


# HPC-Systeme Network

Prof. Dr. Volker Gülzow

Dr. Yves Kemp

SS 2017

# Wiederholung: Distributed Memory Systeme




Jeder Prozessor hat seinen eigenen Speicher.


Message Passing um Daten zwischen Prozessoren auszutauschen

# Interconnects: Ein bisschen Graphentheorie

- Voll vermascht: Jeder Prozessor ist mit jedem anderen Prozessor verbunden




- Stern Topologie: Ein zentraler Prozessor in der Mitte, zu dem alle anderen eine Verbindung haben




# Arrays und Ringe

- Lineares Array (1-D Array)
- Ring
- Mesh Netzwerk (2-D Array)




# Torus .

- 2-D Torus (2-D Variante eines Ringes)
  - Die Farben dienen nur der Visualisierung: Alle Verbindungen sind gleichwertig



# Hypercube

- Ein multidimensionales Mesh von Prozessoren mit genau zwei Prozessoren in jeder Dimension. Somit besteht ein d-dimensionaler Hypercube aus  $p=2^d$  Prozessoren
- Hypercubes für  $d=0,1,2,3$



# Induktive Herleitung von Hypercube mit $d=4$



- Starte mit zwei 3-d Hypercubes
- Je zwei Prozessoren aus den beiden 3-d Hypercubes werden verbunden

# Vor/Nachteile von Hypercubes


- Pro
  - Bessere Skalierbarkeit wie zB voll vermasht
  - Die Prozessoren sind gut benachbart: Nicht weiter als  $\log(p)$  entfernt
  - Hohe Bandbreite
  - Wenig contention
- Nachteile
  - Benötigte Verbindungen aus dem Prozessor hängt von  $p$  ab, kompliziertes Prozessordesign
  - Mögliche Werte für  $p=2^d$
  - Aufteilung der Applikation auf Hypercube schwierig (Gray-Codes, rekursives Aufteilen)

# Bus / Hub und Crossbars

- Bus / Hub: Jeder Prozessor teilt den Kommunikations-Link




- Crossbar-Switch: Jeder Prozessor ist mit dem Crossbar Switch verbunden, der die Verbindung routet




# Butterfly Netzwerke

- Aus einfachen Switches aufgebaut
- Mehrere Lagen, die Anzahl der Lagen wächst mit der Anzahl der Prozessoren
- Mehrere nicht-kollidierende Wege möglich
- Uniform Memory Access



# Fat Tree (Clos) Netzwerk

- Mehrere Switches, auf mehreren Ebenen
- Jeder Switch hat gleichviele Links „nach unten“ wie „nach oben“
- Die Anzahl der Links steigt mit jeder Ebene
- Volle Bandbreite zwischen den Links
- Mit jedem Switch steigt die Latenz




# Design-Ziele

- #Links zwischen Prozessoren
  - Mehr ist besser, aber auch teurer und schwieriger umzusetzen
- Abstand zwischen Prozessoren
  - Weniger ist besser, aber skaliert typischerweise nicht gut
- Anzahl der Wege zwischen zwei Prozessoren
  - Mehr ist besser da die contention geringer wird
- Latenz
  - Weniger ist besser
- Bandbreite
  - Punkt-zu-Punkt, als auch aggregiert

# Mehr zu Fat-Tree Netzwerken und InfiniBand


- InfiniBand ist vermutlich die am meisten im HPC Bereich genutzte Inter-Node Kommunikation
  - Intel OmniPath recht neu im Markt, schon einige grosse Projekte
- Basis-Bausteine der Switches sind 36-Ports ASICs (Switching Fabric)

- Einfachstes Setup:




- Skalierung?

# Fat-Tree, fully-non-blocking



# Grössere Netze mit Fat-Tree, fully-non-blocking


- Mindestens drei Lagen ... Aber unübersichtliche Verkablung
- Typischerweise mittels „Director Switches“ (Mellanox Namensgebung)
- Diese bauen aber auch auf den 36-port-ASICs auf
- Beispiel: 2x 648-Port Director-Switch im Spine-Level:



$72 \times 18 = 1296$  Nodes maximal anschliessbar bei zwei 648-Port Director Switches im Spine-Level

## ... Und natürlich auch kleinere Setups

- 36 nodes = 1 Switch
- 37 nodes = 5 Switch
- Oder umgekehrt:
  - zwei 36-Port Switch im Spine-Level
  - =72 Nodes
  - = $72/18 = 4$  Leaf Switches
- Welche sinnvollen #Spine gibt es?
  - Teiler von 18: 1,2,3,6,9,18
  - Andere sind prinzipiell möglich




# Was heisst eigentlich „fully-non-blocking“?

- Keine Contention / Kollisionen
- Ist dies notwendig?
  - Tja ... Hängt von den Applikationen ab
- Viele Cluster haben Netzwerk-Topologien mit „Blocking-Factor“
  - 2/1 ist ein beliebter Blocking Factor für Compute (Inter-Process-Communication)
  - Bei Storage: Man hört Aussagen wie bis „8/1 Blocking Factor kein Problem“
- Blocking Factor
  - Verhältnis Bandbreite im Leaf-Level / Bandbreite im Spine-Level
  - Kann ggf. inhomogen sein im Cluster
  - Kann auch nicht-ganzzahlige Werte annehmen

# Fat-Tree, 2/1 Blocking Factor

- Alle an einem Leaf-Node angeschlossenen Nodes können „fully-non-blocking“ kommunizieren (quasi eine Insel)
- Verkehr über die Spine-Ebene unterliegt dem Blocking-Factor
- Einfachstes Beispiel
  - 1 Spine
  - 3 Leaf
  - $3 \times 36 \times 2 / (1 + 2) = 72$  Ports



# Blocking Factor, zweilagiges Netzwerk, 36-port Switches


| Blocking Factor | Max #Spine | Max #Port |
|-----------------|------------|-----------|
| 1               | 18         | 648       |
| 2               | 12         | 864       |
| 3               | 9          | 972       |
| 5               | 6          | 1080      |
| 8               | 4          | 1152      |
| 11              | 3          | 1188      |
| 17              | 2          | 1224      |
| 35              | 1          | 1260      |

- Wie kommt man auf diese Werte?
- Man beachte den Sprung von 1:1 -> 2:1 Blocking Factor
  - Alle weiteren Erhöhungen des Blocking Factor bringen nur verhältnismässig wenig mehr Max#Port
- Höhere BF können interessant sein: Relativ grosse Inseln (zB 32 ports bei BF 8:1), das kann für manche Anwendungen ausreichend sein
- Scheduler muss die Topologie des Clusters kennen!

# Cluster-Aufbau

- Typischerweise sind alle Nodes eines Leaf-Switches im Rack „nahe beisammen“
  - 2/1 BF: 24 Nodes -> Zb 12 Hoeheneinheiten
  - 48 Nodes = 24 HE (~24 kW) in einem Schrank, zwei Leaf-Switche
  - Kupferverkablung Node -> Leaf-Switch (0.5, 1, 2 m)
  - „Top-Of-Rack“ oder „Access Layer“ Switch
- Die Leaf-Switche sind mit den Spine-Switches verbunden
  - 2/1 BF: 6 Spine -> 18 Leaf (=9 Racks mit Nodes ... Wenn wir Storage vergessen)
  - Kupferverkablung zu umstaendlich (und zu lange Kabellaengen)
  - Glasverkablung Leaf -> Spine (Spine Switches zentral in 1-2 Racks)
  - „Core Layer“ Switches

# 2D/3D Torus Vernetzung: Beispiel 2D



# Vorteile / Nachteile Torus

- Skalierung besser, weniger Switche notwendig
- Bessere Erweiterbarkeit
- Einfachere Verkablung, kürzere Kabel
- Fehler-toleranter
  
- Kommunikationswege schwieriger, ggdfs. mehr Hops
  
- <http://clusterdesign.org/>

# InfiniBand: Verschiedene Generationen

|  | ◆ SDR ◆       | ◆ DDR ◆ | ◆ QDR ◆ | ◆ FDR10 ◆ | ◆ FDR ◆                | ◆ EDR ◆             |
|--|---------------|---------|---------|-----------|------------------------|---------------------|
| <b>Signaling rate (Gbit/s)</b>                                     | 2.5           | 5       | 10      | 10.3125   | 14.0625 <sup>[6]</sup> | 25                  |
| <b>Theoretical effective throughput, Gbs, per 1x<sup>[7]</sup></b> | 2             | 4       | 8       | 10        | 13.64                  | 24.24               |
| <b>Speeds for 4x links (Gbit/s)</b>                                | 8             | 16      | 32      | 40        | 54.54                  | 96.97               |
| <b>Speeds for 8x links (Gbit/s)</b>                                | 16            | 32      | 64      | 80        | 109.08                 | 193.94              |
| <b>Speeds for 12x links (Gbit/s)</b>                               | 24            | 48      | 96      | 120       | 163.64                 | 290.91              |
| <b>Encoding (bits)</b>   | 8/10          | 8/10    | 8/10    | 64/66     | 64/66                  | 64/66               |
| <b>Adapter latency (microseconds)<sup>[8]</sup></b>                | 5             | 2.5     | 1.3     | 0.7       | 0.7                    | 0.5                 |
| <b>Year<sup>[9]</sup></b>  | 2001,<br>2003 | 2005    | 2007    | 2011      | 2011                   | 2014 <sup>[7]</sup> |

<https://en.wikipedia.org/wiki/InfiniBand>

# Mischen erlaubt

- ZB EDR abwärtskompatibel zu FDR abwärtskompatibel zu QDR
- ZB: EDR Switch Infrastruktur, aber Nodes mit FDR angeschlossen
  - Spart Kabel und Switches
  - „Nearly-non-blocking“ ... Interessante Blocking-Faktoren

# Vergleich mit Ethernet

- Ethernet 10 GE ist Standard ... Vergleich zu FDR IB mit 54 Gbit/s
- 40 GE gibt es schon im Rechenzentrum, erste Sichtungen von 100 GE
  - Vergleich zu EDR IB mit 100 Gbit/s
- Welches Ethernet?
  - Normales „Natives Ethernet“
  - RDMA-over-Converged-Ethernet


# Welches Ethernet?

TABLE I. DIRECTLY CONNECTED LATENCY

| <b>Message Size</b> | <b>Average Latency</b> |                  |                             |
|---------------------|------------------------|------------------|-----------------------------|
|                     | <i>Native IB (us)</i>  | <i>RoCE (us)</i> | <i>Native Ethernet (us)</i> |
| 8                   | 0.892                  | 0.988            | 12.662                      |
| 16                  | 0.938                  | 1.014            | 12.692                      |
| 32                  | 0.95                   | 1.026            | 12.718                      |
| 64                  | 0.958                  | 1.024            | 12.712                      |
| 128                 | 1.344                  | 1.418            | 12.78                       |
| 256                 | 1.402                  | 1.474            | 12.884                      |
| 512                 | 1.518                  | 1.584            | 13.104                      |
| 1024                | 1.752                  | 1.814            | 13.55                       |

# Welches Ethernet?

FIGURE I. DIRECTLY CONNECTED LATENCY



[http://sc16.supercomputing.org/sc-archive/tech\\_poster/poster\\_files/post149s2-file3.pdf](http://sc16.supercomputing.org/sc-archive/tech_poster/poster_files/post149s2-file3.pdf)

# Welches Ethernet?


- ... Allerdings sind nicht alle Ethernet Adapter RoCE fähig
  - Und die, die es sind, sind nicht günstiger als InfiniBand
- Wo RoCE
  - „Big-Data“ HPC-Cluster
  - Gutmütige Applikationen mit wenig inter-process-communication
  - Strategische Entscheidung für einheitliches Netzwerk
- Oder ganz Verzicht auf RDMA, dafür schnelle Verbindung: Solarflare etc.
- Dedizierte Interconnects werden definitiv weiterhin eine Rolle spielen!

# InfiniBand und Alternativen

- Eigentlich nur Omni-Path als allgemein verfügbare Alternative
- InfiniBand: Aktuell (quasi) nur Firma Mellanox
- Omni-Path: Entwickelt von der Firma Intel
  
- Quizfrage: Ordnen Sie folgende Aussagen einem Hersteller/Technologie zu:
- A) Interconnects profitieren von einer Integration in die CPU
- B) Separate PCI-Adapter Karten ermöglichen bessere Performance zB durch Offload

# Omni-Path

- Relativ neu: Verfügbarkeit erst seit Anfang 2016
  - 100 Gbit/s ... Also identisch zum direkten Vergleich EDR IB
  - 48-Port-Switches ... Ggbfs. Weniger Infrastruktur-Kosten als IB
  - Latenz vergleichbar zu EDR IB
- 
- „On-Load“ Strategie (auf CPU)
  - Vs. „Off-Load“ bei InfiniBand



<http://www.intel.com/content/www/us/en/high-performance-computing-fabrics/omni-path-architecture-performance-overview.html>


# Omni-Path

- Für den Hersteller interessant: Direkt auf der CPU
  - Einige Server-CPU Modelle
  - Xeon-Phi / Knights-Landing: Spezial-CPU

# Knights Landing Overview

## TILE

|       |        |       |
|-------|--------|-------|
| 2 VPU | CHA    | 2 VPU |
| Core  | 1MB L2 | Core  |



Omni-path not shown

**Chip: 36 Tiles** interconnected by **2D Mesh**

**Tile: 2 Cores + 2 VPU/core + 1 MB L2**

**Memory: MCDRAM: 16 GB on-package; High BW**

**DDR4: 6 channels @ 2400 up to 384GB**

**IO: 36 lanes PCIe Gen3. 4 lanes of DMI for chipset**

**Node: 1-Socket only**

**Fabric: Omni-Path on-package (not shown)**

**Vector Peak Perf: 3+TF DP and 6+TF SP Flops**

**Scalar Perf: ~3x over Knights Corner**

**Streams Triad (GB/s): MCDRAM : 400+; DDR: 90+**

Source Intel: All products, computer systems, dates and figures specified are preliminary based on current expectations, and are subject to change without notice. KNL data are preliminary based on current expectations and are subject to change without notice. 1 Binary Compatible with Intel Xeon processors using Haswell Instruction Set (except TSX). 2 Bandwidth numbers are based on STREAM-like memory access pattern when MCDRAM used as local memory. Results have been estimated based on internal Intel analysis and are for informational purposes only. Any difference in system hardware or software design may impact actual performance.

<https://www.nextplatform.com/2016/06/20/intel-knights-landing-yields-big-bang-buck-jump/>


# Weitere Netzwerke & Topologien: Cray Dragonfly

- Exkurs: Seymour Cray *der* HPC Pionier
- Firma Cray (in mehreren Versionen) führend bei HPC Systemen und Innovation
- Aktuell mehre ganz grosse Systeme in TOP500
- Komplexer Aufbau, eigenes Netzwerk

Cray-1  
Deutsches Museum  
(Quelle Wikipedia)



# Aufbau einer Cray XC30




# Routing: Viele Algorithmen

- ... Aber erstmal Namensverwirrung:
- Routing bedeutet eigentlich: Pakete zwischen verschiedenen Subnetzen zu bewegen
- In diesem Kontext heisst Routing aber auch häufig Pakete innerhalb des gleichen Subnetzes zu bewegen ... Also eigentlich Switching

# Beispiel eines Algorithmus: Up/Down

Schritt 1:


Breadth-First Spanning Tree aufbauen, und in (in diesem Beispiel) drei Ebenen kategorisieren



# Beispiel eines Algorithmus: Up/Down

Schritt 2:

Mögliche Wege suchen, wobei Wege mit Down->Up Sequenz verboten sind



# Beispiel eines Algorithmus: Up/Down

Je nach Topologie können ggf nicht alle Knoten miteinander kommunizieren.  
Das kann aber auch gewollt sein

