

ГЛАВА I

ВВЕДЕНИЕ

§1. Математическое моделирование. Численные методы и использование ЭВМ в решении прикладных задач

Рассматривая *математический анализ явления* как своего рода *теоретический эксперимент*, из общих и достаточно естественных соображений процесс *математического моделирования* разбивается на несколько этапов:

- **Формулировка математической модели явления.** Математическая модель любого изучаемого явления, по причине его чрезвычайной сложности, должна охватывать важнейшие для рассматриваемой задачи стороны процесса, его существенные характеристики и формализованные связи, подлежащие учёту.

Как правило, *математическая модель* изучаемого физического явления формулируется в виде *уравнений математической физики*. На этой стадии анализа это существенно нелинейные, многомерные системы уравнений, содержащие большое число неизвестных и параметров.

Если *математическая модель* выбрана недостаточно тщательно, то какие бы мы не применяли методы для дальнейших расчётов, полученные результаты будут *ненадёжны*, а в отдельных случаях и совершенно *неверны*.

- **Проведение математического исследования** полученной модели и получение соответствующего *решения*.

На этом этапе моделирования, в зависимости от сложности рассматриваемой модели, применяют различные подходы к её исследованию и различный смысл вкладывается в понятие *решения* задачи. Скажем, доказательство теорем *существования и единственности* в определённом смысле *решает* задачу, однако, являясь зачастую неконструктивным, оно не позволяет нам решить проблему изучения качественного поведения решения и оценки его количественных характеристик.

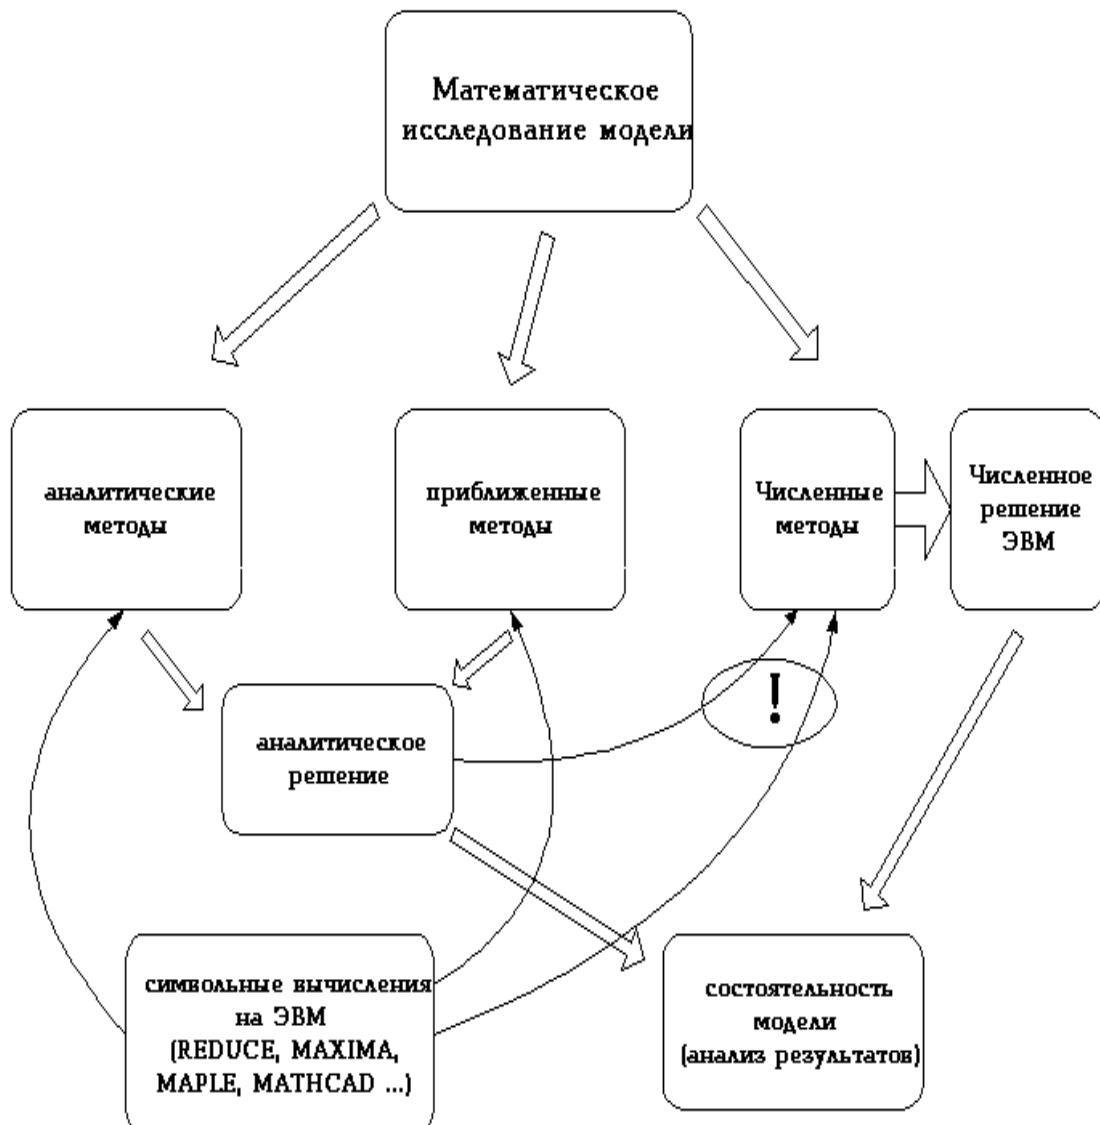
Для наиболее *грубых* и несложных (в некотором смысле) моделей удаётся получить их *аналитическое решение*. Следует оговориться — использование средств *символьных вычислений* на ЭВМ таких как REDUCE, MAXIMA, MAPLE, "интеллектуальных калькуляторов" MATHEMATICA, MathCAD, MatLab и пр. существенно революционизировало это, традиционное для "бумаги и карандаша", поле деятельности.

Для более точных и сложных моделей *аналитическое решение* удаётся получить сравнительно редко. При теоретическом анализе задачи в такой ситуации

пользуются обычно *приближенными* математическими методами, например разложением по малому параметру, осреднением, изучение различных асимптотик и другими. Эти приёмы позволяют опять-таки представить приближенное решение в аналитической форме и с его помощью получить удовлетворительные численные результаты.

Наконец для наиболее точных и сложных моделей основными методами решения являются *численные* методы решения с необходимостью требующие проведения большого объёма вычислений на ЭВМ. Эти методы позволяют добиться хорошего *количественного* и даже *качественного* результата в описании модели. Но, правда, у них есть и принципиальные недостатки — как правило, речь идёт о рассмотрении некоторого *частного* решения.

Приведённая схема частично отражает обсуждаемые взаимосвязи этапов математического моделирования.



Как мы видим, каждый из этапов математического исследования модели связан с использованием *численных методов* и получением *численного решения* задачи.

- **Анализ состоятельности предложенной модели**, т. е. осмысление результатов решения, сопоставление полученного решения с имеющимися данными физического эксперимента. На этом этапе решается вопрос о состоятельности математической модели и проведённого исследования. "Хорошее" согласование с "экспериментом" обычно свидетельствует о правильности выбора модели. В противном случае необходимы дополнительные уточнения, изменения и т. п., повторение предыдущих этапов исследования.

Обсуждая предмет лекционного курса, мы акцентировали наше внимание на двух сторонах предмета "Численные методы": *этапе в математическом моделировании* и на *необходимом моменте в процессе исследования, сопряженному с использованием ЭВМ*.

Использование ЭВМ в процессе математического исследования модели требует специфических, численных методов, т.е. такой "интерпретации" математической модели, которая может быть реализована на ЭВМ – назовём её *дискретной* (или *вычислительной*) моделью. Поскольку ЭВМ выполняет только арифметические и логические операции, то для реализации *вычислительной модели* требуется разработка соответствующего *вычислительного алгоритма*. Дальнейшая последовательность действий — это программирование. расчет на ЭВМ, обработка результатов расчета.

В рамках нашего лекционного курса мы остановимся на отдельных проблемах численных методов при анализе сравнительно простых и ставших классическими математических моделей.

Теперь посмотрим на проблему "численных методов" несколько подругому.

§2. Задача "вычисления"

2.1 Задача "вычисления". Анализ постановки

Обычно задачу вычисления величины y по известной величине x записывают, с учётом интересующих нас причинно-следственных связей, в виде

$$y = \mathcal{A}(x), \quad (1)$$

где $y \in \mathcal{Y}$, $x \in \mathcal{X}$ – элементы соответствующих функциональных пространств ^{*1};

\mathcal{A} – оператор (правило), реализующий вычисления.

В первую очередь нас будут интересовать корректно поставленные задачи вычисления.

Задача вычисления $y = \mathcal{A}(x)$ называется корректно поставленной, если для любых входных данных из некоторого класса решение задачи существует, единственно и устойчиво по входным данным (т.е. непрерывно зависит от входных данных задачи).

^{*1}) Если не оговорено особо, то \mathcal{Y}, \mathcal{X} – как правило линейные, нормированные, полные, т.е. банаховы пространства.

В сформулированное понятие *корректности* поставленной задачи (по Адамару) учтены достаточно естественные требования, действительно: чтобы численно решать задачу нужно быть уверенным, что её решение *существует*. Столь же разумны для конкретных условий и требования *единственности* решения, и, поскольку наши действия носят принципиально приближенный характер, то необходимо требование *устойчивости* решения.

Сделаем несколько замечаний об *устойчивости*. Нас интересует решение y задачи (1) соответствующее входным данным x . Реально мы имеем возмущенные входные данные с погрешностью δx , т.е. $x + \delta x$ и находим возмущенное решение

$$y + \delta y = \mathcal{A}(x + \delta x).$$

Эта погрешность входных данных порождает *неустранимую* погрешность решения

$$\delta y = \mathcal{A}(x + \delta x) - \mathcal{A}(x).$$

Если решение непрерывно зависит от входных данных, то

$$\|\delta y\| \rightarrow 0 \quad \text{всегда при} \quad \|\delta x\| \rightarrow 0$$

и задача (1) устойчива по входным данным.

Отсутствие устойчивости означает, что даже "небольшим" погрешностям δx могут соответствовать "большие" погрешности δy , т.е. построенное при расчёте решение будет сильно отличаться от истинного.

Применять непосредственно к такой неустойчивой задаче численные методы бесполезно. Однако и не всякую формально устойчивую задачу удобно решать практически. Пусть имеет место оценка

$$\|\delta y\| \leq C \cdot \|\delta x\|, \quad \text{но} \quad C - \text{велико.}$$

Задача формально устойчива, но *неустранимая ошибка* решения может быть большой. Это случай *плохой обусловленности* или *слабой устойчивости* задачи вычисления.

Приведем несколько примеров постановки *задачи вычисления* (1).

2.2 Примеры постановки задачи вычисления

1° Задача нахождения корней полинома. Рассмотрим некоторый полином степени n в приведенном виде (старший коэффициент равен единице):

$$p_n(x) \equiv x^n + a_1 x^{n-1} + a_2 x^{n-2} + \cdots + a_{n-1} x + a_n$$

вообще говоря с комплексными коэффициентами ($a_k, x \in \mathbb{C}$).

Требуется определить его корни. Пусть E^n — n -мерное комплексное евклидово пространство. Положим, что компоненты некоторого вектора $\vec{z} = \{z_1, z_2, \dots, z_n\}$ этого пространства являются корнями полинома $p_n(x)$, т.е.

$$p_n(z_i) = 0, \quad i = \overline{1, n}.$$

Тогда, в силу теоремы Безу, мы можем $p_n(x)$ записать в виде:

$$p_n(x) = x^n + a_1x^{n-1} + a_2x^{n-2} + \cdots + a_{n-1}x + a_n = (x - z_1)(x - z_2) \cdots (x - z_n) = \prod_{i=1}^n (x - z_i).$$

Отсюда мы получаем известные формулы Виетта:

$$a_k = (-1)^k \sigma_k, \quad k = \overline{1, n}. \quad (*)$$

Здесь σ_k — элементарные, симметричные относительно z_1, z_2, \dots, z_n однородные функции k -го порядка

$$\left\{ \begin{array}{lcl} \sigma_1 & = & z_1 + z_2 + \cdots + z_n \\ \sigma_2 & = & z_1z_2 + z_1z_3 + \cdots + z_1z_n + z_2z_3 + \cdots + z_{n-1}z_n \\ \dots & & \\ \sigma_n & = & z_1z_2 \cdots z_n. \end{array} \right.$$

(каждое σ_k содержит C_n^k слагаемых).

Таким образом формулы Виетта $(*)$ сопоставляют каждому вектору $z \in E^n$ вектор $\vec{a} = \{a_1, a_2, \dots, a_n\} \in E^n$ того же пространства, т.е. определяют отображение $\mathcal{V} : E^n \Rightarrow E^n$ пространства E^n на себя. С помощью этого отображения \mathcal{V} задача определения корней полинома $p_n(x)$ формулируется следующим образом:

Для заданного вектора \vec{a} найти вектор $\vec{z} \in E^n$ такой, что

$$\mathcal{V}(\vec{z}) = \vec{a}. \quad (2)$$

В курсе высшей алгебры показано, что отображение \mathcal{V} взаимнооднозначное и взаимнонепрерывное, т.е. задача (2) корректна.

2° Основная задача линейной алгебры. Пусть дана матрица $A_{(p \times q)} = \|a_j^i\|_q^p$ и два евклидовых пространства E^p и E^q . Тогда определено отображение

$$A : E^q \Rightarrow E^p; \quad \vec{y} = A\vec{x}, \quad \vec{y} \in E^p, \vec{x} \in E^q,$$

(\vec{x}, \vec{y} — столбцы соответствующих размерностей).

Основная задача линейной алгебры состоит в том, чтобы по заданному вектору $\vec{f} \in E^p$ найти вектор $\vec{x} \in E^q$ такой, что

$$A\vec{x} = \vec{f}. \quad (3)$$

Задача (3) представляет собой задачу решения *системы линейных алгебраических уравнений* — СЛАУ. Связанная с решением СЛАУ ситуация нами подробно изучена в курсе *линейной алгебры*:

- 1) если $p = q$ и $\det A \neq 0$, то задача (3) поставлена *корректно* (её решение дается формулами Крамера);
- 2) в остальных случаях, если система (3) совместна ($\text{rang } A = \text{rang } A'$), то решение неединственно. В противном случае решение вовсе отсутствует, т.е. задача (3) в этих случаях *некорректно поставлена*.

3° Задача Коши для обыкновенного дифференциального уравнения.

Пусть требуется найти решение обыкновенного дифференциального уравнения (ОДУ), отвечающее начальному условию $y(a) = b$

$$\begin{cases} \frac{dy}{dx} = f(x, y), & a < x \leq c \\ y(a) = b. \end{cases} \quad (*)$$

Здесь a, b — заданные числа; $f(x, y)$ — определена в полосе $\Pi = \{(x, y); a \leq x \leq c; y \in (-\infty; \infty)\}$ и удовлетворяет в Π условиям теоремы о продолжимости решения $(*)$ на отрезок $[a; c]$.

Обозначим через \mathcal{R}_0 множество всевозможных решений задачи Коши $(*)$, отвечающих различным значениям начального условия b . Определим отображение $\mathcal{K}: \mathcal{R}_0 \Rightarrow R^1$, полагая

$$\mathcal{K}(y(x)) = y(a), \quad \forall y \in \mathcal{R}_0.$$

Тогда решение задачи Коши для ОДУ $(*)$ можно сформулировать так:
по заданному числу b найти функцию $y(x)$ такую, что

$$\mathcal{K}(y(x)) = b. \quad (4)$$

В курсе *дифференциальных уравнений* доказана корректность задачи (4).

Число рассмотренных примеров задачи вычисления можно было бы множить, но мы ограничимся рассмотренными примерами постановки задачи вычисления.

§3. Численное решение корректных задач**Структура погрешности решения****3.1 Задача "вычисления". Погрешности**

Обратимся снова к задаче вычисления (1)

$$y = \mathcal{A}(x).$$

В рассмотренных примерах (2)–(4) соответствующее *правило* \mathcal{A} реализующее "вычисление" задано явно неконструктивно. Речь идёт по сути об обращении операторов $\mathcal{V}^{-1}, A^{-1}, \mathcal{K}^{-1}$, точнее о численной реализации обратного отображения для (2)–(4). Такая ситуация типична и лишний раз показывает, что, как правило, *вычисление* \mathcal{A} не может быть "просто" реализовано. Чтобы преодолеть эти сложности задачу (1) заменяют другой, "близкой" к ней задачей, но уже которая "легко" решается численно. При этом в первую очередь анализируют вопрос о вносимых в решение погрешностях.

Есть четыре основных источника погрешности результата вычислений: *математическая модель*; *исходные данные* задачи; *приближённый метод* и *погрешность при реализации вычислений* (в частности *погрешность округления*):

δ_{1y} — *погрешность математической модели*, связана с физическими допущениями при выборе математической модели и на анализе этой погрешности мы останавливаться не будем;

$\delta_2 y$ – погрешность исходных данных, порождает неустранимую погрешность решения

$$\delta_2 y = \mathcal{A}(x + \delta x) - \mathcal{A}(x);$$

$\delta_3 y$ – погрешность метода. Выражение $\mathcal{A}(x)$, вообще говоря, не может быть ”просто” численно реализовано. Задачу $y = \mathcal{A}(x)$ заменяют ”близкой” задачей

$$\bar{y} = \bar{\mathcal{A}}(\bar{x}), \quad (1')$$

Мы переходим к другим функциональным пространствам $\mathcal{X}, \mathcal{Y} \Rightarrow \bar{\mathcal{X}}, \bar{\mathcal{Y}}$ элементы которых допускают сравнительно ”простую” численную реализацию. Соответствующим образом меняется и отображение $\mathcal{A} \Rightarrow \bar{\mathcal{A}}$.

При этом естественно требовать, чтобы задача (1') была *корректна* и чтобы решение \bar{y} было близко к решению y . Величина

$$\delta_3 y = y - \bar{y} = \mathcal{A}(x) - \bar{\mathcal{A}}(\bar{x})$$

и представляет собой *погрешность метода*.

$\delta_4 y$ – вычислительная погрешность. При численной реализации \bar{y} , которая уже, по предположению, возможна получают элемент \tilde{y} , поскольку промежуточные результаты округлялись и т.п. Таким образом *вычислительная погрешность метода* может быть записана в виде

$$\delta_4 y = \bar{y} - \tilde{y} = \bar{\mathcal{A}}(\bar{x}) - \tilde{y}.$$

Полезно сразу же сформулировать некоторые эмпирические правила, которых придерживаются при реализации задачи вычисления:

$$\|\delta_2 y\| \sim (2 \div 5) \|\delta_3 y\| \gg \|\delta_4 y\|.$$

- 1) При проведении вычислений нужно стремиться, чтобы погрешность метода $\delta_3 y$ была бы в несколько раз меньше *неустранимой погрешности* решения $\delta_2 y$:
- 2) *Вычислительная погрешность* $\delta_4 y$ должна быть существенно меньше всех остальных погрешностей решения, т.е. расчёт нужно вести с таким количеством значащих цифр, чтобы погрешность округления была существенно меньше всех остальных погрешностей.

Теперь мы можем ещё раз очертить круг вопросов, рассматриваемых в рамках нашего лекционного курса ”Численных методов” — это ^{*)1)}

- 1) конструирование *дискретной* (или *вычислительной*) модели $\{\bar{\mathcal{X}}, \bar{x}, \bar{\mathcal{A}}\}$:
- 2) разработка на её основе соответствующих алгоритмов решения редуцированной задачи вычисления

$$\bar{y} = \bar{\mathcal{A}}(\bar{x});$$
- 3) анализ погрешности метода $\delta_3 y$ и частично вычислительной погрешности $\delta_4 y$ алгоритма, реализующего вычисления $\bar{\mathcal{A}}$.

^{*)1)} Предмет лекционного курса мог бы быть и более содержательным и обширным, но, как всегда, здесь есть свои, не зависящие от нашего желания, ограничения, определяемые спецификой учебного плана факультета.

3.2 Погрешность округления на t -разрядной ЭВМ

Остановимся несколько подробнее в рамках этого параграфа, но кратко, на анализе вычислительной погрешности δ_{4y} , обвязанной погрешностям округления при реализации численного алгоритма.

1°. Погрешность единичного округления. В современных ЭВМ действительные числа представляются в т.н. форме с *плавающей запятой*, т.е. если само число a в позиционной системе счисления с основанием r записано в виде r -ичной дроби

$$a = \text{sign } a(a_n a_{n-1} \dots a_1 a_0, a_{-1} a_{-2} \dots)_r = \text{sign } a(a_n r^n + \dots + a_1 r + a_0 + \frac{a_{-1}}{r} + \frac{a_{-2}}{r^2} + \dots),$$

то такую форму записи числа a называют *представлением с фиксированной запятой*. Здесь $a_k \in \{0; 1; \dots; "(r-1)"\}$ — r -ичные цифры.

Представление числа a в форме с *плавающей запятой* или *нормализованное представление* означает его запись в виде

$$a = \text{sign } a M r^p = \text{sign } a \cdot r^p \cdot (\frac{b_1}{r} + \frac{b_2}{r^2} + \dots),$$

где p — порядок числа (целое); M — мантисса числа a , причем $1/r \leq M < 1$, т.е. превая r -ичная цифра в записи мантиссы b_1 неравна нулю.

В современных ЭВМ в качестве основания системы счисления r выбирается двойка — $r = 2$. Тогда, если для записи мантиссы отводится только t двоичных разрядов, то это позволяет из диапазона $[M_0; M_\infty = M_0^{-1}]$ (для положительных чисел) записать лишь конечное число рациональных чисел, а все остальные вещественные числа подвергаются округлению при их представлении в ЭВМ.

Точность представления числа a с помощью округлённого числа \tilde{a} характеризуется относительной погрешностью округления

$$\delta_a = \frac{|a - \tilde{a}|}{|a|}.$$

При простейшем способе округления *усечением*, когда все лишние разряды мантиссы просто отбрасываются, можно легко получить оценку величины относительной погрешности δ_a единичного округления. Действительно *1)

$$|a - \tilde{a}| = 2^p \left| \frac{b_{t+1}}{2^{t+1}} + \dots \right| \leq 2^p \cdot \frac{1}{2^{t+1}} \left(1 + \frac{1}{2} + \dots \right) = 2^{p-t}.$$

С другой стороны*2) $|a| \geq 2^p \cdot (1/2)$. Таким образом для погрешности единичного округления получаем

$$\delta_a = \frac{|a - \tilde{a}|}{|a|} \leq \frac{2^{p-t}}{2^{p-1}} = 2^{-(t-1)}.$$

Более точный способ округления дает для погрешности единичного округления вдвое меньшую оценку через *машинное эпсилон*

$$\delta_a = 2^{-t} \leq \varepsilon_M. \quad (5)$$

*1) Здесь при оценке все двоичные цифры в остатке заменены единицей $b_k \leq 1, k \geq t+1$.

*2) Мы полагаем $a_i = 0$, при $i \geq 2$; $a_1 = 1$ всегда.

Относительная погрешность представления числа с плавающей запятой в ЭВМ определяется числом разрядов мантиссы и не превышает машинного эпсилон $\varepsilon_M = 2^{-t} (\sim 10^{-12})$.

Опираясь на оценку (5) мы можем считать, что само число a и его округлённое значение \tilde{a} связаны соотношением

$$\tilde{a} = \text{fl}(a) = a(1 + \varepsilon_a),$$

где $|\varepsilon_a| \leq \varepsilon_M = 2^{-t}$. Однако отметим, что для чисел $|a| < M_0$ в результате округления получим $\tilde{a} = 0$ и тем самым для этих чисел $\varepsilon_a = -1$ (!).

Арифметическое Устройство (AY) современных ЭВМ сконструировано таким образом, что любая арифметическая операция при последующем округлении даёт относительную ошибку не более ε_M .

Для оценки влияния погрешности округлений на результат того или иного вычислительного алгоритма пользуются предположением о том, что *результат вычислений,искаженный погрешностью округления совпадает с результатом точного вычисления по тому же алгоритму, но с иными — \tilde{x} , входными данными.*

Таким образом

$$\tilde{y} = \bar{\mathcal{A}}(\tilde{x}) \quad \text{и} \quad \delta_4 y = \bar{y} - \tilde{y} = \bar{\mathcal{A}}(\bar{x}) - \bar{\mathcal{A}}(\tilde{x}).$$

Это допущение позволяет связать анализ *вычислительной погрешности $\delta_4 y$* с анализом *устойчивости алгоритма $\bar{\mathcal{A}}$ по входным данным*.

Пример. Рассмотрим задачу о нахождении произведения n сомножителей

$$z_n = \prod_{k=1}^n y_k.$$

Пусть вычисления реализованы по алгоритму $\bar{\mathcal{A}}$ следующим образом:

$$\begin{cases} z_k = y_k \cdot z_{k-1}, & k = 1, 2, \dots, n \\ z_0 = 1. \end{cases}$$

Предположим, что в результате округлений вместо точного значения z_{k-1} получено значение \tilde{z}_{k-1} . Тогда вместо величины $y_k \tilde{z}_{k-1}$ получим величину

$$\tilde{z}_k = \text{fl}(y_k \cdot \tilde{z}_{k-1}) = y_k \cdot \tilde{z}_{k-1}(1 + \varepsilon_k); \quad |\varepsilon_k| \leq \varepsilon_M.$$

Таким образом мы получили алгоритм $\tilde{\mathcal{A}}^{*1})$

$$\begin{cases} \tilde{z}_k = \tilde{y}_k \cdot \tilde{z}_{k-1}, & k = 1, 2, \dots, n \\ \tilde{z}_0 = 1. \end{cases}$$

Оценим результирующую относительную погрешность

$$\delta_{z_n} = \left| \frac{z_n - \tilde{z}_n}{z_n} \right| = \frac{\left| \prod_{k=1}^n y_k - \prod_{k=1}^n (1 + \varepsilon_k) y_k \right|}{\left| \prod_{k=1}^n y_k \right|} \leq (1 + \varepsilon_M)^n - 1 = n\varepsilon_M + O(\varepsilon_M^2).$$

или, пренебрегая слагаемыми второго и больших порядков по ε_M получим окончательно

$$\delta_{z_n} \leq n\varepsilon_M.$$

¹⁾Структура полученного алгоритма $\bar{\mathcal{A}}$ подтверждает сформулированное допущение.