Verteilte Systeme

10. Middleware I

Verteiltes Programmieren leicht gemacht ...

- Verteilte Middleware
  - Vermittlerrolle zwischen verteilter Anwendung und Rechnernetz
  - Teil moderner Systemsoftware
- Einfache Handhabbarkeit
- Leichte Portierbarkeit
- Hohe Abstraktionen
  - Gruppen
  - Logische Uhren
  - Transaktionen
  - Verteilte Algorithmen
  - ...
- Wo ist die Mitte?

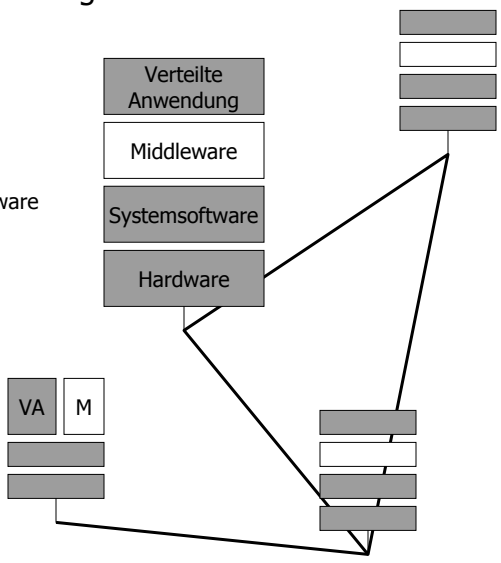

Verteilte Systeme, Sommersemester 1999 Folie 10.2

Verteilte Middleware I

- Einfache Middleware mit dem Funktionsumfang
  - Verwaltung beteiligter Rechner
  - Unicast
  - Datenkonvertierung
  - Verteilte Kontrollalgorithmen
  - Einfache Multicast-Varianten
- PVM = Parallel Virtual Machine
  - Einer der ersten Middleware-Ansätze (1989)
  - Leicht verständlich, Leicht installierbar, Breite Verfügbarkeit
- MPI = Message Passing Interface
  - Im Vergleich zu PVM "ausgereifter" und größerer Funktionsumfang
  - Versuch eines Standards für nachrichtenbasierte Kommunikation
- Primäres Einsatzgebiet
  - Verteilung numerischer Simulationen wie z.B. Mehrgitterverfahren

10.1 Parallel Virtual Machine (PVM)

PVM

- Anfang: 1989 am Oak Ridge National Laboratory (ORNL)
- Abstrakte Schicht
  - Realisiert auf einer benutzerdefinierten Menge von Rechnern in einem Netz die Sicht eines großen Rechners mit verteiltem Speicher
- Funktionsumfang
  - Verwaltung der Rechnermenge
  - Verwaltung sogenannter Tasks
  - Kommunikation
  - Synchronisation
  - Unterstützung für heterogene Systeme

Unterstützte Architekturen

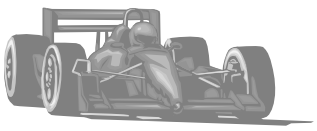

- Alliant FX/8
- DEC Alpha
- Sequent Balance
- Sequent Symmetry
- Intel-basierte UNIX-Systeme
- Thinking Machines CM2
- Thinking Machines CM5
- Cray C-90
- Cray YMP
- Cray-2
- Cray S-MP
- HP-9000 Model 300, PA-RISC
- Intel Paragon
- Silicon Graphics IRIS
- SUN 3, Sparcs
- ...

PVM-Architektur

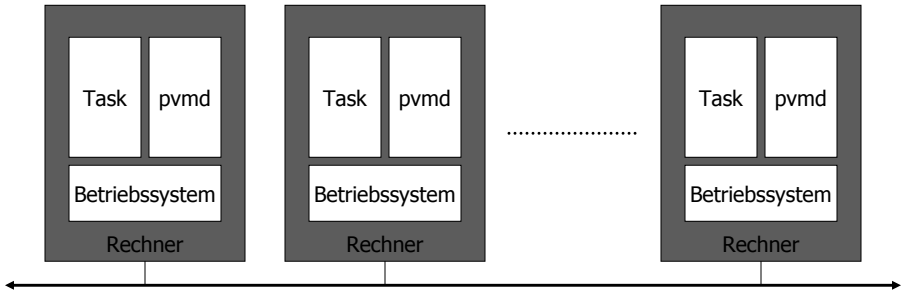

- Mehrere Rechner bilden einen virtuellen Rechner
- Ein Dämon pvmd pro beteiligtem Rechner
- pvmd ist normaler Benutzerprozeß

Verteilte Systeme, Sommersemester 1999 Folie 10.7

PVMD-Shell

- Starten eines lokalen pvmd
- Kommandos
  - **`add`** = ein oder mehrere Rechner hinzufügen
  - **`delete`** = Rechner entfernen (laufende Task wird abgebrochen)
  - **`conf`** = Aktuelle Konfiguration ausgeben
  - **`mstat`** = Status der beteiligten Rechner
  - **`ps -a`** = Liste der aktuellen Prozesse
  - **`pstat`** = Zustand eines einzelnen Prozesses
  - **`spawn`** = PVM-Anwendung starten
  - **`kill`** = Prozeß terminieren
  - **`reset`**
  - **`quit`**

Verteilte Systeme, Sommersemester 1999 Folie 10.8

Skelett eines PVM-Prozesses

```
int main (int ac, char **av) {
     int tid;
     tid = pvm_mytid();
     ...
     pvm_exit();
}
```

- Erster Aufruf von **`pvm_mytid()`** meldet den Prozeß an
  - Rückgabewert eindeutige Taskidentifikation
- **`pvm_exit()`** meldet nur ab (keine Terminierung)

Erzeugung weiterer Prozesse

```
int numt = pvm_spawn (
   char *task,
   char **argv,
   int flag,
   char *where,
   int ntask,
   int *tids
   )
```

- Werte für **`flag`**:
  - **`PvmTaskDefault`**
    pvmd wählt Rechner aus
  - **`PvmTaskHost`**
    In where steht Zielrechner
  - **`PvmTaskArch`**
    In where steht Architekturtyp
  - **`PvmTaskDebug`**
    Prozesse werden in einem Debugger gestartet
  - **`PvmTaskTrace`**
    Aufruf der erzeugten Tasks werden protokolliert
- **`ntask`** = Anzahl der zu erzeugenden Prozesse
- numt = Anzahl erfolgreich instanziierter Prozesse

Verwaltungsfunktionen

- **`int tid = pvm_parent()`**
  Identifikation des erzeugenden Prozesses sonst PvmNoParent
- **`int pstat = pvm_stat(int tid)`**
  Status einer Task
- **`int mstat = pvm_mstat(char *host)`**
  Informationen über den angegebenen Rechner
- **`int info = pvm_config(...)`**
  Informationen über den virtuellen Rechner
- **`int info = pvm_tasks(...)`**
  Informationen über bestimmte oder alle Tasks
- **`pvm_kill(int tid)`**
  Terminierung einer Task erzwingen

Verteilte Systeme, Sommersemester 1999 Folie 10.11

Einfachstkommunikation: Signale

```
int info = pvm_sendsig (
   int tid,
   int signum
   )
```

- Sendet Signal **`signum`** an Task **`tid`**

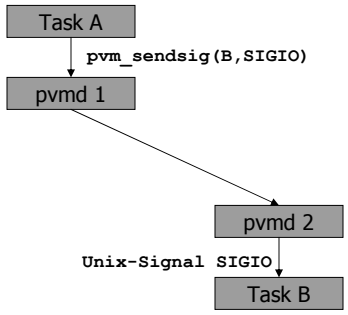


```
int info = pvm_notify (
   int about,
   int msgtag,
   int ntask,
   int *tids
   )
```

- Benachrichtigung der angegebenen Tasks über besondere Ereignisse
  - Task terminiert
  - Rechner wurde ausgetragen oder stürzte ab
  - Weitere Rechner kamen hinzu

Verteilte Systeme, Sommersemester 1999 Folie 10.12

Nachrichtenkommunikation

- Senden einer Nachricht:
  - Aufbau eines Sendepuffers
  - Einpacken der Nachricht (Datenkonvertierung)
  - Absenden der Nachricht
- Empfang einer Nachricht:
  - Aufruf einer Empfangsoperation
  - Auspacken der Nachricht
- Alle Nachrichten besitzen eine Kennung (Message Tag)

Sende- und Empfangspuffer

- Explizite Erzeugung und Freigabe
  - `int bufid = pvm_mkbuf (int encoding)`
  - `int info = pvm_freebuf (int bufid)`
  - encoding legt die Konvertierungmethode fest:
    - xdr-Konvertierung (PvmDataDefault)
    - Keine Konvertierung (PvmDataRaw)
    - Pointer auf Daten statt Daten (PvmDataInPlace)
- Ein aktiver Sendepuffer pro Task
  - `int old_bufid = pvm_setsbuf(int new_bufid)`
  - `int bufid = pvm_getsbuf ()`
- Ein aktiver Empfangspuffer pro Task
  - `int old_bufid = pvm_setrbuf(int new_bufid)`
  - `int bufid = pvm_getrbuf ()`

Ein- und Auspacken

- Datenkonvertierung wird nicht direkt unterstützt
- Basiskonvertierungen für
  - Byte, Float, Double, Integer, Long, Short, String
  - Grundformat
    - `int info = pvm_pkdouble ( double *data, int nitem, int stride )`
    - `int info = pvm_upkdouble ( ... )`
- Explizite Nutzung der xdr-Routinen
  - Datentypen definieren
  - RPCGEN aufrufen

Verteilte Systeme, Sommersemester 1999 Folie 10.15

Senden und Empfangen

- **`int info = pvm_send(int tid, int msgtag)`**
  Die Nachricht im aktuellen Sendepuffer wird versendet
- **`int info = pvm_mcast(int *tids, int ntids, int msgtag)`**
  Einfacher Multicast
- **`int bufid = pvm_nrecv(int tid, int msgtag)`**
  Nichtblockierendes Empfangen
  - Keine Nachricht wenn bufid = 0
  - tid = Nachricht von einem bestimmten Task oder -1
  - msgtag = Bestimmter Nachrichtentyp oder -1
- **`int bufid = pvm_recv(...)`**
  Blockierendes Empfangen
- **`int bufid = pvm_probe(...)`**
  Asynchrones Empfangen

Verteilte Systeme, Sommersemester 1999 Folie 10.16

Weitere Funktionen

- Aufbau direkter Kommunikationsverbindungen
  - Zwei Task kommunizieren eng miteinander
- Gruppenkommunikation
  - Noch experimenteller Status
  - Eigener Gruppenserver
  - Keine Garantien
  - Barrier-Synchronisation
    - Warten, bis eine vorgegebene Anzahl von Prozessen `pvm_barrier()` aufgerufen hat
- Implementierung
  - pvmds kommunizieren über UDP
  - pvmd, lokale Tasks und direkte Verbindungen nutzen TCP

10.2 Message Passing Interface (MPI)

MPI

- MPIF = Message Passing Interface Forum
  - mehr als 40 Organisationen
  - Beginn November 1992
  - Viele PVM-Entwickler beteiligt
- Vergleichbar PVM, aber ausgereifter und größerer Funktionsumfang
  - Unicast
  - Kollektive Operationen (Maximumsuche, Barrier, ...)
  - Prozeßgruppen
  - Kommunikationskontexte
- Sprachbindungen
  - C und C++
  - Fortran

Kollektive Operationen

- Multicast-Kommunikation
- Barrier-Synchronisation
- Scatter/Gather-Operationen
  - Verteilen von Datenstücken auf mehrere Rechner
  - Einsammlen verteilter Datenstücke
- Globale Reduktionsoperationen
  - Maximum, Minimum
  - Summe, Produkt
  - Logische Operationen
  - Benutzerdefinierte Operationen möglich
  - Varianten
    - Resultat kommt bei einem Prozeß an
    - Resultat kommt bei allen Prozessen an
    - Resultat kommt bei ausgewählten Prozessen an (Prefix Scan)

Zusammenfassung

- Entwicklung einfacher verteilter Anwendungen wird deutlich erleichtert
  - Im Bereich numerischer Simulationen sehr efolgreich
  - Gute Übungsgrundlage für Vorlesungen
- Einsatz scheitert meist, wenn die verteilte Anwendung komplexer wird
  - Keine vollständige Integration der Systemsoftware
  - Work-Arounds
  - ...
- Offene Probleme
  - Bessere und automatisierte Lösung der Datenkonvertierung
  - Höhere Garantien bei Multicast-Kommunikation
  - Stärkere Systemintegration

Übungsaufgaben

1. Implementieren Sie den in einer früheren Übung bereits besprochenen Raymond-Algorithmus für verteilten wechselseitigen Ausschluß unter Verwendung von PVM oder MPI.

   Die Anzahl der beteiligten Prozesse (Rechner) sollte parametrisierbar sein.

Literatur

- A. Geist, A. Beguelin, J. Dongarra, W. Jiang, R. Manchek, V. Sunderam
  PVM 3 User's Guide and Reference Manual
  ORNL/TM-12187, 1993
  typischerweise Teil einer PVM-Distribution