Praktikum: Paralleles Programmieren für Geowissenschaftler

Prof. Thomas Ludwig, Hermann Lenhart, Tim Jammer

Dr. Hermann-J. Lenhart
hermann.lenhart@informatik.uni-hamburg.de

MPI Kommunikation:

Ein wesentliches Kriterium für die Entwicklung paralleler Programme besteht darin die Kommunikation effektiv zu gestalten.

Zur Information:

Ein moderner Parallelrechner kann

bis zu **3 Mrd floating-point Operationen pro Sekunde** berechnen,

aber nur etwa **10 Millionen Wörter pro Sekunde**

zwischen den Prozessen verschicken!

(Using MPI; Gropp,Lusk,Skjellm, 1999)

MPI Standard Send / Receive = Blocking Communication

MPI_SEND Programm läuft erst weiter nachdem

Send-Buffer zur Wiederverwendung gelehrt wurde

MPI_RECV Programm läuft erst weiter nachdem

Receive-Buffer gefüllt ist, d.h. die Daten stehen zur Verfügung

Die Ausführung der Kommunikation ist abhängig von der Größe der Nachricht

und der Größe des Systembuffers .

Blockierende Kommunikaton ist einfach einzusetzen, aber anfällig für Deadlocks!

„It is incorrect for an MPI program to require buffering in MPI send“ (Groop,Lusk & Skjellum)

Programmbeispiel für Deadlock I

```
program main

        use mod_communication
        use mpi
        implicit none

        integer :: ierr, rank, numProcesses,, root=0, array_size, i, max_size=20000
        real, dimension(:), allocatable :: array

        call MPI_INIT(ierr)
        call MPI_COMM_RANK(MPI_COMM_WORLD, rank, ierr)
        call MPI_COMM_SIZE(MPI_COMM_WORLD, numProcesses, ierr)

                do i=1,max_size
                        array_size = i

                        call initialize_array(array_size, array)            => allocate(array(array_size))

                        call deadlock(numProcesses, rank, array)

                        if (rank == root) print*,'Program finished successfully: ', i, ' array entries', i*4, ' bytes'

                        deallocate(array)
                end do

        call MPI_FINALIZE(ierr)

end program main
```

Programmbeispiel für Deadlock II

```
subroutine deadlock(numProcesses, rank, array)

        integer, intent(in) :: numProcesses, rank
        real, dimension(:), intent(in) :: array
        integer :: partner1, partner2, array_size, ierr, status(MPI_STATUS_SIZE)

        array_size = size(array)

        call calc_partner(rank, numProcesses, partner1, partner2)

        call MPI_SEND(array, array_size, MPI_REAL, partner1, rank, MPI_COMM_WORLD, ierr)
        call MPI_RECV(array, array_size, MPI_REAL, partner2, partner2, MPI_COMM_WORLD, status, ierr)

end subroutine deadlock


subroutine calc_partner(rank, numProcesses, partner1, partner2)
        integer, intent(in) :: rank, numProcesses
        integer, intent(out) :: partner1, partner2
        partner1 = rank+1
        partner2 = rank-1
        if (rank == numProcesses-1) then
                partner1 = 0
        else if (rank == 0) then
                partner2 = numProcesses-1
        end if
end subroutine calc_partner
```

Programmbeispiel für Deadlock IIIA

```
subroutine calc_partner(rank, numProcesses, partner1, partner2)
        integer, intent(in) :: rank, numProcesses
        integer, intent(out) :: partner1, partner2
        partner1 = rank+1
        partner2 = rank-1
        if (rank == numProcesses-1) then
                partner1 = 0
        else if (rank == 0) then
                partner2 = numProcesses-1
        end if
end subroutine calc_partner
```

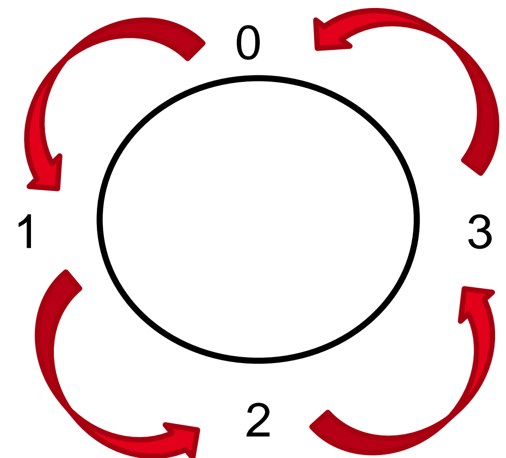

Beispiel: numProcesses = 4

	SEND	Dest	Tag
rank = 0		1	0
rank = 1		2	1
rank = 2		3	2
rank = 3		0	3

Programmbeispiel für Deadlock IIIB

```
subroutine calc_partner(rank, numProcesses, partner1, partner2)
        integer, intent(in) :: rank, numProcesses
        integer, intent(out) :: partner1, partner2
        partner1 = rank+1
        partner2 = rank-1
        if (rank == numProcesses-1) then
                partner1 = 0
        else if (rank == 0) then
                partner2 = numProcesses-1
        end if
end subroutine calc_partner
```

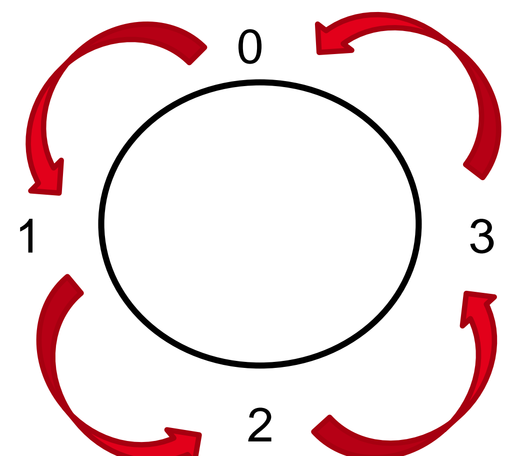

Beispiel: numProcesses = 4

	SEND	Dest	Tag	RECV	Source	Tag
rank = 0		1	0		3	3
rank = 1		2	1		0	0
rank = 2		3	2		1	1
rank = 3		0	3		2	2

Programmbeispiel für Deadlock VI

```
subroutine deadlock(numProcesses, rank, array)

        ........
        array_size = size(array)

        call calc_partner(rank, numProcesses, partner1, partner2)

        call MPI_SEND(array, array_size, MPI_REAL, partner1, rank, MPI_COMM_WORLD, ierr)
        call MPI_RECV(array, array_size, MPI_REAL, partner2, partner2, MPI_COMM_WORLD, status, ierr)

end subroutine deadlock
```

Beispiel: numProcesses = 4

	SEND	Dest	Tag	RECV	Source	Tag
rank = 0		1	0		3	3
rank = 1		2	1		0	0
rank = 2		3	2		1	1
rank = 3		0	3		2	2

Kein Deadlock durch Anordnung der send-receive Befehle

```
if (mod(rank,2) == 0) then

        call MPI_SEND(array, array_size, MPI_REAL, partner1, rank, MPI_COMM_WORLD, ierr)
        call MPI_RECV(array, array_size, MPI_REAL, partner2, partner2, MPI_COMM_WORLD, status, ierr)

else

        call MPI_RECV(array, array_size, MPI_REAL, partner2, partner2, MPI_COMM_WORLD, status, ierr)
        call MPI_SEND(array, array_size, MPI_REAL, partner1, rank, MPI_COMM_WORLD, ierr)

end if
```

Beispiel: numProcesses = 4

	SEND	Dest	Tag	RECV	Source	Tag
rank = 0		1	0		3	3
rank = 1		2	1		0	0
rank = 2		3	2		1	1
rank = 3		0	3		2	2

Kombinierter Send-Receive Befehl gegen Deadlocks

```
subroutine sendrecv(numProcesses, rank, array)

        integer, intent(in) :: numProcesses, rank
        real, dimension(:), intent(in) :: array
        integer :: partner1, partner2, array_size, ierr, status(MPI_STATUS_SIZE)

        array_size = size(array)

        call calc_partner(rank, numProcesses, partner1, partner2)

        call MPI_SENDRECV(array, array_size, MPI_REAL, partner1, rank, array, array_size, MPI_REAL, &
                &    partner2, partner2, MPI_COMM_WORLD, status, ierr)

end subroutine sendrecv
```

Erlaubt das Versenden und Empfangen von Daten
ohne Sorge vor Deadlock
aus Mangel an Bufferkapazität!

Hinweis: Es gibt keinen Tag!

MPI nicht blockierende Kommunikation

Eine weitere Option bietet die nicht-blockierende Kommunikation
(non-blocking communication)

Zwischen dem Senden (nach Füllen des Buffers) kann dann weiter gerechnet werden
=> Umgehen der Latenz in der Kommunikation

Unabhängig vom Zeitpunkt des Füllens des Buffers entscheidet der Programmier
wann die Nachricht mit dem receive Befehl empfangen wird.

Nachteil: Programmierer muss Abfragen einfügen um die Abwicklung zu checken.

MPI non-blocking Send

MPI_ISEND(Message, Count, Datatype, Dest, Tag, Comm, request, Ierror)

z.B:

Call MPI_ISEND(temp, 1, MPI_Real, dest, tag, MPI_COMM_World, req, Ierror)

temp	Adresse des Sendepuffers; Real :: temp
1	Count – Anzahl der Elemente im Puffer
MPI_Real	Datentyp des gesendeten Elementes
dest	Angabe des Ranges des Zielprozesses; integer :: dest
tag	Nachrichtenkennung; integer :: tag
MPI_COMM_World	Kommunikator (Gruppe, Kontext)
request	Handle; integer :: req

, Ierror

MPI non-blocking Receive

MPI_IRECV(Message, Count, Datatype, Source, Tag, Comm, request, Ierror)

z.B:

Call MPI_IRECV(temp, 1, MPI_Real, source, tag, MPI_COMM_World, req, Ierror)

temp	Adresse des Sendepuffers; Real :: temp
1	Count – Anzahl der Elemente im Puffer
MPI_Real	Datentyp des gesendeten Elementes
source	Angabe des Ranges des Sourceprozesses; integer :: source
tag	Nachrichtenkennung; integer :: tag
MPI_COMM_World	Kommunikator (Gruppe, Kontext)
request	Handle; integer :: req **!!! Kein Status** , ierror

Dr. Hermann-J. Lenhart
hermann.lenhart@informatik.uni-hamburg.de

MPI non-blocking Kommunikation Statusabfrage

Zur Abfrage des **Status der Nachricht** , gibt es das Wait Kommando:

MPI_WAIT(request,**status**, Ierror)

Integer :: request, **status(MPI_STATUS_SIZE)**, ierror

D.h. die Statusabfrage wir quasi aus dem Receive Befehl „ausgelagert“!

MPI non-blocking Kommunikation Statusabfrage

Bei der Verwendung von ISEND und IRECV ergibt sich folgende Abfolge der Befehle :

Call MPI_ISEND(Message, Count, Datatype, Dest, Tag, Comm, request, Ierror)

….. Der Prozess rechnet weiter

Call MPI_IRECV(Message, Count, Datatype, Source, Tag, Comm, request, Ierror)

Call WAIT (request, status, ierr)

Geht weiter wenn die ISEND-Nachricht angekommen ist

und der Buffer wieder frei ist und neu belegt werden kann.

Dr. Hermann-J. Lenhart
hermann.lenhart@informatik.uni-hamburg.de

Programmbeispiel für non-blocking Kommunikation

```
subroutine non_blocking_communication(numProcesses, rank, array)

        integer, intent(in) :: numProcesses, rank
        real, dimension(:), intent(in) :: array
        integer :: partner1, partner2, array_size, ierr, request, status(MPI_STATUS_SIZE)

        array_size = size(array)

        call calc_partner(rank, numProcesses, partner1, partner2)

        call MPI_ISEND(array, array_size, MPI_REAL, partner1, rank, MPI_COMM_WORLD, request, ierr)
        call MPI_IRECV(array, array_size, MPI_REAL, partner2, partner2, MPI_COMM_WORLD, &
        &   request, ierr)

        call MPI_WAIT(request, status, ierr)

end subroutine non_blocking_communication
```

MPI non-blocking Kommunikation Statusabfrage II

Hinweis:

Die WAIT Routine blockiert den Programmablauf

bis die Kommunikation beendet ist.

d.h. man kann zwischen iSend und iRecv z.B. Berechnungen einschieben

bis WAIT erreicht wird.

Ein WAIT unmittelbar nach einer non-blocking Kommunikation

wirkt wie eine blocking Kommunikation !

MPI non-blocking Kommunikation Statusabfrage III

Zur Abfrage des aktuellen **Status der Nachricht zur Programmsteuerung** gibt es das TEST Kommando:

```
MPI_TEST(request, flag, status, Ierror)
Integer  :: request,  status(MPI_STATUS_SIZE), ierror
Logical :: flag
```

Gibt einen TRUE Wert zurück sobald die Kommunikation abgeschlossen wurde.

```
Do while ( .not. flag)
     ........
   call MPI_TEST(request, flag, status, Ierror)
enddo
```

Zusammenfassung

- Achte auf effektive Kommunikation - 3 Mrd. floating point op./s vs. 10 Mio .Wörter /s

- Standard (blocking) send und recv-Befehle sind anfällig für Deadlocks

- Kombinierter Sendrecv-Befehl umgeht dieses Problem, aber immer noch Latenz

- Non-Blocking Kommunikation mittels Isend und Irecv-Befehlen
  erlaubt eine bessere Verzahnung von Berechnung und Kommunikation

- Allerdings muss der Nachrichtenaustausch genau bekannt sein!

Danke das wars!