

МІНІСТЕРСТВО ОСВІТИ І НАУКИ УКРАЇНИ
ДОНЕЦЬКИЙ НАЦІОНАЛЬНИЙ УНІВЕРСИТЕТ ІМЕНІ ВАСИЛЯ СТУСА

БІЛОУС РОСТИСЛАВ ВІТАЛІЙОВИЧ

Допускається до захисту:

в. о. завідувача кафедри

Прикладної математики,

Трофименко О. Д.

« ____ » _____ 20__ р.

**ДОСЛІДЖЕННЯ ЗБІЖНОСТІ КОМП'ЮТЕРНИХ ОБЧИСЛЕНЬ (НА
ПРИКЛАДІ ПОСЛІДОВНОСТІ МЮЛЛЕРА)**

Спеціальність 113 Прикладна математика

Кваліфікаційна (бакалаврська) робота

Керівник:

Ветров О. С., старший викладач

кафедри Прикладної математики

Оцінка: ____ / ____ / ____
(бали за шкалою ЄКТС/за національною шкалою)

Голова ЕК: _____
(підпис)

АНОТАЦІЯ

Білоус Р. В. Дослідження збіжності комп'ютерних обчислень (на прикладі послідовності Мюллера). Спеціальність 113 «Прикладна Математика», спеціалізація «Прикладна математика». Донецький національний університет імені Василя Стуса, Вінниця 2021.

У кваліфікаційній (бакалаврській) роботі досліджена послідовність Мюллера та збіжність комп'ютерних досліджень. Продемонстровано виникнення похибок при комп'ютерних обчисленнях не складних виразів. Побудовано математичне обґрунтування проблеми нестійких початкових значень, коли ми наперед знаємо, число до якого має збігатись значення членів послідовності, але стандартні методи комп'ютерних обчислень дають некоректний результат.

Ключові слова: комп'ютерні обчислення, послідовність Мюллера, збіжність, похибки, програмування, стійкість, числа з плаваючою комою.

33 с., 1 табл., 4 рис., 8 лістингів, 23 джерела.

ABSTRACT

Bilous R. Study of the convergence of computer calculations (on the example of the Mueller sequence). Specialty 113 "Applied Mathematics", specialization "Applied Mathematics". Vasyl' Stus Donetsk National University, Vinnytsia, 2021.

In the qualification (bachelor's) work, the sequence of Mueller and the convergence of computer research are studied. Errors in computer calculations of simple expressions have been demonstrated. A mathematical substantiation of the problem of unstable initial values is constructed, when we know in advance the number to which the values of the members of the sequence should coincide, but standard methods of computer calculations give an incorrect result.

Keywords: computer calculations, Mueller sequence, convergence, errors, programming, stability, floating point numbers

ЗМІСТ

ВСТУП	4
РОЗДІЛ 1.....	7
Проблематика комп'ютерних обрахунків.	7
1.1. Простий випадок похибки комп'ютерних обчислень.....	7
1.2. Парадоксальні результати комп'ютерних обчислень. Приклад 3. Рампа.	11
Висновки до розділу 1	16
РОЗДІЛ 2.....	17
Проблема стійкості комп'ютерних обчислень (на прикладі послідовності Мюллера).....	17
2.1. Постановка задачі.	17
2.2. Математичне дослідження проблеми.	21
2.3. Збіжність рекурентної послідовності Мюллера.	26
Висновки до розділу 2	29
ВИСНОВКИ.....	30
СПИСОК ВИКОРИСТАНОЇ ЛІТЕРАТУРИ	31

ВСТУП

Проблема надійності (достовірності) комп'ютерних обчислень є однією з фундаментальних проблем Computer Science [1], оскільки лежить на перетині прикладної математики з одного боку, та фізико-технічних обмежень комп'ютерної техніки – з іншого. Фізичні обмеження на обсяг пам'яті, що виділяється комп'ютерною технікою для обробки числа накладає принципові обмеження на можливості та логіку організації комп'ютерних обрахунків, що також потребує залучення специфічних математичних методів дослідження.

При цьому, проблема полягає не лише у можливості некоректного результату теоретичного дослідження. Як показує практика, наслідки невірних комп'ютерних обчислень можуть бути катастрофічними. Відомий випадок: 25 лютого 1991 року установка ППО Patriot не змогла перехопити ворожу ракету, і снаряд потрапив в барак солдатів США, в результаті чого загинуло 28 осіб. Офіційне розслідування показало [2], що 24-бітові процесори перехоплювача при конвертації часу роблять помилку в 0.013 секунди щогодини. Patriot не перезапускався понад 100 годин, що стало причиною помилки обчислення положення ракети на 600 метрів.

В сучасній вітчизняній науковій літературі тематика точності комп'ютерних обчислень, на думку автора, відображена явно недостатньо, на рівні констатації проблеми. Майже будь-який академічний підручник з методів обчислень – невід'ємної дисципліни курсу підготовки фахівців як фізико-математичного профілю, так і спеціалістів з комп'ютерних наук – містить, як правило, лише математичні відомості про похибки та межі точності обчислень. Прикладна ж сторона питання, тобто саме комп'ютерна реалізація обрахунків, залишається поза увагою. Технічні ж дисципліни, на кшталт «Програмування», якщо знову ж таки судити з навчальної літератури, дають зазвичай лише базові поняття конвертації чисел до бінарного коду і назад, та наводять загальні відомості про існуючі стандарти представлення чисел з плаваючою комою.

Частково через це автор і зацікавився тематикою коректності комп'ютерних обчислень. Для прикладу, в даній роботі автор зосередився на

розгляді двох відомих випадках некоректної поведінки програмних обрахунків: прикладі 3. Рампа [3] та послідовності Мюллера [4], що не відображені у вітчизняній літературі.

Основною проблемою при проведенні представленого дослідження було відсутність загальної методології аналітичного дослідження нелінійних рекурентних послідовностей. Теорія побудови розв'язку лінійних рекурентних рівнянь добре вивчена, з основними поняттями та методами можна ознайомитись в доброму підручнику з дискретної математики [5], наявна серйозна наукова література, присвячена зв'язку рекурентних (різницевих) рівнянь та обчислювальних процесам у інформатиці (наприклад, [6, 7]). Що стосується випадку нелінійності, то загальних методів аналітичного розв'язку подібного роду рівнянь не існує, і кожен окремий випадок представляє собою творчу задачу. Автор ознайомився із доступними для нього матеріалами з цього приводу [8-10], запозичив деякі ідеї, але основна методологія дослідження аналізу збіжності послідовності Мюллера (розділ 2) була розроблена їм самостійно разом із науковим керівником.

Прикладна задача дослідження стійкості комп'ютерних обчислень була розглянута як з точки зору практичної реалізації мовами програмування, так і з математичного боку, оскільки в даному випадку лише інтуїтивний підхід приводить до некоректних результатів.

За матеріалами представлено дослідження були зроблені доповіді на конференціях [11-13] і опублікована стаття методичної спрямованості [14].

Частина результатів знайшла застосування при виконанні науково-дослідної роботи «Розробка методів дослідження міцності та стійкості тонкостінних оболонок та пружних твердих тіл з рідиною при дії різного виду динамічних навантажень» під керівництвом академіка В.П. Шевченка (№ держреєстрації: 0119U100042). Посилання на цей факт наявне в річному звіті виконання теми за 2020 рік та зазначене у [14].

Актуальність даної теми полягає в тому, кожного дня майже будь-яка людина має справу з комп'ютерними обчисленнями. Хоча розглянуті похибки

та їм подібні трапляються вкрай рідко, але враховуючи кількість ЕОМ у світі та ще більшу кількість операцій, що відбуваються щосекунди, виникненням таких похибок та їх впливом на людство не можна нехтувати.

Мета: Дослідити збіжність комп'ютерних обчислень взявши за приклад послідовність Мюллера.

Об'єкт дослідження: Збіжність комп'ютерних обчислень.

Предмет дослідження: Рекурентна послідовність Мюллера другого порядку порядку та збіжність комп'ютерних обчислень на її прикладі.

Для досягнення поставленої мети необхідно виконати наступні **завдання:**

- 1) Дослідити представлення дійсних чисел у пам'яті комп'ютера.
- 2) Досліди процес виникнення помилок при комп'ютерних обчисленнях.
- 3) Дослідити методи, які дають змогу позбутись деяких помилок комп'ютерних обчислень.
- 4) Дослідити збіжність комп'ютерних обчислень на прикладі послідовності Мюллера.

Кваліфікаційна (бакалаврська) робота складається із вступу, двох розділів, загального висновку, списку використаної літератури (23 літературних джерел).

Загальний обсяг роботи – 30 сторінок.

РОЗДІЛ 1. ПРОБЛЕМАТИКА КОМП'ЮТЕРНИХ ОБРАХУНКІВ.

В розділі коротко наведені деякі приклади некоректності комп'ютерних обчислень, що виникають у зв'язку із обмеженим обсягом пам'яті, що виділяється комп'ютером для роботи із числами. Дійсні числа, що є фундаментальним об'єктом математики, перетворюються на числа з плаваючою комою (*floating point numbers*) згідно ухвалених стандартів.

Неврахування фундаментальних основ бінарної арифметики та засад стандарту IEEE-754 може суттєво вплинути на коректність як теоретичного дослідження (якщо для моделювання була використана комп'ютерна техніка), так і просто на якість продукту при розробці прикладних програм.

Програми реалізуються мовами C++ або Python в залежності від того, коли це доречніше: в C++ ми можемо наочно експериментувати, змінюючи типи чисел з плаваючою комою *float* та *double*; в Python же за замовчуванням реалізована довга арифметика.

Розділ є продовженням дослідження методичного характеру, опублікованого автором в 2020 році [14].

1.1. Простий випадок похибки комп'ютерних обчислень

Розглянемо наступний приклад особливості комп'ютерних обчислень. Перевіримо за допомогою мови програмування C++, чи виконується закон дистрибутивності у комп'ютерних обчисленнях. Проста програма реалізована на C++ матиме вигляд (лістинг 1)

Лістинг 1

```
#include <iostream>
using namespace std;
int main() {
    double a = 0.987;
    double b = 0.278;
    double c = 1.268;
    double expr_1 = a*c + b*c;
    double expr_2 = (a + b)*c;
    cout<<(expr_1 == expr_2);
}
```

Лістинг 2

```
#include <iostream>
using namespace std;
int main() {
    float a = 0.9871;
    float b = 0.2781;
    float c = 1.268;
    float expr_1 = a*c + b*c;
    float expr_2 = (a + b)*c;
    cout<<(expr_1 == expr_2);
}
```

Очікувано, ми отримаємо результат 1 (тобто *true*). Трохи змінимо значення чисел a та b , збільшивши їх на 0.0001 (тобто змінимо числа a та b на 0,01 % та 0,04 % відповідно). В результаті вже отримаємо результат 0 (в значенні *false*). Якщо ми виведемо на консоль відповідні значення для випадку $a = 0.9871$ та $b = 0.2781$ з точністю 20 знаків після коми то отримаємо

$$\begin{aligned} a \cdot c + b \cdot c &\rightarrow 1.60427359999999996631 \\ (a + b) \cdot c &\rightarrow 1.604273600000000018836' \end{aligned}$$

різні значення, що несуттєво, але відрізняються від реального значення 1.6042736 (абсолютна похибка складає $3.4 \cdot 10^{-17}$ та $1.9 \cdot 10^{-16}$). Змінимо типи змінних у програмі на *float* (лістинг 2), і в результаті вже отримаємо результат *true*. Тобто, саме зменшення точності обчислень повертає нас до коректного з математичної точки зору результату, що на перший погляд виглядає дещо парадоксально.

Справедливою є стара істина про те, що порівнювати числа з плаваючою комою завжди треба дуже обережно, оскільки результати з теоретичної точки зору можуть видаватись некоректними. І для того, щоб переконатись у цьому не потрібно вигадувати складні приклади. Достатньо ознайомитись з відповідною документацією стосовно класичної проблеми комп'ютерних обчислень " $(0.1 + 0.2) \neq 0.3$ " [15].

Дивлячись на отримані результати, може скластися думка, що принциповість проблеми коректності комп'ютерних обчислень є дещо надуманою, бо навіть в наведеному прикладі похибка складає значення співмірне із машинним епсилоном. Та й при реалізації реальних обчислень в прикладних задачах точність в 16 знаків після коми є скоріш за все надмірною. Тим не менш, аналізуючи отримані результати лише на одному прикладі обчислень, ми можемо зробити попередні висновки:

- змінюючи тип операндів у виразах (в нашому прикладі експериментуючи з типами *float* та *double*), можна отримати принципово різні результати, обраховані формально на одному і тому ж наборі даних;

- точність комп'ютерних обчислень може якісно впливати на результат (в нашому прикладі отримані результати відрізняються від математичного зовсім несуттєво, але формально перестає виконуватись закон дистрибутивності);
- результат комп'ютерних обчислень залежить від порядку виконання арифметичних операцій;
- порівняння чисел з плаваючою комою доречніше здійснювати не на точну рівність, а за схемою $|x - y| < \varepsilon$.

Зазначені складності комп'ютерних обчислень виникають в наслідок способу представлення дійсних чисел у пам'яті комп'ютера, що регулюється стандартами IEEE-754 [16].

Опис стандарту IEEE-754 виходить за межі даної роботи, тому обмежимося лише демонстрацією представлення чисел з описаного вище прикладу у форматах *float* та *double*.

Формат *float* – під число виділяється 32 біти: старший біт знаковий (0 означає додатне число, 1 – число є від'ємним), далі 8 біт виділяється під експоненту, і останні 23 біти під нормалізовану мантису. Схематично це можна зобразити на (рисунку 1) як :

sign	Exponent (8 bit)								Mantissa (23 bit)																						
.

Рис. 1.

Числа з прикладу, конвертовані у бінарний код згідно правил формату *float*, матимуть вигляд

$$(0.9871)_{10} = (00111111\ 01111100\ 10110010\ 10010110)_2,$$

$$(0.2781)_{10} = (00111110\ 10001110\ 01100011\ 00100000)_2,$$

$$(1.2680)_{10} = (00111111\ 10100010\ 01001101\ 11010011)_2.$$

1.2. Парадоксальні результати комп'ютерних обчислень. Приклад 3. Рампа.

В попередньому розділі автором був наведений елементарний приклад проблемних ситуацій, що можуть виникати при організації комп'ютерних обрахунків. Обмеження, що накладаються на представлення дійсних чисел у різних форматах згідно стандарту [16], призводять до некоректних по факту результатів обчислень навіть при виконанні в комп'ютерній програмі елементарних арифметичних дій. В роботі [14] автором наведено ще чимало подібних прикладів, реалізованих мовами програмування C++ та Python. В принципі, всі згадані приклади не змінюють нашого розуміння результатів обчислень, а лише змушують постійно пам'ятати про невід'ємну похибку комп'ютерних обчислень, пов'язану із скінченим обсягом пам'яті, що може бути виділений для зберігання дійсного числа.

Далі наведемо приклади дійсно парадоксальності деяких випадків комп'ютерних обчислень, принаймні таке вони справляють перше враження. В подальшому ми будемо спиратись на результати, раніше вже опубліковані автором [14].

Зображення на рисунку 3 – кадр зі серії "The Wizard of Evergreen Terrace" відомого анімаційного серіалу The Simpsons, а зображення на рисунку 4 – серія "Treehouse of Horror VI. Homer3 (Homer Cubed)".




Рисунок 3. [17]




Рисунок 4. [18]

Гомер Сімпсон знайшов щонайменше два контр-приклади, що ніби доводять нам, що Велика теорема Ферма не вірна. Оскільки нам відомо, що Велика теорема Ферма була остаточно доведена у 1995 році, то ми можемо

просто сприйняти наведені числа як жарт з випадковими числами, наведений лише для наукоподібності. Насправді зазначений жарт значно цікавіший, особливо з позицій проблематики, що підіймаються у даній роботі.

Саймон Сінгх [19] пропонує за допомогою калькулятора переконатись у істинності $3987^{12} + 4365^{12} = 4472^{12}$, але ми перевіримо припущення Гомера реалізувавши програму, написану на C++.

Лістинг 3.

```
#include <iostream>
#include <cmath>
using namespace std;
int main() {
    float an = pow(398.7,12);
    float bn = pow(436.5,12);
    float cn = pow(447.2,12);
    cout << (an + bn == cn);
}
```

Результатом виконання представленої програми буде 1 (*true*). Одразу зазначимо, що ми замінили наведені на рисунку 2 числа їх аналогами, скороченими в 10 раз, оскільки для оригінальних значень результати обчислень дорівнюють *inf*.

Дійсно, значення $4472^{12} = 63976656348486725806862358322168575784124416$ занадто велике, щоб зберігати його у змінній типу *float* (чотирьох байтів виявляється недостатньо). Тому ми і реалізуємо наступний трюк: будемо перевіряти на рівність з математичної точки зору еквівалентний початковому вираз $398.7^{12} + 436.5^{12} \stackrel{?}{=} 447.2^{12}$.

Ми отримали нібито підтвердження рівності (і спростування твердження теореми Ферма), але реальні математичні значення чисел 398.7^{12} , 436.5^{12} , 447.2^{12} наступні

$$398.7^{12} = 16134474609751291283496491970515.151715346481$$

$$436.5^{12} = 47842181739947321332739738982639.336181640625$$

$$447.2^{12} = 63976656348486725806862358322168.575784124416$$

і можна переконатись, що

$$398.7^{12} + 436.5^{12} - 447.2^{12} = 1211886809373872630985.912112862690.$$

Занадто велика похибка, щоб її ігнорувати.

Повернемось до представлення чисел з плаваючою комою у стандарті IEEE-754 [16]. Числа з прикладу 398.7^{12} , 436.5^{12} , 447.2^{12} у форматі *float* матимуть наступний вигляд

$$398.7^{12} \rightarrow = (01110011\ 01001011\ 10100101\ 01001101)_2$$

$$436.5^{12} \rightarrow = (01110100\ 00010110\ 11110110\ 10011011)_2$$

$$447.2^{12} \rightarrow = (01110100\ 01001001\ 11011111\ 11101110)_2$$

Якщо тепер виконати зворотну конвертацію з двійкового коду до десяткової системи числення отримаємо

$$\text{float}(398.7^{12}) = 16134475104304292794275463168000.000000000000$$

$$\text{float}(436.5^{12}) = 47842180292230967173839872589824.000000000000$$

$$\text{float}(447.2^{12}) = 63976655396535259968115335757824.000000000000$$

Числа вже змінені та відрізняються від оригіналу.

Можна переконатись, що

$$\text{float}(398.7^{12}) + \text{float}(436.5^{12}) = \text{float}(447.2^{12})$$

Звідси і результат *true* роботи нашої програми з лістингу 3. Варто дуже обачливо ставитись до комп'ютерних обчислювальних експериментів у математиці.

Зазначимо, що для типу *double* відповідний результат буде *false*: більш висока точність не дає нам отримати некоректний результат. Але як ми побачимо далі, і тип *double* не є панацеєю від усіх проблем комп'ютерних обчислень.

Розглянемо далі приклад, запропонований З. Рампом [3] ще у 1988 році. Необхідно обрахувати значення виразу

$$f(x, y) = 333.75 \cdot y^6 + x^2 \cdot (11 \cdot x^2 y^2 - y^6 - 121 \cdot y^4 - 2) + 5.5 \cdot y^8 + 0.5 \cdot \frac{x}{y}$$

в точці (77617, 33096).

Задача виглядає досить простою. Якщо тимчасово не зважати на останній доданок $\frac{x}{2y}$ (який насправді і немає великого значення), та враховуючи, що $y = 33096$ парне число, то очевидним є той факт, що значення виразу

$$f(x, y) - \frac{x}{2y}$$

взагалі має бути цілим числом.

Для реалізації прикладу 3. Рампа скористаємось Python 3.x, оскільки в Python за замовчуванням реалізований механізм довгої арифметики, що дає змогу працювати з цілими числами довільної довжини. Також, важливо зазначити, що Python дає можливість дуже просто звертатись до великої кількості сторонніх спеціальних бібліотек для професійної роботи з комп'ютерними обчисленнями.

Лістинг 4.

```
x = 77617
y = 33096
print (333.75*y**6 + x**2 * (11*x**2*y**2 - y**6 - 121*y**4 - 2) + 5.5*y**8 + 0.5*x/y)
```

Результатом виконання наведеної в лістингу 4 програми буде значення 1180591620717411303424.0, хоча реально

$$f(77617, 33096) = -\frac{54767}{66192}.$$

Особливо цікавим з даному прикладі є не те, що комп'ютерні обрахунки є некоректними (це бачили вже не раз), а те, наскільки нестійким є цей результат. Збільшимо або зменшимо будь-яке число 77617 або 33096 бодай на одиницю, і комп'ютер стане рахувати ближче до реальності, принаймні порядки математичного та машинного результатів будуть значно більш співвідносні. Характерна проблема саме в точці (77617, 33096).

Пояснимо у чому особливість зазначеної точки. Відокремимо додатну та від'ємну частини виразу (як вже було сказано: останній доданок $0.5 \cdot x/y$ на коректність результату обчислення суттєво не впливає). Відділимо додатну та від'ємну частини виразу $f(x, y) - \frac{x}{2y}$, як це продемонстровано в лістингу 5.

Лістинг 5.

```
x = 77617
y = 33096
positive = 1335*y**6//4 + x**2*11*x**2*y**2 + 11*y**8//2
negative = x**2*y**6 + 121*x**2*y**4 + 2*x**2
print(positive, negative, sep="\n")
```

Отримаємо результат

```
positive = 7917112216566288664689761316426849984
negative = 7917112216566288664689761316426849986
```


Тобто в нашому прикладі $\text{positive} - \text{negative} = -2$, і тоді остаточний результат збігається з математичним. Діло у тому, що однією із головних проблем при роботі з числами з рухомою комою є операція віднімання, оскільки при відніманні близьких за значенням чисел значимі розряди можуть втрачатись, і результат у цьому випадку буде некоректним. Якщо ми змінимо в програмі один рядок, замінивши цілочисельне ділення ($//$) на звичайне ($/$), тобто

```
positive = (1335*y**6)/4+x**2*(11*x**2*y**2)+(11*y**8)/2,
```

результат вже буде дорівнювати

```
positive = 7917112216566288629721075632129966080.00
```

і різниця між значеннями `positive` та `negative` складатиме вже -34968685684296883906 . Якщо ж записати вираз для змінної `positive` в більш звичному для користувача Python форматі

```
positive = 1335/4*y**6 +x**2*(11*x**2*y**2)+11/2*y**8,
```

то результат буде вже

```
positive = 7917112216566289810312696349541269504.00
```

оскільки даються в знаки різні похибки округлень для різних арифметичних операцій (як ми вже зазначали у попередньому розділі: порядок операцій також має значення для точності обчислень). Різниця в цьому випадку між отриманим значенням `positive` і попереднім складатиме 1180591620717411303424 , а значення $\text{positive} - \text{negative} = 1145622935033114419518$. Коректно змінюємо послідовність виконання арифметичних операцій і одразу отримуємо похибки порядку 10^{21} .

Зазначимо, що в Python є можливість певною мірою нівелювати деякі проблеми, що виникають при обрахунках з числами з плаваючою комою – наприклад, використовуючи функціонал модуля *decimal* для контролю точності обчислень. З офіційною документацією щодо модуля *decimal* можна ознайомитись за посиланням [20]. Не вдаючись в зайві подробиці, зазначимо,

що модуль *decimal* (зокрема клас *Decimal*) дає можливість працювати з числами з плаваючою комою як із звичайними дробами.

При всьому вище сказаному, для прикладу 3. Рампа лише використання можливостей класу *Decimal* видається недостатнім. Пропускаючи декілька проміжних етапів дослідження, автор знайшов спосіб отримати коректний результат програмних обрахунків. Спосіб цей полягає у спільному використанні модулю *decimal* разом із застосуванням схеми скорочення множення (схеми Горнера), з метою скорочення кількості арифметичних операцій, так і збільшення точності обчислень. У цьому випадку ми маємо переписати вираз $f(x, y) - \frac{x}{2y}$ у вигляді

$$f(x, y) = y^2 \cdot \left(y^2 \cdot \left(y^2 \cdot (5.5 \cdot y^2 + (333.75 - x^2)) - 121 \cdot x^2 \right) + 11 \cdot x^4 \right) - 2 \cdot x^2.$$

Програмно реалізуємо описаний підхід (лістинг 6).

Лістинг 6.

```
from decimal import Decimal
x = 77617
y = 33096
x2 = Decimal(x)**2
y2 = Decimal(y)**2
y4 = y2**2
print(y2*(y2*(y2*(Decimal(5.5)*y2+(Decimal(333.75)-x2))-121*x2)+11*x2**2)-2*x2)
```

В результаті отримаємо очікуване значення -2.

Висновки до розділу 1

У першому розділі було розглянуто стандарт IEEE-754 та різні похибки комп'ютерних обчислень, пов'язані з представленням дійсних чисел. Також були представлені конкретні приклади парадоксальних результатів начебто простих обчислень, що пов'язані з обмеженістю пам'яті комп'ютера.

В результаті проведених експериментів та досліджень, можна зробити висновки, що в рідкісних випадках, навіть прості операції можуть призвести до великих похибок та непередбачуваних результатів. Що в свою чергу змушує звернути увагу на методи, що дозволяють зменшити частоту виникання таких помилок та спрогнозувати потенційне їх виникнення.

РОЗДІЛ 2. ПРОБЛЕМА СТІЙКОСТІ КОМП'ЮТЕРНИХ ОБЧИСЛЕНЬ (НА ПРИКЛАДІ ПОСЛІДОВНОСТІ МЮЛЛЕРА).

В попередньому розділі автором були розглянуті досить прості випадки некоректних комп'ютерних обчислень, що виникають при роботі з числами з плаваючою комою. Описані приклади можна назвати лінійними, оскільки причини виникнення особливостей обчислень стає очевидною навіть при побіжному аналізі, якщо взяти до уваги стандарт IEEE-754.

В даному розділі ми розглянемо досить складний випадок парадоксальності деяких висновків, що в нас виникнуть при дослідженні числової збіжності певної нелінійної рекурентної послідовності, відомої в літературі як послідовність Мюллера.

Для аналізу особливості поведінки програмних обчислень зазначеного об'єкту, нам вже недостатньо просто знання про стандарт представлення тих чи інших чисел в пам'яті комп'ютера. Також лише загальних відомостей про точки стійкості-нестійкості (як в теорії диференціальних рівнянь) виявиться з теоретичної точки зору замало. Ми будемо вимушені залучити потужний математичний апарат для розуміння тих нетривіальних проблем, що можуть виникати при програмній реалізації досить нескладної на перший погляд математичної задачі.

2.1. Постановка задачі.

Розглянемо математичний об'єкт, що був наведений назвемо послідовністю Ж.-М. Мюллером у фундаментальній роботі [4], присвяченій проблемі прикладних комп'ютерних обчислень. Це нелінійне неоднорідне рекурентне рівняння другого порядку, яку будемо називати просто послідовністю Мюллера

$$\begin{cases} u(n) = 111 - \frac{1130}{u(n-1)} + \frac{3000}{u(n-1) \cdot u(n-2)}, \\ u(0) = 2, u(1) = -4. \end{cases} \quad (2.1)$$

Реалізуємо просту програму на Python (лістинг 7).

Лістинг 7

```
u0 = 2
u1 = -4
for n in range(2, 31):
    un = 111 - 1130 / u1 + 3000 / u0 / u1
    u0 = u1
    u1 = un
    print("%.10f" % un)
```

Таблиця 1 Результати роботи програми для перших 30 значень послідовності відображені в таблиці 1 в стовпці «Python».

n	Математичний результат	Python
0	2	2.0000000000
1	-4	-4.0000000000
2	37/2	18.5000000000
3	347 / 37	9.3783783784
4	2707 / 347	7.8011527378
5	19367 / 2707	7.1544144810
6	131827 / 19367	6.8067847369
7	869087 / 131827	6.5926327687
8	5605147 / 869087	6.4494659338
9	35584007 / 5605147	6.3484520567
10	223269667 / 35584007	6.2744385982
11	1388446127 / 223269667	6.2186957398
12	8574817387 / 1388446127	6.1758373049
13	52669607447 / 8574817387	6.1423590812
14	322121160307 / 52669607447	6.1158830666
15	1963244539967 / 322121160307	6.0947394393
16	11932055130427 / 1963244539967	6.0777223048
17	72355270235687 / 11932055130427	6.0639403225
18	437946318679747 / 72355270235687	6.0527217610
19	2646751398406607 / 437946318679747	6.0435521102
20	15975875822080267 / 2646751398406607	6.0360318811
21	96332092090684727 / 15975875822080267	6.0298473250
22	580376738335123987 / 96332092090684727	6.0247496524
23	3494181358965822047 / 580376738335123987	6.0205399841
24	21024692798570322907 / 3494181358965822047	6.0170582573
25	126446180015298890567 / 21024692798570322907	6.0141749146
26	760167196211178109027 / 126446180015298890567	6.0117845879
27	4568453757863992482287 / 760167196211178109027	6.0098012393
28	27447975450168574034347 / 4568453757863992482287	6.0081543789
29	164874117215934539909207 / 27447975450168574034347	6.0067860930
30	990176025870222717970867 / 164874117215934539909207	6.0056486888

Другий та третій стовпці таблиці 1 демонструють контрольні результати математичних обчислень у вигляді звичайних дробів (третій стовпчик – їх раціональне наближення з прийнятою в програмі точністю в 10 знаків після коми).

Аналізуючи дані таблиці 1, можна зробити висновок, що до 13 члену послідовності математичні та програмні результати добре співвідносяться, а починаючи з 14 члену поступово розбігаються в різні сторони: аналітичні результати при збільшені n будуть прямувати до значення 6, тоді як програмні обрахунки так само при збільшені n застигнуть на значенні 100.

Некоректність комп'ютерних обчислень вже не є для нас дивиною: перший розділ представленої роботи був цілком присвячений демонстрації різних класичних аспектів даної проблеми. Послідовність Мюллера являє собою своєрідний унікальний об'єкт, оскільки мають місце наступні оригінальні аспекти програмних обрахунків:

- 1) Зазначена послідовність (2.1) в залежності від початкових значень може як розбігатись, так і збігатись до одного з трьох значень: 5, 6 та 100. Тому некоректна збіжність (2.1) при заданих початкових значеннях не викличе підозру, і буде здаватись, що ми отримали цілком прийнятний результат.
- 2) Некоректна збіжність до числа 100 спостерігається не для будь-яких початкових значень, а лише за наявності конкретної залежності $u(1) = 11 - \frac{30}{u(0)}$ ($u(0) = 2$, $u(1) = -4$ як раз такий випадок).
- 3) Якби б ми зупинили наші програмні обчислення на 7-16 кроці, ми б отримали більш-менш коректний результат з відповідною відносною похибкою в найгіршому випадку біля 10 %. Це забагато, але значно краще, ніж ситуація, що розгортається при $n > 16$. Має місце цікавий парадокс обчислень: чим більше членів послідовності ми враховуємо, тим менш точний ми отримуємо результат. З одного боку – це класична проблема стійкої-нестійкої точки в процесі збіжності обчислень. Але з іншого боку природа цієї нестійкості поки що залишається невідомою.

Подібний випадок нестійкості комп'ютерних обчислень заслуговує додаткового математичного дослідження.

Щодо програмної реалізації, то Python дає нам можливість отримати коректний результат обчислення, навіть поки ще не розуміючи причино-наслідкових зав'язків означеної проблеми.

Аналогічно тому, як в розділі 1 для контролю точності ми підключали модуль *decimal*, так для задачі коректного обчислення значень рекурентної послідовності (2.1) нам потрібний функціонал модуля *fraction* [21] для роботи із раціональними числами.

Лістинг 8

```
from fractions import Fraction
u0 = Fraction(2)
u1 = Fraction(-4)
for n in range(2, 31):
    un = 111 - 1130 / u1 + 3000 / u0 / u1
    u0 = u1
    u1 = un
    print("%.10f" % un)
```

В даному випадку отримані результати будуть співпадати із даними третього стовпця таблиці 1.

На перспективу можна мати на увазі можливість сторонньої бібліотеки *mpmath* [22], що містить зокрема механізми роботи з інтервальною арифметикою. Але в конкретному випадку використання можливостей *mpmath* не дасть суттєвих результатів.

2.2. Математичне дослідження проблеми.

Проблемі парадоксу Мюллера присвячена досить обмежена кількість наукових джерел. Автор [23] зачіпає різні аспекти питання, але вичерпного дослідження причин обчислювальної нестійкості (2.1), та й подібних рекурентних послідовностей більш загального вигляду, автор не зустрічав. Спробуємо побудувати наочну обчислювальну схему, а не лише обмежуватись констатацією, що точка 100 для (2.1) є стійкою, а 6 – нестійкою.

В роботі пропонується алгебраїчний підхід до побудови замкнутого вигляду розв'язку послідовності (2.1).

Розглянемо вираз

$$\begin{cases} u(n+2) = A + \frac{B}{u(n+1)} + \frac{C}{u(n+1) \cdot u(n)}, \\ u(0) = x, u(1) = y. \end{cases} \quad (2.2)$$

Для зручності введемо до розгляду числа z_1, z_2, z_3 , що задовольняють співвідношенням

$$\begin{aligned} A &= z_1 + z_2 + z_3 \\ B &= -z_1 z_2 - z_1 z_3 - z_2 z_3 \\ C &= z_1 z_2 z_3 \end{aligned} \quad (2.3)$$

Таким чином z_1, z_2, z_3 є коренями характеристичного рівняння

$$z^3 - Az^2 - Bz - C = 0.$$

Приклад (2.1) відповідає набору умов $z_1, z_2, z_3 \in \mathbb{R}$ та $|z_1| < |z_2| < |z_3|$. В подальшому в роботі ми обмежимося розглядом лише вказаного випадку.

Пропускаючи деякі проміжні кроки, позначимо

$$Q_n = \frac{z_3^{n+2}}{(z_3 - z_2)(z_3 - z_1)(z_2 - z_1)} \cdot \left[x \cdot \left(y \cdot \left(z_2 - z_1 - \left(\frac{z_2}{z_3} \right)^{n+2} \cdot (z_3 - z_1) + \left(\frac{z_1}{z_3} \right)^{n+2} \cdot (z_3 - z_2) \right) - \right.$$

$$\begin{aligned}
& - \left(z_2^2 - z_1^2 - \left(\frac{z_2}{z_3} \right)^{n+2} \cdot (z_3^2 - z_1^2) + \left(\frac{z_1}{z_3} \right)^{n+2} \cdot (z_3^2 - z_2^2) \right) + \\
& + z_1 z_2 \cdot (z_2 - z_1) - \left(\frac{z_2}{z_3} \right)^{n+2} \cdot z_1 z_3 \cdot (z_3 - z_1) + \left(\frac{z_1}{z_3} \right)^{n+2} \cdot z_2 z_3 \cdot (z_3 - z_2) \Big]
\end{aligned}$$

Припустимо далі, що розв'язок (2.2) у замкнутому вигляді має вид

$$\begin{cases} u(0) = x, \quad u(1) = y, \\ u(k+2) = \frac{Q_{k+1}}{Q_k}, \quad k = \overline{0, \infty} \end{cases} \quad (2.4)$$

Для зручності подальших перетворень, введемо наступні векторні позначення

$$\begin{cases} \vec{a}^{(n)} = \left(z_2 - z_1; -(z_3 - z_1) \cdot \left(\frac{z_2}{z_3} \right)^{n+2}; (z_3 - z_2) \cdot \left(\frac{z_1}{z_3} \right)^{n+2} \right), \\ \vec{\lambda}_1 = (1; 1; 1), \vec{\lambda}_2 = (z_2 + z_1; z_3 + z_1; z_3 + z_2), \vec{\lambda}_3 = (z_1 z_2; z_1 z_3; z_2 z_3). \end{cases}$$

Тоді можемо записати

$$Q_n = \frac{z_3^{n+2}}{(z_3 - z_2)(z_3 - z_1)(z_2 - z_1)} \cdot \left\langle \vec{a}^{(n)}, x \cdot y \cdot \vec{\lambda}_1 - x \cdot \vec{\lambda}_2 + \vec{\lambda}_3 \right\rangle, \quad (2.5)$$

де $\langle \cdot \rangle$ розуміємо у сенсі скалярного добутку векторів.

Доведемо, що система (2.4) у позначеннях (2.5) є замкнутим розв'язком (2.2) при вказаних вище обмеженнях. Доведення здійснімо методом математичної індукції.

Доведення.

Перевіримо, чи є справедливим (2.4) при $k = 0$. Маємо наступний вираз

$$x_2 = \frac{Q_1}{Q_0} = \frac{\frac{z_3^3}{(z_3 - z_2)(z_3 - z_1)(z_2 - z_1)} \cdot \left(\vec{a}^{(1)}, x \cdot y \cdot \vec{\lambda}_1 - x \cdot \vec{\lambda}_2 + \vec{\lambda}_3 \right)}{\frac{z_3^2}{(z_3 - z_2)(z_3 - z_1)(z_2 - z_1)} \cdot \left(\vec{a}^{(0)}, x \cdot y \cdot \vec{\lambda}_1 - x \cdot \vec{\lambda}_2 + \vec{\lambda}_3 \right)},$$

або після всіх необхідних перетворень можна записати

$$x_2 = z_3 \cdot \frac{x \cdot y \cdot \left(z_1^3 z_3 + z_1 z_2^3 + z_2 z_3^3 - z_1^3 z_2 - z_1 z_3^3 - z_2^3 z_3 \right) + x \cdot \left(z_1^3 z_3^2 + z_1^2 z_2^3 + z_2^2 z_3^3 - z_1^3 z_2^2 - z_1^2 z_3^3 - z_2^3 z_3^2 \right) + z_1 z_2 z_3 \cdot \left(z_1^2 z_3 + z_1 z_2^2 + z_2 z_3^2 - z_1^2 z_2 - z_1 z_3^2 - z_2^2 z_3 \right)}{x \cdot y \cdot \left(z_1^2 z_3 + z_1 z_2^2 + z_2 z_3^2 - z_1^2 z_2 - z_1 z_3^2 - z_2^2 z_3 \right)}.$$

Розглянемо окремо вирази в дужках в чисельнику і знаменнику.

$$\begin{aligned}
& \underline{z_1^3 z_3 + z_1 z_2^3 + z_2 z_3^3 - z_1^3 z_2 - z_1 z_3^3 - z_2^3 z_3} = z_1 \cdot (z_1^2 z_3 + z_1 z_2^2 + z_2 z_3^2 - z_1^2 z_2 - z_1 z_3^2 - z_2^2 z_3) - \\
& - z_1^2 z_2^2 - z_1 z_2 z_3^2 + z_1^3 z_2 + z_1^2 z_3^2 + z_1 z_2^2 z_3 + z_1 z_2^3 + z_2 z_3^3 - z_1^3 z_2 - z_1 z_3^3 - z_2^3 z_3 = \\
& = z_1 \cdot (z_1^2 z_3 + z_1 z_2^2 + z_2 z_3^2 - z_1^2 z_2 - z_1 z_3^2 - z_2^2 z_3) + z_2 \cdot (z_1^2 z_3 + z_1 z_2^2 + z_2 z_3^2 - z_1^2 z_2 - z_1 z_3^2 - z_2^2 z_3) - \\
& - z_1^2 z_2 z_3 - z_2^2 z_3^2 + z_1^2 z_2^2 + z_1 z_2 z_3^2 + z_2^3 z_3 - z_1^2 z_2^2 - z_1 z_2 z_3^2 + z_1^2 z_3^2 + z_1 z_2^2 z_3 + z_2 z_3^3 - z_1 z_3^3 - z_2^3 z_3 = \\
& = z_1 \cdot (z_1^2 z_3 + z_1 z_2^2 + z_2 z_3^2 - z_1^2 z_2 - z_1 z_3^2 - z_2^2 z_3) + z_2 \cdot (z_1^2 z_3 + z_1 z_2^2 + z_2 z_3^2 - z_1^2 z_2 - z_1 z_3^2 - z_2^2 z_3) + \\
& + z_3 \cdot (z_1^2 z_3 + z_1 z_2^2 + z_2 z_3^2 - z_1^2 z_2 - z_1 z_3^2 - z_2^2 z_3) = \underline{(z_1 + z_2 + z_3) \cdot (z_1^2 z_3 + z_1 z_2^2 + z_2 z_3^2 - z_1^2 z_2 - z_1 z_3^2 - z_2^2 z_3)}.
\end{aligned}$$

Так само,

$$\begin{aligned}
& \underline{z_1^3 z_2^2 + z_1^2 z_2^3 + z_2^2 z_3^3 - z_1^3 z_2^2 - z_1^2 z_3^3 - z_2^3 z_3^2} = \\
& = z_1 z_2 \cdot (z_1^2 z_3 + z_1 z_2^2 + z_2 z_3^2 - z_1^2 z_2 - z_1 z_3^2 - z_2^2 z_3) - \\
& - z_1^3 z_2 z_3 - z_1 z_2^2 z_3^2 + z_1^2 z_2 z_3^2 + z_1 z_2^2 z_3 + z_1^3 z_2^2 + z_2^2 z_3^3 - z_1^2 z_3^3 - z_2^3 z_3^2 = \\
& = z_1 z_2 \cdot (z_1^2 z_3 + z_1 z_2^2 + z_2 z_3^2 - z_1^2 z_2 - z_1 z_3^2 - z_2^2 z_3) + z_1 z_3 \cdot (z_1^2 z_3 + z_1 z_2^2 + z_2 z_3^2 - z_1^2 z_2 - z_1 z_3^2 - z_2^2 z_3) - \\
& - z_1^2 z_2^2 z_3 - z_1 z_2 z_3^3 - z_1 z_2^2 z_3^2 + z_1^2 z_2 z_3^2 + z_1 z_2^2 z_3 + z_2^2 z_3^3 - z_2^3 z_3^2 = \\
& = z_1 z_2 \cdot (z_1^2 z_3 + z_1 z_2^2 + z_2 z_3^2 - z_1^2 z_2 - z_1 z_3^2 - z_2^2 z_3) + z_1 z_3 \cdot (z_1^2 z_3 + z_1 z_2^2 + z_2 z_3^2 - z_1^2 z_2 - z_1 z_3^2 - z_2^2 z_3) + \\
& + z_2 z_3 \cdot (z_1^2 z_3 + z_1 z_2^2 + z_2 z_3^2 - z_1^2 z_2 - z_1 z_3^2 - z_2^2 z_3) = \\
& = \underline{(z_1 z_2 + z_1 z_3 + z_2 z_3) \cdot (z_1^2 z_3 + z_1 z_2^2 + z_2 z_3^2 - z_1^2 z_2 - z_1 z_3^2 - z_2^2 z_3)}
\end{aligned}$$

В кінці кінців

$$x_2 = z_3 \cdot \frac{(x \cdot y \cdot (z_1 + z_2 + z_3) + x \cdot (z_1 z_2 + z_1 z_3 + z_2 z_3) + z_1 z_2 z_3) \cdot (z_1^2 z_3 + z_1 z_2^2 + z_2 z_3^2 - z_1^2 z_2 - z_1 z_3^2 - z_2^2 z_3)}{z_3^3},$$

тобто

$$x_2 = \frac{x \cdot y \cdot (z_1 + z_2 + z_3) + x \cdot (z_1 z_2 + z_1 z_3 + z_2 z_3) + z_1 z_2 z_3}{x \cdot y},$$

що відповідає дійсності.

Припустимо, для $k = n$ має місце $u(n+2) = \frac{Q_{n+1}}{Q_n}$.

Розглянемо випадок $k = n+1$, тобто вираз

$$\begin{aligned}
u(n+3) &= A + \frac{B}{u(n+2)} + \frac{C}{u(n+1) \cdot u(n+2)} = \frac{A \cdot u(n+1) \cdot u(n+2) + B \cdot u(n+1) + C}{u(n+1) \cdot u(n+2)} = \\
&= \frac{A \cdot \frac{Q_n}{Q_{n-1}} \frac{Q_{n+1}}{Q_n} + B \cdot \frac{Q_n}{Q_{n-1}} + C}{\frac{Q_n}{Q_{n-1}} \frac{Q_{n+1}}{Q_n}} = \frac{A \cdot Q_{n+1} + B \cdot Q_n + C \cdot Q_{n-1}}{Q_{n+1}}.
\end{aligned}$$

Враховуючи позначення (2.3), можемо записати

$$\begin{aligned}
A \cdot Q_{k+1} + B \cdot Q_k + C \cdot Q_{k-1} &= (z_1 + z_2 + z_3) \cdot Q_{k+1} - (z_1 z_2 + z_1 z_3 + z_2 z_3) \cdot Q_k + z_1 z_2 z_3 \cdot Q_{k-1} = \\
&= \frac{z_3^{k+2}}{(z_3 - z_2)(z_3 - z_1)(z_2 - z_1)} \times \left[z_3 \cdot (z_1 + z_2 + z_3) \cdot \left(\overrightarrow{a^{(k+1)}}, x \cdot y \cdot \vec{\lambda}_1 - x \cdot \vec{\lambda}_2 + \vec{\lambda}_3 \right) - \right. \\
&\quad \left. - (z_1 z_2 + z_1 z_3 + z_2 z_3) \cdot \left(\overrightarrow{a^{(k)}}, x \cdot y \cdot \vec{\lambda}_1 - x \cdot \vec{\lambda}_2 + \vec{\lambda}_3 \right) + z_1 z_2 \cdot \left(\overrightarrow{a^{(k-1)}}, x \cdot y \cdot \vec{\lambda}_1 - x \cdot \vec{\lambda}_2 + \vec{\lambda}_3 \right) \right] = \\
&= \frac{z_3^{k+2}}{(z_3 - z_2)(z_3 - z_1)(z_2 - z_1)} \times \\
&\quad \times \left(z_3 \cdot (z_1 + z_2 + z_3) \cdot \overrightarrow{a^{(k+1)}} - (z_1 z_2 + z_1 z_3 + z_2 z_3) \cdot \overrightarrow{a^{(k)}} + z_1 z_2 \cdot \overrightarrow{a^{(k-1)}}, x \cdot y \cdot \vec{\lambda}_1 - x \cdot \vec{\lambda}_2 + \vec{\lambda}_3 \right)
\end{aligned}$$

Використавши тотожність

$$z_3 \cdot (z_1 + z_2 + z_3) \cdot \left(\frac{z_i}{z_3} \right)^2 - (z_1 z_2 + z_1 z_3 + z_2 z_3) \cdot \left(\frac{z_i}{z_3} \right) + z_1 z_2 = \frac{z_i^3}{z_3}, \quad i = \overline{1, 3}$$

отримаємо

$$Q_{k+2} = (z_1 + z_2 + z_3) \cdot Q_{k+1} - (z_1 z_2 + z_1 z_3 + z_2 z_3) \cdot Q_k + z_1 z_2 z_3 \cdot Q_{k-1}.$$

Таким чином, робимо висновок, що $u(n+3) = \frac{Q_{n+2}}{Q_{n+1}}$. Доведення завершено.

Ми підтвердили справедливість запропонованої нами формули (2.4)-(2.5).

Тоді, оскільки вірним є твердження, що

$$\lim_{n \rightarrow \infty} \frac{Q_n}{z_3^{n+2}} = \frac{x \cdot y - x \cdot (z_2 + z_1) + z_1 z_2}{(z_3 - z_2)(z_3 - z_1)},$$

можемо записати, що

$$\lim_{n \rightarrow \infty} \frac{Q_{n+1}}{Q_n} = \lim_{n \rightarrow \infty} u(n+2) = z_3$$

за умови, що $y \neq (z_2 + z_1) - \frac{z_1 z_2}{x}$.

Ось ми і отримали шукане значення початкового значення $y = (z_2 + z_1) - \frac{z_1 z_2}{x}$, що порушувало коректність обчислень. Прямою підстановкою зазначеного значення у в Q_n отримаємо

$$u(n+2) = z_2 \cdot \left(\frac{z_1}{z_2} + \frac{\left(\frac{z_1}{z_2} - 1 \right) \cdot (x - z_1)}{\left(\frac{z_1}{z_2} \right)^{n+1} \cdot (x - z_2) - x + z_1} \right),$$

тобто в свою чергу для випадку $y = (z_2 + z_1) - \frac{z_1 z_2}{x}$ матимемо $\lim_{n \rightarrow \infty} u(n+2) = z_2$.

Узагальнюючи, у випадку $z_1, z_2, z_3 \in \mathbb{R}$ та $|z_1| < |z_2| < |z_3|$ для (2.2) у разі збіжності можемо записати аналітичний розв'язок

$$\begin{cases} u(0) = u(1) = z_i, & u(n) \xrightarrow{n \rightarrow \infty} z_i \\ u(1) = z_1 + z_2 - \frac{z_1 \cdot z_2}{u(0)}, & u(n) \xrightarrow{n \rightarrow \infty} z_2 \\ u(0) = x, u(1) = y, & u(n) \xrightarrow{n \rightarrow \infty} z_3 \end{cases} \quad (2.6)$$

Повертаючись до конкретного прикладу (2.1), ми бачимо, що $z_1 = 5$, $z_2 = 6$, $z_3 = 100$ є коренями рівняння $z^3 - 111 \cdot z^2 + 1130 \cdot z - 3000 = 0$ і початкові значення $u(0) = 2$, $u(1) = -4$ відповідає другому випадку (2.6), і послідовність $u(n)$ має збігатись до значення $z_2 = 6$. Але по факту, виходячи вже з відомих нам особливостей організації процесу комп'ютерних обчислень, ми розуміємо, що значення виразу $x \cdot y - x \cdot (z_2 + z_1) + z_1 z_2$ в силу принципової похибки обчислень не буде строго дорівнювати 0 (якщо обраховувати в форматі float для Python або ж float чи double для C++), і відповідно вироджується до третього випадку збіжності з (2.6). Тому то ми і отримуємо в останньому стовпці таблиці 1 починаючи з двадцятого члена послідовності значення близькі до 100.

Залишилось останнє математичне питання – аналіз умов розбіжності рекурентної послідовності (2.2) за прийнятих нами умов умов $z_1, z_2, z_3 \in \mathbb{R}$ та $|z_1| < |z_2| < |z_3|$.

2.3. Збіжність рекурентної послідовності Мюллера.

Розглянемо рівняння $x(n+2)=0$, тобто

$$A + \frac{B}{x(n+1)} + \frac{C}{x(n+1) \cdot x(n)} = 0. \quad (2.7)$$

З (2.7) слідує, що якщо ввести позначення $B_1 = B/A$ та $C_1 = C/A$, отримаємо нелінійну рекурентну послідовність першого порядку

$$\begin{cases} x(n+1) = -B_1 - \frac{C_1}{x(n)}, \\ x(0) = x_0 \ (x_0 \neq 0). \end{cases} \quad (2.8)$$

Надалі будемо проводити дослідження (2.8) вже за відомою схемою. Розглянемо відповідне характеристичне рівняння – квадратне рівняння з коренями λ_1 та λ_2

$$\begin{cases} x^2 + B_1 \cdot x + C_1 = 0, \\ B_1 = -\lambda_1 - \lambda_2, \\ C_1 = \lambda_1 \cdot \lambda_2. \end{cases}$$

Розглянемо декілька перших членів рекурентної послідовності (2.8), групуючи в чисельнику та знаменнику відповідних дробів подібні доданки

$$x(1) = \frac{x_0 \cdot (\lambda_1 + \lambda_2) - \lambda_1 \cdot \lambda_2}{x_0},$$

$$x(2) = \frac{x_0 \cdot (\lambda_1^2 + \lambda_1 \cdot \lambda_2 + \lambda_2^2) - (\lambda_1^2 \cdot \lambda_2 + \lambda_1 \cdot \lambda_2^2)}{x_0 \cdot (\lambda_1 + \lambda_2) - \lambda_1 \cdot \lambda_2},$$

$$x(3) = \frac{x_0 \cdot (\lambda_1^3 + \lambda_1^2 \cdot \lambda_2 + \lambda_1 \cdot \lambda_2^2 + \lambda_2^3) - (\lambda_1^3 \cdot \lambda_2 + \lambda_1^2 \cdot \lambda_2^2 + \lambda_1 \cdot \lambda_2^3)}{x_0 \cdot (\lambda_1^2 + \lambda_1 \cdot \lambda_2 + \lambda_2^2) - (\lambda_1^2 \cdot \lambda_2 + \lambda_1 \cdot \lambda_2^2)},$$

$$x(4) = \frac{x_0 \cdot (\lambda_1^4 + \lambda_1^3 \cdot \lambda_2 + \lambda_1^2 \cdot \lambda_2^2 + \lambda_1 \cdot \lambda_2^3 + \lambda_2^4) - (\lambda_1^4 \cdot \lambda_2 + \lambda_1^3 \cdot \lambda_2^2 + \lambda_1^2 \cdot \lambda_2^3 + \lambda_1 \cdot \lambda_2^4)}{x_0 \cdot (\lambda_1^3 + \lambda_1^2 \cdot \lambda_2 + \lambda_1 \cdot \lambda_2^2 + \lambda_2^3) - (\lambda_1^3 \cdot \lambda_2 + \lambda_1^2 \cdot \lambda_2^2 + \lambda_1 \cdot \lambda_2^3)},$$

...

Винесемо в елементі послідовності $x(k)$ за дужки в першому доданку в чисельнику член λ_2^k (і так само у знаменнику елемент λ_2^{k-1}), а відповідно у

другому доданку винесемо за душки член $\lambda_1 \cdot \lambda_2^k$. Тоді, наприклад, для $x(4)$ будемо мати

$$\begin{aligned} x(4) &= \frac{x_0 \cdot \lambda_2^4 \cdot \left(\frac{\lambda_1^4}{\lambda_2^4} + \frac{\lambda_1^3}{\lambda_2^3} + \frac{\lambda_1^2}{\lambda_2^2} + \frac{\lambda_1}{\lambda_2} + 1 \right) - \lambda_1 \cdot \lambda_2^4 \cdot \left(\frac{\lambda_1^3}{\lambda_2^3} + \frac{\lambda_1^2}{\lambda_2^2} + \frac{\lambda_1}{\lambda_2} + 1 \right)}{x_0 \cdot \lambda_2^3 \cdot \left(\frac{\lambda_1^3}{\lambda_2^3} + \frac{\lambda_1^2}{\lambda_2^2} + \frac{\lambda_1}{\lambda_2} + 1 \right) - \lambda_1 \cdot \lambda_2^3 \cdot \left(\frac{\lambda_1^2}{\lambda_2^2} + \frac{\lambda_1}{\lambda_2} + 1 \right)} = \\ &= \lambda_2 \cdot \frac{x_0 \cdot \left(\frac{\lambda_1^4}{\lambda_2^4} + \frac{\lambda_1^3}{\lambda_2^3} + \frac{\lambda_1^2}{\lambda_2^2} + \frac{\lambda_1}{\lambda_2} + 1 \right) - \lambda_1 \cdot \left(\frac{\lambda_1^3}{\lambda_2^3} + \frac{\lambda_1^2}{\lambda_2^2} + \frac{\lambda_1}{\lambda_2} + 1 \right)}{x_0 \cdot \left(\frac{\lambda_1^3}{\lambda_2^3} + \frac{\lambda_1^2}{\lambda_2^2} + \frac{\lambda_1}{\lambda_2} + 1 \right) - \lambda_1 \cdot \left(\frac{\lambda_1^2}{\lambda_2^2} + \frac{\lambda_1}{\lambda_2} + 1 \right)}. \end{aligned}$$

Поки що ми не накладали жодних обмежень на значення коренів характеристичного рівняння λ_1 та λ_2 , але очевидно можливі два варіанти: $\lambda_1 \neq \lambda_2$ або $\lambda_1 = \lambda_2$.

Спочатку розглянемо випадок $\lambda_1 \neq \lambda_2$. Також будемо додатково вважати, що $|\lambda_1| < |\lambda_2|$.

Позначимо

$$P_k(\lambda_1, \lambda_2) = \frac{\lambda_2}{\lambda_2 - \lambda_1} \cdot \left(-x_0 \cdot \left(\left(\frac{\lambda_1}{\lambda_2} \right)^{k+1} - 1 \right) + \lambda_1 \cdot \left(\left(\frac{\lambda_1}{\lambda_2} \right)^k - 1 \right) \right). \quad (2.9)$$

Припустимо, що враховуючи (2.9), k член рекурентної послідовності (2.8) можна записати

$$x(k) = \frac{\lambda_2 \cdot P_k(\lambda_1, \lambda_2)}{P_{k-1}(\lambda_1, \lambda_2)}, \quad (2.10)$$

Або в явному вигляді

$$x(k) = \lambda_2 \cdot \frac{-x_0 \cdot \left(\left(\frac{\lambda_1}{\lambda_2} \right)^{k+1} - 1 \right) + \lambda_1 \cdot \left(\left(\frac{\lambda_1}{\lambda_2} \right)^k - 1 \right)}{-x_0 \cdot \left(\left(\frac{\lambda_1}{\lambda_2} \right)^k - 1 \right) + \lambda_1 \cdot \left(\left(\frac{\lambda_1}{\lambda_2} \right)^{k-1} - 1 \right)}.$$

Після спрощення

$$x(k) = \lambda_1 + \frac{\lambda_2 - \lambda_1}{1 - \left(\frac{\lambda_1}{\lambda_2} \right)^k \cdot \frac{x_0 - \lambda_2}{x_0 - \lambda_1}}. \quad (2.11)$$

З виразу (2.11) слідує, що ми маємо ще окремо розглянути два випадки, початкового значення x_0 , коли $x_0 = \lambda_1$ або

$$x_0 = \lambda_2 \cdot \frac{1 - \left(\frac{\lambda_2}{\lambda_1}\right)^{k-1}}{1 - \left(\frac{\lambda_2}{\lambda_1}\right)^k}.$$

Пряма підстановка в (2.8) показує, що при $x_0 = \lambda_1$ значення $x(k)$ стає дорівнювати λ_1 для будь-якого k . А за початкового значення

$$x_0 = \lambda_2 \cdot \frac{1 - \left(\frac{\lambda_2}{\lambda_1}\right)^{k-1}}{1 - \left(\frac{\lambda_2}{\lambda_1}\right)^k}$$

при $k \in \mathbb{N}$ виникне проблема ділення на нуль на k кроці, оскільки $x(k-1) = 0$.

Вираз (2.11) є розв'язком рекурентного рівняння (2.8) за умови $\lambda_1 \neq \lambda_2$. Доведення цього факту здійснюється методом математичної індукції, як це було продемонстровано у розділі 2.2.

У випадку $\lambda_1 = \lambda_2$ розв'язком (2.11) очевидно буде вираз

$$x(k) = \lambda_2 \cdot \left(1 + \frac{x_0 - \lambda_2}{x_0 \cdot k - \lambda_2 \cdot (k-1)}\right). \quad (2.12)$$

Доведення коректності формули (2.12) здійснюється аналогічно розглянутим раніше випадкам. Якщо при цьому $x_0 = \lambda_2 \cdot \left(1 - \frac{1}{k}\right)$ також при натуральному $k > 1$ виникне проблема ділення на нуль на k кроці, оскільки $x(k-1) = 0$.

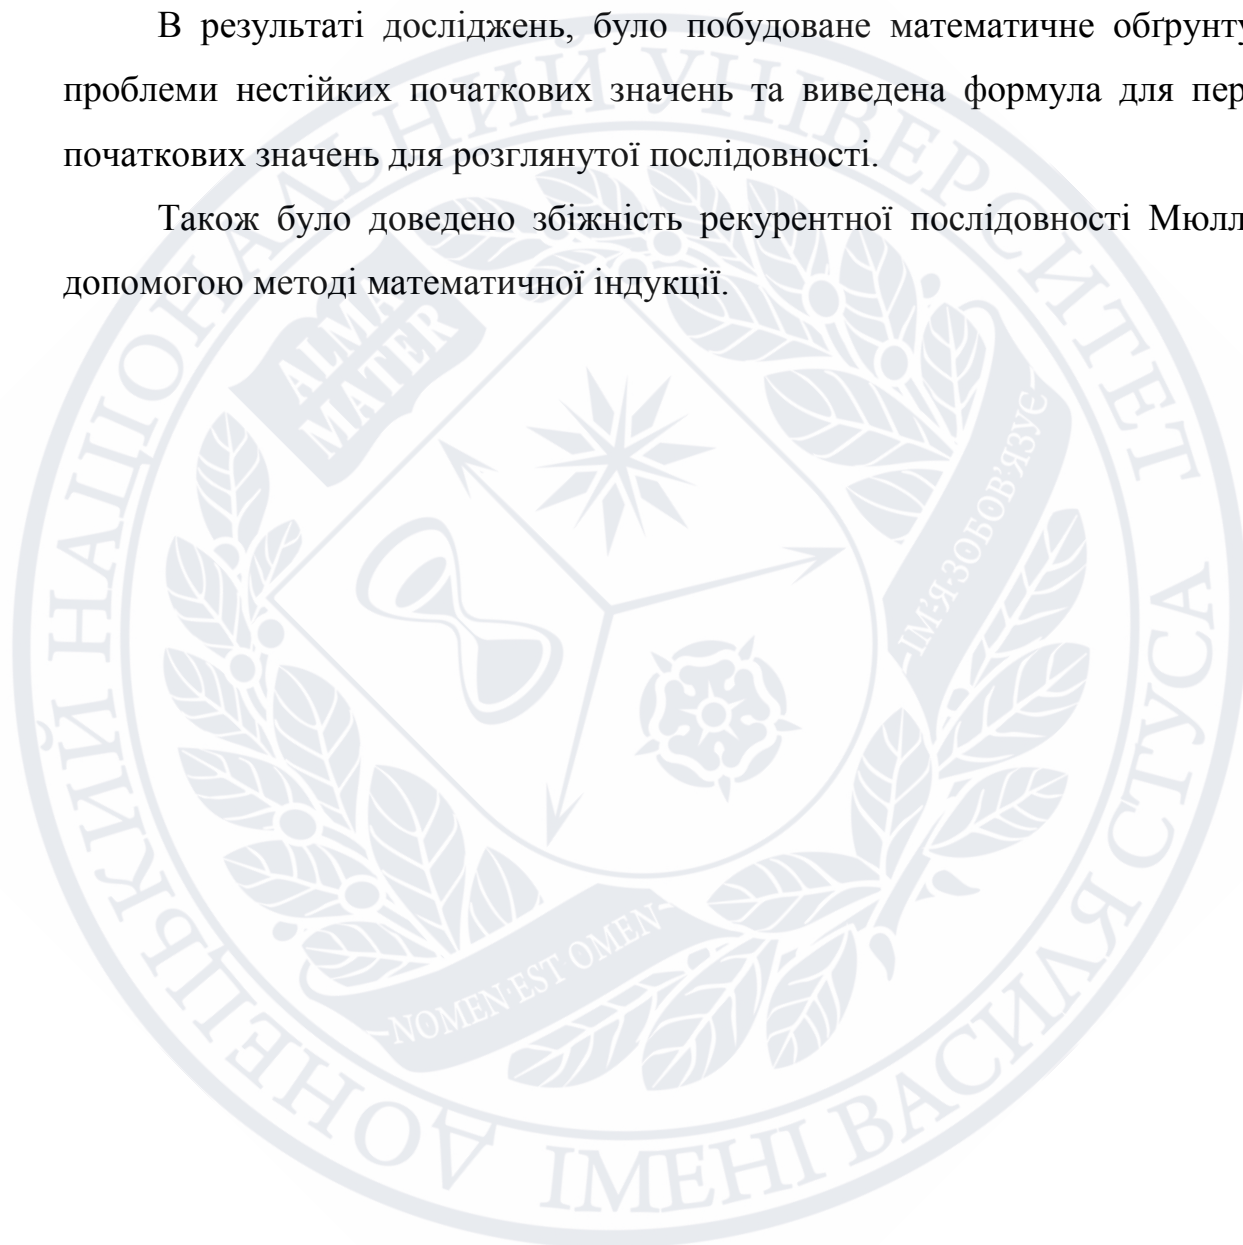
Залишається лише зазначити, що λ_1 та λ_2 обраховуються відносно значень $B_1 = B/A$ та $C_1 = C/A$, при цьому A, B, C визначаються відповідно до формул (2.3). Для подальших досліджень може виявитись доречним виразити значення λ_1 та λ_2 через z_1, z_2, z_3 .

Висновки до розділу 2

У цьому розділі була досліджена рекурентна послідовність Мюллера другого порядку. За розглянутим вище, можна бути впевненим, що хоч досліджувана послідовність збігається при комп'ютерних обчисленнях членів послідовності виникає суттєва похибка.

В результаті досліджень, було побудоване математичне обґрунтування проблеми нестійких початкових значень та виведена формула для перевірки початкових значень для розглянутої послідовності.

Також було доведено збіжність рекурентної послідовності Мюллера за допомогою методу математичної індукції.



ВИСНОВКИ

В роботі були представлені результати дослідження автора, пов'язані із аналізом проблематики достовірності комп'ютерних обчислень, їх стійкості та збіжності. Були продемонстровані відповідні приклади некоректної роботи програм: як зовсім прості, так і значно менш очевидні, як то приклад 3. Рампа та послідовність Мюллера.

Для послідовності Мюллера автором вперше було побудоване математичне обґрунтування проблеми нестійких початкових значень, коли ми наперед знаємо, до якого числа має збігатись значення членів послідовності, але стандартними методами комп'ютерних обчислень ми завжди в цьому випадку отримуємо некоректний результат.

Окрім математичних викладок, автор акцентував увагу на суто програмних можливостях контролю за точністю складних обчислень. З цією метою були наведені приклади ефективного використання функціоналу модулів *decimal* та *fraction* в Python 3.x, що допомагають певною мірою зменшити проблему коректності програмних обрахунків. Зазначимо, що обмежений обсяг роботи не дав змоги розглянути додатково спеціальні модулі для проведення складних обрахунків в Python *numpy* та *mpmath*, функціонал яких також заслуговує на увагу в контексті означеної проблеми.

В перспективі, автор вважає доречним продовжити дослідження особливостей стійкості обчислень послідовності Мюллера у випадку однакових та комплексних коренів характеристичного рівняння, більше уваги приділивши проблемі розбіжності рекурентної послідовності. Також в майбутньому актуальним було б узагальнення результатів дослідження на нелінійні рекурентної послідовності вищих порядків.

СПИСОК ВИКОРИСТАНОЇ ЛІТЕРАТУРИ

1. Кулиш У. Достоверные вычисления. Базовые численные методы / У. Кулиш, Д. Рац, Р. Хаммер, М. Хокс // Москва-Ижевск: НИЦ «Регулярная и хаотическая динамика», 2005. – 496 с.
2. Patriot Missile Defense: Software Problem Led to System Failure at Dhahran, Saudi Arabia: IMTEC-92-26 / A report of the General Accounting office, GAO/IMTEC-92-261992, 1992.
URL: <https://www.gao.gov/assets/220/215614.pdf>
3. Rump S.M. Algorithms for Verified Inclusions: Theory and Practice / S.M. Rump // Reliability in Computing: the Role of Interval Methods in Scientific Computing. – 1988. – S. 109-126. URL: <https://doi.org/10.15480/882.316>
4. Muller J.-M. Handbook of Floating-Point Arithmetic / J.-M. Muller, N. Brisebarre, F. de Dinechin, C.-P. Jeannerod etc. // Birkhäuser Basel, 2018. – 627 p. URL: <https://doi.org/10.1007/978-3-319-76526-6>
5. Андерсон Дж. А. Дискретная математика и комбинаторика / Дж. А. Андерсон // Москва: Вильямс, 2004. – 960 с.
6. Andrica D. Recurrent Sequences: Key Results, Applications, and Problems / D. Andrica, O. Bagdasar // Springer, 2020. – 410 p.
URL: <https://doi.org/10.1007/978-3-030-51502-7>
7. Greene D.H. Mathematics for the Analysis of Algorithms / D.H. Greene, D.E. Knuth // Birkhauser, 1981. – 107 p.
8. Hengkrawita C. Solutions of a class of nonlinear recursive equations and applications / C. Hengkrawita, V. Laohakosolb, W. Pimsert // Science Asia. – 2011. – No 37. – PP. 136-144. URL: <https://doi.org/10.2306/scienceasia1513-1874.2011.37.136>
9. Rabinovich S. Solving nonlinear recursions / S. Rabinovich, G. Berkolaiko, S. Havlin // J. Math. Phys. – 1996. – 37, No. 11. – PP. 5828-2836
10. Вепринцев Р.А. Об одной нелинейной рекуррентной последовательности третьего порядка / Р.А. Вепринцев // Известия Тульского государственного Университета. Естественные науки. – 2012. – Вып. 2. – С. 20-38.

11. Білоус Р. Дослідження стійкості комп'ютерних обчислень деяких рекурентних послідовностей другого порядку / Р. Білоус // Конференція молодих учених «Підстригачівські читання – 2020», Львів. – 2020.
URL: <http://www.iapmm.lviv.ua/chyt2020/abstracts/Bilous2.pdf>
12. Bilous R.V. Some problems of difference equations computer calculations / R.V. Bilous, B.Y. Varer // Book of Abstracts 6th Ya.B. Lopatynsky International School-Workshop on Differential Equations and Applications (18-20 June, 2019, Vinnytsia, Ukraine). – 2019. – Pp. 24-25.
13. Білоус Р.В. Точність та принципові обмеження комп'ютерних обчислень засобами мов програмування / Р.В. Білоус, Б.Ю. Варер // Міжнародна наукова інтернет-конференція "Інформаційне суспільство: технологічні, економічні та технічні аспекти становлення" (2 квітня 2019 року). – Вип. 37. – 2019. URL: <http://www.konferenciaonline.org.ua/arhiv-konferency/arhiv-konferency02-04-2019>
14. Білоус Р. Проблема коректності комп'ютерних обчислень при підготовці майбутніх фахівців галузі IT / Р. Білоус, О. Ветров // Heritage of european science: engineering and technology, informatics, security, transport, architecture. Monographic series «European Science». Book 2. Part 3. 2020. – С. 81-96. DOI: 10.30888/978-3-9821783-5-6.2020-02-03-019.
URL: <https://www.sworld.com.ua/simpge2/sge2-03.pdf>
15. Електронний ресурс URL: <https://0.300000000000000004.com/>
16. IEEE Standard for Floating-Point Arithmetic URL: <https://irem.univ-reunion.fr/IMG/pdf/ieee-754-2008.pdf>
17. Джерело картинки URL: <https://www.dailymail.co.uk/sciencetech/article-2975606/Did-Homer-Simpson-discover-HIGGS-BOSON-Maths-1998-episode-predicts-particle-s-mass-14-years-CERN.html>
18. Джерело картинки URL: <https://ew.com/tv/2018/10/19/the-simpsons-homer-cubed-treehouse-of-horror-vi/>
19. Singh S. The Simpsons and Their Mathematical Secrets / S. Singh // Bloomsbury USA, 2013. – 272 p. ISBN-10: 1620402777

- 20.Електронний ресурс URL: <https://docs.python.org/3/library/decimal.html>
- 21.Електронний ресурс URL: <https://docs.python.org/3/library/fractions.html>
- 22.Електронний ресурс URL: <https://mpmath.org/>
- 23.Kahan W. How futile are mindless assessments of round off in floating-point computation? / W. Kahan // 2006. – 56 p.
URL <http://http.cs.berkeley.edu/~wkahan/Mindless.pdf>

