6 Prozessorvergabe in verteilten Systemen

6.1 Systemmodelle

- Arbeitsplatzrechner-Modell

  Das System besteht aus einer Menge von vernetzten Arbeitsplatzrechnern, zu denen jeder Benutzer Zugang hat

- Prozessorpool-Modell

  Benutzer haben Zugang zu einem einfachen Terminal (X-Terminal), ihre Aufträge werden zur Ausführung an einen Pool von Rechnern gesandt

- Hybrides Modell

- Arbeitsplatzrechner-Modell

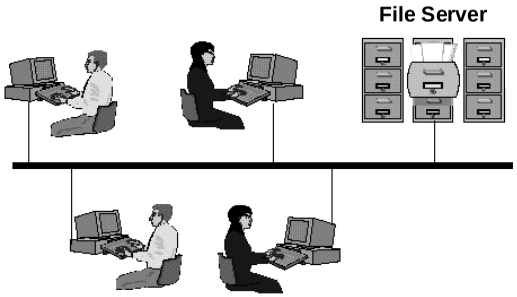

- Berechnungen werden am lokalen Rechner durchgeführt
- Dateien werden am *File Server* gespeichert
- Lokaler Plattenspeicher wird für Paging, Swapping, temporäre Dateien und Dateipufferung benutzt
- Schlechte Betriebsmittelnutzung

- Nutzung freier Kapazitäten

- Was ist ein freier Arbeitsplatzrechner?
  - Ein Rechner, an dem seit mehreren Minuten keine Eingabe erfolgte und kein Benutzerprozeß läuft

- Wie findet man freie Arbeitsplatzrechner?
  - Server-initiiert: Ein freier Rechner macht bekannt, daß er frei geworden ist
  - Client-initiiert: Benutzerrechner sucht per Broadcast nach einem freien Rechner

- Was geschieht, wenn der Besitzer seinen Rechner benötigt?
  - Nichts: Der Benutzer findet einen verlangsamten Rechner vor; keine gute Idee!
  - Verlagerung auf anderen freien Rechner: Erheblicher Aufwand
  - Fernen Prozeß mit niedrigster Priorität weiter bearbeiten: Nicht bemerkbar bezüglich Rechenleistung, belegt aber Betriebsmittel.

- Prozessorpool-Modell

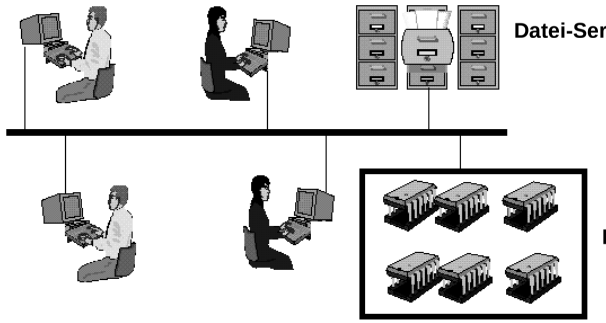

- Prozessoren werden dynamisch nach Bedarf zugeteilt

Nicht alles, was man im Internet findet, muß richtig sein!

Rationale for the Processor Pool Model

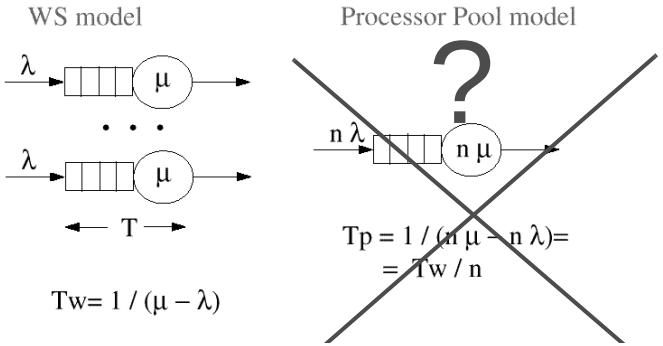

- **Rechnerzuteilung**
  - **Ziel: Auf welchem Prozessor sollte ein Prozeß laufen um Lastausgleich zu erreichen und die Ausführungszeit zu optimieren?**
  - **Annahmen**
    - **Alle Prozessoren sind binär-kompatibel (evtl. mit unterschiedlicher Ausführungsgeschwindigkeit)**
    - **Das System ist voll vermascht, d. h. jeder Prozessor kann mit jedem anderen Nachrichten austauschen**
  - **Quantifizierung des Vorteils von Lastausgleich**

- **Man betrachte eine Menge von M/M/1-Systemen**
  - **Es sei p die Wahrscheinlichkeit, daß wenigstens ein Server frei ist und wenigstens ein Auftrag auf Bearbeitung wartet**
  - **Zunächst Betrachtung eines Arbeitsplatzrechners**
    - $p_0 = 1 - \rho$ **Wahrscheinlichkeit, daß er frei ist**
    - $p_1 = \rho p_0 = (1-p_0)\, p_0$ **Wahrscheinlichkeit, daß er genau einen Auftrag enthält**
  - **Menge gleichartiger Prozessoren**
    - $q_i = p_0^i$ **Wahrscheinlichkeit, daß i vorgegebene Prozessoren frei sind**
    - h_{N-i} **Wahrscheinlichkeit, daß N-i vorgegebene Prozessoren beschäftigt sind und wenigsten eine ihrer Warteschlangen nicht leer ist**
    - h_{N-i} **= {Wahrscheinlichkeit, daß alle N-i wenigstens einen Auftrag enthalten} - {Wahrscheinlichkeit, daß alle genau einen Auftrag enthalten}**

      ⇒ $h_{N-i} = (1-p_0)^{N-i} - (1-p_0)\, p_0^{N-i}$

Also $p = \sum_{i=1}^{N} \binom{N}{i} q_i h_{N-i}$

$= \sum_{i=1}^{N} \binom{N}{i} p_0^i \{(1-p_0)^{N-i} - [(1-p_0)\, p_0]^{N-i}\}$

$1 + p = (1-p_0)^N - (1-p_0)^N - p_0^N (2-p_0)^N$

- **Wahrscheinlichkeit p, daß wenigstens ein Prozessor frei und ein Auftrag wartend ist, wenn ohne Lastausgleich gearbeitet wird**

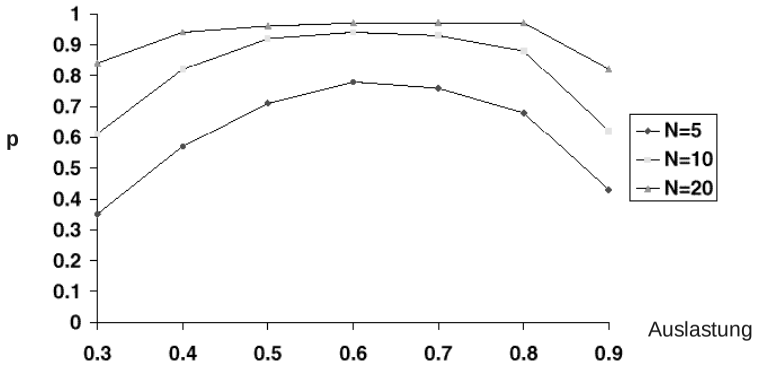

Bereich, in dem sich Lastverteilung lohnt

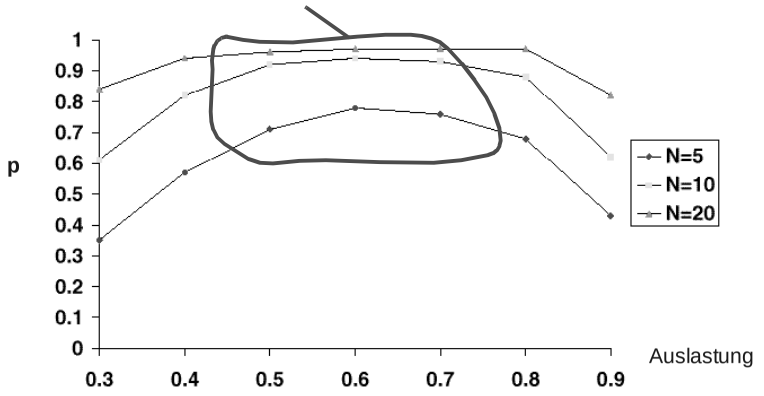

❑ **Lastverteilung versus Lastausgleich**

- **Lastverteilung (*load sharing*)**
  - **Es wird versucht zu vermeiden, daß ein Rechner leersteht, während in irgendeiner Warteschlange ein Auftrag wartet**
- **Lastausgleich (*load balancing*)**
  - **Es wird versucht, die Last gleichmäßig auf alle Rechner zu verteilen. Größerer Overhead durch Transfers kann den erwarteten Vorteil in einen Nachteil verkehren.**

6.2 Lastverteilung

❑ **Wesentliche Gesichtspunkte**

- **Die Warteschlangenlänge korreliert sehr gut mit der Verweilzeit**
- **Bei großen Übertragungsverzögerungen sollten Veränderungen der Wartschlangenlänge verbreitet werden, wenn Transferentscheidungen getroffen werden, nicht wenn neue Prozesse ins System kommen**
- **Timeouts werden zur Reduktion der Warteschlangenlänge benutzt, wenn Prozeß nicht ankommt**
- **Auch die Auslastung kann in die Entscheidungen einbezogen werden**

- **Rechnerzuordnung**
  - **Strategien**
    - **Nicht-migrierend (*nonmigratory*): Ein Prozeß kann nach seinem Start nicht mehr verlagert werden**
    - **Migrierend (*migratory*): Prozesse können während ihrer Ausführung verlagert werden um Lastausgleich zu erzielen**
  - **Optimierungsziele**
    - **Maximierung der Gesamtauslastung**
    - **Minimierung der mittleren Verweilzeit**
    - **Minimierung des Verhältnisses von Warte- zu Bedienzeit**

Beispiel

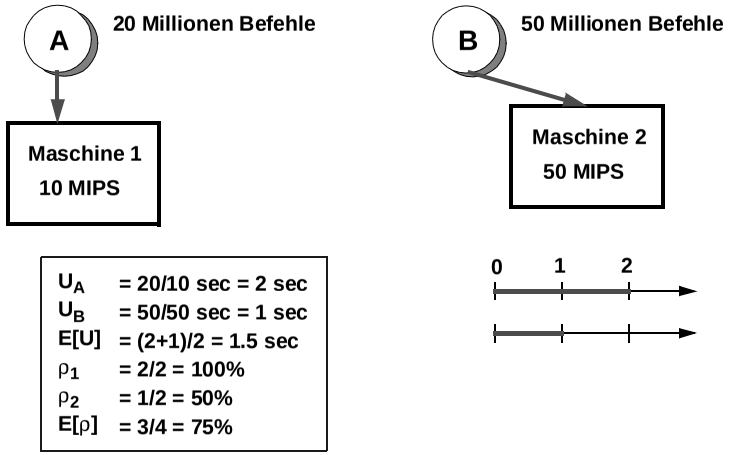

U_A = 20/10 sec = 2 sec
U_B = 50/50 sec = 1 sec
E[U] = (2+1)/2 = 1.5 sec
ρ_1 = 2/2 = 100%
ρ_2 = 1/2 = 50%
E[ρ] = 3/4 = 75%

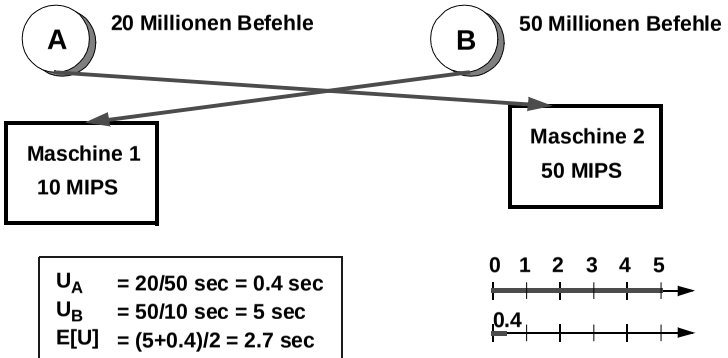

U_A = 20/50 sec = 0.4 sec
U_B = 50/10 sec = 5 sec
E[U] = (5+0.4)/2 = 2.7 sec
ρ_1 = 5/5 = 100%
ρ_2 = 0.4/5 = 8%
E[ρ] = (5+0.4)/10 = 54%

6.3 Komponenten eines Lastverteilungsalgorithmus

- **Transport-Strategie (*Transfer Policy*)**
  Wann soll ein Prozeß verlagert werden?
- **Auswahl-Strategie (*Selection Policy*)**
  Welcher Prozeß soll verlagert werden?
- **Plazierungsstrategie (*Location Policy*)**
  Wohin soll der Prozeß verlagert werden
- **Informations-Strategie (*Information Policy*)**
  Welche Informationen über andere Rechner werden wann und woher eingesammelt?

❑ **Transportstrategie**

- **Schwelle (*threshold*)**
  - **Wenn die vorhandene Last mehr als T Zeiteinheiten für ihre Abarbeitung benötigt, werden Prozesse ausgelagert.**
  - **Wenn die Last unter T Zeiteinheiten zurückgeht, werden Prozesse eingelagert**
- **Verfeinerung**
  - **Unterer und oberer Schwellwert zur Vermeidung von Prozeßflattern**

❑ **Auswahl-Strategie**

- **Auswahl eines neu hinzugekommen Prozesses; einfach zu migrieren**
- **Auswahl nach Verlagerungsaufwand (z. B. möglichst wenig lokaler Kontext)**
- **Prozeß verlagern, wenn dadurch seine Verweilzeit verkürzt werden kann**

❑ **Plazierungs-Strategie**

- **Pollen: Andere Rechner werden regelmäßig auf ihre Aufnahmefähigkeit hin überprüft**
  - **Überprüfung seriell oder parallel**
  - **Zufällige Auswahl**
  - **Nächster Nachbar**
  - **Aufgrund von früheren Informationen**
- **Anfrage per Broadcast**

❑ **Informations-Strategie**

- **Auf Anforderung (*demand-driven*): Informationen werden nur eingesammelt, wenn der Rechner in eine Verlagerung involviert wird**
  - **Sender-initiiert (*sender-initiated*): Sender sucht Empfänger**
  - **Empfänger-initiiert (*receiver-initiated*): Empfänger sucht Prozeß**
  - **Symmetrisch initiiert (*symmetrically-initiated*): Kombination der beiden vorangehenden Methoden**
- **Periodisch (*periodic*): Rechner tauschen regelmäßig Informationen aus**
  - **Ständiger Overhead**
  - **Nicht an Systemlast anpaßbar: Bei Hoch- und Niederlast nutzlose Zusatzbelastung**
- **Durch Zustandsänderungen veranlaßt (*state-change-driven*): Rechner verbreiten Information nur, wenn sich ihr Zustand ändert**
  - **Statusinformation wird verbreitet, nicht eingesammelt**
  - **zentralisiert: Statusinformationen werden zentral verwaltet und ausgewertet**
  - **verteilt: Statusinformationen gehen an alle Rechner**
  - **Zusatzaufwand für Entgegennahme der Statusinformationen ist Funktion der Systemlast**

❑ **Stabilität und Effektivität**

- **Algorithmus ist instabil (*unstable*), wenn die gesamte Ankunftsrate von Last die Leistungsfähigkeit des Rechners überfordert**
- **Algorithmus ist instabil (*unstable*), wenn mit einer endlichen Wahrscheinlichkeit Prozesse von einem Rechner zum anderen wandern oder Fortschritt zu erzielen**
- **Ein Algorithmus ist effektiv (*effective*) , wenn er die Systemleistung erhöht**

❑ **Klassifikation von Lastverteilungsalgorithmen**

- **Dynamisch: Entscheidung auf Grund der Knotenlast**
  - **Ausnutzen kurzfristiger Lastschwankungen**
  - **Zusatzbelastung beim Sammeln, Speichern und Auswerten von Zustandsinformation**
- **Statisch: Transferentscheidungen auf Grund von a-priori-Information**
- **Adaptiv: Wie dynamisch, aber zusätzlich adaptive Regelalgorithmen**

⧫ **Sender-initiierte Algorithmen**

- **Transport-Strategie:**
  - **Schwellwert-Strategie, die auf der Länge der Bereitwarteschlange basiert**
- **Auswahl-Strategie: Neu angekommene Prozesse**
- **Plazierungs-Strategie:**
  - **Zufällig: Vermeidung von Flattern durch Begrenzung der Transfers**
  - **Schwellwert-basiert: Befragen einer durch den Schwellwert begrenzten Menge von Knoten, um einen Empfänger zu finden. Falls kein Kandidat gefunden wird, lokal bearbeiten**
  - **Kürzeste Warteschlange: Befragen einer begrenzten Menge von Knoten und Auswahl desjenigen, mit der kürzesten Warteschlange**
- **Informations-Strategie:**
  - **Einsammeln der Zustandsinformation wird ausgelöst, wenn ein Knoten Last abgeben möchte**
- **Stabilität:**
  - **Instabil bei hoher Systemlast, da mit großer Wahrscheinlichkeit kein Empfänger gefunden wird und damit nur Zusatzaufwand entsteht**

⧫ **Empfänger-initiierte Algorithmen**

- **Transport-Strategie:**
  - **Schwellwert-Strategie, die auf der Länge der Bereitwarteschlange basiert**
- **Auswahl-Strategie: Irgendeine**
- **Plazierungs-Strategie:**
  - **Zufällig: Befragung einer begrenzten Menge von Knoten, ob ihr Schwellwert überschritten ist**
  - **Falls Suche fehlschlägt, warten bis ein anderer Prozeß fertig wird, dann erneut überprüfen (evtl. auch nach einem vorbestimmten Zeitintervall)**
- **Informations-Strategie:**
  - **Einsammeln der Zustandsinformation wird ausgelöst, wenn ein Knoten zusätzliche Last aufnehmen kann**
- **Stabilität:**
  - **Stabil. Bei hoher Systemlast wird mit großer Wahrscheinlichkeit ein zur Abgabe von Last geeigneter Knoten gefunden.**

❑ **Symmetrisch initiiert:**

- **Transport-Strategie:**
  - **Schwellwert-Strategie, die auf der Länge der Bereitwarteschlange basiert**
- **Auswahl-Strategie: Irgendeine**
- **Informations-Strategie:**
  - **Informationsaustausch nur bei Bedarf**
  - **Mittlere Systemlast wird lokal bestimmt**
  - **Akzeptierbarer Bereich bestimmt das Stabilisationsvermögen des Algorithmus**

- **Plazierungs-Strategie:**
  - **Sender-initiiert**
    - **Sender sendet “zu hoch”-Nachricht und wartet auf “empfangsbereit”**
    - **Empfänger sendet “empfangsbereit” und korrigiert seine Last mit der zu erwartenden**
    - **Nach Empfang von “empfangsbereit”: Falls immer noch Sender, verlagere günstigeren Prozeß**
    - **Falls kein “empfangsbereit”, dann per Broadcast “Mittelwerte ändern”.**
  - **Empfänger-initiiert:**
    - **Ein Empfänger versendet per Broadcast “zu wenig Last” und Wartet auf “zu viel Last”**
    - **Nach Empfang von “zu wenig Last” wird “empfangsbereit” versandt und die Last des Empfängers entsprechend erhöht.**
    - **Falls keine “zu viel Last”-Nachricht empfangen, dann per Broadcast “Mittelwerte anpassen” um die Schätzung der mittleren Last anderer Prozessoren zu erniedrigen**

6.4 **Beispiele**

❑ **Algorithmus 1**

♦ **Strategien**

- **Transport-Strategie:**
  - **Last-Schwellwert mit Transportschwellwert**
- **Auswahl-Strategie:**
  - Irgendeine
- **Plazierungs-Strategie:**
  - Zufällig
- **Informations-Strategie:**
  - **Informationsaustausch ausgelöst durch Sender**

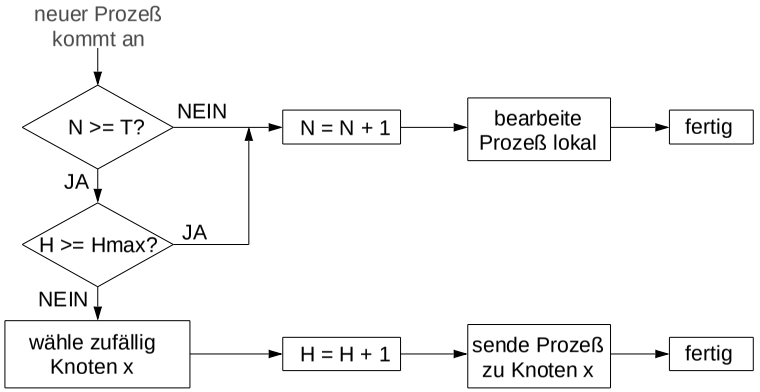

N: Länge der lokalen Bereitwarteschlange

T: Schwellwert für die lokale Bereitwarteschlange

H: Verlagerungszähler des Prozesses

Hmax: maximal erlaubte Verlagerungszahl

❑ **Algorithmus 2**

♦ **Strategien**

- **Transport-Strategie:**
  - **Last-Schwellwert**
- **Auswahl-Strategie:**
  - Irgendeine
- **Plazierungs-Strategie:**
  - Schwellwertbegrenzte zufällige Prüfung
- **Informations-Strategie:**
  - **Informationsaustausch ausgelöst durch Sender**

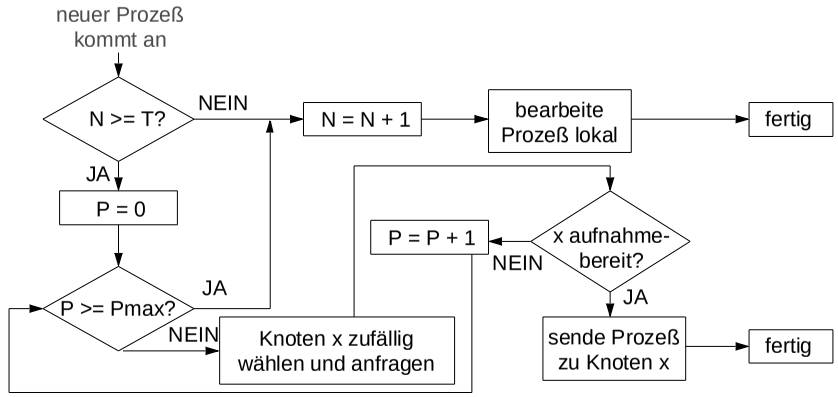

N: Länge der lokalen Bereitwarteschlange

T: Schwellwert für die lokale Bereitwarteschlange

P: Versuchszähler

Pmax: maximal erlaubte Versuchszahl

- **Algorithmus 3**

- **Strategien**
  - **Transport-Strategie:**
    - **Last-Schwellwert**
  - **Auswahl-Strategie:**
    - Irgendeine
  - **Plazierungs-Strategie:**
    - Geringste Last
  - **Informations-Strategie:**
    - **Informationsaustausch ausgelöst durch Sender**

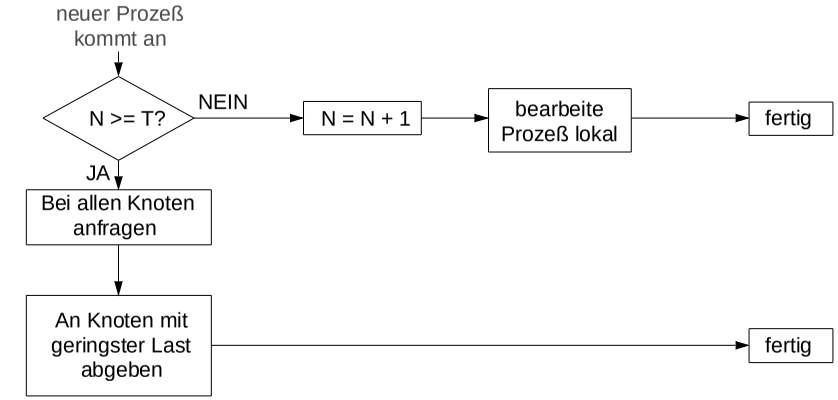

N: Länge der lokalen Bereitwarteschlange

T: Schwellwert für die lokale Bereitwarteschlange

- **Hybrides Modell**

- **Up-Down-Algorithmus**

Mutka, M. W.; Livny, M.: Scheduling Remote Processing Capacity In A Workstation-Processor Bank Network. Proceedings of the 7th International Conference on Distributed Computing Systems, Berlin, West Germany, September 21-25, 1987, pp. 2 - 9.

- **Jeder Arbeitsplatzrechner w besitzt einen Zuordnungsindex U(w) in einer zentralen Nutzungs-Tabelle**
- **Wenn der Besitzer von w unbearbeitete Aufträge für einen Poolrechner anstehen hat, bekommt U(w) negative, mit der Zeit zunehmende Strafpunkte**
- **Wenn der Besitzer von w Aufträge auf einem Poolrechner laufen hat, bekommt U(w) positive, mit der Zeit zunehmende Strafpunkte**
- **Wenn Rechner w keine Aufträge für den Pool anstehen hat und kein Poolrechner von ihm genutzt wird, wird U(w) näher an null gebracht bis es den Wert null hat.**
- **Heuristik: Ein freier Poolprozessor wird dem Auftrag zugeordnet, der den kleinsten Wert U(w) hat.**

6.5 **Zuordnung bei nebenläufigen abhängigen Aufträgen**

- **Fragenstellung**
  - **Gegeben ist**
    - eine Menge von Aufträgen mit Reihenfolgebedingungen und Forderungen an Rechenzeit und Kommunikation
    - eine Menge von Prozessoren, die über ein Kommunikationsnetzwerk verbunden sind
  - **Gesucht ist**
    - eine Zuordnung der Aufträge zu Prozessoren so, daß die Ausführungszeit minimiert wird.

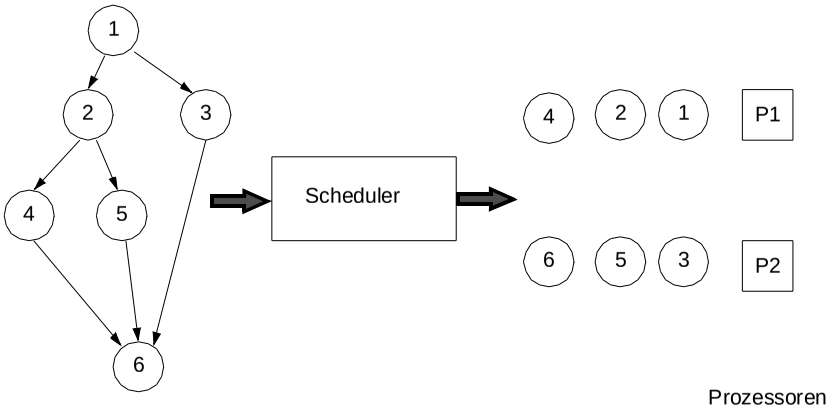

Auftrags-Graph

- **Problem ist NP-vollständig**
- **In sehr speziellen Fällen gibt es zeitlich polynomial begrenzte Lösungsalgorithmen**
  - Baumartiger Graph, wobei alle Aufgaben die gleiche Ausführungszeit haben
  - Im Fall von 2 Prozessoren
- **Im allgemeinen müssen heuristische Verfahren benutzt werden**

- **Eigenschaften von Zuordnungsalgorithmen**
  - **Bewertungsmaßstäbe**
    - Verweildauer der Gesamtaufgabe
    - Zusatzbelastung durch den Zuordnungsalgorithmus
  - **Einzelne Anwendung versus mehrere Anwendungen im Zeitmultiplex**
    - Einzel-Anwendungen: Minimierung der Verweilzeit
    - Mehrere Anwendungen: Lastausgleich
  - **Verdrängend oder nicht-verdrängend**

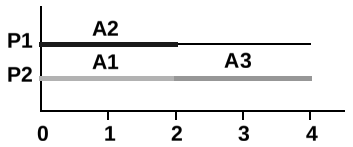

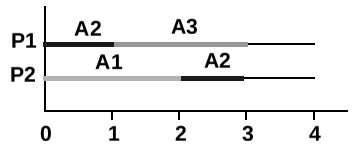

  - **Adaptiv oder nicht-adaptiv**
    - Adaptive Zuordnung kann Laufzeitmessungen nutzen
    - Sammeln und Auswerten von Laufzeitinformationen erzeugt Zusatzaufwand

Clustering

- **Aufgabenstellung**
  - Wenn zwei Aufträge dem gleichen Knoten zugeordnet werden, ist der Kommunikationsaufwand zwischen ihnen null.
  - Zuordnung zu unterschiedlichen Knoten erhöht die Parallelität und erniedrigt die Verweildauer.
- **Cluster-Algorithmen**
  - Aufträge werden in Cluster eingeteilt.
  - Alle Aufträge eines Clusters werden dem gleichen Knoten zugeteilt
  - Optimales Clustering ist NP-vollständig

Beispiele