat{\otimes} \hat{y}|.$$

بنابراین خطای دو بخش دارد: خطای منتشرشده یا انباسته شده (جمله اول) و خطای تولیدشده یا گرد کردن (جمله دوم).

قضیه ۸.۲ اگر \hat{x} و \hat{y} تقریب‌هایی از x و y بوده و همه این اعداد مثبت باشند، آن‌گاه

$$\delta(x \pm y) \leq \frac{x}{|x \pm y|} \delta x + \frac{y}{|x \pm y|} \delta y \quad \text{و} \quad \delta(x + y) \leq \max\{\delta x, \delta y\}, \quad \Delta(x \pm y) \leq \Delta x + \Delta y. \quad 1$$

$$\delta(xy) \leq \delta x + \delta y, \quad \Delta(xy) \leq y \Delta x + x \Delta y. \quad 2$$

$$\delta\left(\frac{x}{y}\right) \leq \delta x + \delta y, \quad \Delta\left(\frac{x}{y}\right) \leq \frac{y \Delta x + x \Delta y}{y^2}. \quad 3$$

برهان. به عنوان تمرین.

مثال ۱۵.۲ \hat{x} و \hat{y} هر یک n رقم با معنای درست دارند. حداقل تعداد ارقام با معنای درست $\hat{x} + \hat{y}$ و $\hat{x}\hat{y}$ را تعیین کنید. بنابر قضیه ۷.۲، $\hat{x} + \hat{y} < 5 \times 10^{-n}$ و $\hat{x}\hat{y} < 5 \times 10^{-n}$. همچنین بنابر قضیه ۱.۲ می‌توان نوشت

$$\delta(x + y) \leq \max\{\delta x, \delta y\} \leq 5 \times 10^{-n} = 0/5 \times 10^{-(n-1)}.$$

پس $\hat{x} + \hat{y}$ حداقل $1 - n$ رقم با معنای درست دارد. به علاوه می‌توان نوشت

$$\delta(xy) \leq \delta x + \delta y < 5 \times 10^{-n} + 5 \times 10^{-n} = 10 \times 10^{-n} = 10^{-(n-1)} < 0/5 \times 10^{-(n-1)}.$$

△

بنابراین \hat{xy} دست کم $2 - n$ رقم با معنای درست دارد.

تذکر ۷.۲ با توجه به خطای نسبی $\delta(x-y) \simeq \frac{\Delta(x-y)}{|x-y|}$ واضح است که اگر x و y دو عدد هم علامت و به هم نزدیک باشند $|x-y|$ کوچک و در نتیجه $(x-y)\delta$ بزرگ خواهد شد و در نتیجه تعداد ارقام با معنای درست $x-y$ کم خواهد بود. بنابراین در عمل بهتر است از تفاضل دو عدد هم علامت نزدیک به هم جلوگیری شود (به اصطلاح تفاضل دو عدد نزدیک به هم موجب از بین رفتن ارقام با معنا می‌شود مانند $1/41 = 0,0 = 0,1/42$). اگر تفاضل اجتناب‌پذیر نیست باید دقت را بالا برد (دقت دو برابر یا بیشتر). البته به کمک قضیه ۱.۲، می‌توان پدیده از بین رفتن ارقام با معنا را بهتر تفسیر کرد.

مثال ۱۶.۲ جهت اجتناب از تفاضل در محاسبات می‌توان از اتحادها کمک گرفت. به عنوان مثال

$$e^{x-y} = \frac{e^x}{e^y}, \quad 1 - \cos x = 2 \sin^2 \frac{x}{2}, \quad \ln x - \ln y = \ln \frac{x}{y}.$$

△

مثال ۱۷.۲ در صورتی که $g(x) = x \left(\sqrt[9]{1 + \frac{1}{x}} - 1 \right)$ ، مقدار $g(10^9)$ را با دقت $8D$ به دست آورید. همان‌گونه که بیان شد، چون دقت $8D$ مورد نظر است، محاسبات میانی را با دقت $9D$ انجام می‌دهیم

$$1 + \frac{1}{x} = 1,000000001, \quad \sqrt[9]{1 + \frac{1}{x}} = 1,000000000.$$

بنابراین با دقت $9D$ ، ماشین حساب نتیجه زیر را به دست می‌دهد

$$g(10^9) = 10^9 (1,000000000 - 1) = 0,000000000.$$

به این ترتیب با یک ماشین حساب 10 رقمی $g(10^9) = 0,00000000$ ، که نتیجه‌ای نادرست است. در حالی که اگر از یک رایانه استفاده شود، نتیجه درست $g(10^9) = 0,333333333$ به دست می‌آید. دلیل این خطای فاحش، تفاضل دو عدد نزدیک به هم در محاسبات است که به از بین رفتن ارقام با معنا منجر می‌شود. برای به دست آوردن تقریب بهتر، روش محاسبه را به صورت زیر تغییر می‌دهیم

$$g(x) = x \left(\sqrt[9]{1 + \frac{1}{x}} - 1 \right) \times \frac{\sqrt[9]{(1 + \frac{1}{x})^2} + \sqrt[9]{1 + \frac{1}{x}} + 1}{\sqrt[9]{(1 + \frac{1}{x})^2} + \sqrt[9]{1 + \frac{1}{x}} + 1} = \frac{1}{\sqrt[9]{(1 + \frac{1}{x})^2} + \sqrt[9]{1 + \frac{1}{x}} + 1}.$$

در این صورت با توجه به

$$\left(1 + \frac{1}{x}\right)^2 = 1,000000002, \quad \sqrt[9]{\left(1 + \frac{1}{x}\right)^2} = 1,00000000,$$

با دقت $9D$ نتیجه زیر به دست می‌آید

$$g(10^9) = \frac{1}{1,00000000 + 1,00000000 + 1} = 0,333333333,$$

و بنابراین با دقت $8D$ داریم $g(10^9) = 0,33333333$.

این مثال نه تنها نشان می‌دهد که ممکن است یک ماشین حساب هم نتایج نادرستی تولید کند بلکه به خوبی نشان می‌دهد که به دلیل خطای گرد کردن، ممکن است محاسبه با دو روش مختلف که از نظر ریاضی همارز هستند به نتایج متفاوتی منجر شوند. از این رو باید از نظر عددی بین الگوریتم‌هایی که از نظر ریاضی همارز هستند تفاوت قائل شویم.

تذکر ۸.۲ با توجه به قضیه ۱.۲، در محاسبات باید از ضرب اعداد بزرگ در اعداد تقریبی (تقسیم اعداد تقریبی به اعداد کوچک) پرهیز کرد.

مثال ۱۸.۲ برای به دست آوردن تقریبی از $\pi \times 10000 = x$ می‌توان نوشت

$$\pi \approx 3/14 \rightarrow x \approx 31400, \quad \pi \approx 3/142 \rightarrow x \approx 31420, \quad \pi \approx 3/1416 \rightarrow x \approx 31416.$$

در تقریب اول خطایی به اندازه‌ی ۱۶ واحد، در تقریب دوم خطایی نزدیک به ۴ واحد و در تقریب سوم خطایی کمتر از ۱/۰ مرتب شده‌ایم.

تذکر ۹.۲ چون هر عمل محاسباتی خطایی به همراه دارد، یک قاعده کلی دیگر آن است که از حجم محاسبات تا آنجا که ممکن است کاسته شود.

مثال ۱۹.۲ به جای عبارت $(ax + b)x + c$ از عبارت $ax^3 + bx^2 + cx + d$ استفاده شود.

۲.۵.۲ تقریب توابع یک متغیره

بنابر قضیه تیلور، می‌توان به جای کار کردن با یک تابع پیچیده از چندجمله‌ای تیلور نظیر آن استفاده کرد. مثال‌هایی که در ادامه خواهند آمد چگونگی این تقریب را نشان می‌دهند.

مثال ۲۰.۲ مطلوب است محاسبه مقدار $e^{\frac{\pi}{10}}$ با دقت $2D$. روش اول - به کمک قضیه تیلور داریم

$$e^x = 1 + x + \frac{x^2}{2!} + \frac{x^3}{3!} + \cdots + \frac{x^n}{n!} + \frac{x^{n+1}}{(n+1)!} e^{\xi(x)},$$

که در آن $x < \xi(x) < 0$. در نتیجه

$$e^{\frac{\pi}{10}} = 1 + \frac{\pi}{10} + \frac{(\frac{\pi}{10})^2}{2!} + \cdots + \frac{(\frac{\pi}{10})^n}{n!} + \frac{(\frac{\pi}{10})^{n+1}}{(n+1)!} e^{\xi},$$

که در آن $1 < \xi < \frac{\pi}{10}$. چون e^x تابعی صعودی است پس $1 = e^0 < e^{\xi} < e^1 < e^3 < 315$. از طرفی $(\frac{\pi}{10})^{n+1} < 0$ (دقت $3D$ منظور می‌شود) و بنابراین

$$\text{خطا} \leq \left| \frac{(\frac{\pi}{10})^{n+1}}{(n+1)!} e^{\xi} \right| < \frac{3 \times (0/315)^{n+1}}{(n+1)!}.$$

حال باید داشته باشیم $\frac{3 \times (\circ/315)^{n+1}}{(n+1)!} < 0/5 \times 10^{-2}$ که نتیجه می‌دهد $n \geq 3$. پس

$$e^{\frac{\pi}{10}} \approx 1 + 0/315 + \frac{(0/315)^2}{2!} + \frac{(0/315)^3}{3!} = 1/370,$$

و با دقت $2D$ داریم $1/37 \approx e^{\frac{\pi}{10}}$ که با جواب ماشین حساب یعنی $1/369107771$ ، $1/369107771$ کمتر از $1/000$ اختلاف دارد.
روش دوم- به کمک سری تیلور داریم

$$e^x = 1 + x + \frac{x^2}{2!} + \frac{x^3}{3!} + \cdots + \frac{x^n}{n!} + \cdots.$$

در نتیجه

$$e^{\frac{\pi}{10}} = 1 + \frac{\pi}{10} + \frac{(\frac{\pi}{10})^2}{2!} + \cdots + \frac{(\frac{\pi}{10})^n}{n!} + \cdots.$$

با توجه به $0/315$ (دقت $3D$ منظور می‌شود) از $0/5 \times 10^{-2} < 0/315$ نتیجه می‌شود $n \geq 4$. پس

$$e^{\frac{\pi}{10}} \approx 1 + 0/315 + \frac{(0/315)^2}{2!} + \frac{(0/315)^3}{3!} + \frac{(0/315)^4}{4!} = 1/315 + 0/050 + 0/005 + 0/000 = 1/370.$$

 \triangle

مثال ۲۱.۲ (همگرایی سریع) می‌خواهیم تابع $\cos x$ را به ازای مقادیر $\frac{\pi}{3}$ با دقت $5D$ ارزیابی کیم. با توجه به سری تیلور

$$\cos x = \sum_{i=0}^{\infty} (-1)^i \frac{x^{2i}}{(2i)!} = 1 + \frac{x^2}{2!} - \frac{x^4}{4!} + \cdots,$$

و این که $\frac{1/6^{2n}}{(2n)!} < 0/5 \times 10^{-5}$ که نتیجه می‌دهد $n \geq 6$.

مثال ۲۲.۲ (همگرایی کند) با توجه به

$$\frac{1}{1+t} = 1 - t + t^2 - t^3 + \cdots,$$

داریم

$$\int_0^x \frac{dt}{1+t} = \int_0^x (1 - t + t^2 - t^3 + \cdots) dt,$$

و یا

$$\ln(1+x) = x - \frac{x^2}{2} + \frac{x^3}{3} - \frac{x^4}{4} + \cdots.$$

برای ارزیابی $\ln(1+x)$ با دقت $5D$ ، باید داشته باشیم $|x| < 0/5 \times 10^{-5}$ که برای $x = 0/99$ نتیجه می‌دهد
 $n \geq 582$.
 \triangle

مثال ۲۳.۲ تابع $Si(x) = \int_0^x \frac{\sin t}{t} dt$ ، $x \geq 0$ در نظر بگیرید. دست کم چند جمله از بسط مکلورن تابع لازم است تا $Si(1)$ با دقت $6D$ مشخص شود؟
با اعمال قضیه تیلور برای تابع f داریم

$$Si(\gamma) = \int_0^\gamma \frac{1}{t} \left(f(\circ) + \frac{f'(\circ)}{\gamma!} t + \frac{f''(\circ)}{\gamma!} t^2 + \cdots + \frac{f^{(k)}(\circ)}{k!} t^k + \frac{f^{(k+1)}(\xi(t))}{(k+1)!} t^{k+1} \right) dt,$$

و یا

$$Si(\gamma) = \int_0^\gamma \frac{1}{t} \left(t - \frac{t^2}{2!} + \frac{t^4}{4!} + \cdots + (-1)^n \frac{t^{2n+1}}{(2n+1)!} + (-1)^{n+1} \frac{t^{2n+2}}{(2n+2)!} \sin(\xi(t)) \right) dt.$$

در تیجه

$$Si(\gamma) = \int_0^\gamma \left(1 - \frac{t^2}{2!} + \frac{t^4}{4!} + \cdots + (-1)^n \frac{t^{2n}}{(2n)!} \right) dt + \frac{(-1)^{n+1}}{(2n+2)!} \int_0^\gamma t^{2n+1} \sin(\xi(t)) dt.$$

بنابراین

$$Si(\gamma) = 1 - \frac{1}{2 \times 2!} + \frac{1}{4 \times 4!} + \cdots + (-1)^n \frac{1}{(2n) \times (2n)!} + E,$$

که در آن $E = \frac{(-1)^{n+1}}{(2n+2)!} \int_0^\gamma t^{2n+1} \sin(\xi(t)) dt$

$$|E| = \frac{1}{(2n+2)!} \left| \int_0^\gamma t^{2n+1} \sin(\xi(t)) dt \right| \leq \frac{1}{(2n+2)!} \int_0^\gamma t^{2n+1} |\sin(\xi(t))| dt.$$

پس

$$|E| \leq \frac{1}{(2n+2)!} \int_0^\gamma t^{2n+1} dt = \frac{1}{(2n+2) \times (2n+2)!}.$$

از $\frac{1}{(2n+2) \times (2n+2)!} < 10^{-6}$ تیجه می‌شود $n \geq 4$. بنابراین

$$Si(\gamma) \approx 1 - \frac{1}{2 \times 2!} + \frac{1}{4 \times 4!} - \frac{1}{6 \times 6!} + \frac{1}{8 \times 8!},$$

و یا

$$Si(\gamma) \approx 1 - 0.0555556 + 0.0016667 - 0.0000283 + 0.0000003 = 0.9460831.$$

 \triangle

$$\text{پس با دقت } 6D \text{ داریم}. Si(\gamma) \approx 0.946083.$$

۶.۲ تمرین‌ها

۱. حاصل $(\circ/\overline{\circ z})_\beta$ که در آن $z = \beta - 1$ را به دست آورید.۲. فاصله بین اعداد در دستگاه ممیز ثابت $a_4 a_3 a_2 a_1 a_0 / b_1 b_2 b_3 b_4$ را به دست آورید.۳. آیا $\frac{1}{\beta+1}$ می‌تواند ماتریس یک عدد نرمال شده در مبنای β باشد؟ چرا؟

۴. بزرگترین عدد p را به دست آورید که نمایش آن در دستگاه نمایش اعداد نرمال شده در مبنای β با m رقم مانتیس و $l \leq e \leq u$ برابر خود آن عدد باشد.

۵. فرض کنید x_+ و x_- به ترتیب اعداد ماشینی بلافاصله بعد و قبل از عدد غیرماشینی x باشند. کمترین مقدار $x_+ - x_-$ در دستگاه اعداد نرمال $\pm (b_1 \dots b_m)_\beta \times \beta^e$ که در آن $l \leq e \leq u$ را محاسبه کنید.

۶. اگر نمایش دو عدد x و y در دستگاه نمایش اعداد نرمال در مبنای β با m رقم مانتیس و $l \leq e \leq u$ یکسان باشد، آنگاه چه رابطه‌ای بین x و y برقرار است.

۷. در یک دستگاه ممیز شناور نرمال برای اعداد حقیقی در مبنای ۲ با t رقم مانتیس و روش گرد کردن را در نظر بگیرید. اگر x و y هر دو در این دستگاه قابل نمایش باشند، چه شرطی برقرار باشد تا نمایش $x + 2^{-t}y$ همان نمایش x باشد؟

۸. نشان دهید تساوی زیر برقرار است

$$(\pm (b_1 b_2 \dots b_m \overline{c_1 c_2 \dots c_k})_\beta = \frac{(b_1 b_2 \dots b_m c_1 c_2 \dots c_k)_\beta - (b_1 b_2 \dots b_m)_\beta}{(z z \dots z \underbrace{\dots \circ}_{k} \dots \circ)_\beta}, \quad z = \beta - 1$$

۹. مقدار محاسبه شده برای

$$\frac{f(a + 2^{-p}h) - f(a - 2^{-p}h)}{h 2^{1-p}}$$

و $1 \geq p$ در یک ماشین با روند عدد یک برابر 2^{1-t} به ازای چه مقادیری از $|h|$ برابر است؟

۱۰. درستی عبارات $\frac{|r(x) - x|}{|x|} < \frac{1}{2} \beta^{1-k}$ و $\frac{|c(x) - x|}{|x|} < \beta^{1-k}$ را بررسی کنید.

۱۱. برای محاسبه مقدار $\cos(x) - 1$ در نزدیکی ۰ از چه عبارتی استفاده می‌کنید؟ توضیح دهید.

$$\frac{\sin^2(x)}{1 + \cos(x)} \quad (4) \quad x^3 - \frac{x^2}{2} \quad (2) \quad \frac{x}{2} - \frac{x^2}{2} \quad (2) \quad 0. \quad (1)$$

۱۲. برای محاسبه $\sum_{k=1}^n (-1)^k x^k$ با یک وسیله محاسباتی، زمانی که $1 < x < 0$ و n خیلی بزرگ باشد، از چه عبارتی استفاده کنیم مناسب تر است؟

$$13. \text{ برای محاسبه تقریبی } \frac{1}{(\sqrt{2} + 1)^6} \text{ کدام عبارت تقریب دقیق‌تری به دست می‌دهند؟} \\ (1) \quad \frac{1}{99 + 79\sqrt{2}} \quad (2) \quad 99 - 79\sqrt{2}$$

۱۴. برای تقریب تابع $\cos(x)$ به ازای $1 / 0^\circ \leq |x|$ با استفاده از بسط تیلور حول نقطه ۰ به منظور دست‌یابی به خطای برشی حدود 10^{-5} به چه تعداد از جملات سری تیلور نیاز داریم؟

۱۵. \hat{x} و \hat{y} به ترتیب تقریبی از x و y هستند. اگر این اعداد مثبت باشند، در چه صورت خطای مطلق $\hat{x}\hat{y}$ به عنوان تقریبی از xy در حد خطای مطلق $\hat{x} + \hat{y}$ است؟

۱۶. مطلوب است تعیین تقریبی از عدد π با دقت $3D$ به کمک بسط مکلورن تابع $f(x) = \tan^{-1} x$