Middleware – Cloud Computing – Übung

Verteilte Dateisysteme & Container: Hadoop Distributed File System

Wintersemester 2020/21

Michael Eischer, Laura Lawniczak, Tobias Distler

Friedrich-Alexander-Universität Erlangen-Nürnberg
Lehrstuhl Informatik 4 (Verteilte Systeme und Betriebssysteme)
www4.cs.fau.de

Lehrstuhl für Verteilte Systeme
und Betriebssysteme

FRIEDRICH-ALEXANDER
UNIVERSITÄT
ERLANGEN-NÜRNBERG

TECHNISCHE FAKULTÄT

Überblick

Verteilte Dateisysteme

Dateisysteme

Dateisysteme

Lokale Dateisysteme

- Adressierung von Daten auf physikalischen Datenträgern
- *Beispiele:* FAT32, `Ext4`, `Btrfs`

Netzwerk-Dateisysteme

- Zugriff auf entfernte, persistente Daten über Rechnergrenzen
- *Beispiele: Andrew File System* (AFS), *Network File System* (NFS)

Probleme

- Fehleranfälligkeit (z.B. Ausfall von Netzwerkverbindungen)
- Flaschenhalsbildung durch Ungleichgewicht
  (Anzahl Clients vs. Server)

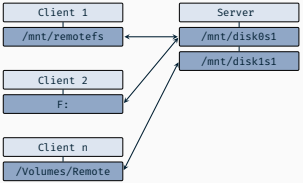

- Trennung von Belangen (engl. *separation of concerns*)
  - Indizierung
  - Datenverwaltung
- Replikation der Daten für höhere Ausfallsicherheit
  $\rightarrow$ Einhaltung von *Service-Level-Agreement*, kurz: SLA
- Auflösung von Konflikten zwischen Clients
- Beispiele:
  - Ceph
  - Google File System
  - **Hadoop Distributed File System**

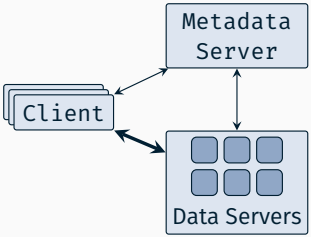

Verteilte Dateisysteme

Hadoop Distributed File System (HDFS)

Apache Hadoop: Überblick

- Teil des Apache Hadoop Frameworks für skalierbare, verteilte Datenverarbeitung

Quelle der Illustration: https://blog.codecentric.de/2013/08/einfuhrung-in-hadoop-die-wichtigsten-komponenten-von-hadoop-teil-3-von-5/

Hadoop Distributed File System (HDFS)

Konzepte

- Write-once, read-many (WORM)
- Replikation
- Datenlokalität („rack-aware“)

Architektur

- HDFS-Client
- NameNode → Namensraum (Index, Metadaten)
- DataNode → Blockreplikate (Blockdaten + Metadaten)

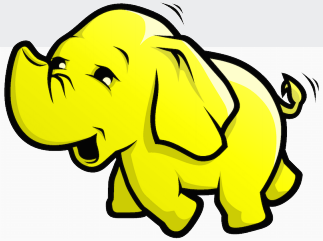

Hadoop Distributed File System (HDFS)

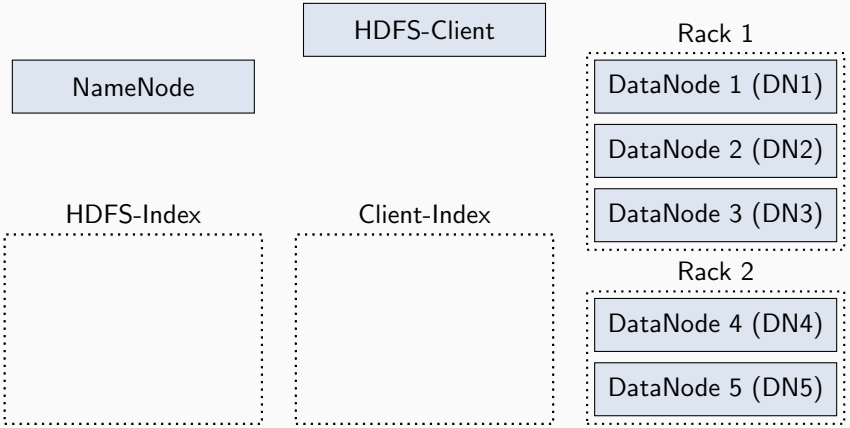

- System-Konfiguration
  - 1x HDFS-Client
  - 1x NameNode
  - 5x DataNodes (Rack 1: DN1–3, Rack 2: DN4–5)

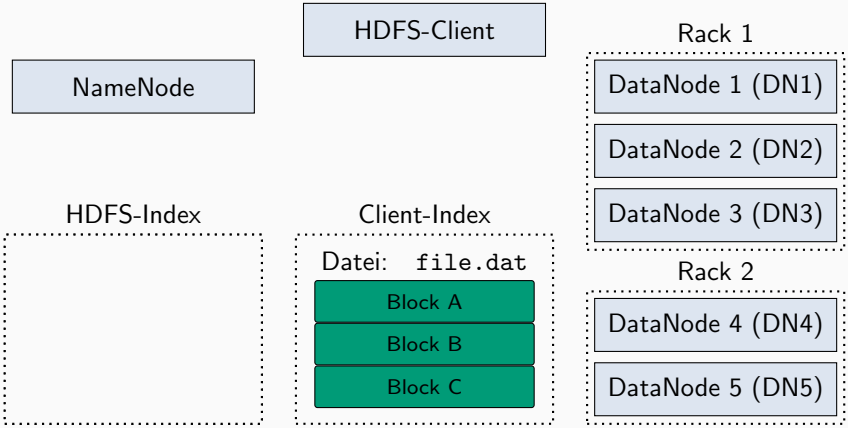

- HDFS-Client legt die aus drei Blöcken (A, B und C) bestehende Datei `file.dat` im HDFS an

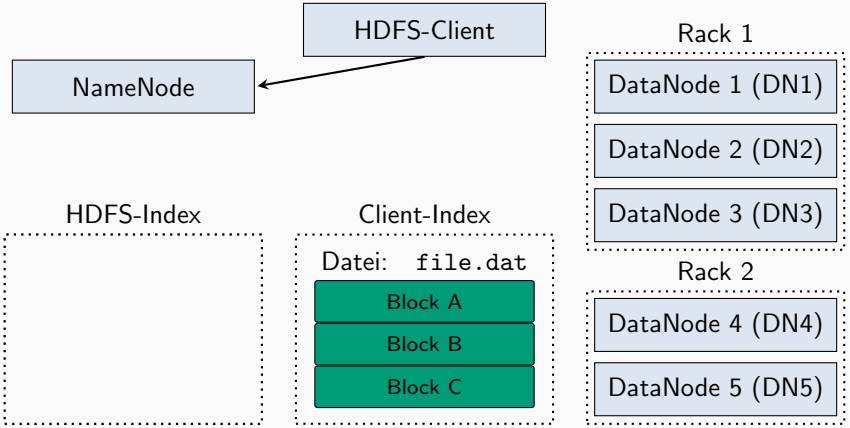

1. HDFS-Client → NameNode:
   Anforderung eines sog. Lease (dt. *Miete*) für das Schreiben der Datei `file.dat`

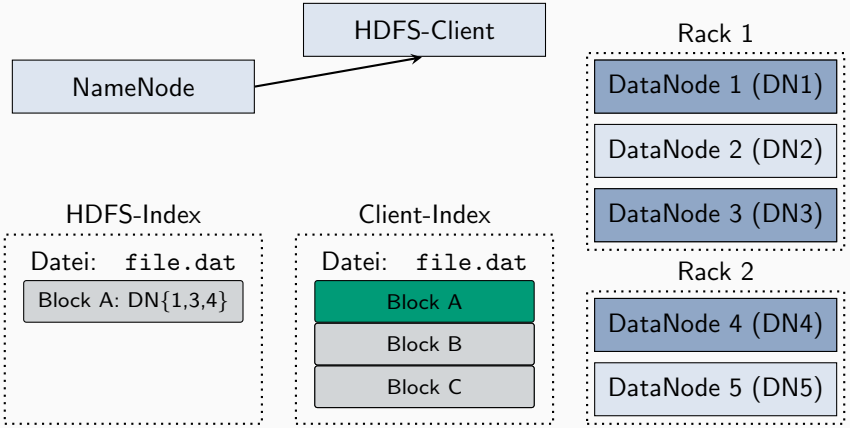

2. NameNode → HDFS-Client:
   Erteilung des Lease, Erzeugung einer Block-ID für den ersten Block (Block A),
   Zuteilung der Replikate (DN1, DN3 und DN4)

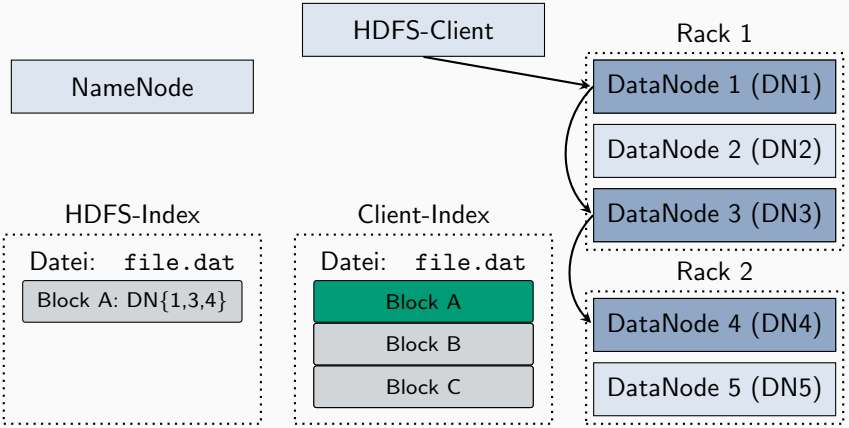

3. „Daten-Pipeline“ zur Vorbereitung der Schreiboperation*en* von Block A:
   HDFS-Client — DN1 — DN3 — DN4

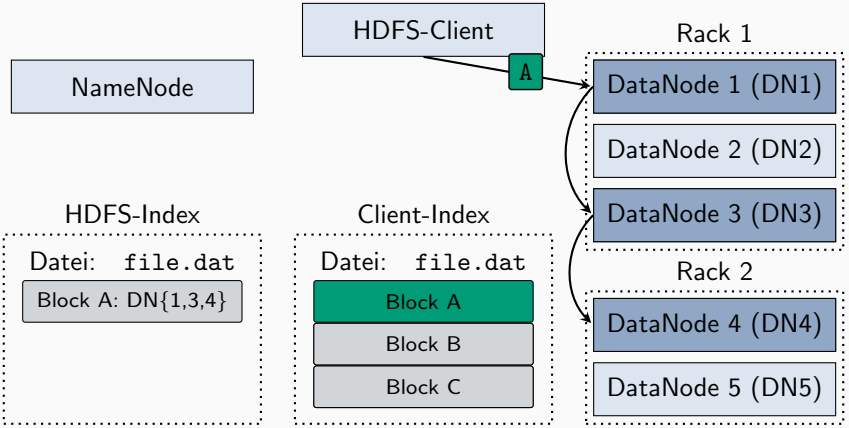

4. Durchführung der Schreiboperationen:
   HDFS-Client sendet Block A an DN1, DN1 sendet empfangenen Block A an DN3, DN3 sendet empfangenen Block A an DN4

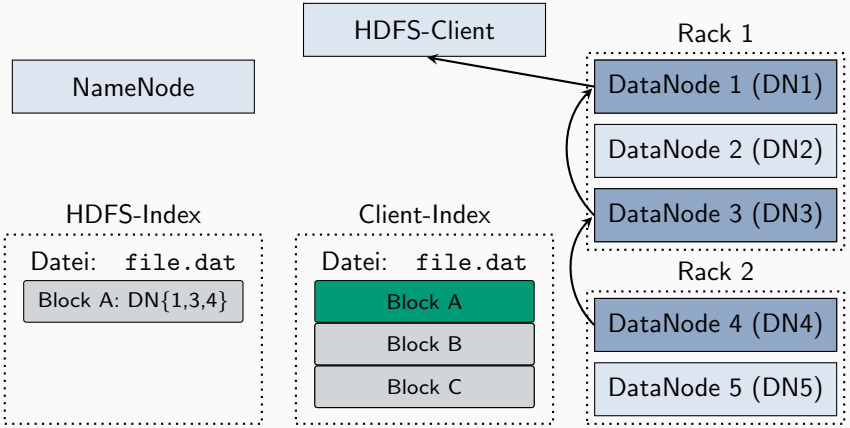

5. Bestätigung der Schreiboperationen:
   Jede DataNode bestätigt das erfolgreiche Schreiben von Block A entlang der Pipeline (Abbau)

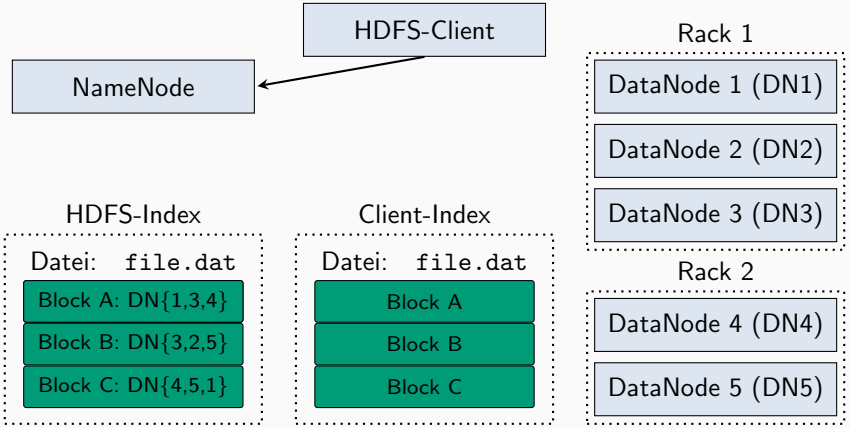

6. HDFS-Client → DataNodes:
   Analog werden die restlichen Blöcke der Datei vom HDFS-Client an die DataNodes verschickt; HDFS-Client benachrichtigt NameNode von erfolgreicher Schreiboperation

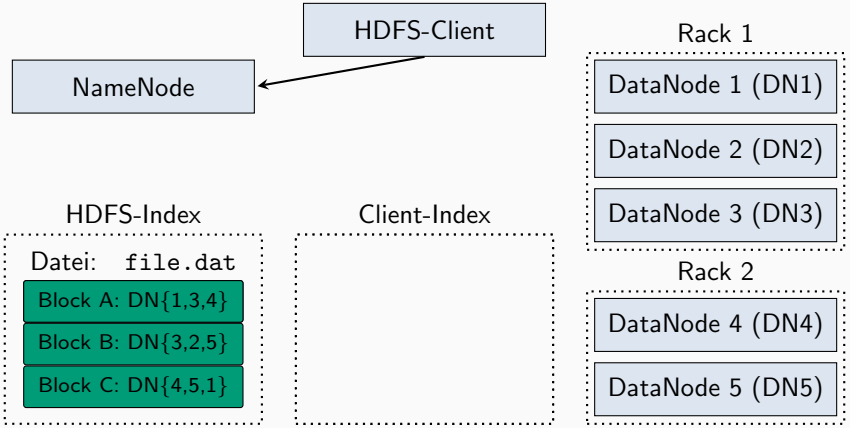

1. HDFS-Client → NameNode:
   Anforderung der DataNodes-Liste: Alle DataNodes, die Blöcke der zu lesenden Datei `file.dat` speichern

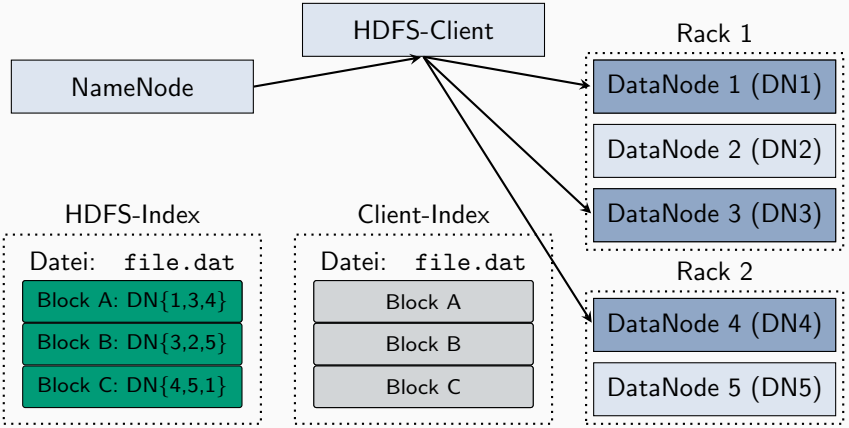

2. NameNode → HDFS-Client, HDFS-Client → DataNodes:
   Client erhält DataNodes-Liste und wählt den ersten DataNode für jeden der Datenblöcke

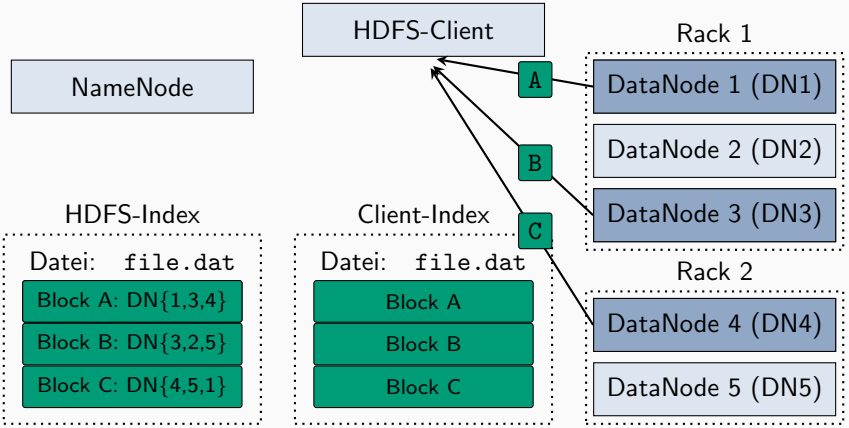

3. DataNodes → HDFS-Client:
   HDFS-Client liest die Blöcke sequentiell, DataNodes senden die angeforderten Blöcke an den HDFS-Client

Hadoop Distributed File System (HDFS)

- (Weitere) HDFS-Details
  - Herzschlag-Nachrichten (engl. heartbeat) von DataNodes zum NameNode
    - → Alle drei Sekunden (Default) ein Herzschlag
    - → Replikationsfaktor sicherstellen
    - → Grundlast bei sehr großen Clustern
  - Block-Report: NameNode generiert Metadaten aus den Block-Reports
    - → Umfangreicher Bericht über alle Blöcke alle 60 Minuten (Default)
    - → Löschen ungenutzter Blöcke
  - NameNode
    - → *Die Sollbruchstelle des Systems?*

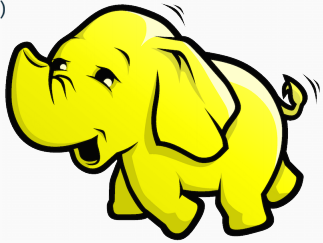

- Literatur

Konstantin Shvachko, Hairong Kuang, Sanjay Radia, and Robert Chansler

The Hadoop distributed file system

Proceedings of the 26th IEEE Symposium on Mass Storage Systems and Technologies (MSST '10), pages 1–10, 2010.