



IA039: Architektura superpočítačů a náročné výpočty

Message Passing Interface

Luděk Matyska

Jaro 2020



Paralelní programování

■ Data parallelismus

- Stejné instrukce na různých procesorech zpracovávají různá data
- V podstatě odpovídá SIMD modelu (Single Instruction Multiple Data)
 - Např. paralelizace cyklu

■ Task parallelismus

- MIMD model (Multiple Instruction Multiple Data)
- Paralelně prováděné nezávislé bloky (funkce, procedury, programy)

■ SPMD

- Není synchronizován na úrovni jednotlivých instrukcí
- Ekvivalentní MIMD

■ Message passing určeno pro SPMD/MIMD

Message Passing Interface

- Komunikační rozhraní pro paralelní programy
- Definováno API
 - Standardizováno
 - Řada nezávislých implementací
 - Možnost optimalizace pro konkrétní hardware
 - Určité problémy se skutečnou interoperabilitou

Vývoj MPI

- Postupné uvádění verzí
 - Verze 1.0
 - Základní, nebyla implementována
 - Vazba na jazyky C a Fortran
 - Verze 1.1
 - Oprava nějvětších nedostatků
 - Implementována
 - Verze 1.2
 - Přechodá verze (před MPI-2)
 - Rozšíření standardu MPI-1

MPI-2.0

- Experimentální implementace plného standardu
- Rozšíření
 - Paralelní I/O
 - Jednosměrné operace (put, get)
 - Manipulace s procesy
- Vazba na C++ i Fortran 90

MPI-3.0

- Snaha odstranit nedostatky předchozích verzí a reagovat na vývoj v oblasti hardware (zejména multicore procesory), viz <http://www.mpi-forum.org/>
- Pracovní skupiny
 - Collective Operations and Topologies
 - Backward Compatibility
 - Fault Tolerance
 - Fortran Bindings
 - Remote Memory Access
 - Tools Support
 - Hybrid Programming
 - Persistency
- Aktuální standard je MPI-3.1 (vydán v červnu 2015)
- Probíhají práce na nové specifikaci (MPI Forum)

Cíle návrhu MPI

- Přenositelnost
 - Definice standardu (API)
 - Vazba na různé programovací jazyky
 - Nezávislé implementace
- Výkon
 - Nezávislá optimalizace pro konkrétní hardware
 - Knihovny, možnost výměny algoritmů
 - Např. nové verze kolektivních algoritmů
- Funkcionalita
 - Snaha pokrýt všechny aspekty mezičipové komunikace

Cíle II

- Specifikace knihovny pro podporu předávání zpráv
- Určena pro paralelní počítače, clustery i Gridy
- Zpřístupnění paralelního hardware pro
 - Uživatele
 - Autory knihoven
 - Vývojáře nástrojů a aplikací



Core MPI

MPI_Init	Inicializace MPI
MPI_Comm_Size	Zjištění počtu procesů
MPI_Comm_Rank	Zjištění vlastní identifikace
MPI_Send	Zaslání zprávy
MPI_Recv	Přijetí zprávy
MPI_Finalize	Ukončení MPI

Inicializace MPI

- Vytvoření prostředí
- Definuje, že program bude používat MPI knihovny
- Nemanipuluje explicitně s procesy

Identifikace prostředí

- Paralelní (distribuovaný) program potřebuje znát
 - Kolik procesů se účastní výpočtu
 - Jaká je „moje“ identifikace
- MPI_Comm_size(MPI_COMM_WORLD, &size)
 - Vrací počet procesů sdílejících komunikátor MPI_COMM_WORLD (viz dále)
- MPI_Comm_rank(MPI_COMM_WORLD, &rank)
 - Vrací číslo procesu

Práce se zprávami

- Primitivní model:
 - Proces A posílá zprávu: operace *send*
 - Proces B přijímá zprávu: operace *receive*
- Celá řada otázek:
 - Jak vhodně popsat data?
 - Jak specifikovat proces (kterému jsou data určena)?
 - Jak přijímající pozná, že data patří jemu?
 - Jak poznáme (úspěšné) dokončení těchto operací?

Klasický přístup

- Data posíláme jako proud bytů
 - Je úkolem posílajícího a přijímajícího data správně nastavit a rozpozнат
- Každý proces má jedinečný identifikátor
 - Musíme znát identifikátor příjemce/vysílajícího
 - Broadcast operace
- Můžeme specifikovat příznak (tag) zprávy pro snazší rozpoznání (např. pořadové číslo zprávy)
- Synchronizace
 - Explicitní spolupráce vysílajícího a přijímajícího
 - Definuje pořadí zpráv

Klasický přístup II

- `send(buffer, len, destination, tag)`
 - *buffer* obsahuje data, jeho délka je *len*
 - Zpráva je zaslána procesu s identifikací '*destination*'
 - Zpráva má příznak *tag*
- `recv(buffer, maxlen, source, tag, actlen)`
 - Zpráva bude přijata do paměťové oblasti specifikované položkou *buffer* jehož délka je *maxlen*
 - Skutečná délka přijaté zprávy je *actlen* ($actlen \leq maxlen$)
 - Zpráva přijde od procesu s identifikátorem *source* a musí mít příznak *tag*

Nedostatky klasického přístupu

- Nedostatečná úroveň definice dat
 - Heterogenita cíle a zdroje (nekompatibilní reprezentace)
 - Příliš mnoho kopírování
 - Příliš vysoká zátěž programátora
- Příznaky (tags) globální
 - Komplikace při realizaci nezávislých knihoven
- Kolektivní operace
 - Příliš mnoho send/receive, neefektivní

Rozšíření v MPI

- Procesy mohou být uspořádány do **skupin**
- Každá zpráva má definovaný **kontext** (ne pouze příznak)
 - Zaslání a přijetí zprávy je možné pouze v rámci stejného kontextu
- Skupina a kontext společně definují **komunikátor**
 - Příznak může být lokální konkrétnímu komunikátoru
- Defaultní komunikátor **MPI_COMM_WORLD**
 - Skupina tvořená všemi procesy MPI programu
- Identifikace (rank) procesu je vždu uvnitř kontextu

Datové typy

- Data nejsou popsána dvojicí (adresa, délka), ale trojicí (adresa, počet, datotyp)
- MPI Datotyp je definován *rekurzivně* jako:
 - Předdefinované datové typy používaného jazyka (např. MPI_INT)
 - Souvislé pole MPI datotypů
 - Krokované (strided) pole MPI datotypů
 - Indexované pole bloků datotypů
 - Libovolná struktura datotypů
- K dispozici MPI funkce pro definici vlastních datotypů
 - Např. řádek matice která je ukládána po sloupcích

Příznaky

- Každá zpráva má přiřazený příznak (tag)
 - Usnadňuje rozpoznání zprávy přijímajícímu
 - Příznak vždy definován v rámci použitého kontextu
- Přijímající může specifikovat, jaký příznak očekává
 - Alternativně může příznaky ignorovat (specifikací MPI_ANY_TAG)

Point-to-point Communication

- Předání zprávy mezi dvěmi procesy
- Blokující / Neblokující volání
 - Blokující – čeká se na dokončení operace
 - Neblokující – operace se zahájí, nečeká se na dokončení, testuje se stav
- Bufferující/Nebufferující předání zprávy
 - Bez bufferu – zpráva se předá bez bufferu
 - MPI buffer – spravován přímo MPI
 - User buffer – spravován aplikací (programátorem)

Komunikační mody I

- Standardní mod (Send)
 - Blokující volání
 - Samo MPI rozhodne, jestli se použije MPI buffer
 - použije se → Send skončí když jsou všechna data v bufferu
 - nepoužije se → Send skončí když jsou data přijata odpovídajícím Receive
- Synchronní mod
 - Blokující volání
 - Když se dokončí Send, data byla přijata odpovídajícím Receive (synchronizace)

Komunikační mody II

■ Bufferovaný mod

- Buffer na straně aplikace (programátora)
- Blokující i neblokující – po dokončení jsou data v user bufferu

■ Ready mod

- Receive musí předcházet send (připraví cílový buffer)
- Jinak chyba

Základní send operace

- Blokující send
 - MPI_SEND(start, count, datatype, dest, tag, comm)
 - Trojice (start, count, datatype) definuje zprávu
 - *dest* definuje cílový proces, a to relativně vzhledem ke komunikátoru *comm*
- Když operace skončí, znamená to
 - Všechna data byla systémem akceptována
 - Buffer je možné okamžitě znova použít
 - Příjemce nemusel ještě data dostat

Základní *receive* operace

■ Blokující operace

- MPI_RECV(start, count, datatype, source, tag, comm, status)
 - Operace čeká dokud nedozájí zpráva s odpovídající dvojicí (source, tag)
 - source je identifikátor odesílatele (relativně vůči komunikátoru comm) nebo MPI_ANY_SOURCE
 - status obsahuje informace o výsledku operace
 - Obsahuje také příznak zprávy a identifikátor procesu při použití specifikací MPI_ANY_TAG a MPI_ANY_SOURCE
 - Pokud přijímaná zpráva obsahuje méně než count bloků, není to identifikováno jako chyba (je poznačeno v status)
 - Přijetí více jak count bloků je chyba

Krátký Send/Receive protokol

- Plně duplexní komunikace
 - Každá zasílaná zpráva odpovídá přijímané zprávě
 - ```
int MPI_Sendrecv(void *sendbuf, int sendcnt,
 MPI_Datatype sendtype, int dest, int sendtag,
 void *recvbuf, int recrcnt, MPI_Datatype recvtype,
 int source, int recvtag,
 MPI_Comm comm, MPI_Status *status)
```

# Asynchronní komunikace

- Neblokující operace *send*
  - Buffer k dispozici až po úplném dokončení operace
- Operace *send* i *receive* vytvoří požadavek
  - Následně lze zjišťovat stav požadavku
- Volání
  - ```
int MPI_Isend(void *buf, int cnt, MPI_Datatype datatype,
              int dest, int tag, MPI_Comm comm,
              MPI_Request *request)
int MPI_Irecv(void *buf, int cnt, MPI_Datatype datatype,
              int source, int tag, MPI_Comm comm,
              MPI_Request *request)
```

Asynchronní operace II

■ (Blokující) čekání na výsledek operace

```
■ int MPI_Wait(MPI_Request *request, MPI_Status *status)
    int MPI_Waitany(int cnt, MPI_Request *array_of_requests,
                    int *index, MPI_Status *status)
    int MPI_Waitall(int cnt, MPI_Request *array_of_requests,
                    MPI_Status *array_of_statuses)
```

Asynchronní operace III

■ Neblokující zjištění stavu

```
■ int MPI_Test(MPI_Request *request, int *flag,  
              MPI_Status *status)  
    int MPI_Testany(int cnt, MPI_Request *array_of_requests,  
                  int *flag, int *index, MPI_Status *status)  
    int MPI_Testall(int cnt, MPI_Request *array_of_requests,  
                  int *flag, MPI_Status *array_of_statuses)
```

■ Uvolnění požadavku

```
int MPI_Request_free(MPI_Request *request)
```

Trvalé (persistentní) komunikační kanály

- Neblokující
- Spojeny ze dvou „půl“-kanálů
- Životní cyklus
 - **Create (Start Complete)* Free**
 - Vytvořeny, pak opakovaně používány, následně zrušeny

Persistentní kanál – vytvoření

```
int MPI_Send_init(void *buf, int cnt,  
                  MPI_Datatype datatype,  
                  int dest, int tag, MPI_Comm comm,  
                  MPI_Request *request)  
  
int MPI_Recv_init(void *buf, int cnt,  
                  MPI_Datatype datatype,  
                  int dest, int tag, MPI_Comm comm,  
                  MPI_Request *request)
```

Přenos

- Zahájení přenosu (Start)

- `int MPI_Start(MPI_Request *request)`
`int MPI_Startall(int cnt,`
`MPI_Request *array_of_requests)`

- Zakončení přenosu (Complete)

- Jako u asynchronních (wait, test, probe)



Zrušení kanálu

- Ekvivalentní zrušení odpovídajícího požadavku
`int MPI_Cancel(MPI_Request *request)`

Kolektivní operace

- Operace provedené současně všemi procesy v rámci skupiny
 - Broadcast: MPI_BCAST
 - Jeden proces (root) pošle data všem ostatním procesům
 - Redukce: MPI_REDUCE
 - Spojí data ode všech procesů ve skupině (komunikátoru) a vrátí jednomu procesu
 - Často je možné skupinu příkazů *send/receive* nahradit *bcast/reduce*
 - Vyšší efektivita (*bcast/reduce* optimalizováno pro daný hardware)

Kolektivní operace II

- Další operace
 - alltoall: výměna zpráv mezi všemi
 - *bcast/reduce* realizuje tzv. *scatter/gather* model
- Speciální redukce
 - min, max, sum, ...
 - Uživatelsky definované kolektivní operace

Virtuální topologie

- MPI umožňuje definovat komunikační vzory odpovídající požadavkům aplikace
- Ty jsou v dalším kroku mapovány na konkrétní komunikační možnosti použitého hardware
 - Transparentní
- Vyšší efektivita při psaní programů
- Přenositelnost
 - Program není svázan s konkrétní topologií použitého hardware
- Možnost nezávislé optimalizace

Datové typy

- Mapa typu
 - Typemap = $\{(type_0, disp_0), \dots, (type_{n-1}, disp_{n-1})\}$
- Signatura typu
 - Typesig = $\{type_0, \dots, type_{n-1}\}$
- Příklad:
 - MPI_INT == {(int,0)}

Rozsah a velikost

- MPI_Type_extent(MPI_Datatype Type, MPI_Aint *extent)
- MPI_Type_size(MPI_Datatype Type, int *size)
- Příklad:
 - Type = {(double,0),(char,8)}
 - extent = 16
 - size = 9

Konstrukce datotypů

- Souvislý datový typ

- `int MPI_Type_contiguous(int count,
MPI_Datatype oldtype,
MPI_Datatype *newtype)`

- Vektor

- `int MPI_Type_vector(int count, int blocklength,
int stride,
MPI_Datatype oldtype,
MPI_Datatype *newtype)`
 - `int MPI_Type_hvector(int count, int blocklength,
int stride,
MPI_Datatype oldtype,
MPI_Datatype *newtype)`

Konstrukce datotypů II

■ Indexovaný datový typ

```
■ MPI_Type_indexed(int count, int *array_of_blocklengths,  
                   int *array_of_displacements, MPI_Datatype oldtype,  
                   MPI_Datatype *newtype)  
MPI_Type_hindexed(int count, int *array_of_blocklength,  
                   int *array_of_displacements, MPI_Datatype oldtype,  
                   MPI_Datatype *newtype)
```

■ Struktura

```
■ MPI_Type_struct(int count, int *array_of_blocklengths,  
                  MPI_Aint *array_of_displacements,  
                  MPI_Datatype *array_of_types,  
                  MPI_Datatype *newtype)
```

Konstrukce datotypů III

- Potvrzení definice datového typu
 - `int MPI_Type_commit(MPI_Datatype *datatype)`
- Krokové (strided) datové typy
 - Mohou obsahovat „díry“
 - Implementace může optimalizovat způsob práce
 - Příklad: Každý druhý prvek vektoru
 - Může skutečně „složit“
 - Může ale také poslat celý vektor a druhá strana vybere jen specifikované typy

Operace nad soubory

- Podpora až od MPI-2
- „Paralelizace“ souborů
- Základní pojmy

file	displacement
etype	filetype
view	offset
file size	file pointer
file handle	

Operace nad soubory II

Umístění	Synch	Koordinace	
		nekolektivní	kolektivní
explicitní offset	blokující	MPI_File_read_at MPI_File_write_at	MPI_File_read_at_all MPI_File_write_at_all
	neblokující & split collect.	MPI_File_iread_at MPI_File_iwrite_at	MPI_File_read_at_all_begin MPI_File_read_at_all_end MPI_File_write_at_all_begin MPI_File_write_at_all_end
individuální file ptrs	blokující	MPI_File_read MPI_File_write	MPI_File_read_all MPI_File_write_all
	neblokující & split collect.	MPI_File_iread MPI_File_iwrite	MPI_File_read_all_begin MPI_File_read_all_end MPI_File_write_all_begin MPI_File_write_all_end
sdílený file ptr.	blokující	MPI_File_read_shared MPI_File_write_shared	MPI_File_read_ordered MPI_File_write_ordered
	neblokující & split collect. split collect.	MPI_File_iread_shared MPI_File_iwrite_shared	MPI_File_read_ordered_begin MPI_File_read_ordered_end MPI_File_write_ordered_begin MPI_File_write_ordered_end

MPI a optimalizující překladače

- Při asynchronním použití se mění hodnoty polí, o nichž překladač nemusí vědět

- Kopírování parametrů způsobí ztrátu dat

```
call user(a, rq)
call MPI_WAIT(rq, status, ierr)
write (*,*) a
```

```
subroutine user(buf, request)
call MPI_IRecv(buf, ..., request, ...)
end
```

- V tomto případě se v hlavním programu vypíše nesmyslná hodnota „a“, protože se při návratu z „user“ zkopíruje aktuální hodnota; přitom operace *receive* ještě nebyla dokončena