Verteilte Softwaresysteme

Lastverteilung

Prof. Dr. Oliver Braun

Fakultät für Informatik und Mathematik
Hochschule München

Letzte Änderung: 10.12.2018 21:11

Inhaltsverzeichnis

Begriffe

- Regelung der konkurrierenden Zugriffe auf die Ressourcen
- zu verteiltende Objekte sind die Prozesse der Anwendungen
  - der Begriff Tasks wird in dem Zusammenhang synonym genutzt
- Unterscheidung von Prozessen:
  - **lokaler Prozess**: wird dort ausgeführt, wo er gestartet wurde
  - **Remote-Prozess**: können durch Lasstverteilung ausgelagert werden
- **reguläre Prozesse** können nur lokal ausgeführt werden
- **generische Prozesse** können verteilt ausgeführt werden
- Synonyme für die Rechenressourcen:
  - **Prozessor**, **Rechner**, **Knoten**

Unterschiedliche Ziele

- Minimierung der Kosten der Interprozesskommunikation
- Erreichung eines hohen Speedups
- Effiziente Ausnutzung aller Prozessoren
- minimale Bearbeitungszeiten für Prozesse
- Minimierung der totalen Ausführungskosten

Eigenschaften von besonders geeigneten Lastverteilungsverfahren

- keine Verwendung von Vorwissen über Prozesse
- dynamisch, basierend auf Systemzustand
- schnelle Algorithmen
- geringer Overhead für Beschaffung von Systeminformationen über Zustand
- Stabilität des Systems, Aufwand für Lastausgleich gering ggü Rechnenprozesse

- Skalierbar bei Hinzunahme neuer Knoten
- Ortstransparent
- hohe Ausfallsicherheit
- Fairness ggü Nutzern, d.h. Besitzer eines Rechners hat Vorrang

Statische Lastverteilung

Eigenschaften

- vor dem Ausführen verteilen
- nutzen auch **Anforderungsprofil** der Prozesse, z.B. an Prozessoren, Speicher, etc.
- besonders wichtig ist die Kenntnis von Ausführungszeiten, sowie der Speedup-Characteristik
- veschiedene Stufen von Vorwissen
  - kein Vorwissen
  - Verteilung der Ausführungszeiten im gesamten Workload bekannt, aber keine Informationen über einzelne Jobs
  - Jobs sind Klassen mit spezifischen Eigenschaften zugeordnet
  - Ausführungszeiten für Jobs für jede beliebige Rechnerkombination liegen vor

Scheduling-Problem

- statische Lastverteilung ist ein Scheduling-Problem
- Ablaufplan muss erstellt werden
- **Queuing-Systeme**
  - verteilen Prozesse auf verschiedene Queues, ohne Startzeiten festzulegen
- **Plannende Systeme**
  - vollständige Ablaufpläne mit Startzeiten und Zuweisung von Zeitintervallen auf Rechnern an Jobs
- Ausführbarkeit eines Schedules (*feasibility*) ist gegeben, wenn es
  - keine Überlappungen von Zeitintervallen für denselben Job
  - oder auf demselben Rechner gibt
- **at-most-once-schedule**: keine Umplanung möglich
- **multiple-schedule**: Umplanung möglich

Komplexität des Scheduling-Problems

- für die Zuweisung von m Prozesse auf q Prozessoren gibt es q^m Möglichkeiten
  - wenn keine sonstigen Einschränkungen vorliegen
- optimale Zuordnung kann, außer in einfachen Fällen, nicht in polynominaler Zeit gefunden werden
  - NP-schweres Problem

Statische Lastverteilung: Jobmodelle

3 Ansätze

1. **Task-Präzedenz-Graphen**
2. **Task-Interaktionsgraphen**
3. **Workflows**

- wesentlicher Teil ist die **Partitionierung** der Graphen
  - Zerlegung in Gruppen von Tasks, die einem Prozessor zugeordnet werden
- gegenläufige Ziele
  - Minimierung des Overheads der Interprozesskommunikation
  - Parallelisierungspotential soll so gut wie möglich ausgeschöft werden

Task-Präzedenzgraphen

- sei $P = \{P_1, P_2, ..., P_n\}$ die Menge von Prozessen, die auf einer Menge von identischen Prozessoren ausgeführt werden sollen
- gegeben sei eine partielle Ordnungsrelation $<$ auf P
  - entspricht der zeitlichen Reihenfolge oder Präzedenzordnung
- $(P, <)$ wird beschrieben durch den Graph $G = (V, A)$ mit
  - Knoten V repräsentieren die Prozesse
  - gerichtete Kanten A stellen die Präzedenz zwischen den Knoten dar
- den Knoten $u \in V$ wird als Kostenfunktion $W(u)$ die Ausführungszeit der Tasks zugeordnet
- den gerichteten Kanten $(u, v) \in A$ ist eine Kostenfunktion $w(u, v) = (l, l')$ zugeordnet mit

  - l = Kommunikationskosten, falls u und v verschiedenen Prozessoren zugeordnet sind
  - l' = Kommunikationskosten, falls u und v dem gleichen Prozessor zugeordnet sind
- sind die Kosten l' vernachlässigbar klein gegenüber den Kosten l, nimmt man üblicherweise nur $w(u, v) = l$

Beispiel

- 5 Tasks mit Ausführungszeiten, Abhängigkeiten und Kommunikationskosten
- Wie könnte der Ablaufplan aussehen?

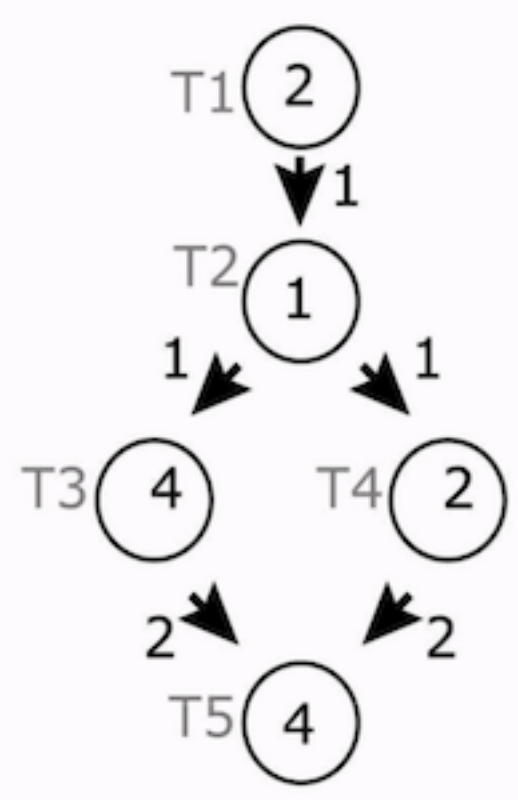

Quelle: Bengel et. al, Masterkurs Parallele und Verteilte Systeme

Task-Interaktionsgraphen

- zeitlicher Ablauf und zeitliche Abhängigkeiten bleiben unberücksichtigt
- die Kanten stellen Interaktion zwischen zwei kommunizierenden Prozessen dar
- jede Kante $(u, v) \in A$ hat Kantengewicht $w(u, v)$, die Kommunikationskosten darstellen, wenn u und v auf verschiedenen Prozessoren ausgeführt werden
- Knotengewicht $w(u)$ repräsentiert die Ausführungszeit als Kostenfunktion

- verschiedene Algorithmen
- ein einfacher:
  - man finde minimale Schnitte um die Kommunikationskosten zu minimieren, ohne die Prozessoren zu überlasten

Beispiel

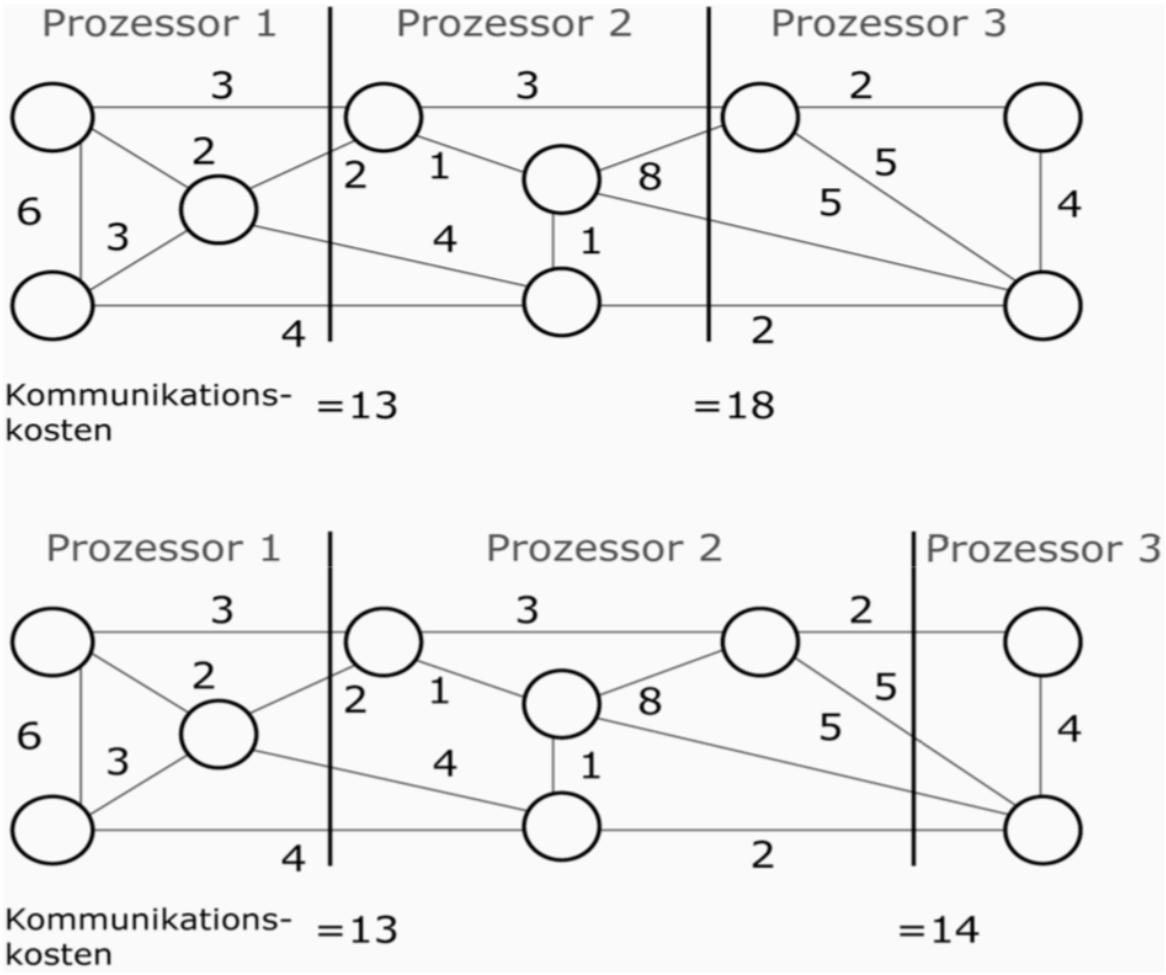

Quelle: Bengel et. al, Masterkurs Parallele und Verteilte Systeme

Workflows

- Erweiterung der Jobmodelle
- insebsondere für den Einsatz im Grid Computing
- oft als DAGs oder als Petrinetze
- komplexere Workflows enthalten Schleifen und bedingte Anweisungen und können dann **dynamisch** stückweise in DAGs überführt werden

- Beispiele
  - DAGMan für Lastverwaltungssystem Condor
  - BPEL bzw. BPEL4WS
  - Abstract Grid Workflow Language (AGWL)
  - Grid Workflow Definition Language (GworkflowDL)

Statische Lastverteilung: Lösungsverfahren

Schedulingproblem hat viele Varianten

- abhängig von den Jobs und von deren Anforderungen
- abhängig von Rechnerumgebung, z.B. ob homogen oder heterogen
- es existiert eine Vielzahl von Optimalitätskriterien (Zielfunktionen)
- im allgemeinen kein optimales Lösungsverfahren

Mögliche Zielfunktionen

aus Anwendersicht:

- Gesamtbearbeitungszeit (Makespan)
  - = Fertigstellungszeit des letzten Tasks
- Anzahl der Überschreitungen einer Deadline
- Summe der gewichteten Fertigstellungszeiten
- Summe der gewichteten Antwortzeiten
  - = Fertigstellungszeiten, gerechnet ab einer frühestmöglichen Startzeit
- Summe der gewichteten Verzugszeiten

aus Ressourcensicht:

- Auslastung / Grad der Parallelisierung

Lösungsverfahren

- dynamische Programmierung
- lineare Programmierung
- Branch-and-Bound-Algorithmus
- lokale Suchverfahren
- Simulated Annealing
- Tabu Search
- Evolutionäre Algorithmen
- …

Dynamische Lastverteilung

Problemstellung

- zwei Beispiele zur Verdeutlichung:
- Workstation-Modell
  - Workstations mehrere Benutzer sind vernetzt
  - Workstation ist entweder benutzt oder unbenutzt und könnte Berechnungen übernehmen
  - Lastverteilung so, dass Prozesse auf unbenutzte Workstations ausgelagert werde
  - Rückkehrende Benutzer haben aber Vorrang auf eigener Workstation
- Prozessorpool
  - zentraler Server nimmt Prozesse von Benutzern entgegen und verteilt sie auf Rechner im Pool
  - Benutzer erhalten eine passende Anzahl von Prozessoren, je nach Parallelisierungsgrad der Anwendung

Regelkreis

- die Aufgaben bei der dynamischen Lastverteilung entsprechen den Aufgaben in einem **Regelkreis**
- **Lasterfassung** oder **Lastmessung** (Messfühler)
- **Lastbewertungskomponente** (Regler)
- **Lastverschiebekomponente** (Stellglied)

Ausprägungen

- **anwendungsintegrierte** vs. **systemintegrierte** Lastverwaltung
- **Load Sharing** vs. **Load Balancing**
  - Load Sharing – Ziel: kein Rechner ungenutzt, solange passende Prozesse warten
  - Load Balancing – Ziel: darüber hinaus noch möglichst ausgeglichen verteilt
- bei Load Balancing mehr Tasktransfers ⇒ Kosten/Nutzen abschätzen
- Lastverwaltung
  - minimal: nur bzgl. direkter Nachbarn
  - maximal: gesamtes System

Strategien für automatische Lastverteilung

- **Initialisierungsstrategie** (*Initiation Policy*)
  - legt fest von welchem Knoten die Initiative zur Lastverteilung ausgeht
- **Informationsstrategie** (*Information Policy*)
  - bestimmt wann Information ausgetauscht wird
  - von welchem Knoten angefordert bzw. verbreitet wird
  - welche Informationen wichtig sind
- **Transferstrategie** (*Transfer Policy*)
  - entscheidet ob Lastausgleich erorderlich ist
- **Selektionsstrategie** (*Selection Policy*)
  - wählt zu transferierenden Prozess aus
- **Lookationsstrategie** (*Location Policy*)
  - bestimmt, welcher Knoten an einem als erforderlich erkannten Lastausgleich beteiligt werden soll

Zentrale Lastverteilungssysteme

- zentrale Komponente mit den Strategien
  - Initialisierungsstrategie ist nicht notwendig
- Lastmessung erfolgt auf den einzelnen Knoten
- einfaches Beispiel: Prozessorfarm zum parallelen Rechnen
  - ein Master führt die sequentiellen Teile durch
  - die Worker fordern beim Master Arbeit an, dieser verteilt
- zentraler Knoten ist Flaschenhals
- dadurch skaliert der Ansatz schlecht
- ist aber einfacher zu implementieren

Dezentrale Lastverteilungssysteme

- mehrere oder sogar alle Knoten verfügen über Lastbewertung
- gemischte Verfahren halten z.B. Informationen zentral, während Bewertung und Lastausgleich dezentral erfolgt
- kooperative und nicht-kooperative Verfahren
- kooperative sind komplexer, da die Lastverteilungseinheiten miteinander kommunizieren um einen gemeinsamen Algorithmus auszuführen

Lastausgleich ohne Migration

- eher Load Sharing statt Load Balancing
- Prozessor der Prozesse bekommt, verteilt diese weiter
- sehr viel einfacher zu implementieren, da Prozesse nie im Laufenden Zustand migriert werden
- Beispiel: Zufallsalgorithmus
  - jeder Prozessor schickt die Tasks an zufällig ausgewählte Knoten weiter
  - dadurch ist die Wahrscheinlichkeit einen Prozess zu erhalten für jeden Knoten gleich

Lastausgleich mit Migration

- neue Tasks optimal platzieren und
- Last von einem überlasteten Knoten weg zu transferieren
- Migration in dezentralen Systemen ermöglicht den höchsten Grad an Lastausgleich

Vorteile von Systemen mit der Möglichkeit zur Migration

- verringern von Laufzeiten durch parallele Prozessausführung oder Transferieren auf schneller CPUs
  - Achtung: Kosten/Nutzen
- erhöhen des Durchsatzes durch Nutzung freier Kapazitäten
- Reduktion der Netzwerkbelastung durch kürzere Wege
- Verlässlichkeit erhöhen
  - kritische Prozesse auf verlässliche Rechner verlegen oder Kopien anlegen und transferieren
- Bewältigung von Lastspitezn oder heterogener Lastverteilung
- Transferieren bei Shutdown oder wenn Besitzer der Rechner eigene Jobs startetn
- Transfer auf Rechner mit höheren Sicherheitsanforderungen
- vermeinden von Verhungern (starvation) von Prozessen

Anforderungen an Migrationsmechanismus

- Transparenz bzgl. Objektnamen und -orten, Systemaufrufen und IPC
- Transparenz gegenüber dem Nutzer
- möglichst geringe Kosten für Transfer
- keine Restabhängigkeit zu altem Knoten
  - Zugriffe mit höherer Last verbunden
  - Fehlertoleranz nimmt ab

Durchführung der Migration

- **Einfrieren** des Prozesses
  - Prozess muss entweder sofort oder nach einem nicht-unterbrechbaren Systemaufruf blockiert werden
  - schnelle I/O-Operationen werden zu Ende geführt
  - bei langsamen muss korrekte Weiterführung nach dem Neustart sichergestellt werden
  - Informationen über geöffnete Dateien müssen festgehalten werden
- **Transfer des Adressraums** und der Zustandsinformationen

  3 mögliche Methoden
  - **vollständiges Einfrieren**
    * Prozess bleibt während der gesamten Prozedur gestoppt
    * es kann zu Timeouts kommen und Benutzer kann beeinträchtigt werden
  - **Vortransferierung** (*pre-copying*)
    * transferiert den Adressraum des noch laufenden Prozesses
    * Seiten, die der Prozess noch modifiziert, werden sukzessive nachgeladen bis nur noch wenige übrig sind
  - **Transfer bei Referenzierung** (*copy-on-reference*)
    * Adressraum wird auf dem Quellknoten zurück gelassen und der Prozess auf dem Zielknoten gestartet
    * bei Bedarf werden die Seiten sukzessive nachgeladen
    * durch die weitere Abhängigkeit vermindert sich aber die Fehlertoleranz
- **Nachrichtenweiterleitung**

  3 Arten von Nachrichten
  - Nachrichten, die während der Prozess eingefroren ist, am Quellknoten eintreffen
  - Nachrichten, die nach Weiterführung auf dem Zielknoten, am Quellknoten eintreffen
  - Nachrichten, die nach Weiterführung erst versendet werden

4 Methoden um mit den Nachrichten zu verfahren

- **Rücksendung**, mit Maßgabe erneut zu senden und dazu den Empfänger zu finden
- **Weiterleitung vom Ursprungsknoten**, Ursprungsknoten muss über weitere Migration informiert werden
- **Wiederholte Weiterleitung**, durch alle Knoten auf denen der Prozess je war
- **Aktualisierung** von potentiellen Sendern
- **Ermöglichen der Fortführung der Kommunikation mit Koprozessen**

  zwei grundsätzliche Möglichkeiten

  - **Verbot der Trennung**
    * Eltern- und Kindprozesse müssen gemeinsam migriert werden
    * dadurch kann Parallelisierungspotential nicht genutzt werden
  - **Kommunikation über den Ursprungsknoten**
    * bekannte Nachteile: erhöhte Last, verringerte Fehlertoleranz

- **Aktivieren des Prozesses auf dem Zielknoten**
- das Verfahren funktioniert in homogenen Umgebungen
- in heterogenen Umgebungen sehr viel komplexer und sprengt hier den Rahmen