Database as a Service

Neue Technologien aus dem Bereich Cloud Computing, NoSQL und Big Data

Universität Hamburg
DER FORSCHUNG | DER LEHRE | DER BILDUNG

Themenblöcke

- Basistechnologien
- Cloud Computing und DBaaS Plattformen
- Big Data Plattformen
- NoSQL Systeme

Ziele des Seminars

Database-as-a-Service & Cloud Data Management

Umbrüche in der Datenbankwelt

1. Cloud Computing:

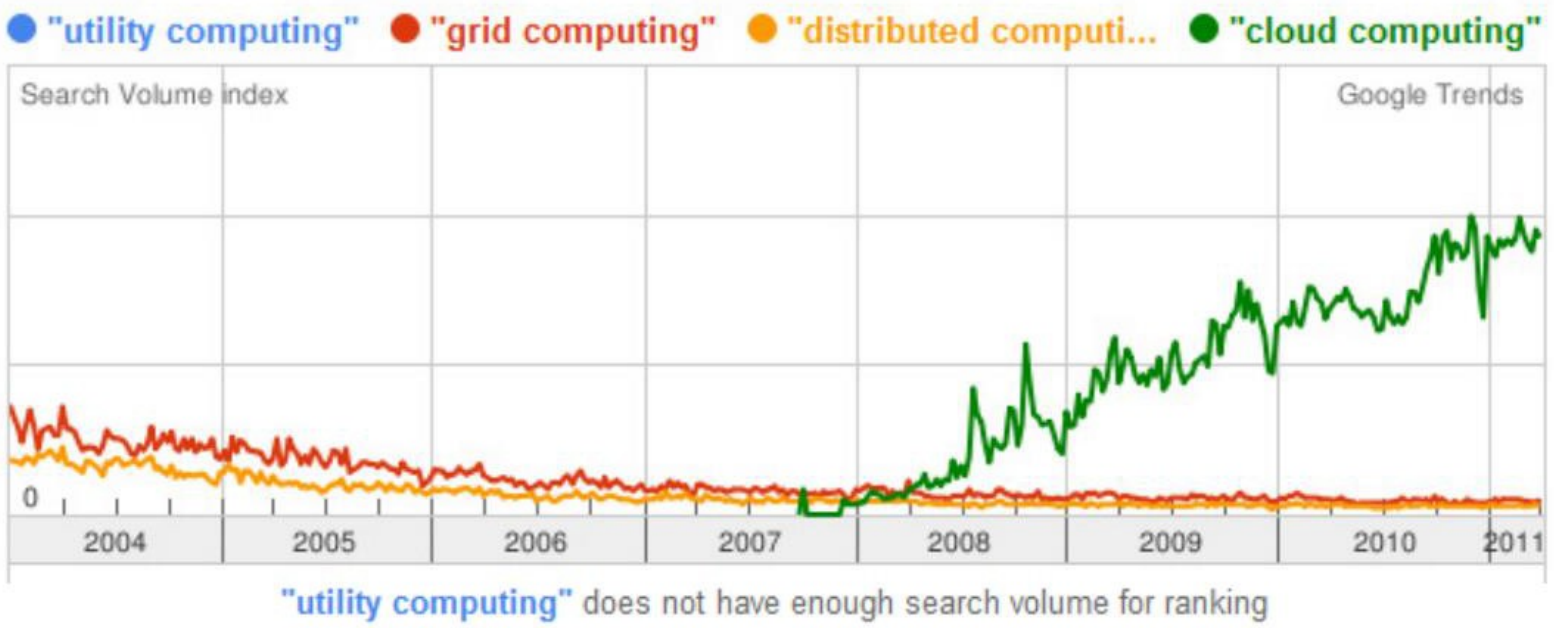

Umbrüche in der Datenbankwelt

2. NoSQL

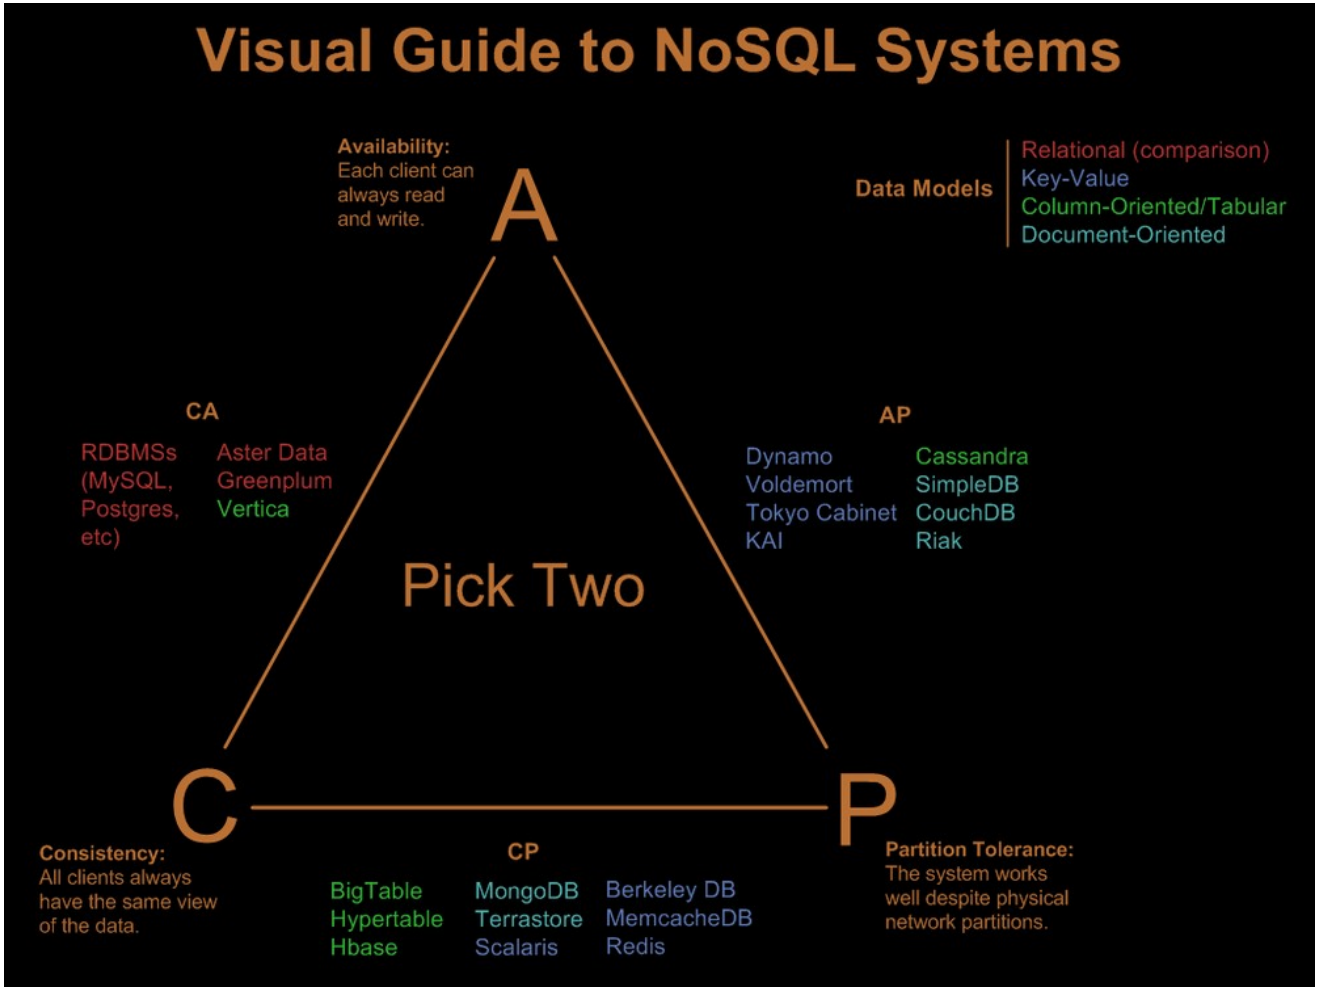

[Nathan Hurst, Visual Guide to NoSQL Systems]

Umbrüche in der Datenbankwelt

[451 Group Report, 2011]

2. NoSQL

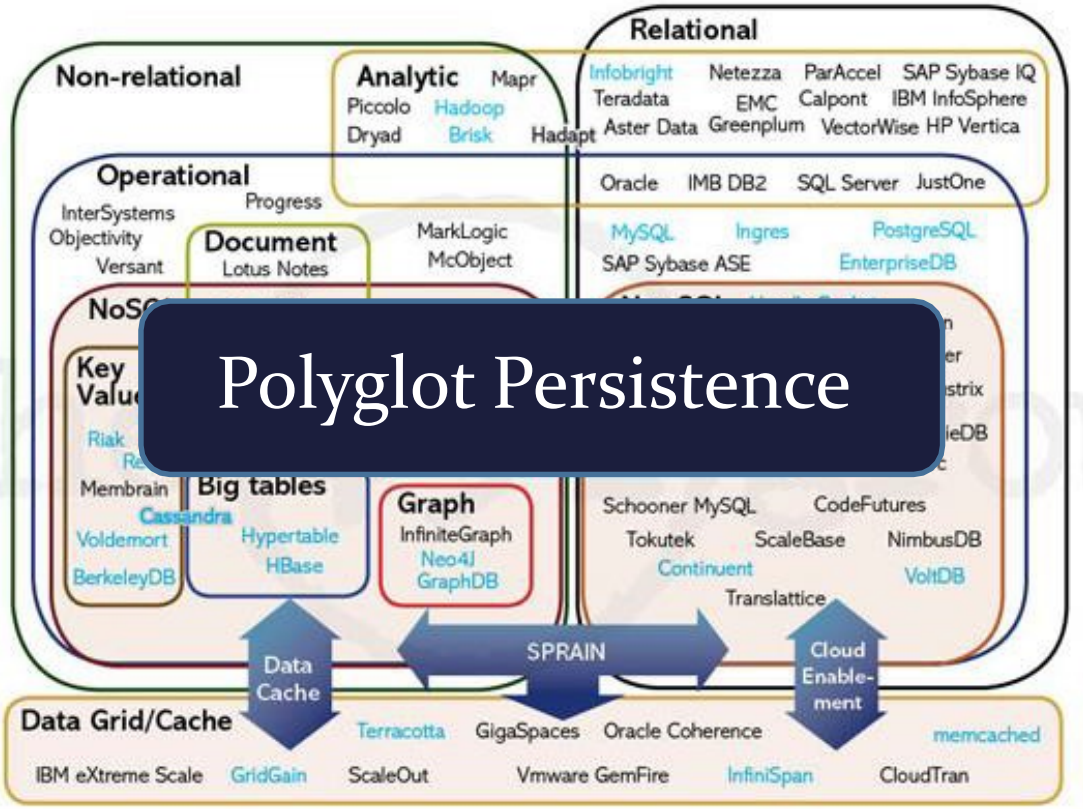

Umbrüche in der Datenbankwelt

3. Big Data

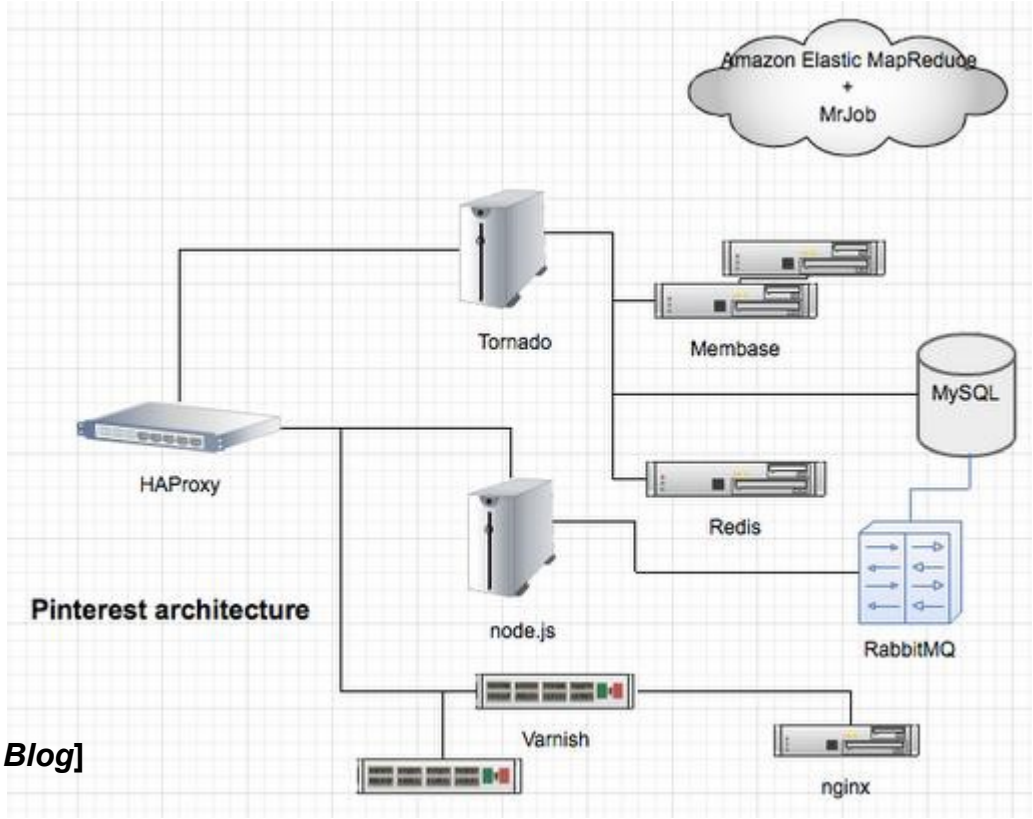

[Poepescu: *myNoSQL Blog*]

Database as a Service

bietet an

as-a-Service

Database as a Service

Schritt 1: Anmelden

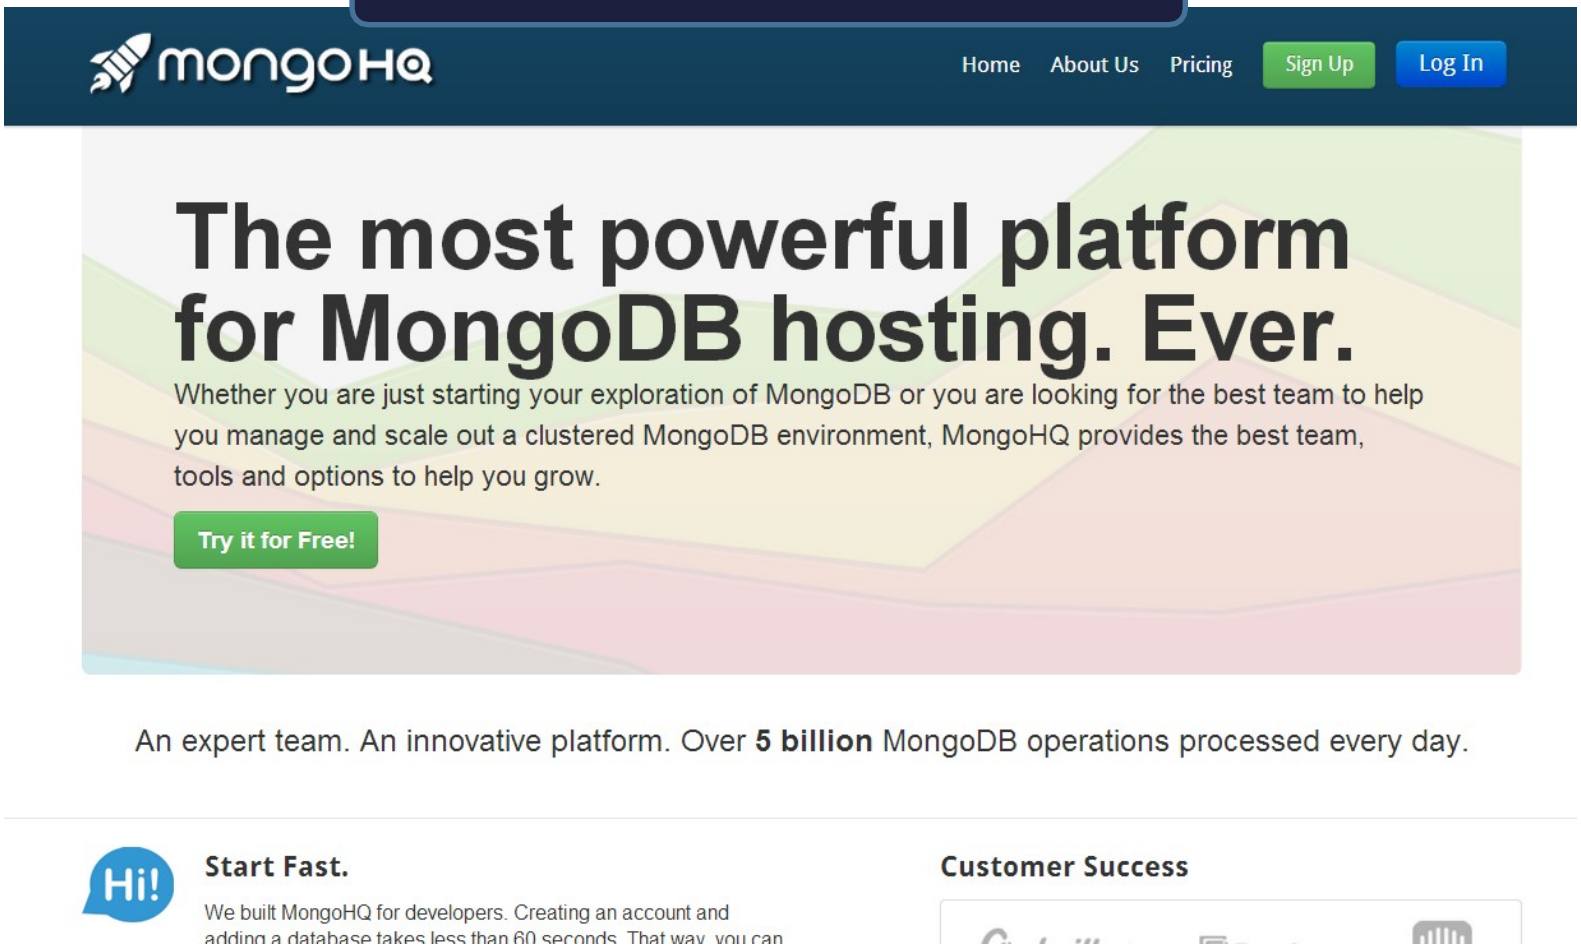

Database as a Service

Schritt 2: DB anlegen

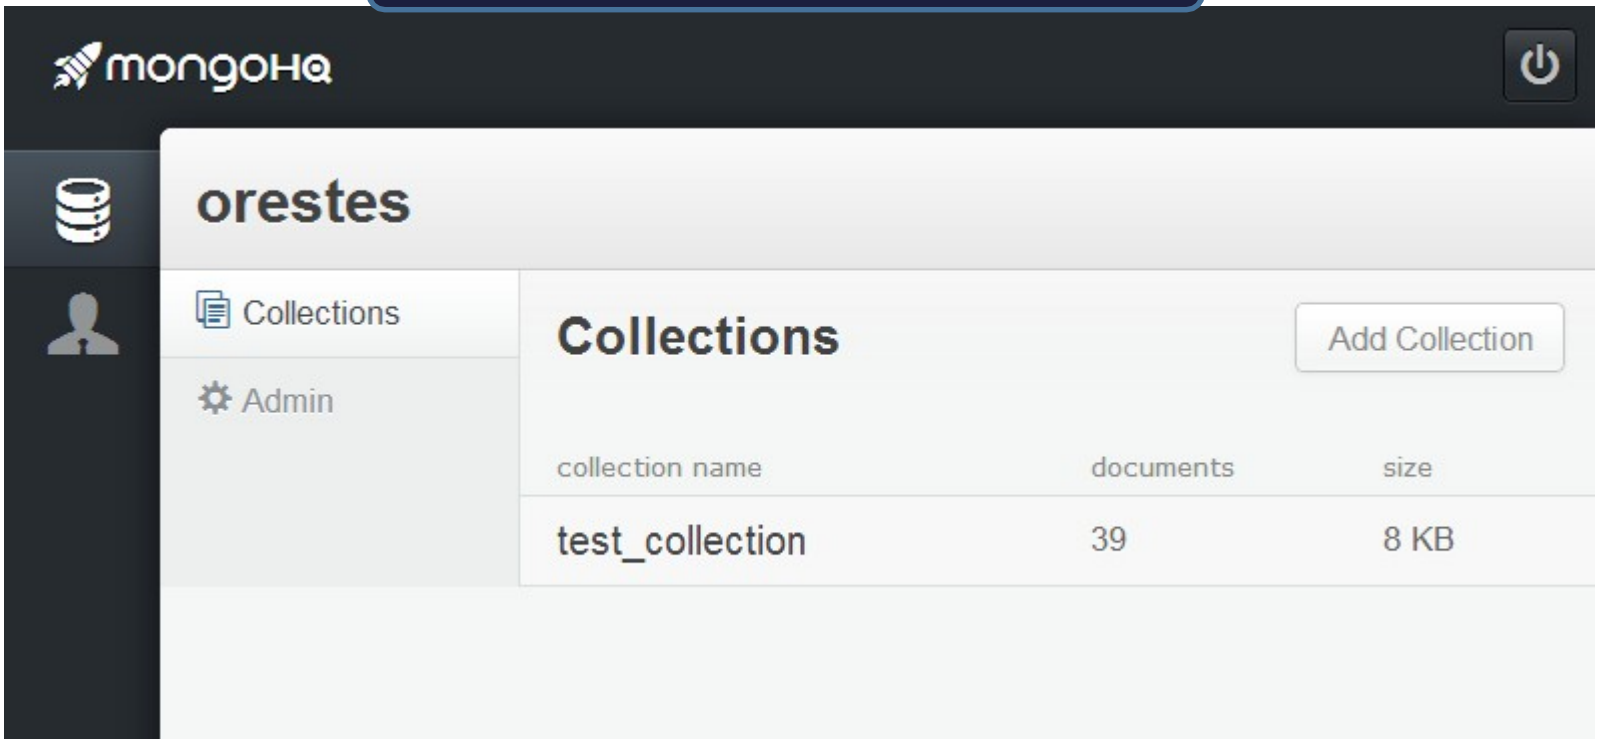

Database as a Service

Schritt 3: App

```
c = Connection('mongodb://orestes:BrotBrot@alex.mongohq.com:10008/orestes')
obj = { "User" : "Felix", "message" : "Testing MongoDB", "test" : [1,2,3,4] }
c.orestes.test_collection.insert(obj)

with timer:
    c.orestes.test_collection.find_one( {"User":"Felix" })
timer.show()
```

Ziele des Seminars

Ziel: Die drei neuen Trends und ihren Zusammenhang verstehen

Themen

Basistechnologien

Cloud Computing - Terminologie

Inhalt:

- Unterscheidung zwischen
  - Software as a Service
  - Platform as a Service
  - Infrastrucutre as a Service
- Public Clouds, Private Clouds, Hybrid Clouds
- Praxisbeispiele
- Abgrenzung zu Grid Computing – Ersetzt die Cloud das Grid?

Basistechnologien

Cloud Computing - Terminologie

Referenzen:

- http://www.infoq.com/presentations/Cloud-Introduction
- P. Mell and T. Grance, "The NIST definition of cloud computing," *National Institute of Standards and Technology*, vol. 53, no. 6, p. 50, 2009.
- Lehner, Wolfgang, and Kai-Uwe Sattler. *Web-scale Data Management for the Cloud*. Springer, 2013.
- M. Armbrust, A. Fox, R. Griffith, A. D. Joseph, R. Katz, A. Konwinski, G. Lee, D. Patterson, A. Rabkin, I. Stoica, and others, "A view of cloud computing," *Communications of the ACM*, vol. 53, no. 4, pp. 50–58, 2010.
- I. Foster, Y. Zhao, I. Raicu, and S. Lu, "Cloud computing and grid computing 360-degree compared," in *Grid Computing Environments Workshop, 2008. GCE'08*, 2008, pp. 1–10.
- I. Foster, C. Kesselman, J. M. Nick, and S. Tuecke, "The physiology of the grid," in *Grid computing*, 2003, pp. 217–249.
- C. Baun, M. Kunze, J. Nimis, and S. Tai, *Cloud Computing: Web-basierte dynamische IT-Services (Informatik im Fokus)*, 2nd ed. Springer, 2011.

Basistechnologien

DBaaS - Grundlagen

Inhalt:

- Mandantenfähigkeit: Shared machine, Shared Process, Shared Tables
- Privacy/Verschlüsselung
- Skalierbarkeit und Elastizität
- Quality of Service und Workload Management
- DBaaS-Konzepte für relationale Datenbanken: „Relational Cloud“

Basistechnologien

DBaaS - Grundlagen

Referenzen:

- Vortrag „Creating Scalable Multitenant Architectures for the Cloud“: http://dbaas.wordpress.com/2011/05/14/creating-scalable-multitenant-architectures-for-the-cloud/
- Beispiele: http://dbaas.wordpress.com/database-as-a-service-dbaas-product-directory/
- M. Seibold and A. Kemper, “Database as a Service,” *Datenbank-Spektrum*, pp. 1–4, 2012.
- C. A. Curino, E. P. C. Jones, R. A. Popa, N. Malviya, E. Wu, S. R. Madden, H. Balakrishnan, N. Zeldovich, and others, “Relational cloud: A database-as-a-service for the cloud,” 2011.
- R. A. Popa, C. Redfield, N. Zeldovich, and H. Balakrishnan, “CryptDB: protecting confidentiality with encrypted query processing,” in *Proceedings of the Twenty-Third ACM Symposium on Operating Systems Principles*, 2011, pp. 85–100.
- S. Krompass, D. Gmach, A. Scholz, S. Seltzsam, and A. Kemper, “Quality of service enabled database applications,” *Service-Oriented Computing–ICSOC 2006*, pp. 215–226, 2006.
- S. Sakr, A. Liu, D. M. Batista, and M. Alomari, “A survey of large scale data management approaches in cloud environments,” *Communications Surveys & Tutorials, IEEE*, vol. 13, no. 3, pp. 311–336, 2011.
- Lehner, Wolfgang, and Kai-Uwe Sattler. *Web-scale Data Management for the Cloud*. Springer, 2013.

Basistechnologien

Virtualisierung

Inhalt:

- Virtualisierung als Grundlage für isoliert laufende Systeme
- Virtuelle Maschinen – Grundlagen:
  - Hardware Virtualisierung und Paravirtualisierung
  - Typ I und Typ II Hypervisor
- Ein Beispiel-Hypervisor erklären, z.B: KVM, Xen, VmWare, HyperV
- Ist Virtualisierung transparent für DBs?

Basistechnologien

Virtualisierung

- Referenzen:
- Vorlesungsskript: http://pages.cs.wisc.edu/~remzi/OSFEP/
- Podcast: http://cre.fm/cre092
- P. Barham, B. Dragovic, K. Fraser, S. Hand, T. Harris, A. Ho, R. Neugebauer, I. Pratt, and A. Warfield, "Xen and the art of virtualization," in *ACM SIGOPS Operating Systems Review*, 2003, vol. 37, pp. 164–177.
- K. Adams and O. Agesen, "A comparison of software and hardware techniques for x86 virtualization," in *ACM SIGOPS Operating Systems Review*, 2006, vol. 40, pp. 2–13.
- A. Kivity, Y. Kamay, D. Laor, U. Lublin, and A. Liguori, "kvm: the Linux virtual machine monitor," in *Proceedings of the Linux Symposium*, 2007, vol. 1, pp. 225– 230.
- Potentielles Problem für Durability: fsync Verhalten -

  http://petercai.com/virtualization-is-bad-for-database-integrity/

Basistechnologien

Kubernetes

Inhalt:

- Management/Automatisierung von Containern
- Container – Grundlagen
- Aufbau einer Kubernetes Umgebung erklären
- Anwendungsbeispiele für Kubernetes
- Tools/Erweiterungen für Kubernetes

Basistechnologien

Kubernetes

- Referenzen:
- https://kubernetes.io/de/docs/home/
- https://www.informatik-aktuell.de/entwicklung/methoden/kubernetes-architektur-und-einsatz-einfuehrung-mit-beispielen.html

Basistechnologien

REST Services

Inhalt:

- Representational State Transfer – HTTP als Protokoll für serviceorientierte Architekturen
- Grundlagen von HTTP
- REST Constraints, z.B. Statuslosigkeit
- Praxisbeispiel: eine gelungene REST-API erläutern, z.B. Twitter, Facebook, Atom Publishing Protocol, Microsoft OData, Google Gdata, etc.

Basistechnologien

REST Services

Referenzen:

- Vortrag: http://www.infoq.com/presentations/REST-And-Now-for-Something-Completely-Different
- R. T. Fielding, “Architectural styles and the design of network-based software architectures,” University of California, 2000.
- S. Tilkov, *REST und HTTP: Einsatz der Architektur des Web für Integrationsszenarien*. dpunkt, 2011.
- How REST replaced SOAP on the web: http://www.infoq.com/articles/rest-soap

Basistechnologien

Content Delivery Networks (CDNs)

Inhalt:

- Der Schlüssel für schnelle Cloud Services und Websites
- Ziel: Minimierung der Latenz zum Client und Entlastung des Services
- Beispiele: Cloudfront, Akamai
- Techniken (u.a.):
  - DNS-Anycasting, URL-Rewriting, Edge-Site Includes

Basistechnologien

Content Delivery Networks (CDNs)

Referenzen:

- Amazon Cloudfront Doc: http://aws.amazon.com/de/documentation/cloudfront/
- J. Dilley, B. Maggs, J. Parikh, H. Prokop, R. Sitaraman, and B. Weihl, "Globally distributed content delivery," *Internet Computing, IEEE*, vol. 6, no. 5, pp. 50–58, 2002.
- M. Pathan and R. Buyya, "A taxonomy of CDNs," *Content delivery networks*, pp. 33–77, 2008.
- Gilbert and Held, *A Practical Guide to Content Delivery Networks, Second Edition*, 2nd ed. CRC Press, 2012.
- R. Buyya, M. Pathan, and A. Vakali, *Content Delivery Networks*, 1st ed. Springer Berlin Heidelberg, 2008.

Basistechnologien

Cloud Computing Plattformen

Amazon Web Services

Inhalt:

- Derzeit größte Cloud Plattform mit diveresen Diensteen (u.a.):
  - Elastic Compute Cloud (EC2)
  - Simple Storage Service (S3)
  - SimpleDB & DynamoDB & RDS
  - Elastic Load Balancer (ELB)
  - Beanstalk
  - Route 53

Cloud Computing Plattformen

Amazon Web Services

Referenzen:

- Online Dokumentation: http://aws.amazon.com/de/
- Präsentation: http://www.infoq.com/presentations/amazon-web-services und http://www.infoq.com/presentations/Deploying-on-Amazon-EC2
- J. van Vliet and F. Paganelli, *Programming Amazon EC2*. O'Reilly Media, 2011.
- C. Baun, M. Kunze, J. Nimis, and S. Tai, *Cloud Computing: Web-basierte dynamische IT-Services (Informatik im Fokus)*, 2nd ed. Springer, 2011.

Amazon SimpleDB, DynamoDB, S3, RDS

Inhalt:

- Database as a Service in der Amazon Cloud
- SimpleDB:
  - Eingeschränkte aber schnelle Querys
  - Eventually Consistent, Pay-as-you-go, REST-API
- DynamoDB:
  - Automatische Partionierung, SSDs statt HDDs
- Simple Storage Service (S3): Blobs/Dateien
- Relational Data Service (RDS): klassisches Oracle, MS-SQL, MySQL Datenbanksystem

Cloud Computing Plattformen

Amazon SimpleDB, DynamoDB, S3, RDS

Referenzen:

- AWS Online Dokumentation: http://aws.amazon.com/de/
- SimpleDB: http://aws.amazon.com/de/documentation/simpledb/
- DynamoDB: http://aws.amazon.com/de/dynamodb
- RDS: http://aws.amazon.com/de/documentation/rds/
- S3: http://aws.amazon.com/de/documentation/s3/
- J. van Vliet and F. Paganelli, *Programming Amazon EC2*. O'Reilly Media, 2011.

Google App Engine

Inhalt:

- Erläuterung des Google PaaS
- Grundlagen der Anwendungsarchitektur in der GAE
- GAE DataStore – die Schnittstelle zum Google BigTable Backend (die größte DB der Welt)

Cloud Computing Plattformen

Google App Engine

Referenzen:

- Präsentation auf der Google IO 2012: http://www.youtube.com/watch?feature=player_embedded&v=uy0nALQEAM4
- Vortrag „SQL vs NoSQL“ auf der Google IO: Text hinzufügen http://www.youtube.com/watch?v=rRoy6I4gKWU
- Docs: https://developers.google.com/appengine/docs/
- App Engine Datastore: https://developers.google.com/appengine/docs/java/datastore/?hl=de
- M. C. Chu-Carroll, *Code in the Cloud: Programming Google AppEngine*. Pragmatic Programmers, 2011.
- D. Sanderson, *Programming Google App Engine*, 2. Auflage. O'Reilly

Windows Azure

Inhalt:

- Überblick über die Services:
  - Anwendungsentwicklung – Programmiersprachen und SDKs
  - Datenspeicherung
  - Integration mit In-House Lösungen
- Diverse Möglichkeiten zur Persistenz: Azure Blobs, Tables, Queues und SQL Azure
- Architektur und Aufbau der Azure Cloud

Cloud Computing Plattformen

Windows Azure

Referenzen:

- Vortrag „Getting started with Windows Azure“: http://channel9.msdn.com/Events/windowsazure/learn/Keynote-Getting-Started-with-Windows-Azure
- David Chappell, Whitepapers: http://www.davidchappell.com/writing/white_papers.php
- Windows Azure Storage http://www.davidchappell.com/writing/white_papers/Windows_Azure_Data_v1.0.pdf
- S. Krishnan, *Programming Windows Azure: Programming the Microsoft Cloud*, 1st ed. O’Reilly Media, 2010.

Cloud Computing Plattformen

OpenStack

Inhalt:

- Private IaaS Cloud Plattform (begründet von Rackspace und NASA)
- Compute (Nova)
- Object Storage (Swift), Block Storage (Cinder)
- Networking (Neutron)

Openstack

Referenzen:

- Videos von der Konferenz OpenStack Summit: http://www.openstack.org/summit/portland-2013/session-videos/?day=1
- Documentation: http://docs.openstack.org/
- Operating OpenStack (frei verfügbares Buch): http://docs.openstack.org/trunk/openstack-ops/openstack-ops-manual-trunk.pdf
- Einführender Blog-Artikel: http://ken.pepple.info/openstack/2012/09/25/openstack-folsom-architecture/
- Wen, Xiaolong, et al. "Comparison of open-source cloud management platforms: OpenStack and OpenNebula." *Fuzzy Systems and Knowledge Discovery (FSKD), 2012 9th International Conference on*. IEEE, 2012.

Cloud Computing Plattformen

Big Data Processing

GFS und HDFS

Inhalt:

- Verteiltes hochskalierbares Dateisystem
- HDFS (Hadoop Projekt) als Implementierung von GFS (Google)
- Grundlage für Map-Reduce
- Namenode-Datanode Architektur

Big Data Processing

GFS und HDFS

Referenzen:

- Intro to HDFS talk: http://www.youtube.com/watch?v=ziqx2hJY8Hg
- Ghemawat, Sanjay, Howard Gobioff, and Shun-Tak Leung. "The Google file system." ACM SIGOPS Operating Systems Review. Vol. 37. No. 5. ACM, 2003.
- Vorlesung Uni Leipzig zu Cloud Data Management: http://dbs.uni-leipzig.de/de/stud/2012ss/cdm
- T. White, *Hadoop: The definitive guide*. Yahoo Press, 2010.
- D. Borthakur, “The hadoop distributed file system: Architecture and design,” *Hadoop Project Website*, vol. 11, p. 21, 2007.

Big Data Processing

MapReduce und Hadoop

Inhalt:

- Revolution der verteilten Datenverarbeitung durch Google
- Grundlagen:
  - Map-Phase, Shuffle-Phase, Reduce-Phase
- Beispielalgorithmen, z.B. Word-Count
- Hadoop die Open-Source Implementierung:
  - Job-Tracker, Worker, Hadoop Distributed Filesystem
- As-a-Service: Amazon Elastic Map Reduce

Big Data Processing

MapReduce und Hadoop

Referenzen:

- Vortrag über das Hadoop Ökosystem: http://www.infoq.com/presentations/Hadoop-Introduction
- Vorlesung Uni Leipzig zu Cloud Data Management: http://dbs.uni-leipzig.de/de/stud/2012ss/cdm
- Lehner, Wolfgang, and Kai-Uwe Sattler. *Web-scale Data Management for the Cloud*. Springer, 2013.
- J. Dean and S. Ghemawat, "MapReduce: simplified data processing on large clusters," *Communications of the ACM*, vol. 51, no. 1, pp. 107–113, 2008.
- T. White, *Hadoop: The definitive guide*. Yahoo Press, 2010.
- D. Borthakur, "The hadoop distributed file system: Architecture and design," *Hadoop Project Website*, vol. 11, p. 21, 2007.

Big Data Processing

Pig & Hive

Inhalt:

- Anfragesprachen als Layer über MapReduce
- Hive:
  - HiveQL – eine SQL ähnliche Anfragesprache
  - Queryverarbeitung und Übersetzung in MapReduce
- Pig:
  - Pig Latin - Prozedurale Anfragesprache
- Vergleich, Vor- und Nachteile, Amazon EMR

Big Data Processing

Pig & Hive

Referenzen:

- Vorlesung Uni Leipzig zu Cloud Data Management: http://dbs.uni-leipzig.de/de/stud/2012ss/cdm
- C. Olston, B. Reed, U. Srivastava, R. Kumar, and A. Tomkins, “Pig latin: a not-so-foreign language for data processing,” in *Proceedings of the 2008 ACM SIGMOD international conference on Management of data*, 2008, pp. 1099–1110.
- A. Thusoo, J. S. Sarma, N. Jain, Z. Shao, P. Chakka, S. Anthony, H. Liu, P. Wyckoff, and R. Murthy, “Hive: a warehousing solution over a map-reduce framework,” *Proceedings of the VLDB Endowment*, vol. 2, no. 2, pp. 1626–1629, 2009.
- Hive: http://hive.apache.org/
- Pig: http://pig.apache.org/

Big Data Processing

Dremel (Google BigQuery)

Inhalt:

- Idee: wenn man den berüchtigten „Full Table Scan“ nicht vermeiden kann muss man ihn optimieren
- Ziel: SQL Querys auf GigaBytes bis PetaBytes von Daten in wenigen Sekunden
- Interne Realisierung, Verteilungsarchitektur
- As-a-Service: BigQuery

Big Data Processing

Dremel (Google BigQuery)

Referenzen:

- Google IO Vortrag 2012 zu BigQuery: http://www.youtube.com/watch?v=QI8623HlYd4
- S. Melnik, A. Gubarev, J. J. Long, G. Romer, S. Shivakumar, M. Tolton, and T. Vassilakis, “Dremel: interactive analysis of web-scale datasets,” *Proceedings of the VLDB Endowment*, vol. 3, no. 1–2, pp. 330–339, 2010.
- Apache Drill: http://bigdatacraft.com/archives/374

Big Data Processing

Google Pregel / Apache Giraph

Inhalt:

- Programmiermodell für sehr große Graphenprobleme
- Message-Passing zwischen Knoten des Graphens
- Jeder Knoten hat lokale Funktionen, die definiert werden können
- Implementierung von Googles PageRank: 15 Zeilen Code

Big Data Processing

Google Pregel / Apache Giraph

Referenzen:

- Einstieg: http://www.quora.com/Pregel/What-are-the-main-concepts-behind-Googles-Pregel
- G. Malewicz, M. H. Austern, A. J. C. Bik, J. C. Dehnert, I. Horn, N. Leiser, and G. Czajkowski, “Pregel: a system for large-scale graph processing,” in *Proceedings of the 2010 international conference on Management of data*, 2010, pp. 135–146.
- Ricky Ho, Blogpost: http://horicky.blogspot.de/2010/07/google-pregel-graph-processing.html

Big Data Processing

Berkeley Data Analytics Stack

Inhalt:

- BDAS ([Badass]), *the Berkeley Data Analytics Stack*
- Spark: MapReduce mit Optimierungen für iterative Ausführungen
- Shark: SQL-to-MapReduce
- BlinkDB: SQL mit beschränkten Fehlerraten und Antwortzeiten
- MLBase: Deklaratives Machine-Learning Framework
- 2 davon aussuchen und detailliert behandeln

Big Data Processing

Berkeley Data Analytics Stack

Referenzen:

- http://de.slideshare.net/AmazonWebServices/bdt305-tranformingbigdata
- Agarwal, Sameer, et al. "BlinkDB: queries with bounded errors and bounded response times on very large data." *Proceedings of the 8th ACM European Conference on Computer Systems*. ACM, 2013.
- Shenker, Scott, et al. "Shark: SQL and Rich Analytics at Scale." (2012)
- Kraska, Tim, et al. "MLbase: A Distributed Machine-learning System." *CIDR*. 2013.
- Engle, Cliff, et al. "Shark: fast data analysis using coarse-grained distributed memory." *Proceedings of the 2012 ACM SIGMOD International Conference on Management of Data*. ACM, 2012.

Big Data Processing

NoSQL Systeme

NoSQL – Terminologie und Historie

Inhalt:

- Was bedeutet NoSQL und warum ist die Bezeichnung schlecht?
- Kategorien von NoSQL Systemen (unterschiedliche Taxonomien):
  - Key-Value Stores
  - Dokumentendatenbanken
  - Graphendatenbanken
  - Wide Column Stores

NoSQL Systeme

NoSQL – Terminologie und Historie

Referenzen:

- Vortrag: NoSQL Database Technology: A Survey and Comparison of Systems http://www.infoq.com/presentations/NoSQL-Survey-Comparison
- C. Strauch, U. L. S. Sites, and W. Kriha, “NoSQL databases,” *Lecture Notes, Stuttgart Media University*, 2011.
- R. Cattell, “Scalable sql and nosql data stores,” *ACM SIGMOD Record*, vol. 39, no. 4, pp. 12–27, 2011.
- P. J. Sadalage, *NoSQL Distilled: A Brief Guide to the Emerging World of Polyglot Persistence*. Addison-Wesley Professional.
- S. Edlich, *NoSQL Einstieg in die Welt nichtrelationaler Web-2.0-Datenbanken*. München: Hanser, 2010.
- E. Redmond, J. Wilson, and J. Carter, *Seven databases in seven weeks : a guide to modern databases and the NoSQL movement*. Lewisville, Tex.; Farnham: Pragmatic Bookshelf ; O’Reilly [distributor], 2012.
- M. Stonebraker, “SQL databases v. NoSQL databases,” *Communications of the ACM*, vol. 53, no. 4, pp. 10–11, 2010.

NoSQL Systeme

CAP Theorem und Skalierbarkeit

Inhalt:

- Die Unvereinbarkeit von **C**onsistency, **A**vailability und **P**artition Tolerance
- Unterschiede zu ACID
- Warum skalieren relationale DBs schlecht?
- Konsequenzen: BASE, Eventual Consistency, Abgeschwächte Konsistenz, z.B. Read-Your-Writes

NoSQL Systeme

CAP Theorem und Skalierbarkeit

Referenzen:

- Teaser: http://adam.heroku.com/past/2009/7/6/sql_databases_dont_scale/
- Werner Vogels (Amazon CTO), „Eventually Consistent“: http://www.allthingsdistributed.com/2007/12/eventually_consistent.html
- S. Gilbert and N. Lynch, “Brewer’s conjecture and the feasibility of consistent, available, partition-tolerant web services,” *ACM SIGACT News*, vol. 33, no. 2, pp. 51–59, 2002.
- E. A. Brewer, “Towards robust distributed systems,” in *Proceedings of the Annual ACM Symposium on Principles of Distributed Computing*, 2000, vol. 19, pp. 7–10.
- R. Ramakrishnan, “CAP and Cloud Data Management,” *Computer*, vol. 45, no. 2, pp. 43–49, 2012.
- E. Brewer, “CAP twelve years later: How the,” *Computer*, vol. 45, no. 2, pp. 23–29, 2012.

NoSQL Systeme

Google BigTable

Inhalt:

- Das Datenbankbackend von Google
- Verteilungsarchitektur: Sharding (Partitionierung)
- Schnittstelle: nichttransaktionaler Zugriff
- Konsistenzmodell: Replikation, eventually consistent
- Open-Source Implementierung: HBase
  - MapReduce Querys, Verteilte Datenhaltung in HDFS
  - Anfrage durch REST-API oder RPC (Thrift, Avro)

NoSQL Systeme

Google BigTable

Referenzen:

- Jeff Dean, Vortrag http://video.google.com/videoplay?docid=727854405568715642
- Ricky Ho, Blog http://horicky.blogspot.de/2010/10/bigtable-model-with-cassandra-and-hbase.html
- F. Chang, J. Dean, S. Ghemawat, W. C. Hsieh, D. A. Wallach, M. Burrows, T. Chandra, A. Fikes, and R. E. Gruber, "Bigtable: A distributed storage system for structured data," *ACM Transactions on Computer Systems (TOCS)*, vol. 26, no. 2, p. 4, 2008.
- HBase Vortag http://www.infoq.com/presentations/HBase-at-Facebook
- L. George, *HBase: The Definitive Guide: The Definitive Guide*. O'Reilly Media, 2011.

NoSQL Systeme

Amazon Dynamo

Inhalt:

- Hochperformanter, verteilter Key-Value Store
- Verschmelzung raffinierter Algorithmen:
  - Merkle-Trees, Gossip Protokoll
  - Consistent Hashing, Vector Clocks
- Inspiriert Voldemort, Riak, Dynomite
- Besonders gut: Riak
  - Wählbare Konsistenz, Agnostisch gegenüber Speichertechnik (z.B. Dateisystem, Datenbanksystem)

NoSQL Systeme

Amazon Dynamo

Referenzen:

- Einstieg: http://www.infoq.com/presentations/Riak-Core
- Vortrag „Dynamo is not just for Datastores“ http://www.infoq.com/presentations/Dynamo-Is-Not-Just-for-Datastores
- G. DeCandia, D. Hastorun, M. Jampani, G. Kakulapati, A. Lakshman, A. Pilchin, S. Sivasubramanian, P. Vosshall, and W. Vogels, “Dynamo: amazon’s highly available key-value store,” in *ACM SIGOPS Operating Systems Review*, 2007, vol. 41, pp. 205–220.
- C. Strauch, U. L. S. Sites, and W. Kriha, “NoSQL databases,” *Lecture Notes, Stuttgart Media University*, 2011.
- E. Redmond, J. Wilson, and J. Carter, *Seven databases in seven weeks : a guide to modern databases and the NoSQL movement*. Lewisville, Tex.; Farnham: Pragmatic Bookshelf ; O’Reilly [distributor], 2012.

NoSQL Systeme

MongoDB

Inhalt:

- Populäre Dokumentendatenbank
- Funktionalität:
  - Speicherung von JSON Dokumenten
  - Komplexe Queries auf Dokuementen
  - Replikation und Sharding (Kontrollierbare Verfügbarkeit und Performance)
  - Map-Reduce Querys

NoSQL Systeme

MongoDB

Referenzen:

- Teaser-Vortrag http://www.infoq.com/presentations/Why-I-Chose-MongoDB-for-Guardian
- MongoDB Architecture, Ricky Ho, Blog http://horicky.blogspot.de/2012/04/mongodb-architecture.html
- MongoDB Docs: http://www.mongodb.org/display/DOCS/Home
- C. Strauch, U. L. S. Sites, and W. Kriha, “NoSQL databases,” *Lecture Notes, Stuttgart Media University*, 2011.
- K. Chodorow and M. Dirolf, *MongoDB: the definitive guide*. O’Reilly Media, 2010.

NoSQL Systeme

CouchDB

Inhalt:

- Webnahe Dokumentendatenbank
- Eigenschaften:
  - Map-Reduce Views mit JavaScript
  - REST API
  - Replikation und Konflikterkennung
  - Embedded Mode

NoSQL Systeme

CouchDB

Referenzen:

- Damien Katz: http://www.infoq.com/presentations/katz-couchdb-and-me
- Will LeinWeber, Vortrag http://www.infoq.com/presentations/couchdb-Will-Leinweber
- CouchDB Wiki http://wiki.apache.org/couchdb/
- C. Strauch, U. L. S. Sites, and W. Kriha, “NoSQL databases,” *Lecture Notes, Stuttgart Media University*, 2011.
- J. C. Anderson, J. Lehnardt, N. Slater, and Safari Tech Books Online, *CouchDB the definitive guide*. Sebastopol, Calif.: O’Reilly Media, Inc., 2010.
- E. Redmond, J. Wilson, and J. Carter, *Seven databases in seven weeks : a guide to modern databases and the NoSQL movement*. Lewisville, Tex.; Farnham: Pragmatic Bookshelf ; O’Reilly [distributor], 2012.

NoSQL Systeme

Redis

Inhalt:

- Datenstrukturserver: Key-Value Paare, Listen, Sets, Queues, Sorted Sets, Maps
- Extreme Geschwindigkeit
- Replikation und konfigurierbare Persistenzgarantien
- Wahrscheinlicher Erbe von Memcached

NoSQL Systeme

Redis

Referenzen:

- Einstieg, „Redis in depth“, Vortrag http://www.infoq.com/presentations/Redis
- Dokumentation: http://redis.io/documentation
- S. Edlich, *NoSQL Einstieg in die Welt nichtrelationaler Web-2.0-Datenbanken*. München: Hanser, 2010.
- C. Strauch, U. L. S. Sites, and W. Kriha, “NoSQL databases,” *Lecture Notes, Stuttgart Media University*, 2011.
- E. Redmond, J. Wilson, and J. Carter, *Seven databases in seven weeks : a guide to modern databases and the NoSQL movement*. Lewisville, Tex.; Farnham: Pragmatic Bookshelf ; O’Reilly [distributor], 2012.

NoSQL Systeme

Cassandra

Inhalt:

- Synthese aus BigTable und Amazon Dynamo
- Entwickelt für die Suche in der Facebook Inbox
- Eigenschaften:
  - Skalierbarkeit und Fehlertoleranz (Dezentralisierung)
  - Query-Sprache CQL
  - Integration mit Hadoop

NoSQL Systeme

Cassandra

Referenzen:

- „Adopting Apache Cassandra“, Vortrag http://www.infoq.com/presentations/Adopting-Apache-Cassandra
- A. Lakshman and P. Malik, “Cassandra: a decentralized structured storage system,” *ACM SIGOPS Operating Systems Review*, vol. 44, no. 2, pp. 35–40, 2010.
- Cassandra Wiki: http://wiki.apache.org/cassandra/
- P. J. Sadalage, *NoSQL Distilled: A Brief Guide to the Emerging World of Polyglot Persistence*. Addison-Wesley Professional.

NoSQL Systeme

CryptDB

Inhalt:

- Verschlüsselte Datenbank in der Cloud
- Problem: Querys auf verschlüsselten Daten
- Lösung: Homomorphe Verschlüsselung
- Praktische Umsetzung durch Onion Encryption
- Teil des DBaaS Systems *Relational Cloud*

NoSQL Systeme

CryptDB

Referenzen:

- Popa, Raluca Ada, et al. "CryptDB: protecting confidentiality with encrypted query processing." *Proceedings of the Twenty-Third ACM Symposium on Operating Systems Principles*. ACM, 2011.
- Curino, Carlo, et al. "Relational cloud: A database-as-a-service for the cloud." (2011).
- Raluca Ada Popa, Nickolai Zeldovich, and Hari Balakrishnan. Guidelines for Using the CryptDB System Securely. In *Cryptology ePrint Archive*, Report 2015/979.

NoSQL Systeme

Neo4J

Inhalt:

- Graph Datenbank
- Repräsentation der Daten als Graph
- GraphQL als Abfragesprache

NoSQL Systeme

Neo4J

Referenzen:

- https://www.innoq.com/de/articles/2012/09/neo4j-rockt/
- https://neo4j.com/docs/
- Miller, Justin J. "Graph database applications and concepts with Neo4j." *Proceedings of the Southern Association for Information Systems Conference, Atlanta, GA, USA*. Vol. 2324. No. S 36. 2013.

Elasticsearch

Inhalt:

- Suchmaschine
- Speicherung der Daten
- Indexierung für Volltextsuche
- Verteilung auf mehrere Knoten
- Verbindung mit anderen Systemen
    - z.B. ELK Stack

NoSQL Systeme

Elasticsearch

Referenzen:

- Divya, Manda Sai, and Shiv Kumar Goyal. "ElasticSearch: An advanced and quick search technique to handle voluminous data." *Compusoft* 2.6 (2013): 171.
- https://www.elastic.co/guide/index.html
- https://www.schwarzer.de/blog/elasticsearch-tutorial-das-konzept-verstehen/

ToDos für euch

E-Mail an:

kiehn@informatik.uni-hamburg.de

Inhalt:

- Top 3 Themenauswahl
- Nicht in Stine Angemeldete werden gemäß Präferenz verteilt, wenn alle Angemeldeten ein Thema haben:
  Ab 30.10.2019 20:00Uhr, First Come First Serve

Teilnahme an Doodle für Termin:

Dudle-Link

- Abstimmung endet am 30.10.2019 23:59Uhr

Formalien

- Seminararbeit: 12 Seiten netto
- Abgabe Ausarbeitung: 12.03.2020 23:59Uhr
- Vortrag:
  - 25 Minuten + 5 min. Diskussion
  - Text auf Folien < 50%