Programování aplikací pro prostředí s distribuovanou pamětí

Jiří Barnat

Principy programování s předáváním zpráv

Vymezení prostředí

Paradigma – předávání zpráv

- Nesdílený adresový prostor
- Explicitní paralelismus

Pozorování

- Data explicitně dělena a umístěna do jednotlivých lokálních adresových prostorů.
- Datová lokalita je klíčová vlastnost pro výkon.
- Komunikace vyžaduje aktivní účast komunikujících stran.
- Existují efektivně implementované podpůrné knihovny.
- Programátor je zodpovědný za paralelizaci algoritmu.

Struktura programů s předáváním zpráv

Asynchronní paradigma

- Výpočet začne ve stejný okamžik (synchronně), ale ...
- Probíhá asynchronně (různá vlákna různou rychlostí).
- Možnost synchronizace v jednotlivých bodech výpočtu.
- Neplatí "Trojúhelníková nerovnost" v komunikaci.

Další vlastnosti

- Vykazuje nedeterministické chování.
- Těžší prokazování korektnosti.
- Možnost provádění zcela odlišného kódu na jednotlivých procesních jednotkách.
- Typicky však "Single program multiple data".
- Každá procesní jednotka má jednoznačnou identifikaci.

Send a Receive – Základní stavební kameny

Send a Receive

```
send(void *sendbuf, int nelems, int dest)
receive(void *recvbuf, int nelemns, int src)
```

- `sendbuf` – ukazatel na bafr (blok paměti), kde jsou umístěna data připravená k odeslání.
- `recvbuf` – ukazatel na bafr (blok paměti), kam budou umístěna přijatá data.
- `nelems` – počet datových jednotek, které budou poslány, či přijaty (délka zprávy).
- `dest` – adresát odesílané zprávy, tj. *ID* toho, komu je zpráva určena.
- `src` – odesílatel zprávy, tj. *ID* toho, kdo zprávu poslal, nebo toho, od koho chci zprávu přijmout.

Příklad na send a receive

Příklad

- Paralelní systém s 2 procesy

```
1      P0                  P1
2
3      a = 100;            receive (&a, 1, 0);
4      send(&a, 1, 1);     printf("%d\n", a);
5      a = 0;
```

Výstup a efektivita

- Co by mělo být na výstupu procesu `P1`?
- Asynchronní sémantika `send()` a `receive()`.
- Nutné z důvodu zachování výkonu aplikace.
- Co může být na výstupu procesu `P1`?

Blokující nebafrované operace

Blokující operace

- Operace `send`() ukončena až tehdy, je-li to bezpečné vzhledem k sémantice, tj. že příjemce obdrží to, co bylo obsahem odesílaného bafru v okamžiku volání operace `send`().
- Ukončení operace `send()` nevynucuje a negarantuje, že příjemce již zprávu přijal.
- Operace `receive`() skončí po příjetí dat a jejich umístění na správné místo v paměti.

Nebafrované operace

- Operace `send`() skončí až po dokončení operace komunikace, tj. až přijímací proces zprávu přijme.
- V rámci operací `send`() a `receive`() před samotným přenosem dat probíhá synchronizace obou participujících stran (handshake).

Blokující nebafrované operace – problémy

Prodlevy

- Způsobeno synchronizací před vlastní komunikací.
- Proces, který dosáhne bodu, kdy je připraven komunikovat čeká, až do stejného bodu dospěje i druhý proces.
- Volání `send()` a `receive()` ve stejný okamžik nelze garantovat na úrovni kódu.
- Nemá velký vliv, pokud dominuje čas komunikace.

Uváznutí (deadlock)

```
1   P0                      P1
2
3   send(&a, 1, 1);         send(&a, 1, 0);
4   receive(&b, 1, 1);      receive(&b, 1, 0);
```

Blokující bafrované operace

Bafr v bafrované komunikaci

- Extra paměť zdánlivě mimo adresový prostor procesů.
- Mezisklad zpráv při komunikaci.

Bafrované komunikační operace

- Operace `send()` skončí v okamžiku, kdy odesílaná data kompletně překopírována do bafru.
- Případná modifikace posílaných dat po skončení operace `send()`, ale před započetím vlastní komunikace se neprojeví.
- Volání `send()`, vlastní komunikace a následné volání `receive()` na přijímací straně se nemusí časově překrývat.

Blokující bafrované operace – problémy

Režie související s bafrováním

- Eliminace prodlev za cenu režie bafrování.
- Ve vysoce synchroniích aplikacích může být horší než používání blokujících nebafrovaných operací.

Velikost bafrů

- Pokud odesílatel generuje zprávy rychleji, než je příjemce schopen zprávy přijímat, velikost bafrů může neúměrně růst (problém producent-konzument).
- Pokud je velikost pro bafry omezená, může docházet (a to nedeterministicky) k situaci, kdy je předem daná velikost bafrů nedostatečná (buffer overflow).
- Případné samovolné blokování odesílatele do té doby, než odesílatel přijme nějaká data a bafry se uvolní, může vést k uváznutí, podobně jako v případě nebafrované blokující komunikace.

Blokující bafrované operace – problémy

Uváznutí (i bez blokování odesílatele)

```
1   P0                        P1
2
3   receive(&b, 1, 1);        receive(&b, 1, 0);
4   send(&a, 1, 1);           send(&a, 1, 0);
```

Asymetrický model blokující bafrované komunikace

- Neexistence odpovídajících prostředků pro bafrovanou komunikaci na úrovni komunikační vrstvy.
- Operace `send()` je blokující nebafrovaná.
- Přijímací proces je přerušen v běhu a zpráva je přijata do bafru, kde čeká, dokud přijímací proces nezavolá odpovídající operaci `receive()`.
- Dedikované vlákno pro obsluhu komunikace.

Neblokující operace

Motivace

- Komunikace, která nezpůsobuje prodlevy.

Neblokující operace

- Volání funkce může skončit dříve, než je to sémanticky bezpečné.
- Existuje funkce na zjištění stavu komunikující operace.
- Program nesmí modifikovat odesílaná data, dokud komunikace neskončí.
- Po dobu trvání komunikace program může vykonávat kód.
- Překrývání výpočtu a komunikace.

HW Realizace

- DMA

Přehled komunikačních módů

	Blokující	Neblokující
Bafrované	`send` skončí jakmile jsou data nakopírována do bafru	`send` skončí jakmile je inicializován DMA přenos
Nebafrované	`send` skončí až po skončení odpovídajícího `receive`	`send` skončí ihned, odešle se pouze požadavek na komunikaci
	Sémantiku operací nelze porušit	Korektní dokončení operací nutné zjišťovat opakovaným dotazováním se

Message Passing Interface

Message Passing Interface

- Standardizuje syntax a sémantiku komunikačních primitiv
- Přes 120 knihovních funkcí
- Rozhraní pro C, Fortran
- MPI verze 1.2
- MPI verze 2.0 (Paralelní I/O, C++ rozhraní, ...)
- Existují různé implementace standardu
  - mpich
  - LAM/MPI
  - Open MPI
- http://www.mpi-forum.org/

Minimální použití MPI

MPI funkce	Význam
`MPI_Init`	Inicializuje MPI
`MPI_Finalize`	Ukončuje MPI
`MPI_Comm_size`	Vrací počet participujících procesů
`MPI_Comm_rank`	Vrací identifikátor volajícího procesu
`MPI_Send`	Posílá zprávu
`MPI_Recv`	Přijímá zprávu

- Definice typů a konstant: `#include "mpi.h"`
- Návratová hodnota při úspěšném volání fce: `MPI_SUCCESS`
- Kompilace: `mpicc, mpiCC, mpiC++`
- Spuštění programu: `mpirun`

Inicializace a ukončení MPI knihovny

Inicializace

- Nastavuje MPI prostředí
- Musí být voláno na všech procesorech
- Musí výt voláno jako první MPI funkce
- `argv` nesmí být modifikováno před voláním `MPI_Init`
- `MPI_Init(int *argc, char ***argv)`

Finalizace

- Ukončuje MPI prostředí
- Musí být voláno na všech procesech
- Nesmí být následováno voláním MPI funkce
- Provádí různé úklidové práce
- `int MPI_Finalize()`

MPI komunikátory

Komunikační domény

- Sdružování participujících procesorů do skupin
- Skupiny se mohou překrývat

Komunikátory

- Proměnné, které uchovávají komunikační domény
- Typ `MPI_Comm`
- Jsou argumentem všech komunikačních funkcí MPI
- Výchozí komunikátor: `MPI_COMM_WORLD`

Zjišťování velikosti domény a identifikátoru v rámci domény

- `int MPI_Comm_size(MPI_Comm comm, int *size)`
- `int MPI_Comm_rank(MPI_Comm comm, int *rank)`
- `rank` je identifikátor procesu v dané doméně
- `rank` číslo v intervalu `[0,size-1]`

Hello World

```
1   #include "mpi.h"
2
3   main (int argc, char *argv[])
4   {
5     int npes, myrank;
6
7     MPI_Init (&argc, &argv);
8     MPI_Comm_size(MPI_COMM_WORLD, &npes);
9     MPI_Comm_rank(MPI_COMM_WORLD, &myrank);
10
11    printf("Hello World! (%d out of %d)",
12           myrank,npes);
13
14    MPI_Finalize();
15  }
```

Posílání zpráv

```
int MPI_Send(void *buf, int count,
             MPI_Datatype datatype, int dest,
             int tag, MPI_Comm comm)
```

- Odešle data odkazovaná ukazatelem `buf`
- Na data se nahlíží jako na sekvenci instancí typu `datatype`
- Odešle se `count` po sobě jdoucích instancí
- `dest` je rank adresáta v komunikační doméně určené komunikátorem `comm`
- `tag`
    - Přiložená informace typu `int` v intervalu `[0,MPI_TAG_UB]`
    - Pro příjemce viditelná bez čtení obsahu zprávy
    - Typicky odlišuje typ zprávy

Korespondence datových typů MPI a C

MPI datový typ	Odpovídající datový typ v C
MPI_CHAR	signed char
MPI_SHORT	signed short int
MPI_INT	signed int
MPI_LONG	signed long int
MPI_UNSIGNED_CHAR	unsigned char
MPI_UNSIGNED_SHORT	unsigned short int
MPI_UNSIGNED	unsigned int
MPI_UNSIGNED_LONG	unsigned long int
MPI_FLOAT	float
MPI_DOUBLE	double
MPI_LONG_DOUBLE	long double
MPI_BYTE	-
MPI_PACKED	-

Přijímání zpráv

```
int MPI_Recv(void *buf, int count,
             MPI_Datatype datatype, int source,
             int tag, MPI_Comm comm,
             MPI_Status *status)
```

- Přijme zprávu od odesílatele s rankem `source` v komunikační doméně `comm` s tagem `tag`
- `source` může být `MPI_ANY_SOURCE`
- `tag` může být `MPI_ANY_TAG`
- Zpráva uložena na adrese určené ukazatelem `buf`
- Velikost bafru je určena hodnotami `datatype` a `count`
- Pokud je bafr malý, návratová hodnota bude `MPI_ERR_TRUNCATE`

Přijímání zpráv – MPI_Status

```
MPI_Status
```

```
typedef struct MPI_Status {
  int MPI_SOURCE;
  int MPI_TAG;
  int MPI_ERROR;
};
```

- Vhodné zejména v případě příjmu v režimu `MPI_ANY_SOURCE` nebo `MPI_ANY_TAG`
- `MPI_Status` drží i další informace, například skutečný počet přijatých dat (délka zprávy)

```
int MPI_Get_count(MPI_Status *status,
                  MPI_Datatype datatype,
                  int *count)
```

Posílání a přijímání zpráv – sémantika

`MPI_Recv`

- Volání skončí až jsou data umístěna v bafru
- Blokující receive operace

`MPI_Send`

- MPI standard připouští 2 různé sémantiky
  1) Volání skončí až po dokončení odpovídající receive operace
  2) Volání skončí jakmile jsou posílaná data zkopírována do bafru
- Změna odesílaných dat je vždy sémanticky bezpečná
- Blokující send operace

Možné důvody uváznutí

- Jiné pořadí zpráv při odesílání a přijímání
- Cyklické posílání a přijímání zpráv (večeřící filozofové)

Současné posílání a přijímání zpráv

`MPI_Sendrecv`

- Operace pro současné přijímání i odesílání zpráv
- Nenastává cyklické uváznutí
- Bafry pro odesílaná a přijímaná data musí být různé

```
int MPI_Sendrecv (
  void *sendbuf, int sendcount,
  MPI_Datatype senddatatype, int dest, int sendtag,
  void *recvbuf, int recvcount,
  MPI_Datatype recvdatatype,
  int source, int recvtag, MPI_Comm comm,
  MPI_Status *status)
```

Současné posílání a přijímání zpráv – Sendrecv_replace

Problémy `MPI_Sendrecv`

- Bafry pro odesílaná a přijímaná data zabírají 2x tolik místa
- Složitá manipulace s daty díky 2 různým bafrům

`MPI_Sendrecv_replace`

- Operace odešle data z bafru a na jejich místo nakopíruje přijatá data

```
int MPI_Sendrecv_replace (
  void *buf, int count,
  MPI_Datatype datatype, int dest, int sendtag,
  int source, int recvtag, MPI_Comm comm,
  MPI_Status *status)
```

Neblokující komunikace

Neblokující Send a Receive

```
int MPI_Isend(void *buf, int count,
              MPI_Datatype datatype, int dest,
              int tag, MPI_Comm comm,
              MPI_Request *request)
```

```
int MPI_Irecv(void *buf, int count,
              MPI_Datatype datatype, int source,
              int tag, MPI_Comm comm,
              MPI_Request *request)
```

`MPI_Request`

- Identifikátor neblokující komunikační operace
- Potřeba při dotazování se na dokončení operace

Dokončení neblokujících komunikačních operací

```
int MPI_Test(MPI_Request *request, int *flag,
             MPI_Status *status)
```

- Nulový `flag` znamená, že operace ještě probíhá
- Při prvním volání po dokončení operace se naplní `status`, zničí `request` a `flag` nastaví na *true*

```
int MPI_Wait(MPI_Request *request,
             MPI_Status *status)
```

- Blokující čekání na dokončení operace
- Po dokončení je `request` zničen a `status` naplněn

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

- Explicitní zničení objektu `request`
- Nemá vliv na probíhající operaci

Neblokující operace – poznámky

Párování

- Neblokující a blokující send a receive se mohou libovolně kombinovat

Uváznutí

- Neblokující operace řeší většinu problémů s uváznutím
- Neblokující operace mají vyšší paměťové nároky
- Později zahájená neblokující operace může skončit dříve

Sekce

Kolektivní komunikace

Kolektivní operace

- Množina participujících procesů je určena komunikační doménou (`MPI_Comm`).
- **Všechny procesy v doméně musí volat odpovídající `MPI` funkci.**
- Obecně se kolektivní operace nechovají jako bariéry, tj. jeden proces může dokončit volání funkce dříve, než jiný proces vůbec dosáhne místa volání kolektivní operace.
- Forma virtuální synchronizace.
- Nepoužívají tagy (všichni vědí jaká operace se provádí).
- Pokud je nutné specifikovat zdrojový, či cílový proces, musí tak učinit všechny participující procesy a jejich volba cílového, či zdrojového procesu musí být shodná.
- `MPI` podporuje dvě varianty kolektivních operací
  - posílají se stejně velká data (např. `MPI_Scatter`)
  - posílají se různě velká data (např. `MPI_Scatterv`)

Bariéra

```
int MPI_Barrier(MPI_Comm comm)
```

- Základní synchronizační primitivum.
- Volání funkce skončí pokud všechny participující procesy zavolají `MPI_Barrier`.
- Není nutné, aby volaná funkce byla "na stejném místě v programu".

Kolektivní komunikační primitiva a MPI

Operace	Jméno MPI funkce
OTA vysílání	MPI_Bcast
ATO redukce	MPI_Reduce
ATA vysílání	MPI_Allgather
ATA redukce	MPI_Reduce_scatter
Kompletní redukce	MPI_Allreduce
Gather	MPI_Gather
Scatter	MPI_Scatter
ATA zosobněná komunikace	MPI_Alltoall

Všesměrové vysílání – OTA

```
int MPI_Bcast(void *buf, int count,
              MPI_Datatype datatype,
              int source, MPI_Comm comm)
```

- Rozesílá data uložená v bafru `buf` procesu `source` ostatním procesům v doméně `comm`.
- Kromě `buf` musí být parametry funkce shodné ve všech participujících procesech.
- Parametr `buf` na ostatních procesech slouží pro identifikaci bafru pro příjem dat.

Redukce

```
int MPI_Reduce(void *sendbuf, void *recvbuf,
               int count, MPI_Datatype datatype,
               MPI_Op op, int target,
               MPI_Comm comm)
```

- Data ze `sendbuf` zkombinována operací `op` do `recvbuf` procesu `target`.
- Všichni participující musí poskytnout `recvbuf` i když výsledek uložen pouze na procesu `target`.
- Hodnoty `count`, `datatype`, `op`, `target` musí být shodné ve všech volajících procesech.
- Možnost definovat vlastní operace typu `MPI_Op`.

Operátory redukce

Operace	Význam	Datové typy
MPI_MAX	Maximum	C integers and floating points
MPI_MIN	Minimum	C integers and floating points
MPI_SUM	Součet	C integers and floating points
MPI_PROD	Součin	C integers and floating points
MPI_LAND	Logické AND	C integers
MPI_BAND	Bitové AND	C integers and byte
MPI_LOR	Logické OR	C integers
MPI_BOR	Bitové OR	C integers and byte
MPI_LXOR	Logické XOR	C integers
MPI_BXOR	Bitové XOR	C integers and byte
MPI_MAXLOC	Maximum a minimální pozice s maximem	Datové dvojice
MPI_MINLOC	Minimum a minimální pozice s minimem	Datové dvojice

Datové páry a Kompletní Redukce

MPI datové páry	C datový typ
MPI_2INT	int, int
MPI_SHORT_INT	short, int
MPI_LONG_INT	long, int
MPI_LONG_DOUBLE_INT	long double, int
MPI_FLOAT_INT	float, int
MPI_DOUBLE_INT	double, int

```
int MPI_Allreduce(void *sendbuf, void *recvbuf,
                  int count, MPI_Datatype datatype,
                  MPI_Op op, MPI_Comm comm)
```

Prefixový součet

```
int MPI_Scan(void *sendbuf, void *recvbuf,
             int count, MPI_Datatype datatype,
             MPI_Op op, MPI_Comm comm)
```

- Provádí prefixovou redukci.
- Proces s rankem i má ve výsledku hodnotu vzniklou redukcí hodnot procesů s rankem 0 až i včetně.
- Jinak shodné s redukcí.

Gather

```
int MPI_Gather(void *sendbuf, int sendcount,
               MPI_Datatype senddatatype,
               void *recvbuf, int recvcount,
               MPI_Datatype recvdatatype,
               int target, MPI_Comm comm)
```

- Všichni posílají stejný typ dat.
- Cílový proces obdrží *p* bafrů seřazených dle ranku odesílatele.
- `recvbuf`, `recvcount`, `recvbuf` platné pouze pro proces s rankem `target`.
- `recvcount` je počet odeslaných dat jedním procesem, nikoliv celkový počet přijímaných dat.

Allgather

```
int MPI_Allgather(void *sendbuf, int sendcount,
                  MPI_Datatype senddatatype,
                  void *recvbuf, int recvcount,
                  MPI_Datatype recvdatatype,
                  MPI_Comm comm)
```

- Bez určení cílového procesu, výsledek obdrží všichni.
- `recvbuf`, `recvcount`, `recvdatattype` musí být platné pro všechny volající procesy.

Vektorová varianta Gather

```
int MPI_Gatherv(void *sendbuf, int sendcount,
                MPI_Datatype senddatatype,
                void *recvbuf, int *recvcounts,
                int *displs,
                MPI_Datatype recvdatatype,
                int target, MPI_Comm comm)
```

- Odesílatelé mohou odesílat různě velká data (různé hodnoty `sendcount`).
- Pole `recvcounts` udává, kolik dat bylo přijato od jednotlivých procesů.
- Pole `displs` udává, kde v bafru `recvbuf` začínají data od jednotlivých procesů.

Vektorová varianta Allgather

```
int MPI_Allgatherv(void *sendbuf, int sendcount,
                   MPI_Datatype senddatatype,
                   void *recvbuf, int *recvcounts,
                   int *displs,
                   MPI_Datatype recvdatatype,
                   MPI_Comm comm)
```

Scatter

```
int MPI_Scatter(void *sendbuf, int sendcount,
                MPI_Datatype senddatatype,
                void *recvbuf, int recvcount,
                MPI_Datatype recvdatatype,
                int source, MPI_Comm comm)
```

- Posílá různá data **stejné** velikosti všem procesům.

```
int MPI_Scatterv(void *sendbuf, int *sendcounts,
                 int *displs,
                 MPI_Datatype senddatatype,
                 void *recvbuf, int recvcounts,
                 MPI_Datatype recvdatatype,
                 int source, MPI_Comm comm)
```

- Posílá různá data **různé** velikosti všem procesům.

Alltoall

```
int MPI_Alltoall(void *sendbuf, int sendcount,
                 MPI_Datatype senddatatype,
                 void *recvbuf, int recvcount,
                 MPI_Datatype recvdatatype,
                 MPI_Comm comm)
```

- Posílá stejně velké části bafru `sendbuf` jednotlivým procesům v doméně `comm`.
- Proces *i* obdrží část velikosti `sendcount`, která začíná na pozici `sendcount * i`.
- Každý proces má v bafru `recvbuf` na pozici `recvcount * i` data velikosti `recvcount` od procesu *i*.

Vektorová varianta Alltoall

```
int MPI_Alltoallv(void *sendbuf, int *sendcounts,
                  int *sdispls,
                  MPI_Datatype senddatatype,
                  void *recvbuf, int *recvcounts,
                  int *rdispls,
                  MPI_Datatype recvdatatype,
                  MPI_Comm comm)
```

- Pole `sdispl` určuje, kde začínají v bafru `sendbuf` data určená jednotlivým procesům.
- Pole `sendcounts` určuje množství dat odesílaných jednotlivým procesům.
- Pole `rdispls` a `recvcounts` udávají stejné informace pro přijatá data.

Skupiny, komunikátory a topologie

Dělení komunikační domény

```
int MPI_Comm_split(MPI_Comm comm, int color, int key,
                   MPI_Comm *newcomm)
```

- Kolektivní operace, musí být volána všemi.
- Parametr `color` určuje výslednou skupinu/doménu.
- Parametr `key` určuje rank ve výsledné skupině.
  - Při shodě `key` rozhoduje původní rank.

Mapování procesů

Nevýhody "ručního"mapování

- Pravidla mapování určena v době kompilace programu.
- Nemusí odpovídat optimálnímu mapování.
- Nevhodné zejména v případech nehomogenního prostředí.

Mapování přes MPI

- Mapování určeno za běhu programu.
- MPI knihovna má k dispozici (alespoň částečnou) informaci o síťovém prostředí (například počet použitých procesorů v jednotlivých participujících uzlech).
- Mapování navrženo s ohledem na minimalizaci ceny komunikace.

Kartézské topologie

```
int MPI_Cart_create (
  MPI_Comm comm_old, int ndims, int *dims,
  int *periods, int reorder, MPI_Comm *comm_cart)
```

- Pokud je v původní doméně `comm_old` dostatečný počet procesorů, tak vytvoří novou doménu `comm_cart` s virtuální kartézskou topologií.
- Funkci musí zavolat všechny procesy z domény `comm_old`.
- Parametry kartézské topologie
  - `ndims` – počet dimenzí
  - `dims[]` – pole rozměrů jednotlivých dimenzích
  - `periods[]` – pole příznaků cyklické uzavřenosti dimenzí
- Příznak `reorder` značí, že ranky procesů se mají v rámci nové domény vhodně přeuspořádat.
- Nepoužité procesy označeny rankem `MPI_COMM_NULL`.

Koordináty procesorů v kartézských topologiích

- Komunikační primitiva vyžadují rank adresáta.
- Překlad z koordinátů (coords[]) do ranku

```
int MPI_Cart_rank (MPI_Comm comm_cart,
                   int *coords, int *rank)
```

- Překlad z ranku na koordináty
- maxdims je velikost vstupního pole coords[]

```
int MPI_Cart_coord(MPI_Comm comm_cart,
                   int rank, int maxdims,
                   int *coords)
```

Dělení kartézských topologií

```
int MPI_Cart_sub(MPI_Comm comm_cart, int *keep_dims,
                 MPI_Comm *comm_subcart)
```

- Pro dělení kartézských topologií na topologie s menší dimenzí.
- Pole příznaků `keep_dims` určuje, zda bude odpovídající dimenze zachována v novém dělení.

Příklad

- Topologie o rozměrech $2 \times 4 \times 7$.
- Hodnotou `keep_dims` = `{true,false,true}`.
- Vzniknou 4 nové domény o rozměrech 2×7.

Případová studie implementace verifikačního nástroje DiVinE

DiVinE-cluster

DiVinE-Cluster

- Softwarový nástroj pro verifikaci protokolů (LTL MC).
- Problém detekce akceptujícího cyklu v grafu.
- Algoritmy paralelně prochází graf konečného automatu.
- Standardní průzkumová dekompozice.

Algoritmus MAP

- Detekuje, zda existuje akceptující vrchol, který je svůj vlastní předchůdce.

Algoritmus OWCTY

- Označuje vrcholy, které nejsou součástí akceptujícího cyklu
  - nemají přímé předchůdce (neleží na cyklu),
  - nemají akceptující předky (neleží na akceptujícím cyklu).

Co bylo špatně

Obecně

- Při testování na standardním Ethernetu, na malém počtu počítačů, některé nedokonalosti zůstaly neodhaleny.

Konkrétní problémy

- Po inicializaci některých počítačů, aktivita těchto počítačů zabránila inicializaci ostatních počítačů – obrovské prodlevy při startu výpočtu.
- Kombinace posílaných zpráv (bafrování na aplikační úrovni)
  - Příliš časté vylívání – komunikovaly se prázdné bafry.
  - Vylití všech bufferů najednou – náhlá velká zátěž sítě (contention).
  - Používání časových známek a vylívání na základě času – netriviální režie způsobená ověřováním zda uplynulo dané množství času.
- Příliš časté dotazování se na příchozí zprávy.

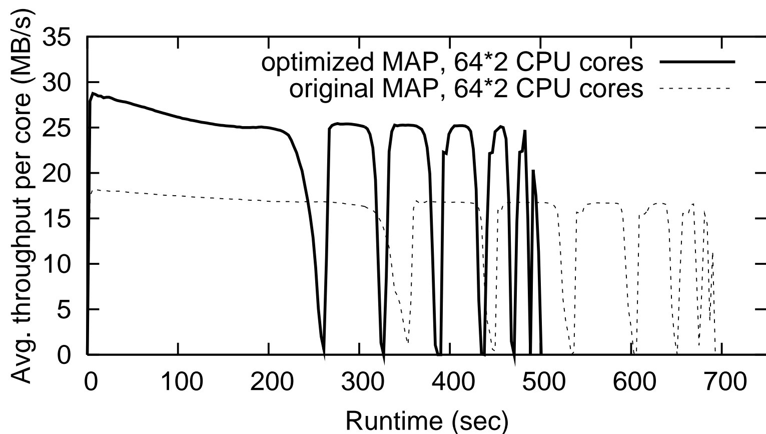
Avg. throughput per core (MB/s)
35
30
25
20
15
10
5
0
0
100
200
300
400
500
600
700
Runtime (sec)
optimized MAP, 64*2 CPU cores
original MAP, 64*2 CPU cores

Výsledky optimalizací

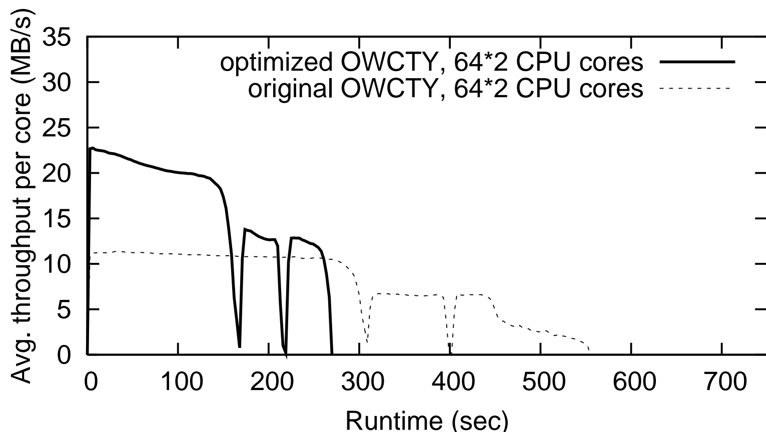

Paralelní výkon nástroje DiVinE

Nodes	Total cores	Runtime (s)		Efficiency	
		MAP	OWCTY	MAP	OWCTY
1	1	956.8	628.8	100%	100%
16	16	73.9	42.5	81%	92%
16	32	39.4	22.5	76%	87%
16	64	20.6	11.4	73%	86%
64	64	19.5	10.9	77%	90%
64	128	10.8	6.0	69%	82%
64	256	7.4	4.3	51%	57%

Tabulka: Efficiency of MAP and OWCTY

Domácí úkol

Zadání

- Napište MPI aplikaci, ve které si participující procesy mezi sebou zvolí jednoho velitele.
- Volba musí být realizována pomocí generování náhodných čísel a jejich výměny mezi jednotlivými MPI procesy.
- Při spuštění tato aplikace vypíše autorovo UČO.
- Kód spustitelný a přeložitelný na `nymfe50`.

Odevzdání

- Neodevzdává se.