

Přesnost výpočtů

Jan Faigl

Katedra počítačů
Fakulta elektrotechnická
České vysoké učení technické v Praze

Přednáška 12

B0B36PRP – Procedurální programování

Přehled témat

- Část 1 – Typové konverze
Typové konverze

S. G. Kochan: kapitola 14 (typové konverze)

- Část 2 – Přesnost výpočtů
Přesnost výpočtů a numerická stability
Příklad použití knihovny gmp

- Část 3 – Implementace bonusového úlohy HW10B
Domácí úkol HW10B

- Část 4 – Rychlost výpočtů (volitelně)

Maticové násobení
Rychlost výpočtu
Comparing C to Machine Code
Paralelní výpočet

Typové konverze

Část I

Část 1 – Typové konverze

Přiřazovací operátor a příkaz

- Slouží pro nastavení hodnoty proměnné.

Uložení číselné hodnoty do paměti, kterou proměnná reprezentuje.

- Tvar přiřazovacího operátoru.

⟨proměnná⟩ = ⟨výraz⟩

Výraz je literál, proměnná, volání funkce, ...

- Zkrácený zápis

⟨proměnná⟩ ⟨operátor⟩ = ⟨výraz⟩


- Přiřazení je výraz asociativní zprava.

- Přiřazovací příkaz – výraz zakončený středníkem ;

```
1 int x; //definice promenne x      1 int x, y; //definice promennych x a y
2 int y; //definice promenne y      3 x = 10;
4 x = 6;                             4 y = 7;
5 y = x = x + 6;                    6 y += x + 10;
```

Konverze primitivních číselných typů

- Primitivní datové typy jsou vzájemně nekompatibilní, ale jejich hodnoty lze převádět.



Typové konverze

- Typová konverze je operace převedení hodnoty nějakého typu na hodnotu typu jiného.
- Typová konverze může být
 - implicitní – vyvolá se automaticky;
 - explicitní – je nutné v programu explicitně uvést.

- Konverze typu **int** na **double** je implicitní.

Hodnota typu **int** může být použita ve výrazu, kde se očekává hodnota typu **double**, dojde k automatickému převodu na hodnotu typu **double**.

Příklad

```
1 double x;
2 int i = 1;
4 x = i; // hodnota 1 typu int se automaticky převede
5       // na hodnotu 1.0 typu double
```

- Implicitní konverze je bezpečná.

Matematické funkce

- <math.h> – základní funkce pro práci s „reálnými“ čísly.
 - Výpočet odmocniny neceleho čísla x.
double sqrt(double x);, float sqrtf(float x);
V C funkce nepřetěžujeme, proto jsou jména odlišena.
 - double pow(double x, double y); – výpočet obecné mocniny.
 - double atan2(double y, double x); – výpočet arctan y/x s určením kvadrantu.
 - Symbolické konstanty – M_PI, M_PI_2, M_PI_4, atd.
 - #define M_PI 3.14159265358979323846
 - #define M_PI_2 1.57079632679489661923
 - #define M_PI_4 0.78539816339744830962
 - isfinite(), isnan(), isless(), ... – makra pro porovnání reálných čísel.
 - round(), ceil(), floor() – zaokrouhlování, převod na celá čísla.
- <complex.h> – funkce pro počítání s komplexními čísly. ISO C99
- <fenv.h> – funkce pro řízení zaokrouhlování a reprezentaci dle IEEE 754. man math

Explicitní typové konverze

- Převod hodnoty typu **double** na **int** je třeba **explicitně** předeepsat.
- Dojde k „odseknutí“ necelé části hodnoty **int**.

Příklad

```
1 double x = 1.2; // definice proměnné typu double
2 int i;          // definice proměnné typu int
3 int i = (int)x; // hodnota 1.2 typu double se převede
4               // na hodnotu 1 typu int
```

- Explicitní konverze je potenciálně nebezpečná.

Příklady

```
1 double d = 1e30;                1 long l = 5000000000L;
2 int i = (int)d;                  2 int i = (int)l;
4 // i je -2147483648              4 // i je 705032704
5 // to je asi -2e9 místo 1e30     5 // (oříznuté 4 bajty)
                                   lec12/demo-type_conversion.c
```

Část II

Část 2 – Přesnost výpočtu

Přesnost výpočtů	Knihovna gmp
Přesnost výpočtu - Příklad dělení dvou čísel	
<pre>1 #include <stdio.h> 2 int main(void) 3 { 4 const int number = 100; 5 double dV = 0.0; 6 float fV = 0.0f; 7 for (int i = 0; i < number; ++i) { 8 dV += 1.0 / 10.0; 9 fV += 1.0 / 10.0; 10 } 11 printf("double value: %lf ", dV); 12 printf(" float value: %lf ", fV); 13 return 0; 14 } 15 clang division.c && ./a.out 16 double value: 10.000000 float value: 10.000002</pre>	
lec12/division.c	

Jan Faigl, 2025	BOB36PRP – Přednáška 12: Přesnost výpočtů	12 / 45
-----------------	---	---------

Podmíněnost numerických úloh

- Podmíněnost úlohy $C_p = \frac{\text{relativní chyba výstupních údajů}}{\text{relativní chyba vstupních údajů}}$.
- Dobře podmíněná úloha $C_p \approx 1$.
- Výpočet je dobře podmíněný, je-li málo citlivý na poruchy ve vstupních datech.
- Numericky stabilní výpočet - vliv zaokrouhlovacích chyb na výsledek je malý.
- Výpočet je stabilní, je-li dobře podmíněný a numericky stabilní.

Přesnost výpočtů	Knihovna gmp
Součin dvou velkých čísel knihovnou gmp - 2/2	
<pre>1 #include <stdio.h> 2 #include <stdlib.h> 3 #include <gmp.h> 4 const char* resultSrc = 5 "932865073719992059629773513614789388266580305083" 6 "920691925740371392254317064584855785088915745761" 7 ; 8 int main(int argc, char *argv[]) 9 { 10 int ret = EXIT_SUCCESS; 11 mpz_t n1, n2, result; 12 mpz_init_set_str(n1, "995663", 10); 13 mpz_init_set_str(n2, "995669", 10); 14 mpz_init(result); 15 gmp_printf("n1: %Zd\n", n1); 16 gmp_printf("n2: %Zd\n", n2); 17 gmp_printf("%Zd*%Zd=%Zd\n", n1, n2, 8) 18 ; 19 mpz_pow_ui(n1, n1, 8); 20 mpz_pow_ui(n2, n2, 8);</pre>	
lec12/gmp/demo-gmp-mpz.c	

Jan Faigl, 2025	BOB36PRP – Přednáška 12: Přesnost výpočtů	19 / 45
-----------------	---	---------

Přesnost výpočtů	Knihovna gmp
Přesnost výpočtu - strojová přesnost	
- Strojová přesnost ϵ_m - nejmenší desetinné číslo, které přičtením k 1.0 dává výsledek různý od 1, pro $v < \epsilon_m$, platí$v + 1.0 == 1.0.$$Symbol == odpovídá porovnání dvou hodnot (test na ekvivalenci).$ - Zaokrouhlovací chyba - nejméně ϵ_m. - Přesnost výpočtu - aditivní chyba roste s počtem operací v řádu $\sqrt{N} \cdot \epsilon_m$. - Často se však kumuluje preferabilně v jedno směru v řádu $N \cdot \epsilon_m$.	

Jan Faigl, 2025	BOB36PRP – Přednáška 12: Přesnost výpočtů	13 / 45
-----------------	---	---------

Možnosti zvýšení přesnosti

- Reprezentace racionálních čísel - podíl dvou celočíselných hodnot, např. *Homogenní souřadnice*.
- „Libovolná přesnost“ - speciální knihovny, např. gmp až do výše volné paměti.
 - <https://gmplib.org/manual/index>
 - Souřadnice x,y - 7511164176768 346868669952 3739567104 ~ 2008,57; 92,76.

Přesnost výpočtů	Knihovna gmp
Racionální čísla knihovny gmp - 1/3	
„Libovolné přesnosti“ reprezentace, např. souřadnic v rovině jako výsledek operací výpočetní geometrie, můžeme realizovat podílem dvou („libovolné velkých“) celých čísel. - Souřadnice x,y - 7511164176768 346868669952 3739567104 ~ 2008,57; 92,76. - Knihovna gmp k tomuto účelu poskytuje typ <code>mpq_t</code>, kromě typu necelého čísla <code>mpf_t</code>, který využijeme pro převod <code>mpq_t</code> na necelé číslo typu <code>double</code>.<pre>49 double mpq2d(const mpq_t *op) 50 { 51 double ret; 52 mpf_t v; 53 mpf_init(v); 54 mpf_set_q(v, *op); 55 ret = mpf_get_d(v); 56 mpf_clear(v); 57 return ret; 58 }</pre>	
lec12/gmp/demo-gmp-mpq.c	

Jan Faigl, 2025	BOB36PRP – Přednáška 12: Přesnost výpočtů	20 / 45
-----------------	---	---------

Přesnost výpočtů	Knihovna gmp
Zdroje a typy chyby	
- Chyby matematického modelu - matematická aproximace fyzikální situace. - Chyby vstupních dat. - Chyby numerické metody. - Chyby zaokrouhlovací. - Absolutní chyba aproximace$E(x) = \hat{x} - x, \hat{x} \text{ přesná hodnota, } x \text{ aproximace.}$ - Relativní chyba $RE(x) = \frac{\hat{x}-x}{x}$.	

Jan Faigl, 2025	BOB36PRP – Přednáška 12: Přesnost výpočtů	14 / 45
-----------------	---	---------

Součin dvou velkých čísel knihovnou gmp - 1/2

- V HW04B je uveden příklad $(995663 \cdot 995669)^8$ jako prvočíselný rozklad čísla
$$932865073719992059629773513614789388266580305083920591925740371392254317064584855785088915745761.$$
<https://cw.fel.cvut.cz/wiki/courses/b0b36prp/hw/hw04>
- Použijme knihovnu gmp pro mocninu a součin dvou čísel, `#include<gmp.h>`.
 - <https://gmplib.org/>
 - Typ celých čísel `mpz_t`, pomocné funkce `mpz_init_set_str()`, `mpz_init()`, `gmp_printf()` a `mpz_clears()` a operace `mpz_pow_ui()` a `mpz_mul()`.
 - Mocnina `unsigned integer` a násobení - multiplication.
 - Knihovna nemusí být součástí operačního systému, proto může být nutné specifikovat cestu k hlavičkovému souboru a vlastní knihovně (`-lgmp`).
 - Můžeme zadat cestu ručně při kompilaci (nebo do `Makefile`).
 - Alternativně můžeme použít nástroj `pkg-config` (nebo `pkgconf`).<https://www.freedesktop.org/wiki/Software/pkg-config/> <http://pkgconf.org/>
 - Argumenty pro překlad (`CFLAGS`).
 - Argumenty pro linkování (`LDFLAGS`).

Přesnost výpočtů	Knihovna gmp
Racionální čísla knihovny gmp - 2/3	
<pre>1 #include <stdio.h> 2 #include <stdlib.h> 3 #include <gmp.h> 4 double mpq2d(const mpq_t *op); 5 int main(int argc, char *argv[]) 6 { 7 int ret = EXIT_SUCCESS; 8 unsigned long x1 = 75111641767681; 9 unsigned long y1 = 3468686699521; 10 unsigned long den1 = 37395671041; 11 const unsigned int digits = 21; 12 double xd = 1. * x1; 13 double yd = 1. * y1; 14 double dnd = 1. * den1; 15 printf("unsigned long: X1u Y1u Xu\n", x1, y1, den1); 16 printf("double: X.01f Y.01f X.01f\n", xd, yd, dnd); 17 printf("double x.y (.2): X.21f Y.21f\n", xd/dend, yd/dend); 18 printf("double x.y (.46): X.461f Y.461f\n", xd/dend, yd/dend); 19 }</pre>	
lec12/gmp/demo-gmp-mpq.c	

Jan Faigl, 2025	BOB36PRP – Přednáška 12: Přesnost výpočtů	21 / 45
-----------------	---	---------

Racionální čísla knihovny gmp - 3/3

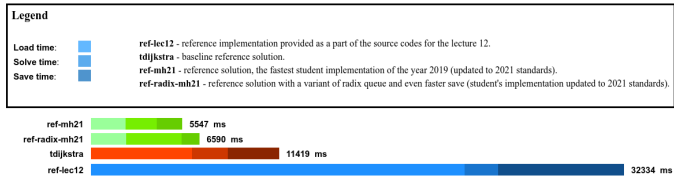
- Souřadnice x,y - 7511164176768 346868669952 3739567104 ~ 2008,57; 92,76.

```
$ make
clang -c -I/usr/local/include -g demo-gmp-mpq.c -o demo-gmp-mpq.o
clang demo-gmp-mpq.o -L/usr/local/lib -lgmp -o demo-gmp-mpq
clang -c -I/usr/local/include -g demo-gmp-mpz.c -o demo-gmp-mpz.o
clang demo-gmp-mpz.o -L/usr/local/lib -lgmp -o demo-gmp-mpz
$ ./demo-gmp-mpq
unsigned long: 7511164176768 346868669952 3739567104
double: 7511164176768 346868669952 3739567104
double x,y (.2): 2008.57 92.76
double x,y (.46): 2008.5651541681761500512948269711265563964843750000
92.7563700036227487544238101691007614135742187500
mpq x,y (canonical form): 399190273/198744 1536231/16562
mpf x,y (to 21 decimal digits): 2008.565154168176146200000 92.756370003622750875500
mpq x,y (double .46): 2008.5651541681759226776193827390670776367187500000
92.756370003622748754423810169100761413574218750
```

lec12/gmp/demo-gmp-mpq.c

Zrychlení domácího úkolu HW10B

- V případě správného použití prioritní fronty haldou, je nejvíce času programu stráveno
 - načítáním grafu z textového souboru a
 - ukládáním výsledku do textového souboru.
- V obou případech se jedná tři celá čísla (v rozsahu `int`) na řádek.
 - Převádíme znaky na celá čísla a zpět.
 - Referenční řešení (ref-`lec11`) využívá funkce `fscanf()` a `fprintf()`, které jsou relativně komplexní a pomalé.



Část IV

Část 4 – Rychlost výpočtu (programu)

Makefile s pkg-config a gmp

```
1 CFLAGS+=$(shell pkg-config --cflags gmp)
2 LDFLAGS+=$(shell pkg-config --libs gmp)
3
4 CFLAGS+=-g
5 DEMO_MPQ=demo-gmp-mpq
6 DEMO_MPZ=demo-gmp-mpz
7 TARGETS+=$(DEMO_MPQ) $(DEMO_MPZ)
8
9 bin: $(TARGETS)
10
11 info:
12     @echo $(CFLAGS)
13     @echo $(LDFLAGS)
14
15
```

```
$ make info
-I/usr/local/include -g
-L/usr/local/lib -lgmp
```

```
$ gmake
clang -c -I/usr/local/include -g demo-gmp-mpq.c -o demo-gmp-mpq.o
clang demo-gmp-mpq.o -L/usr/local/lib -lgmp -o demo-gmp-mpq
clang -c -I/usr/local/include -g demo-gmp-mpz.c -o demo-gmp-mpz.o
clang demo-gmp-mpz.o -L/usr/local/lib -lgmp -o demo-gmp-mpz
```

lec12/gmp/Makefile

Zrychlení domácího úkolu HW10B - Načítání

- Při načítání grafu můžeme využít faktu, že vstupní soubor obsahuje pouze kladná čísla oddělená mezerami v rozsahu `int`.
- Načítání můžeme urychlit přímou konverzí načteného znaku na celé číslo.
- Princip načtení celého čísla z řetězce může být následující. *Vstup je posloupnost znaků.*

```
1 int parse_int(const char *str, int len)
2 {
3     int num = 0;
4     int i = 0;
5     while (i < len && str[i] >= '0' && str[i] <= '9') {
6         num = num * 10 + (str[i++] - '0');
7     }
8     return str[i] == ' ' || str[i] == '\n' ? num : -1;
9 }
```

lec12/int_string.c

Vyžadujeme oddělení číselných hodnot mezerou nebo znakem nového řádku a předpokládáme `str[i] == '\0'`.

Maticové násobení - Naivně

```
1 void simple_multiply(const int n, const double *a, const double *b, double *c)
2 {
3     for (int i = 0; i < n; ++i) {
4         for (int j = 0; j < n; ++j) {
5             double prod = 0;
6             for (int k = 0; k < n; ++k) {
7                 prod += a[i * n + k] * b[k * n + j];
8             }
9             c[i * n + j] = prod;
10        }
11    }
12 }
```

- Pro přehlednost předpokládáme kompatibilní rozměry matic a správně alokované.

Část III

Část 3 – Implementace bonusového úlohy HW10B

Zrychlení domácího úkolu HW10B - Ukládání

- Můžeme využít maximálního počtu znaků v rozsahu typu `int` a výstupní posloupnost znaků reprezentující celé číslo vytvářet od nejnižšího řádu postupným dělením.
- Princip konverze kladného celého čísla může být následující. *Výstup je posloupnost znaků.*

```
1 char* int_to_string(int v, char *buf, size_t capacity)
2 {
3     char *cur = buf + capacity - 1; //last char of the buffer buf
4     *cur = '\0';
5     do {
6         int least = v % 10;
7         v /= 10;
8         *--cur = least + '0';
9     } while (v != 0);
10    return cur;
11 }
```

lec12/int_string.c

Maticové násobení - Naivně s transpozicí

```
1 void simple_multiply_trans(const int n, const double *a, const double *b, double *c)
2 {
3     double *bT = create_matrix(n); // allocate memory for transposed matrix
4     for (int i = 0; i < n; ++i) {
5         bT[i*n + i] = b[i*n + i];
6         for (int j = i + 1; j < n; ++j) {
7             bT[i*n + j] = b[j*n + i];
8             bT[j*n + i] = b[i*n + j];
9         }
10    }
11    for (int i = 0; i < n; ++i) {
12        for (int j = 0; j < n; ++j) {
13            double tmp = 0;
14            for (int k = 0; k < n; ++k) {
15                tmp += a[i*n + k] * bT[j*n + k];
16            }
17            c[i*n + j] = tmp;
18        }
19    }
20    free(bT);
21 }
```


Diskutovaná témata

- Typové konverze.
 - Numerická přesnost.
 - Knihovna `gmp`.
 - Bonusová úloha HW10B.
-
- *Maticové násobení a organizace paměti.*
 - *Rychlost výpočtu a architektura procesoru.*
 - *Paralení výpočty OpenMP.*