

Parallele Hochleistungs-Ein-/Ausgabe in Cluster-Umgebungen

Parallele und verteilte Systeme

Institut für Informatik

Universität Heidelberg

Prof. Thomas Ludwig

pvs.informatik.uni-heidelberg.de

Forschungsgebiete an der TUM


- Lastausgleich durch Prozeßmigration
 - Auf Parallelrechnern (Intel iPSC)
 - Auf Rechner-Clustern
- Werkzeuge-Infrastrukturen
 - Monitoringsysteme für parallele Debugger, parallele Leistungsanalyse (selber wieder paralleles Programm)
 - Schnittstellenspezifikation für interoperable parallele Werkzeuge

Forschungsgebiete in Heidelberg

Parallele Hochleistungs-Ein-/Ausgabe für Cluster-Umgebungen

Warum ist E/A kritisch?

- Heidelberger Helics-Cluster (Rang 165 weltweit) mit 256 Knoten à 2GByte Hauptspeicher erzeugt z.B. 0.5TByte Daten pro Iterationsschritt einer numerischen Simulation
- Ergebnisdaten heute im Bereich TByte-PByte
- Gebiete: Bioinformatik, Physik u.a.





Parallele Ein-/Ausgabe


Parallele Ein-/Ausgabe auf zwei Ebenen

- Auf der Programmebene
 - Viele parallele Prozesse schreiben in dieselbe Datei
 - Zugriff zu verschiedenen/identischen Positionen
 - Disjunkte/nichtdisjunkte Sicht auf die Dateien
- Auf der Systemebene
 - Datei ist physikalisch über viele Platten verteilt
- Typisches Abbildungsproblem; Lokalität wichtig

Man muß nicht beide Ebene haben!

Nichtparallele vs. parallele E/A





Parallele Ein-/Ausgabe...

Ansätze


- Auf der Programmebene
 - MPI-IO (Bestandteil von MPI2)
Definiert API für parallele E/A
Syntax + Zugriffssemantiken
- Auf der Systemebene
 - GPFS (IBM)
 - Lustre (Cluster File Systems)
 - PVFS (Argonne National Labs / Clemson University)

Fragestellungen auf Benutzerebene

- Welche Zugriffssemantik eignet sich für welche Anwendung?
(gemeinsamer/individueller Dateizeiger, gemeinsame/individuelle Datenbereiche)
- Wie kann ich meine E/A charakterisieren?
(zusammenhängend, zufällig, kleine/große Datenmengen)
- Wie kann ich die E/A-Leistung messen?
- Wie kann ich meinen Datendurchsatz optimieren?

Fragestellungen auf Systemebene


- Wie werden die Daten einer Datei über die Platten hinweg verteilt?
- Wie mißt man hier die Lasten im System?
- Automatische Lastoptimierung durch Verlagerungen von Dateiteilen?
- Wie optimiert man Zugriffe auf die Metadatenserver? (Zentrale Komponente als Engpaß im System)
- Was passiert beim Absturz des Programms und beim Ausfall von Platten?
- Wie übertrage ich Riesendateien auf andere Systeme? (Datensicherung)
- Wie verwende ich Riesendateien in anderen Programmen? (Datenvisualisierung)



Laufende Arbeiten

Steuerbare Ressourcennutzung in parallelen Dateisystemen


- Konzept
 - Abbildungsfunktion von logischer Dateiposition auf physische Dateiposition wird dynamisch gesteuert
- Ergebnis
 - Lastausgleich durch Verlagerung von Dateiteilen im parallelen Dateisystem
- Nutzen
 - Bessere Ressourcenauslastung
 - Flexiblere Ressourcennutzung



Laufende Arbeiten...

Optimierung der Leistung der Metadatenserver in parallelen Dateisystemen

- Problem
 - Zugriffe auf Dateien erfordern vorherige Zugriffe auf Metadaten dieser Datei
 - Konzepte mit zentralem Metadatenserver skalieren nicht
- Ansatz
 - Replikation der Metadatenserver
 - Einsatz von Caching- und Locking-Mechanismen
- Wichtig: Benchmark für Metadatenserver



Laufende Arbeiten...

Parallele E/A in numerischen Programmen

- Umstellung relevanter Programme auf MPI-IO
- Evaluierung unserer neuen Verfahren

Forschungslandschaft parallele E/A

- In Deutschland nahezu keine Forschung hierzu
 - Karlsruhe: Tichy / Isaila
Clusterfile (noch nicht frei verfügbar)
- Weltweit auch wenige Gruppen