




Universität Hamburg

DER FORSCHUNG | DER LEHRE | DER BILDUNG

Praktikum: Paralleles Programmieren für Geowissenschaftler

Prof. Thomas Ludwig, Hermann Lenhart & Tim Jammer



Dr. Hermann-J. Lenhart

hermann.lenhart@informatik.uni-hamburg.de



Einführung zum „Umfeld“ vom Paralleles Programmieren:

- Hardware Voraussetzung zur Parallelen Programmierung
- Softwareaspekte zum Parallelen Programmieren
- Modellstruktur zum Parallelen Programmieren
(mit Blick auf MPI)

HPC Top500 Liste - Stand November 2017

Rank	Site	System	Cores	Rmax (TFlop/s)	Rpeak (TFlop/s)	Power (kW)
38	Japan Aerospace eXploration Agency Japan	SORA-MA - Fujitsu PRIMEHPC FX100, SPARC64 XIfx 32C 1.98GHz, Tofu interconnect 2 Fujitsu	110,160	3,157.0	3,481.1	1,652
39	Government United States	Cray XC30, Intel Xeon E5-2697v2 12C 2.7GHz, Aries interconnect Cray Inc.	225,984	3,143.5	4,881.3	6,328
40	Air Force Research Laboratory United States	Thunder - SGI ICE X, Xeon E5-2699v3/E5-2697 v3, Infiniband FDR, NVIDIA Tesla K40, Intel Xeon Phi 7120P HPE	152,692	3,126.2	5,610.5	4,820
41	Academic Center for Computing and Media Studies (ACCMS), Kyoto University Japan	Camphor 2 - Cray XC40, Intel Xeon Phi 7250 68C 1.4GHz, Aries interconnect Cray Inc.	122,400	3,057.3	5,483.5	748
42	DKRZ - Deutsches Klimarechenzentrum Germany	Mistral - bullx DLC 720, Xeon E5-2680v3 12C 2.5GHz/E5-2695V4 18C 2.1GHz, Infiniband FDR Bull, Atos Group	99,072	3,010.7	3,962.9	1,116
43	Information Technology Center, Nagoya University Japan	Fujitsu PRIMEHPC FX100, SPARC64 XIfx 32C 2.2GHz, Tofu interconnect 2 Fujitsu	92,160	2,910.0	3,244.0	1,382
44	Leibniz Rechenzentrum Germany	SuperMUC - iDataPlex DX360M4, Xeon E5-2680 8C 2.70GHz, Infiniband FDR IBM/Lenovo	147,456	2,897.0	3,185.1	3,423
45	Leibniz Rechenzentrum Germany	SuperMUC Phase 2 - NeXtScale nx360M5, Xeon E5-2697v3 14C 2.6GHz, Infiniband FDR14 Lenovo/IBM	86,016	2,813.6	3,578.3	1,481

Quelle: www.top500.org

Rank Site System Cores Rmax (TFlop/s) Rpeak (TFlop/s) Power (kW)

HPC Top500 Liste - Stand November 2017



Rank	Site	System	Cores	Rmax (TFlop/s)	Rpeak (TFlop/s)	Power (kW)
1	National Supercomputing Center in Wuxi China	Sunway TaihuLight - Sunway MPP, Sunway SW26010 260C 1.45GHz, Sunway NRCPC	10,649,600	93,014.6	125,435.9	15,371
2	National Super Computer Center in Guangzhou China	Tianhe-2 (MilkyWay-2) - TH-IVB-FEP Cluster, Intel Xeon E5-2692 12C 2.200GHz, TH Express-2, Intel Xeon Phi 31S1P NUDT	3,120,000	33,862.7	54,902.4	17,808
3	Swiss National Supercomputing Centre (CSCS) Switzerland	Piz Daint - Cray XC50, Xeon E5-2690v3 12C 2.6GHz, Aries interconnect, NVIDIA Tesla P100 Cray Inc.	361,760	19,590.0	25,326.3	2,272
4	Japan Agency for Marine-Earth Science and Technology Japan	Gyokou - ZettaScaler-2.2 HPC system, Xeon D-1571 16C 1.3GHz, Infiniband EDR, PEZY-SC2 700Mhz ExaScaler	19,860,000	19,135.8	28,192.0	1,350
5	DOE/SC/Oak Ridge National Laboratory United States	Titan - Cray XK7, Opteron 6274 16C 2.200GHz, Cray Gemini interconnect, NVIDIA K20x Cray Inc.	560,640	17,590.0	27,112.5	8,209
6	DOE/NNSA/LLNL United States	Sequoia - BlueGene/Q, Power BQC 16C 1.60 GHz, Custom IBM	1,572,864	17,173.2	20,132.7	7,890
7	DOE/NNSA/LANL/SNL United States	Trinity - Cray XC40, Intel Xeon Phi 7250 68C 1.4GHz, Aries interconnect Cray Inc.	979,968	14,137.3	43,902.6	3,844
8	DOE/SC/LBNL/NERSC United States	Cori - Cray XC40, Intel Xeon Phi 7250 68C 1.4GHz, Aries interconnect	622,336	14,014.7	27,880.7	3,939

Germany:

19 HLRS Stuttgart

22 Jülich

29 Jülich

Quelle: www.top500.org

HPC Top500 Liste - Stand November 2016



Laptop heute

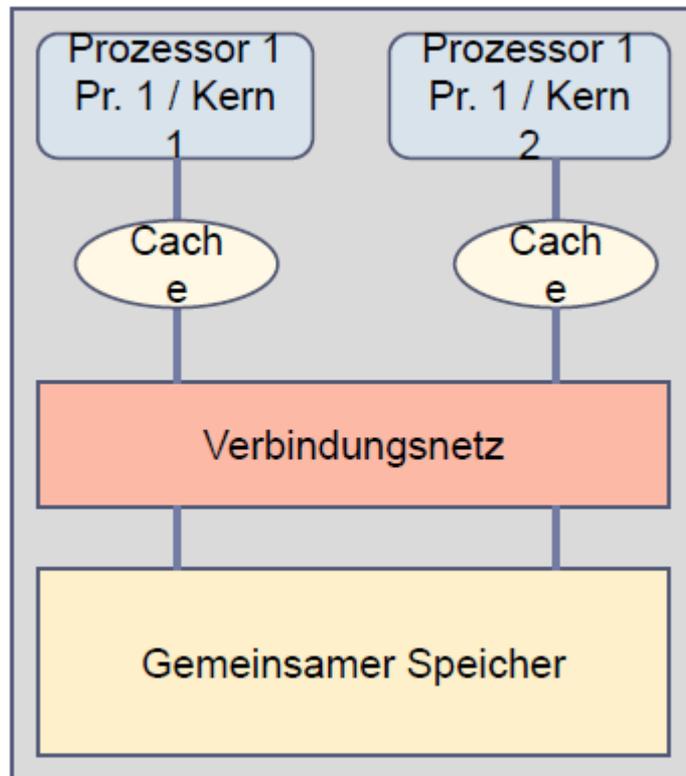


Möglichkeiten der Parallelen Programmierung :

- **OpenMP** - Möglich bei der Nutzung von gemeinsamem Speicher (shared memory directives)
- **MPI** (Message-Passing Interface)
 - bei Rechnerarchitektur mit verteiltem Speicher
 - derzeit einziger Standard mit Portabilität auf allen Plattformen
- **Hybride** Programmierung: Kombination von MPI und OpenMP



OpenMP - Gemeinsamer Speicherzugriff mittels SMP



SMP: Symmetrisches Multiprozessersystem
(symmetric multiprocessing)

[Multiprozessor-Architektur](#),

bei der zwei oder mehr [identische Prozessoren](#) einen gemeinsamen [Adressraum](#) besitzen.

Eine SMP-Architektur erlaubt es, die laufenden [Prozesse](#) dynamisch auf alle verfügbaren [Prozessoren](#) zu verteilen.

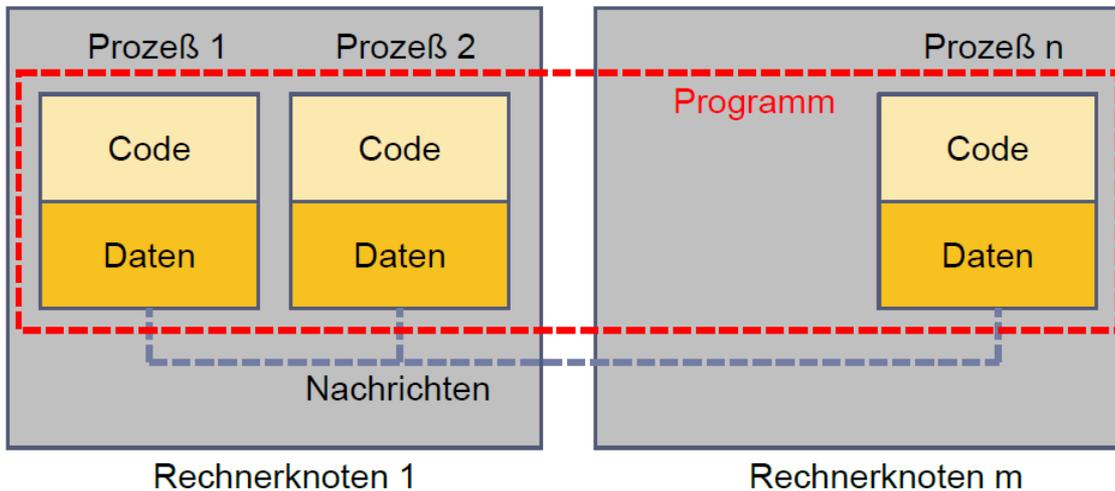
Dagegen muss beim [asymmetrischen Multiprocessing](#) jeder CPU eine Aufgabe fest zugewiesen werden (z. B. führt CPU0 Betriebssystemaufrufe und CPU1 Benutzerprozesse aus).

Source: Grafik Ludwig WS12/13, Text Wikipedia



MPI – Hardware Voraussetzung

Quelle: Ludwig WS12/13



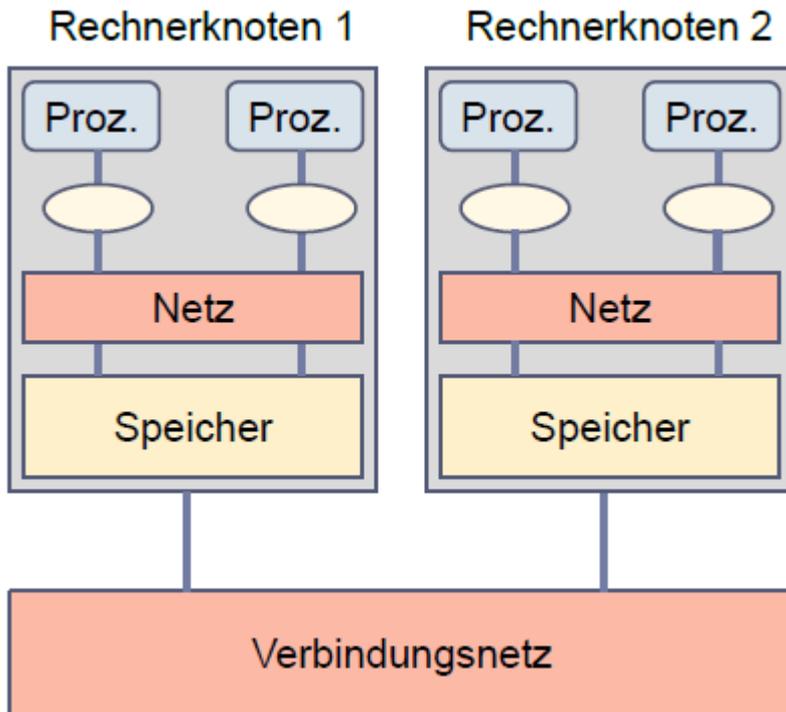
- Keinen direkten Zugriff auf Memory (Daten) von anderen Prozessen.
- Datenverfügbarkeit über expliziten Datenaustausch (Senden/Empfangen)

mit anderen Prozessen!

!! Vorteil: MPI Prozesse lassen sich skalieren !!



Hybride Programmierung



Existierende HPC Rechner sind heute meist eine Kombination aus **Rechnerknoten mit gemeinsamem Speicher**, von den man viele verwendet und **über ein Verbindungsnetz** verbindet.

Hybride Programmierung ermöglicht die Kombination von MPI und OpenMP, aber bedarf mehr Struktur der Zugriffsrechte.

Vortrag von Dr. Panagiotis Adamidis als DKRZ Beitrag am 5. Juli 2018

Quelle: Ludwig WS12/13

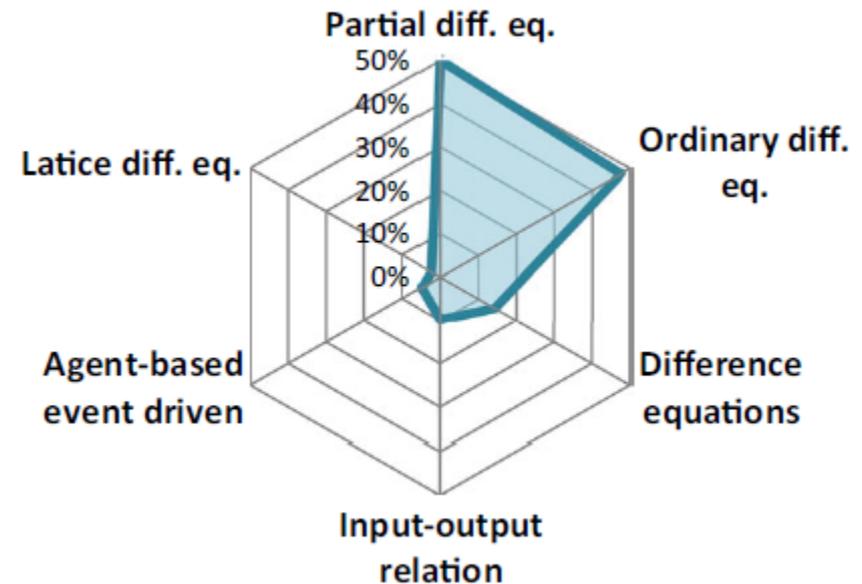
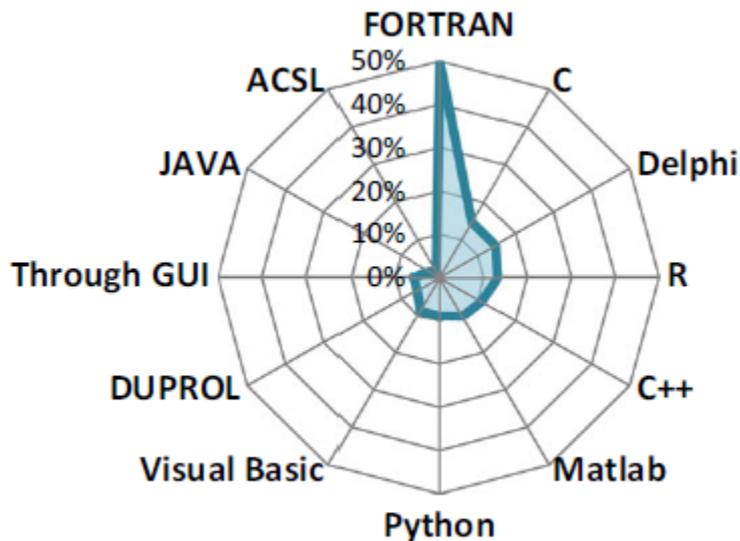


Software-Anwendungen in Erdsystemmodellen

Paper: Exploring, exploiting and evolving diversity of

aquatic ecosystem models: a community perspective.

Janssen et al., 2015 in Aquatic Ecology





Software-Aspekte für Parallele Programmierung I

Neben Hardware gibt es auch einige Anforderungen an Softwarekomponenten, z.B. für die Einbindung von Programm-Bibliotheken.

Thread-Sicherheit (Thread safety)

Softwarekomponente können gleichzeitig von verschiedenen Programmbereichen mehrfach ausgeführt werden, ohne dass diese sich gegenseitig behindern.

Zum Zweck der Mehrfachausführung bieten Betriebssysteme das Konzept von sogenannte **Threads**, die als „leichtgewichtige Prozesse“ gelten.



Software-Aspekte für Parallele Programmierung II

Jeder Thread arbeitet dabei unabhängig von den anderen einen Programmteil ab.

Häufig muss das Programm dabei gleichzeitig auf einen gemeinsamen Speicherbereich des Computers zugreifen.

Änderungen im Speicher durch verschiedene Threads müssen koordiniert werden, um einen chaotischen Zustand des Speichers zu verhindern.



Software-Aspekte für Parallele Programmierung II

Problem beim Parallelen Programmieren:

Reihenfolge der Ausführung nicht steuerbar, bzw. nicht deterministisch.

Ein Beispiel für einen unkontrollierten Zustand des Speichers sind sogenannte

Wettlaufsituation (Race Condition)

Wettlaufsituationen bezeichnen in der Programmierung eine Konstellation, in der das Ergebnis einer Operation vom zeitlichen Verhalten bestimmter Einzeloperationen abhängt.

D.h. die Reihenfolge in der die Berechnungen und Speicherung ablaufen

ist nicht vertauschbar!



Programmstruktur in der Modellierung

Der Ablauf eines Modelles wird üblicherweise in 3 Phasen eingeteilt:

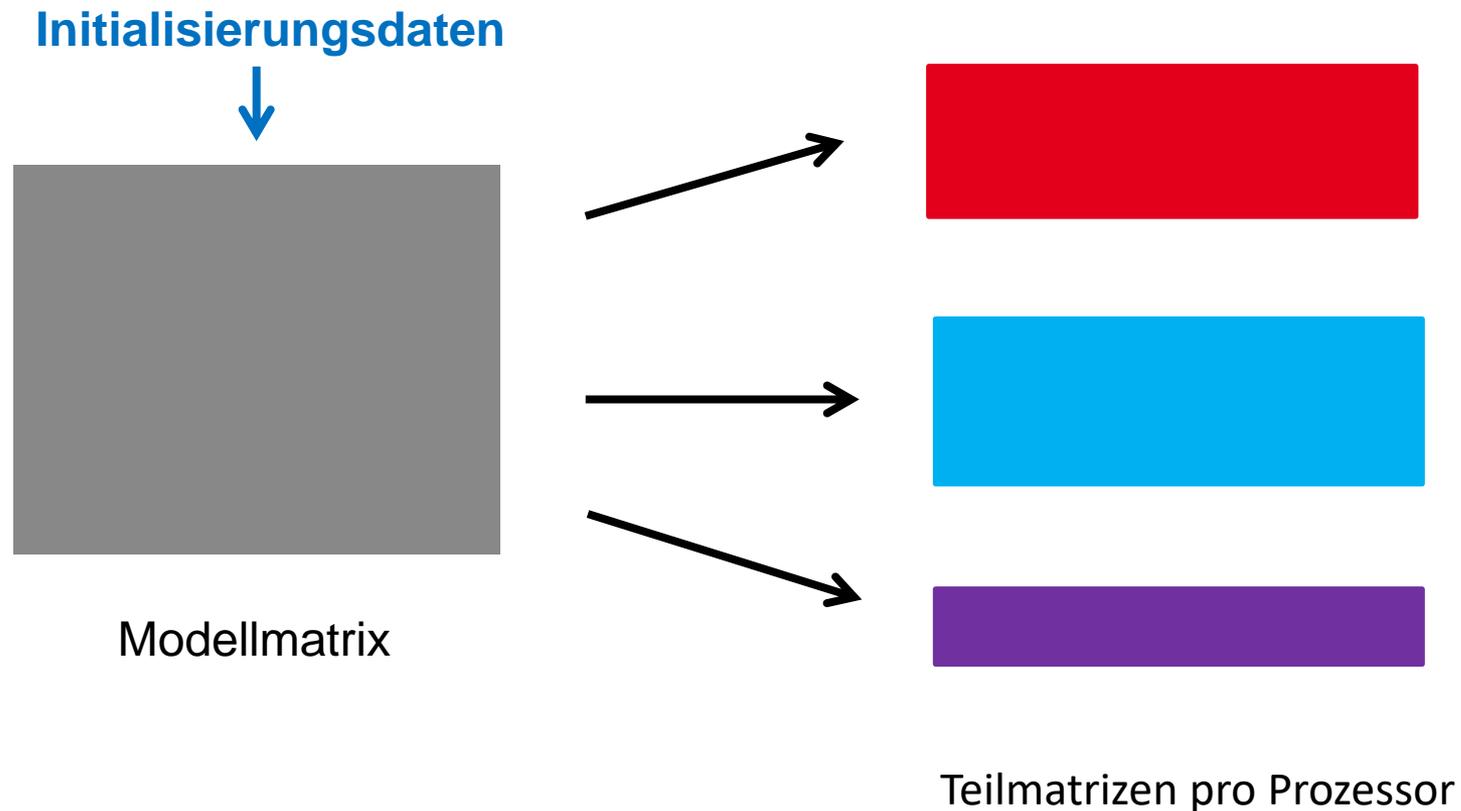
- 1) Initialisierung
- 2) Berechnung des Modells
- 3) Finalisierung

Diese Einteilung wird z.B. von Kopplern wie ESMF gefordert.



MPI Nachrichtenaustausch in der Modellierung I

1) **Initialisierung:** Aufteilung der Rechengebiete und Initialisierung



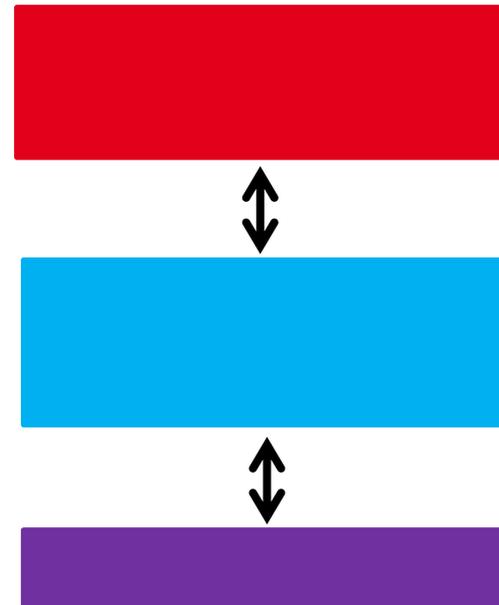


MPI Nachrichtenaustausch in der Modellierung II

2) Berechnung des Modells auf Teilmatrizen: Austausch zwischen Teilmatrizen



Modellmatrix

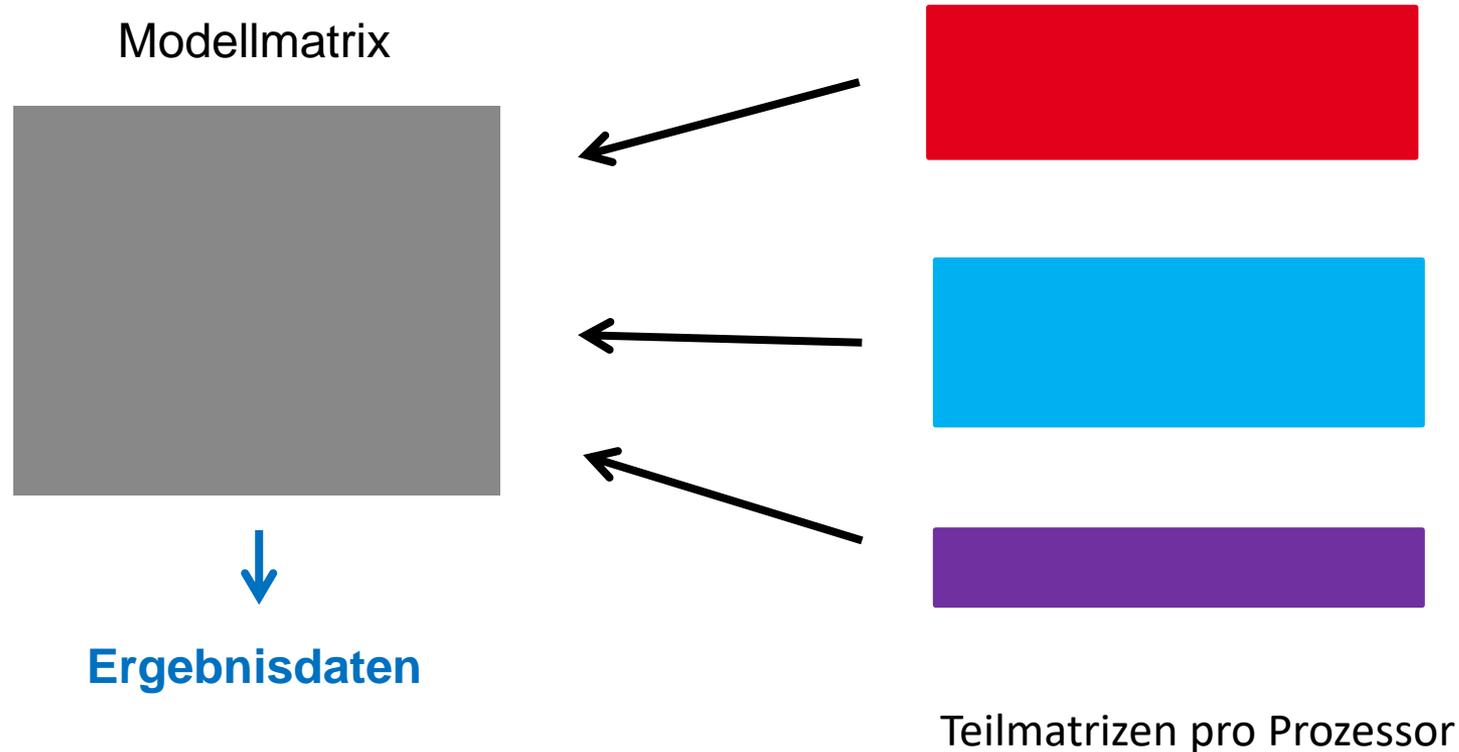


Teilmatrizen pro Prozessor



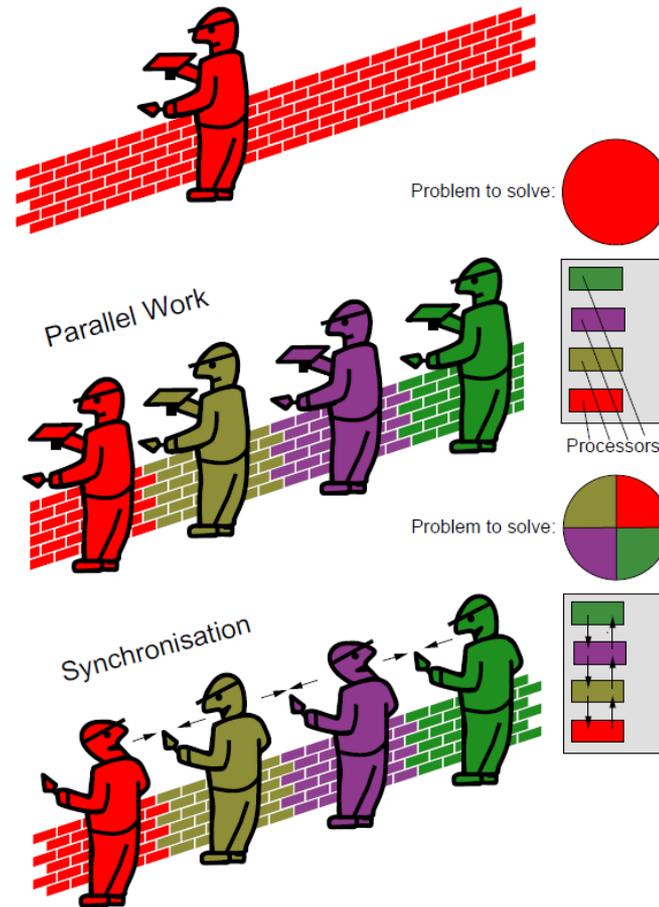
MPI Nachrichtenaustausch in der Modellierung III

3) **Finalisierung:** Zusammenfügen der Rechenergebnisse der Teilmatrizen





MPI Nachrichtenaustausch: **Zu Beachten!!**





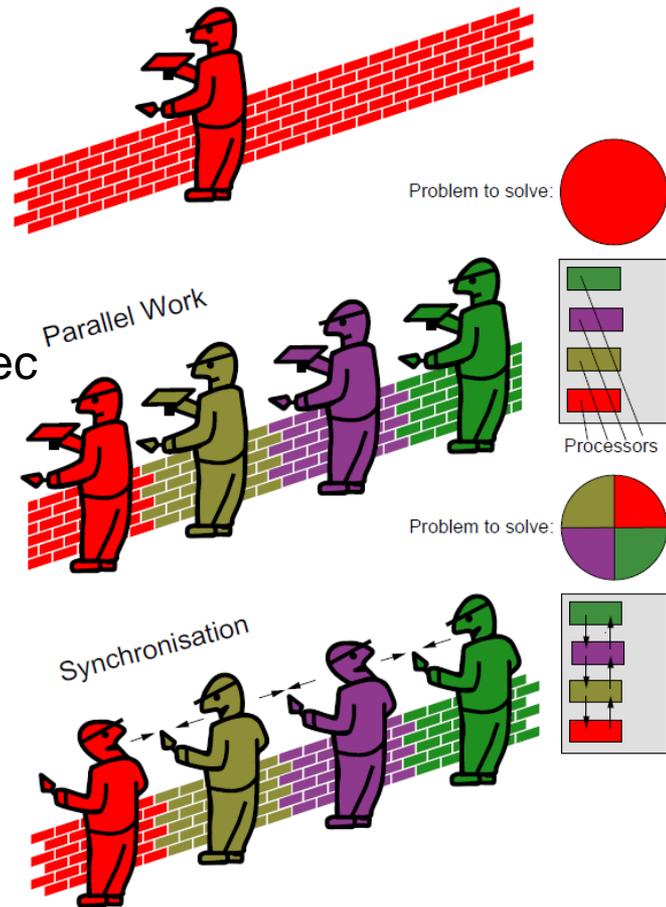
MPI Nachrichtenaustausch: **Zu Beachten!!**

Als Info für das Verhältnis
Rechnen / Nachrichtenaustausch
 soll folgende Abschätzung dienen:

Ein moderner Parallelrechner schafft
 ca. 3 Mrd. floating point operationen / Sec

Der Nachrichtenaustausch
 aber nur 10 Mio. Wörter / Sec

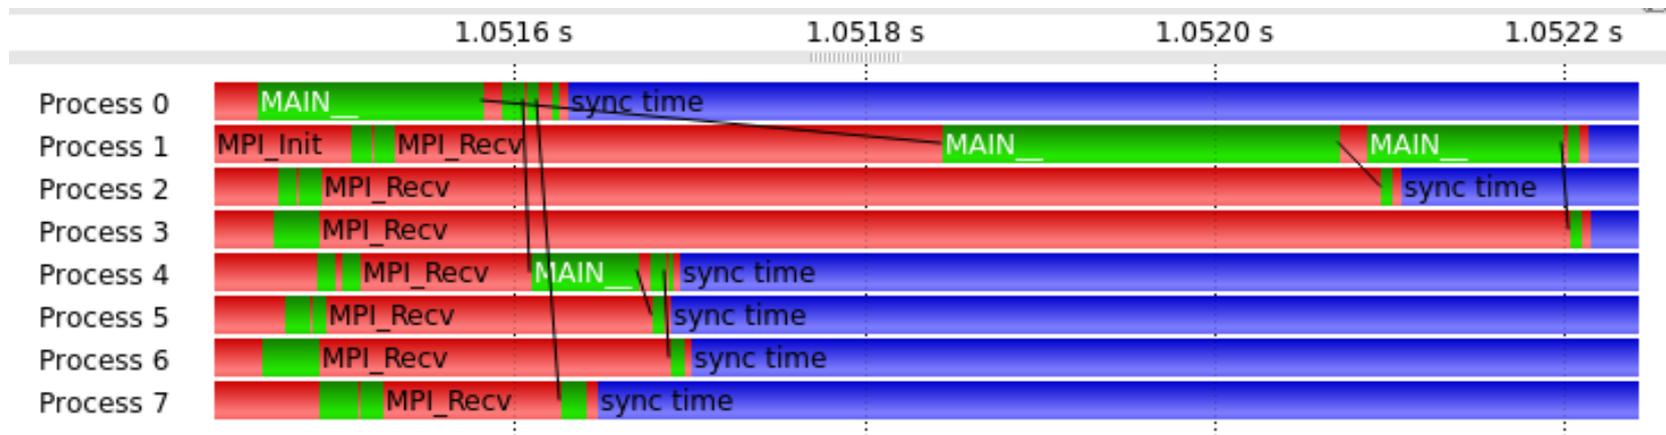
Faktor 300 !!



[picture by W. Baumann]



Visualisierung des Programmablaufes mit Vampire:





Universität Hamburg

DER FORSCHUNG | DER LEHRE | DER BILDUNG



**Danke,
gibt es noch Fragen?**