Fakulteta za informacijske študije
Faculty of information studies

Kreativno jedro: Simulacije
Creative core: Simulations

Kampus šola HPC 2014

Osnove MPI
v jeziku C

Matjaž Depolli
Odsek za komunikacijske sisteme
Inštitut „Jožef Stefan“

Naložba v vašo prihodnost
OPERACIJO DELNO FINANCIRA EVROPSKA UNIJA
Evropski sklad za regionalni razvoj

REPUBLIKA SLOVENIJA
MINISTRSTVO ZA IZOBRAŽEVANJE, ZNANOST IN ŠPORT

Pregled predavanja

- MPI – kaj, zakaj, kako
- Splošno o medprocesni komunikaciji
  - Proces
  - Vrste komunikacije
  - Sinhronizacija
- Priprava MPI okolja
- Poganjanje MPI programov
- MPI Hello world
- Sinhrona komunikacija
- Skupinska komunikacija
- Asinhrona komunikacija

Kaj je MPI

- *MPI (Message-Passing Interface) is a message-passing library interface specification*
- Definira **model** za prenos informacij med oddaljenimi računalniki
- Podan je kot **specifikacija knjižnice** – vse MPI operacije so v obliki funkcij in tipov za posamezni jezik, za katerega je implementacija knjižnice namenjena
- Za mnogo jezikov: **C, FORTRAN**, C++, Java, Python, Perl, R, ...
- Obstaja več implementacij MPI knjižnice (OpenMPI, MPICH)
- De facto standard, specifikacijo ureja MPI forum

Cilji MPI

- Preprosta uporaba
- Prenosljivost
- Omogoča podporo strojne opreme
- Praktičnost, učinkovitost, skalabilnost
- Fleksibilnost (tudi za heterogena okolja)
- Praktična implementacija za C in FORTRAN
- Neodvisnost od jezika
- Zanesljiva komunikacija

Kaj sestavlja MPI implementacijo

- Izvajalno okolje (runtime environment)
- Knjižnjica funkcij, definicij tipov in struktur
- Integracija z okoljem in operacijskim sistemom (npr. procesiranje signalov)

Komunikacija

- Preko sporočil
- Enemu ali več naslovnikom
- Sinhrono / asinhrono
- Z / brez medpomnilnika
- Naslovnik je drug **proces** – isti / drug računalnik

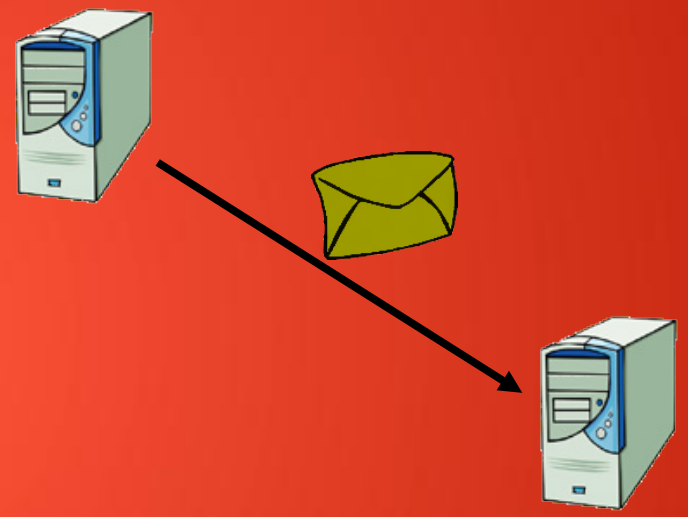

Proces

- Je program v izvrševanju
- Je okolje na računalniku, znotraj katerega se izvaja program
  - Niti programa
  - Bloki pomnilnika (dovoljenje za dostop)
  - Odprte datoteke in ostali sistemski viri
  - Ima na voljo komunikacijo s operacijskim sistemom
  - Lahko upravlja z večimi jedri / procesorji / pospeševalniki
  - Teče na enem računalniku

Proces in komunikacija – poenostavljeno

- CPU izvaja ukaze iz pomnilnika (proces v ožjem smislu)
- Koko komunicirati z njim? Zamenjamo vsebino pomnilnika, ki ga bere
- Procesu ni treba čakati

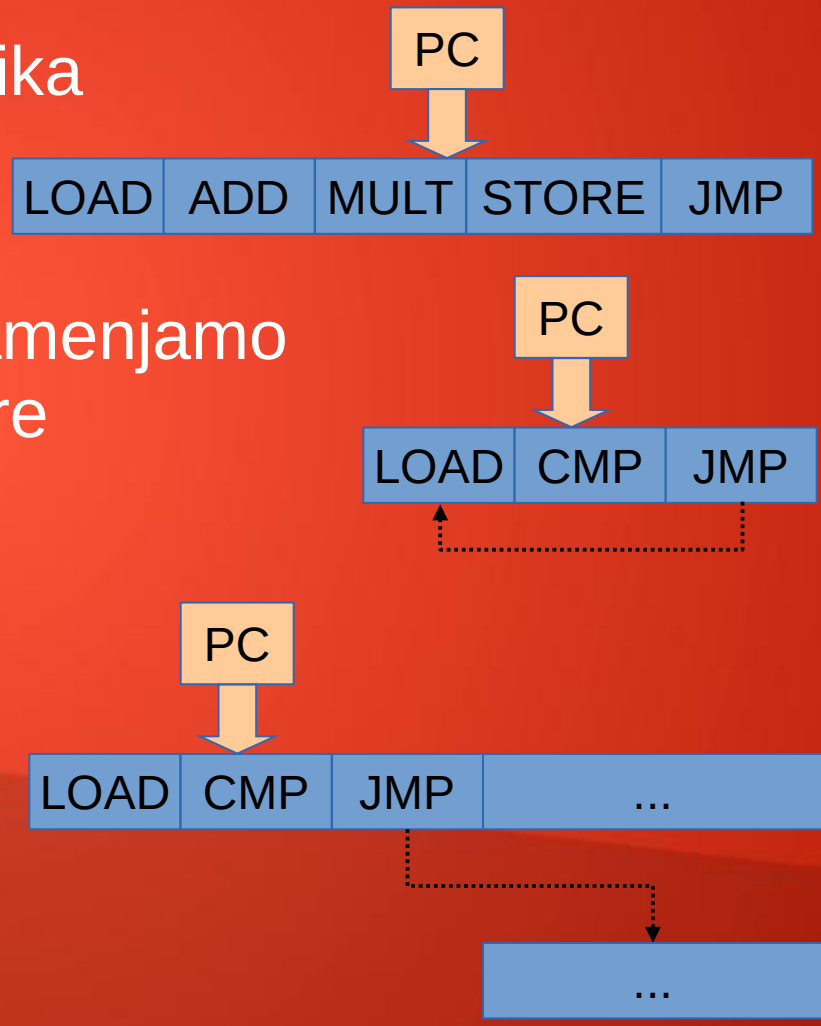

Sinhronizacija

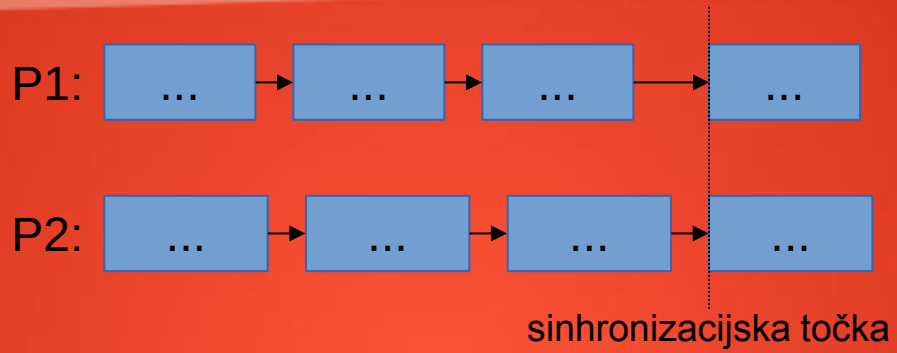

- Oba (vsi) procesi (niti) morajo končati neko nalogo preden gredo lahko na naslednjo

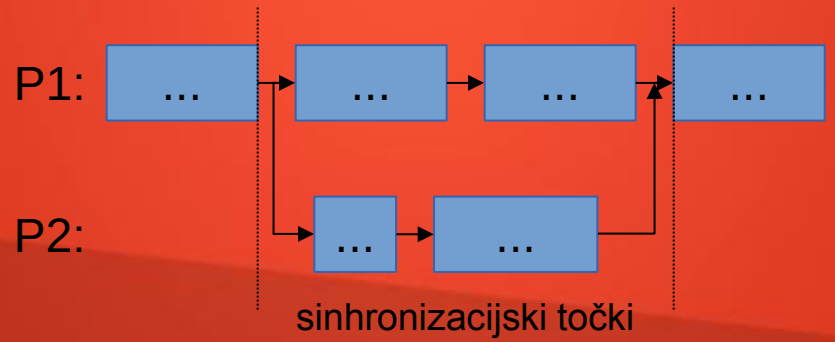

Sinhrono pošiljanje in sprejemanje

- Usklajeno
- Najbolj enostaven in varen model
- Vedno nastopata v paru pošiljanje in sprejemanje
- Vsaj en proces ponavadi čaka

- MPI_Send
- MPI_Recv

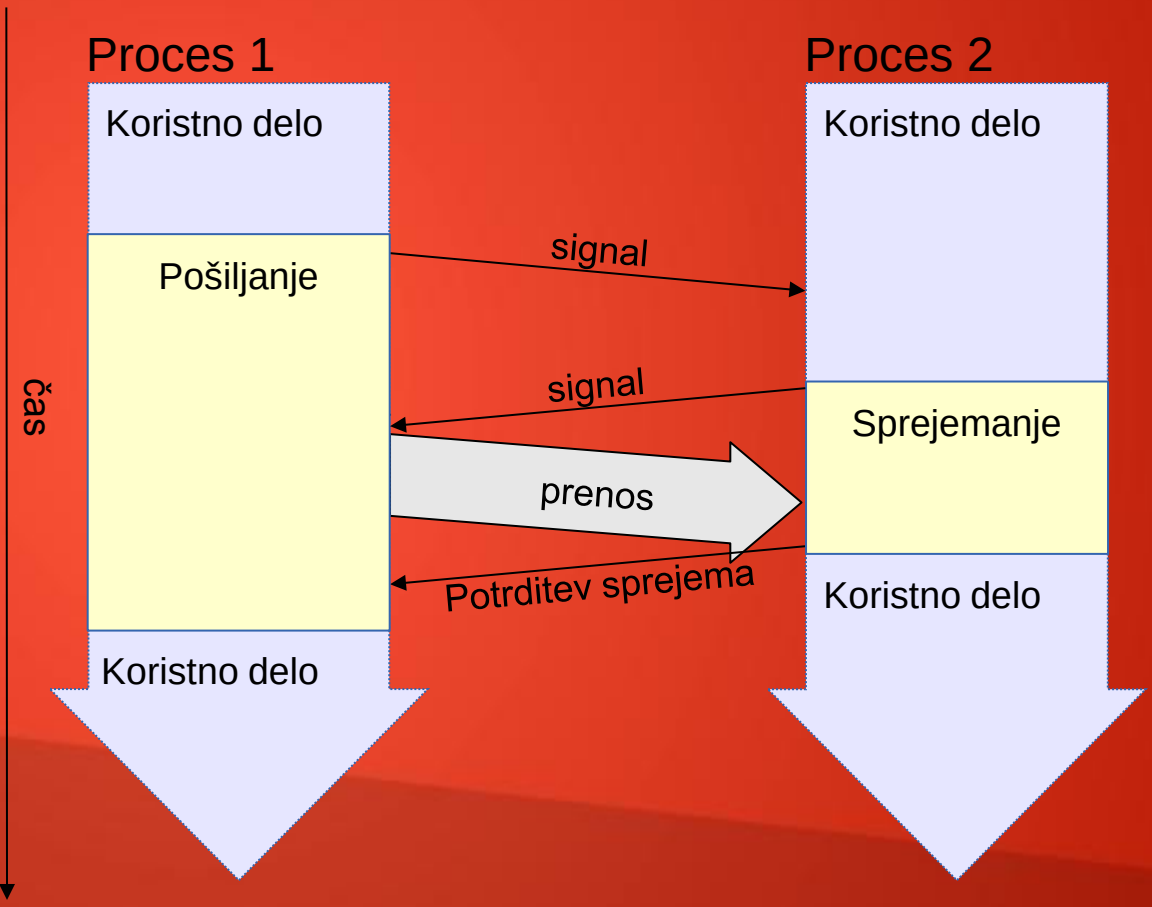

Deadlock

- Vsako pošiljanje ali sprejemanje blokira proces
- Končana komunikacija odblokira proces
- Neprevidna uporaba lahko povzroči 'obešanje' procesov
- Sporočila so prejeta v istem vrstnem redu kot so poslana

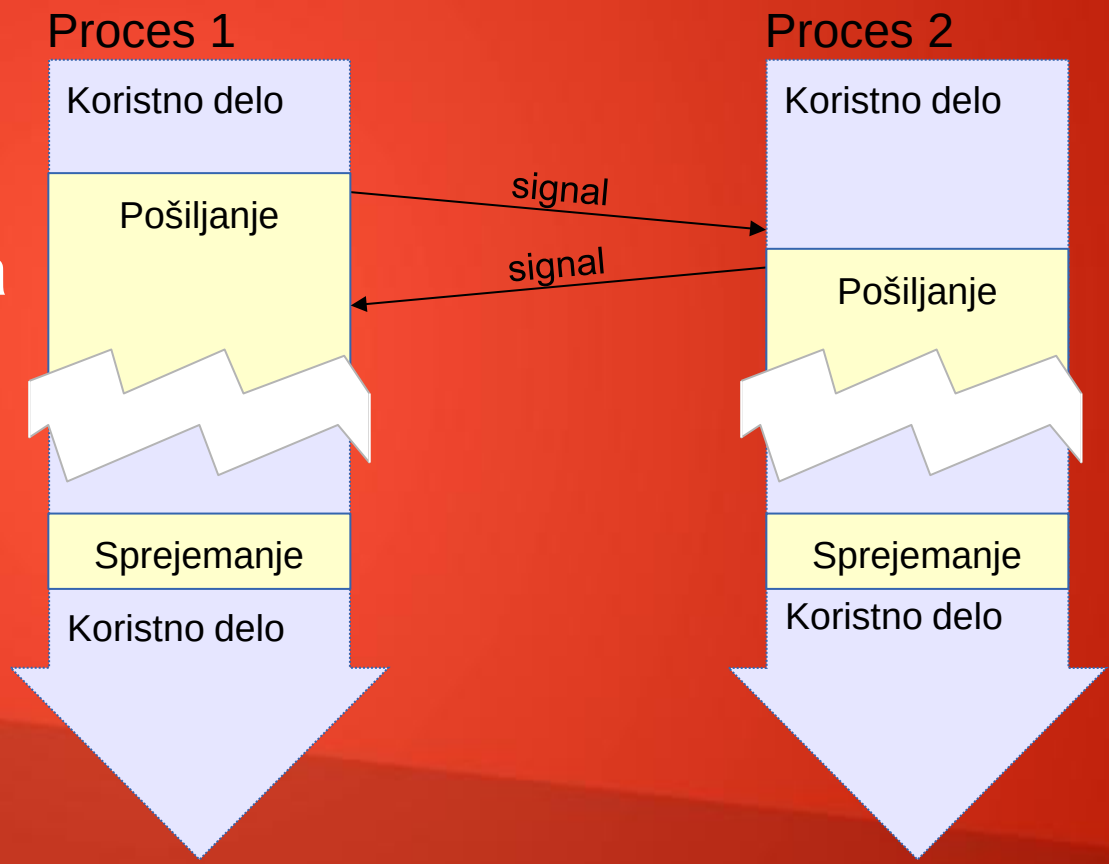

Sinhrono pošiljanje in sprejemanje

- Pošiljanja in sprejemanja si lahko sledijo – izmenjava podatkov
- Predstavljajo pogost vzorec uporabe
- MPI pozna zato optimirano funkcijo
- MPI_Sendrecv

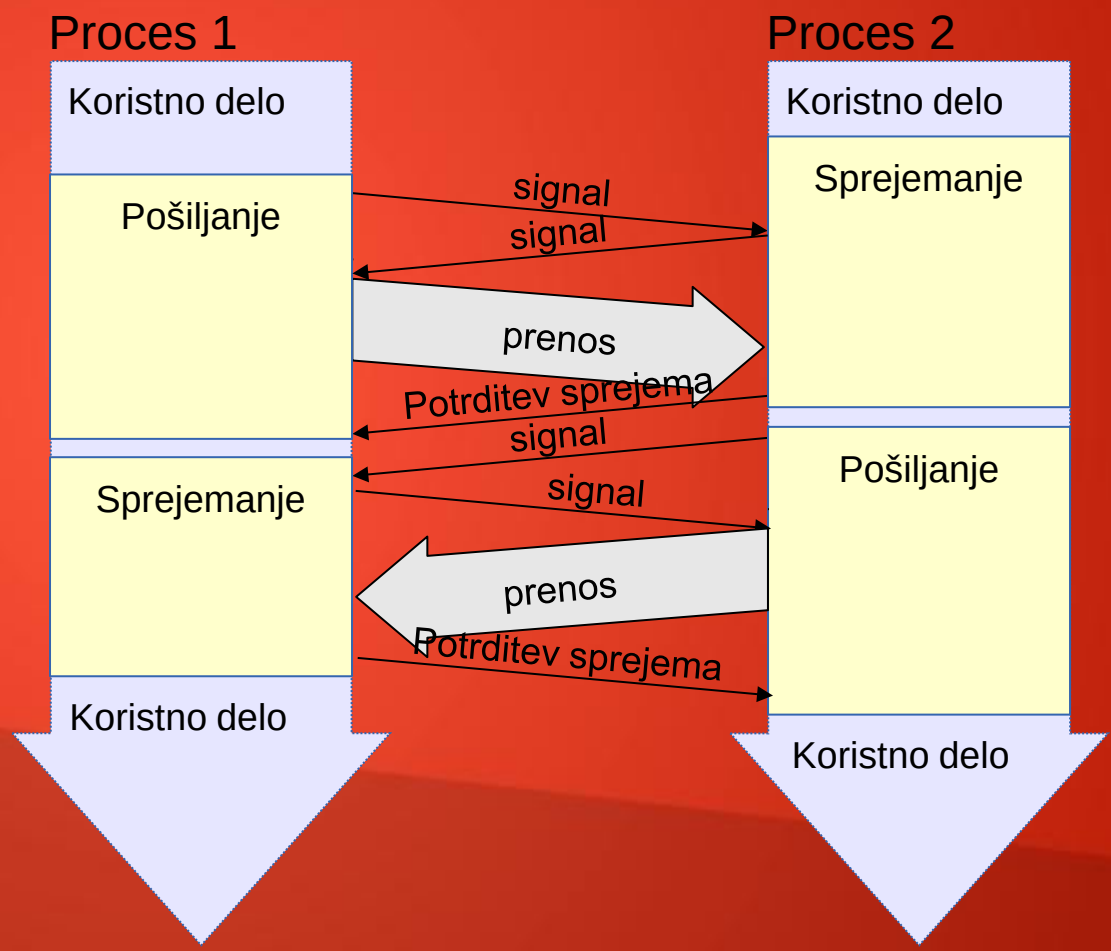

Asinhrona komunikacija

- Vmesnik (MPI), ki skrbi za hrambo sporočil v tranziciji
- Ne blokira procesa
- Sporočilo se ne sme zbrisati, dokler ni preverjeno poslano

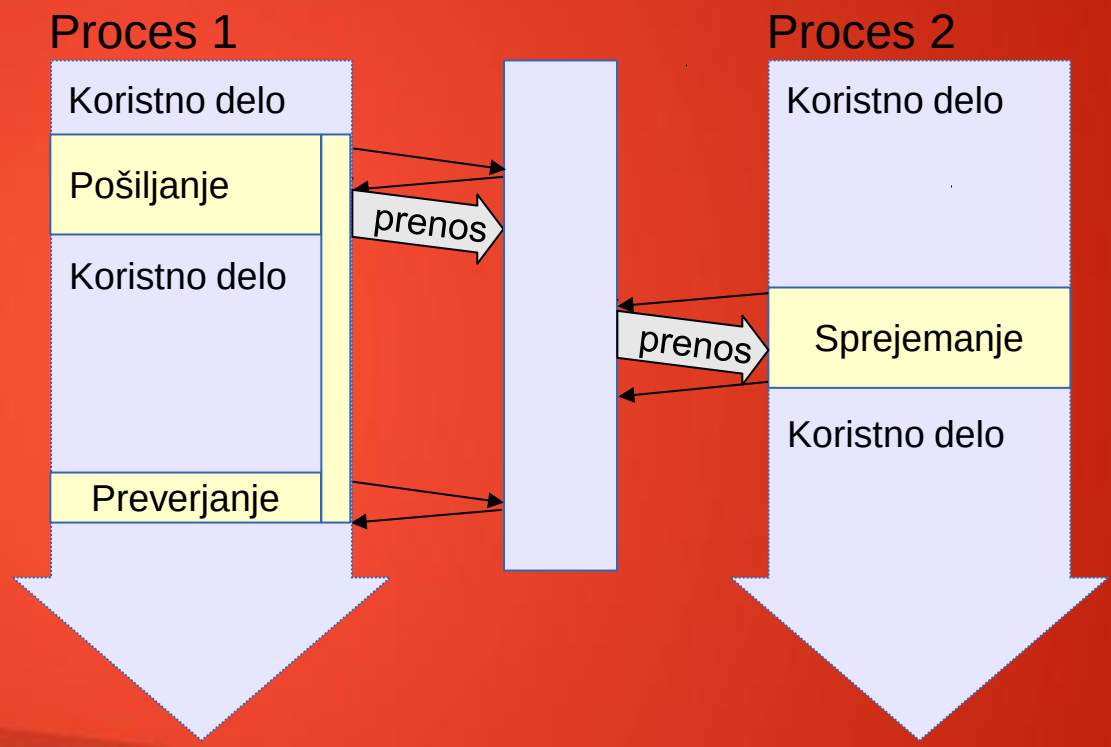

- MPI_Isend
- MPI_Wait ali MPI_Test

Asinhrona komunikacija

- Podobno velja za asinhron sprejem sporočil
- Prostor za sporočilo mora obstajati ob pripravi
- uspešno preverjanje pomeni veljavno sporočilo v tem prostoru

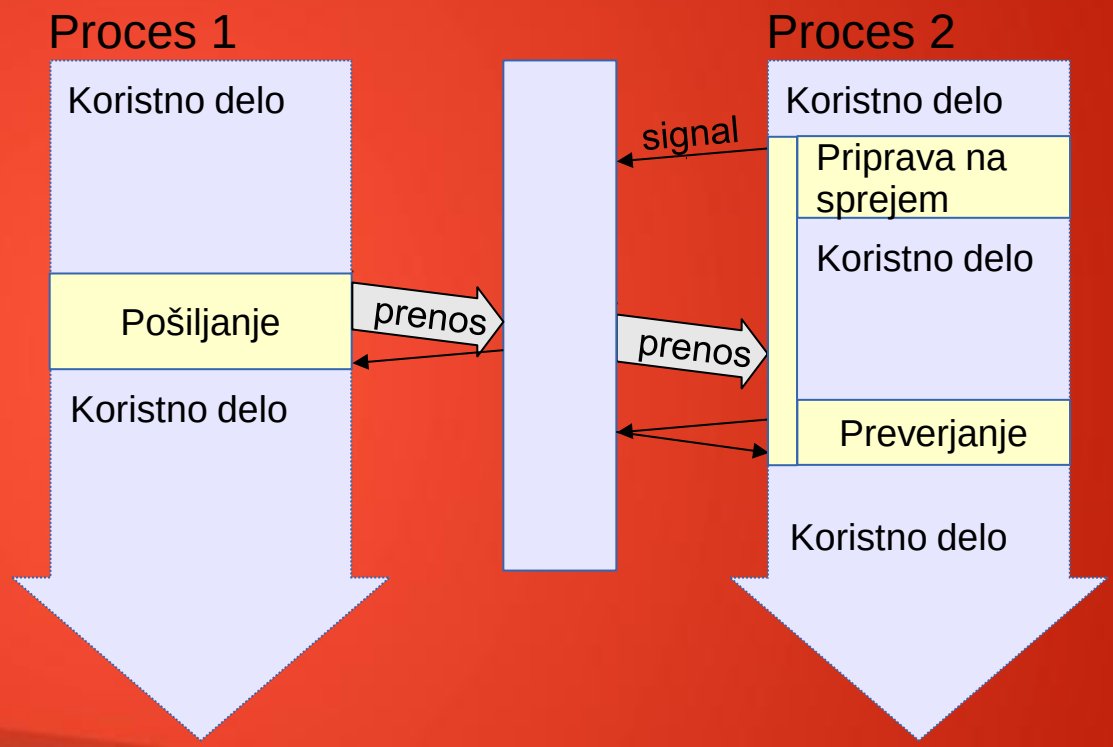

- MPI_Irecv
- MPI_Wait ali MPI_Test

MPI send in receive

- Standard / Immediate + Buffered + Ready + Persistant
- MPI_Send (standardni, blokirajoči – a ne vedno!)
- MPI_Isend (I -> Immediate)
- MPI_Ibsend (B -> Buffered)
- MPI_Rsend (R -> Ready)
- MPI_Ssend (S -> Synchronous)
- MPI_Send_init (isto spremenljivko se bo pošiljalo pogosto)

*Glavna sta MPI_Send in MPI_Isend, ostalo so 'optimirane' verzije za posebne primere

Blokirajoči in neblokirajoči ukazi

- Direktno asociirani z sinhrono in asinhrono komunikacijo
- Med seboj jih lahko mešamo
- Blokirajoči – enostavni, zanesljivi, brez presenečenj
- Neblokirajoči – omogočajo prekrivanje komunikacije in računanja
- V ozadju se dogajata še dodeljevanje in sproščanje sistemskih virov – zato neblokirajoči ukazi nastopajo v paru z ukazoma Wait in Test.

Sprejemanje sporočila

- Dve skrajnosti glede pričakovanega sporočila
  - Točno določen naslovnik, tip sporočila, oznaka
  - Popolnoma nedoločen naslovnik, tip, oznaka
- Možnosti sprejema
  - Blokirajoč sprejem
  - Testiranje za sprejem (ali obstaja kako sporočilo / ali obstaja točno določeno sporočilo?)
  - Čakanje na sporočilo
  - Čakanje na signal o sporočilu (probe)

Kolektivne operacije

- 1 -> n
  - Broadcast
  - Scatter
- n -> 1
  - Reduce (add, mult, min, max)
  - Gather
- n -> n
  - Allgather
  - Allreduce

Operacije so lahko optimirane na topologijo omrežja

Optimiranje kolektivnih operacij

- Vzemimo primer MPI_Scatter in regularno mrežo kot na sliki
- Kako sploh poslati sporočilo nepovezanemu vozlišču?
- Kaj je hitrejše od
  for (int i=1; i<n; ++i)
      MPI_Send(…, i, …)

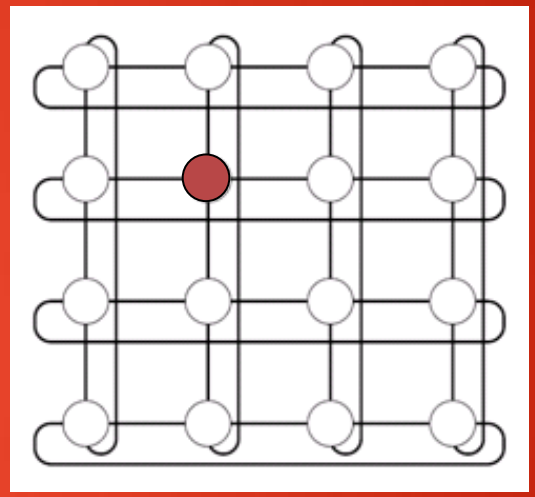

- Bližnjim sosedom se pošlje sporočila za njih in za njihove sosede, nato oni pošljejo drugi del sporočila dalje

Asinhrona komunikacija

- Proti pričakovanjem je precej bolj zapletena
- Nove nevarnosti nepremišljenega programiranja
  - Puščanje (*leaking*) resursov
  - Neuravnovešeno pošiljanje/sprejemanje
  - Procesi ostanejo pozabjeni v pošiljanju ali čakanju
- Bolj vsestranska
  - MPI_Irecv + MPI_Wait = MPI_Recv
  - MPI_Isend + MPI_Wait = MPI_Send

MPI_Wait

- Kdaj konča?
  - Pri MPI_Isend – ko MPI ne dostopa več do pomnilnika s sporočilom
  - Pri MPI_Irecv – ko MPI sporočilo zapiše v podan pomnilnik
- Več variant – waitall, waitsome, waitany
- MPI_Test je neblokirajoča različica MPI_Wait

MPI okolje

- Komunikator (*communicator*)
  - Definira množico procesov, ki lahko komunicirajo med seboj
  - Identifikacija procesov v komunikatorju preko ranka (*rank*)
  - MPI_COMM_WORLD je privzet komunikator
- Poročanje o napakah
  - Je vezano na komunikator
  - Funkcije vračajo *error code*
  - Privzeto je »poenostavljeno« delovanje – napake so *fatal*

MPI okolje

- Datoteka »hosts« vsebuje imena vozlišč za izvedbo programa
- Ukaz mpirun
  mpirun -n 4 -hostfile hosts ./ime_programa parametri_programa
- Funkciji MPI_Init in MPI_Finalize

Na HPCFS

- module load openmpi
- Ukaz bsub
  bsub -o output.txt -e error.txt -n 4 mpirun ./ime_programa parametri_programa

»Hello world« v MPI

```
#include <mpi.h>
#include <stdio.h>

int main(int argc, char **argv) {
    int rank, size;
    char name[MPI_MAX_PROCESSOR_NAME];
    int sLen;
    MPI_Init(&argc, &argv);
    MPI_Comm_rank(MPI_COMM_WORLD, &rank);
    MPI_Comm_size(MPI_COMM_WORLD, &size);
    MPI_Get_processor_name(name, &sLen);
    printf("%s: rank %d of %d\n", name, rank, size);
    MPI_Finalize();
}
```

- #include <mpi.h>
- Funkcije:
  - MPI_Init in MPI_Finalize
  - MPI_Comm_rank
  - MPI_Comm_size
  - MPI_Get_processor_name
- Prevedemo z *mpicc*
- Izhod:

```
cn52: rank 0 of 3
cn52: rank 1 of 3
cn52: rank 2 of 3
```

MPI send in recv

```
MPI_Send(&count,                    - pomnilnik, kjer se nahaja sporočilo
         1,                         - število elementov sporočila
         MPI_INT,                   - tip elementa
         dest,                      - destinacija (rank ciljnega procesa)
         tag,                       - oznaka
         MPI_COMM_WORLD);           - komunikator
MPI_Recv(&count,                    - pomnilnik, kamor se bo shranilo sporočilo
         1,                         - število elementov sporočila
         MPI_INT,                   - tip elementa
         source,                    - izvor (rank izvornega procesa)
         tag,                       - oznaka
         MPI_COMM_WORLD,            - komunikator
         &status);                  - statusna struktura (vsebuje: source, tag, error)
```

Nevarno sinhrono

```
...
int rank, size;
int source, dest, tag=0xf00d;
int sendBuf, recvBuf;
MPI_Status status;
MPI_Init...
source = (rank - 1) % size;
dest = (rank + 1) % size;
MPI_Send (&sendBuf, 1, MPI_INT, dest,   tag, MPI_COMM_WORLD);
MPI_Recv (&recvBuf, 1, MPI_INT, source, tag, MPI_COMM_WORLD, &status);
printf("Process %3i sent %5i and received %5i\n", rank, sendBuf, recvBuf);
MPI_Finalize...
```

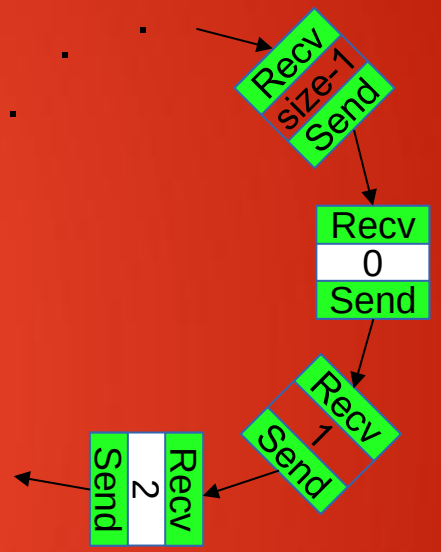

Nevarno sinhrono

- Zakaj nevarno?
  - Vsi procesi imajo isto zaporedje send in recv ukazov.
  - Lahko povzroči 'deadlock'
- Kdaj in zakaj deluje?
  - Na majhnih sporočilih
  - Ker MPI skopira majhna izhodna sporočila v svoj medpomnilnik (buffer)
- Kako elegantno obiti težavo?
  - Asinhrona sporočila
- Vrstni red:
  - Pripravimo prostor za sprejem
  - Napovemo sprejem
  - Pošljemo sporočilo
  - Počakamo sprejem

Varno sinhrono

```
...
int rank, size, sLen;
int source, dest, tag=0xf00d;
int sendBuf, recvBuf;
MPI_Status status[2];
MPI_Request request[2];
MPI_Init...
source = (rank - 1) % size;
dest = (rank + 1) % size;
MPI_Irecv(&recvBuf, 1, MPI_INT, source, tag, MPI_COMM_WORLD, &request[0]);
MPI_Isend(&sendBuf, 1, MPI_INT, dest,   tag, MPI_COMM_WORLD, &request[1]);
MPI_Waitall(2, request, status);
printf("Process %3i sent %5i and received %5i\n", rank, sendBuf, recvBuf);
MPI_Finalize...
```

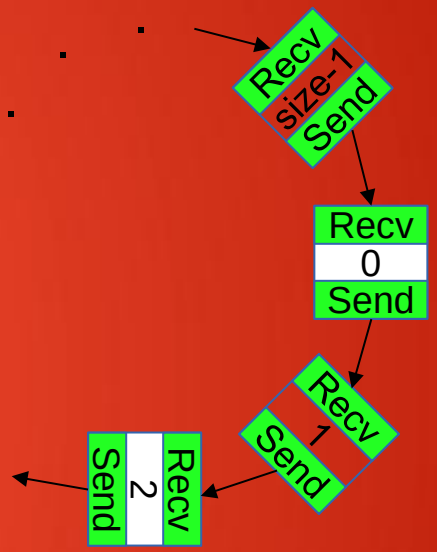

Varno sinhrono 2

```
...
int rank, size;
int source, dest, count, tag=0xf00d;
MPI_Status status;
MPI_Init ...
source = (rank - 1) % size;
dest = (rank + 1) % size;
if (rank == 0) {
    count = 1;
    MPI_Send(&count, 1, MPI_INT, dest,   tag, MPI_COMM_WORLD);
    MPI_Recv(&count, 1, MPI_INT, source, tag, MPI_COMM_WORLD, &status);
    printf("The result of the count = %i\n", count);
} else {
    MPI_Recv(&count, 1, MPI_INT, source, tag, MPI_COMM_WORLD, &status);
    count += 1;
    MPI_Send(&count, 1, MPI_INT, dest,   tag, MPI_COMM_WORLD);
}
MPI_Finalize...
```

Izhod (na 30 procesih):

The result of the count = 30

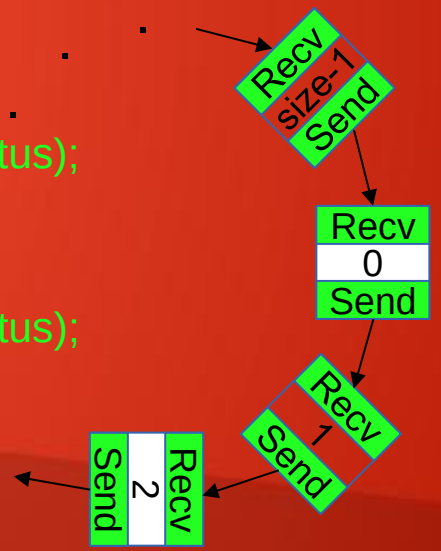

Asinhrona komunikacija

- Vektor (tabela) števil, iščemo določeno vrednost

```
vecSize = 100000000; // 100 M
    int vec*;
    vec = malloc(sizeof(int)*vecSize);
```

- Zaporedni program:

```
for (int i = 0; i < vecSize; ++i)
      if (vec[i] == vrednost) printf("%d", i);
```

- Vzporedni program:
  - Razdelimo vektor med vse procese
  - Vsak proces preišče svoj del vektorja
  - Ko prvi konča obvesti vse ostale
  - Rezultat vrne procesu 0

"Master-slave" princip

- Proces 0 je glavni
- Ostali izvajajo njegove ukaze
- Dodatno: med seboj se smejo obvestiti, da so končali

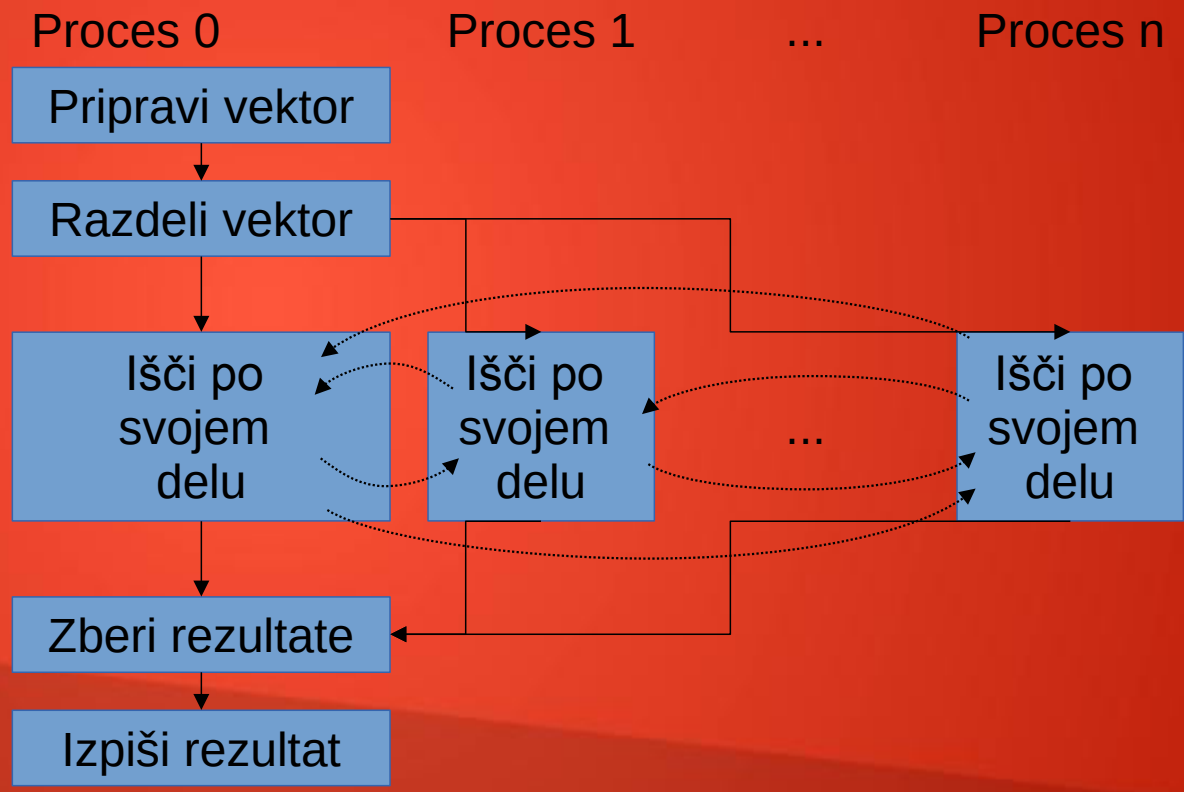

Primer za asinhrono komunikacijo

- Vhod: tabela (vektor) števil
- Problem: iskanje podane vrednosti – na katerem indeksu se nahaja določena vrednost
- Če je najdenih vrednosti več, ni pomembno katero se vrne kot rezultat

- Vektor se razdeli med procesorje
- Vsak procesor išče na svojem odseku in vrne rešitev glavnemu
  - Takoj ko nekdo najde rešitev se sme prekiniti iskanje
- Glavni zbere rešitve in vrne rezultat
  - Rezultat je lahko prva prispela rešitev

Primer za asinhrono komunikacijo

- Vsi procesorji iščejo rešitev na svojem odseku
- Vsi procesorji poslušajo (MPI_Irecv)
- Ko procesor najde rešitev, to sporoči vsem
- Procesorji ugotovijo, da je nekdo že našel rešitev (MPI_Test) in končajo svoje izvajanje
- Glavni proces počaka da vsi končajo izvajanje

Asinhrona komunikacija

```
int rank, size, tag_fail = 0xbad, tag_success = 0xcce;
MPI_Status status;
MPI_Request request, *retRequest;
int done, nValues, luckyProcess = -1;
int vecSize = 400000;
int* vec;
int i, iMax, j, result;
MPI_Init(&argc, &argv);
MPI_Comm_rank(MPI_COMM_WORLD, &rank);
MPI_Comm_size(MPI_COMM_WORLD, &size);
retRequest = malloc(size * sizeof(MPI_Request));
vec = malloc(vecSize * sizeof(int));
if (rank == 0) {
    memset(vec, 0, sizeof(int)*vecSize);
    vec[1987654321 % vecSize] = 42;
}
```

Asinhrona komunikacija

```
MPI_Bcast(vec, vecSize, MPI_INT, 0, MPI_COMM_WORLD);
MPI_Irecv(&result, 1, MPI_INT, MPI_ANY_SOURCE, MPI_ANY_TAG, MPI_COMM_WORLD, &request);
nValues = (vecSize+size-1)/size;
i = rank*nValues;
iMax = i + nValues;
if (iMax > vecSize)
    iMax = vecSize;
for (; i < iMax; ++i) {
    MPI_Test(&request, &done, &status);
    if (done) break;
    if (vec[i] == 42) {
        luckyProcess = rank;
        for (j=0; j<size; ++j) {
            if (j != rank)
                MPI_Isend(&i, 1, MPI_INT, j, tag_success, MPI_COMM_WORLD, &retRequest[j]);
            else
                retRequest[j] = MPI_REQUEST_NULL;
        }
        MPI_Waitall(size, retRequest, MPI_STATUSES_IGNORE);
        break;
    }
};
```

Asinhrona komunikacija

```
if (rank == 0) {
    if (!done)
        MPI_Wait(&request, &status);
    for (j = 1; j < size; ++j) {
        if (j > 1) {
            MPI_Irecv(&result, 1, MPI_INT, MPI_ANY_SOURCE, MPI_ANY_TAG, MPI_COMM_WORLD, &request);
            MPI_Wait(&request, &status);
        }
        if (status.MPI_TAG == tag_success) {
            i = result;
            luckyProcess = status.MPI_SOURCE;
        }
    }
    printf("P:%d found it at index %d\n", luckyProcess, i);
} else {
    if (luckyProcess != rank) {
        MPI_Isend(&i, 1, MPI_INT, 0, tag_fail, MPI_COMM_WORLD, &retRequest[j]);
    } else {
        MPI_Request_free(&request);
    }
}
free(retRequest);
free(vec);
MPI_Finalize();
```

Asinhrona komunikacija

- Optimizacija je draga (nepotrebno zapletena koda)
- Pokriti je treba vse možnosti:
  - Noben proces ne najde iskanega števila
  - Več procesov najde iskano število
  - Glavni / podrejeni najde
- Vsi procesi pošljejo rezultat glavnemu
  - Tisti, ki najde – vrne rezultat
  - Tisti, ki ne najde – sporoči da je končal
  - Tudi tisti, ki jih je ustavil drug proces