

Sinnvolle Datenerhebung für Smart Studies

BETREUER: PROF.DR.MARTIN BECKE

LUKAS KOZLOWSKI - GRUNDSEMINAR WS15/16




Hochschule für Angewandte
Wissenschaften Hamburg
Hamburg University of Applied Sciences

Agenda

- ▶ Motivation
- ▶ Prozesskette
- ▶ Forschungsfeld
- ▶ Komplexität
- ▶ Kontroversität
- ▶ Potenziale
- ▶ Infrastruktur
- ▶ Zielsetzung

Meine Motivation


- ▶ Technische Unterstützung der Forschungsgruppe „**Smart Studies**“
- ▶ Neues frisches Projekt, keine Restriktionen.
- ▶ Die Systemarchitekturbasis **mitentwerfen** und **gestalten**.
- ▶ Die **Forschung** und **Implementierung** von Datenerhebung wie z.B. durch Big-Data-Mining und Analytics Konzepte.




[1]

Prozesskette

Es gilt die Frage nach einer sinnvollen Infrastruktur für das individuelle Studium zu beantworten.





- ▶ Analyse vorhandener Infrastruktur
- ▶ Untersuchung neuer Architekturen



Etablierung adaptiver Prozessstrukturen




„Wie kann eine **adaptive Prozessstrukturkomponente** und **analytische Informationsquelle** in die Smart Studies Systemarchitektur implementiert werden, um den Studenten **aktiv** zu helfen und ihn in seinem **individuellen Studium** unterstützen?“



Forschungsfeld


Individuelle Indexierte Internetseiten von Google

- 
- ▶ 1998 1.000.000 (10^6 **Million**)
 - ▶ 2000 1.000.000.000 (10^9 **Milliarde**)
 - ▶ 2008 1.000.000.000.000 (10^{12} **Billion**)
 - ▶ **2015-2016 ~ 40.000.000.000.000**

Forschungsfeld



[3]



[4]



[5]



[6]



[7]



[8]

Suchanfragen pro Tag: 3.5 Milliarden Tweets pro Tag: 500 Millionen Nachrichten pro Tag: 64 Milliarden Updates pro Tag: 800 Millionen Bilder pro Tag: 3.5 Millionen Views pro Tag: 5 Milliarden

Die Quellen erzeugen Informationen einer Größenordnung von Zettabytes täglich!

Der Durchschnittsbürger hat heute täglich mehr Zugriff auf Informationsdaten, als ein Individuum aus dem 16. Jahrhundert in seinem gesamten Leben.

Jährliche Zuwachsprognose (2015/16)  ~50 %

1 Zettabyte = 10^{21} = 1.000.000.000.000.000.000.000 Bytes
= 1000 Exabytes = 1 Million Petabytes = 1 Milliarde Terrabytes = 1 Billion Gigabytes

90 % der Daten sind in den letzten 2 Jahren entstanden

(Diese Annahme basiert auf dem **Moore'schen Gesetz** welches für die letzten 30 Jahre korrekt war)

Forschungsfeld



Forschungsfeld



[9]

Unstrukturierte Daten

Daten die numerisch **nicht kategorisiert** und analysiert werden können.

Kundenreviews
Photos und Multimedia
Social Network Kommentare

Daten die **vielfältige** Informationen enthalten.

Strukturierte Daten

Zahlen oder Wörter die **leicht kategorisiert** oder analysiert werden können


Netzwerk Sensoren
Smartphones
Transaktionsdaten

Hace - Theorem

- **H**eterogeneous, **A**utonomous, **C**omplex, **E**volving
- Big data starts with large volume, **heterogeneous**, **autonomous** sources with distributed and decentralized control, and seeks to explore **complex** and **evolving** relationships among data.

Dieses Theorem wird zur **Modellierung der Charakteristik** von **Big-Data** verwendet.

Komplexität



- ▶ Die **Handhabung** eines riesigen Datenvolumens.
- ▶ Die **Komplexität** brauchbarer Informationen aus riesigen Datensets oder Datenströmen zu definieren und gezielt zu fördern.
- ▶ Die **Forschung** mit neuen Mining-Techniken.
- ▶ Der Umgang mit **Datenschutz** und **Kontroversität**

Kontroversität

▶ Größer bedeutet nicht Besser.

Es kommt drauf an ob die Daten „**noisy**“ (**Korrupt/Unbrauchbar**) sind und sie das repräsentieren was wir suchen.

▶ Ethische Besorgnisse


Ist es ethisch vertretbar wenn Menschen analysiert werden ohne es zu wissen?

▶ Echtzeit Analysen

Daten verändern sich daher ist nicht die Größe der Daten wichtig sondern das Alter der Daten.

▶ Annahmen auf Genauigkeit

Mit der Variablenanzahl steigt auch die Anzahl falscher Korrelationen (**Zusammenhänge**).



[15]

Blind Man - Problematik

Potenziale

▶ Prozesslaufzeit

Verkürzung der Laufzeit
von Stunden auf Sekunden

▶ DNA-Mining

Vorhersagen/Trends in
Krankheitsausbreitung/Seuchen/Epidemien

Durch gezielte Big-Data Auswertungen
werden bestimmte
Krankheitsausbreitungen verhindert
andere können früher erkannt werden.

▶ Economic Development

Statistiken Interpretieren und
Ökonomische Entscheidungen treffen.

▶ High Quality of Live

Optimierter Verkehrsfluss (Bahn, Auto usw.)
Smart Emergency Service

▶ Customer Personalization

▶ Churn Detection

Potenziale

Projekt der Vereinten Nationen seit 2009

UNITED NATIONS GLOBAL PULSE
Harnessing big data for development and humanitarian action

Search SEARCH

GLOBAL PULSE

ABOUT
PROJECTS
LABS
BLOG
CHALLENGES
PRIVACY
PARTNERSHIPS
CONTACT
HOME

GLOBAL PULSE AT THE 70TH SESSION OF THE UN GENERAL ASSEMBLY
A round-up of activities and events related to advocating for a Data Revolution during the Summit for the Adoption of the Post-2015 Development Agenda and the 70th Session of the UN General Assembly (UNGA 70)
[Read More /](#)

NEWS

Leveraging Data for Humanitarian Response Discussed at 37th International Conference of Data Protection & Privacy Commissioners
Mila Romanoff Nov 5, 2015
In April 2015, the UN Secretary-General announced that "the number of people in need of humanitarian assistance around the world has doubled in just ten years." UNOCHA, in its State of...
[Read More](#)

Global Pulse Data Privacy Advisory Group Annual Meeting Recap
Global Pulse Nov 2, 2015
The Global Pulse Data Privacy Advisory Group Annual Meeting took place last week in The Hague, Kingdom of Netherlands. The Data Privacy Advisory Group is an independent group of international experts...
[Read More](#)

TWITTER

Global Pulse @UNGlobalPulse 1h
We're talking "Future of Data" tomorrow at @UNICEFinnovate Global Innovations for Children & Youth Summit summit.unicef.fr #suminnovate
Expand

Global Pulse @UNGlobalPulse 23h
#Data for #Humanitarian Response Discussed at Int'l Conf of Data Privacy Commissioners bit.ly/8D4DgovNL #IPC2015 #humdata #reshapeaid
Expand

SUBSCRIBE TO OUR NEWSLETTER
email address
GO

► Early Warning

Schnelle Reaktionszeit in Krisenzeiten

► Real-time Awareness

Realitätsgenauere Entwicklungsprogramme und Richtlinien

► Real-time Feedback

Die Echtzeitüberwachung von laufenden Entwicklungsprogrammen.

Infrastrukturen, Mining und Analyse - Tools

- ▶ Apache Hadoop
- ▶ Apache S4
- ▶ Apache Storm
- ▶ Apache Spark
- ▶ Apache Mahout
- ▶ Apache SAMOA
- ▶ Dato (früher GraphLab)
- ▶ R
- ▶ MOA
- ▶ Vowal Wabbit
- ▶ Pegasus




Apache Hadoop

- ▶ Apache Hadoop – Open Source Plattform für scalable, distributed computing
- ▶ Die Softwarebibliothek ist ein Framework was die parallele Berechnung (distributed processing) von großen Datensets über Computercluster ermöglicht.
- ▶ Hadoop kann für **strukturierte** und **unstrukturierte** Datensets verwendet werden.
- ▶ Hadoop verwendet **MapReduce** als Mining-Technik
- ▶ **MapReduce** ist ein Programm das Datensets in einzelne Subsets separiert.
- ▶ **Map()** Funktion für die **Filterung und Sortierung**
- ▶ **Reduce()** Funktion für die **Zusammenfassung**



[29]



[30]

„eine Rose ist eine Rose ist eine Rose“



eine Rose ist
eine Rose ist
eine Rose



eine $\langle 1, 1, 1 \rangle$
Rose $\langle 1, 1, 1 \rangle$
ist $\langle 1, 1 \rangle$



eine, 3
Rose, 3
ist, 2

Buzzword-Problem

BIG-DATA

BIG-DATA

BIG-DATA ... *what else!?*

BIG-DATA

BIG-DATA

BIG-DATA

Zielsetzung.. Aller Anfang ist schwer...

- ▶ **Kleinere Versuche** mit `MapReduce()` (Wordcount usw.)
- ▶ **Tool-Testing** auf Handhabung und Möglichkeiten und Potenziale
- ▶ **Performance Analysen** für die verschiedenen Taskarten
- ▶ **Tieferes Verständnis** für Big Data und Data-Mining-Techniken entwickeln.

USE-CASE – Beispiel

Der Student durchläuft ein QUIZ, Fragebogen basierend auf dieser Erhebung, durch die Auswertung dieser Daten kann der Student in der Anmeldungsphase ein Feedback erhalten, ob die getroffene Klausurauswahl sinnvoll war oder nicht.

Konferenzen / Workshops

- ▶ KDD-2016 2016 : 22nd ACM SIGKDD international conference on knowledge discovery and data mining - San Francisco USA

[Konferenz]

- ▶ BIGMINE 2015

<http://bigdata-mining.org/bigmine-15/>

[Workshop]

- ▶ Big Data Summit 2016

<http://www.bitkom-bigdata.de/>

25. Februar Congress Park Hanau

[Kongress]

The screenshot displays the website for BIGMINE 2015, a workshop on Big Data, Streams and Heterogeneous Source Mining. The page features a navigation menu with links for CFP, DATES, SUBMISSION, KEYNOTES, ACCEPTED PAPERS, SCHEDULE, REGISTRATION, and ORGANIZATION. The main content area is titled "BigMine 15" and includes a "Schedule:" section with a link to the "BIGMINE 2015 Schedule". Below this is a "Keynote Speakers:" section featuring six speakers with their names, affiliations, and topics:

- Xiatian Zhang, TalkingData**
 - Making Data Talk
- Bernhard Pfahringer, University of Waikato, New Zealand**
 - Why Big Data miners should care about Stream Mining
- Francesco Bonchi, Yahoo Labs, Catalonia.**
 - Learning the strength of social influence
- Vincent S. Tseng, National Chiao Tung University, Hsinchu, Taiwan**
 - In-Depth View of Some Key Challenges in Big Data Mining: Perspective from Practical Experiences
- Latifur Khan, University of Texas at Dallas, USA**
 - Stream Data Mining and Applications: A Big Data Perspective

On the right side of the page, there is a "Gold Sponsor" section for TalkingData (Mobile·Data·Value) and a "Social Media" section with icons for RSS, Facebook, Twitter, a plus sign, and LinkedIn.

Konferenzen zum Thema University Information-Systems

► EUNIS – E-learning Task Force (European University Information Systems)



[33]

06.06.2016 – 10.06.2016 – Thessalonki - Griechenland (**Kongress**)

<http://www.eunis.org/eunis2016/>

14.04.2016 - 16.04.2016 Krakow – Polen (**Konferenz**)

<http://www.eunis.org/calendar/e-learning-task-force-workshop>

09.06.2016 Dundee – Großbritannien (**Workshop**)

<http://www.eunis.org/calendar/e-learning-task-force-workshop>

► European MOOCs Stakeholders Summit 2016 (EMOOCs 2016)



[34]

22.02.2016 – 24.02.2016 – Graz Österreich (**Konferenz**)

<http://emoocs2016.eu/>

Quellen

- ▶ International Journal of Advanced Research in Computer Engineering & Technology – Big Data Analysis using Hace Theorem [January 2015]
- ▶ ACM Paper - Mining Big Data: Current Status, and Forecast to the Future [2013]
- ▶ ACM Paper - Scaling Big Data Mining Infrastructure: The Twitter Experience [2013]
- ▶ ACM Paper - Mining Heterogeneous Information Networks: A Structural Analysis Approach
- ▶ ACM Paper - Big Graph Mining: Algorithms and discoveries
- ▶ ACM Paper - Mining Large Streams of User Data for Personalized Recommendations
- ▶ Buch - Software Architecture in Practice [Len Bass, Paul Clement, Rick Kazman 2013]

Bildquellen

- [01] http://www.peterkleinau.com/wp-content/uploads/2014/01/Zeichnung_Motivation_M%C3%B6hre-300x237.jpg
- [03] <http://static1.squarespace.com/static/533c59ece4b07e844a588995/t/5342ea5ce4b0c23c72915fce/1396894308622/goog>
- [04] <http://cdn.flaticon.com/png/256/8800.png>
- [05] <https://danielrehn.files.wordpress.com/2014/11/iconmonstr-whatsapp-3-icon.png>
- [06] https://image.freepik.com/free-icon/facebook-logo_318-49940.jpg
- [07] <http://www.nomarket.org/wp-content/uploads/2014/12/Flickr-Logo.jpeg>
- [08] <http://www.iconsdb.com/icons/preview/black/youtube-3-xxl.png>
- [09] <http://images.offerpop.com/wp-content/uploads/2014/07/bigstock-Big-data-concept-in-word-tag-c-52761202-1-1000x573.jpg?505c96>
- [10] http://www.fullthoughtcc.com/wp-content/uploads/2014/11/Dollarphotoclub_49104710.jpg
- [11] <http://iamcr.org/sites/default/files/cloud19-01.JPG>
- [12] <http://ae-lane-report.s3.amazonaws.com/wp-content/uploads/2014/12/InternetOfThings.jpg>
- [13] <http://www.webmarketingpros.com/blog/wp-content/uploads/2014/02/mobile-web-word-cloud.jpg>
- [14] <http://www.mtabsurveyanalysis.com/wp-content/uploads/2014/08/data-mining.jpg>
- [15] <http://ijarcet.org/wp-content/uploads/IJARCET-VOL-4-ISSUE-1-18-23.pdf>

Bildquellen

- [20] <http://www.unglobalpulse.org>
- [21] <https://hadoop.apache.org/images/hadoop-logo.jpg>
- [22] <http://incubator.apache.org/s4/>
- [23] <http://storm.apache.org/images/logo.png>
- [24] <http://spark.apache.org/>
- [25] http://www.cs.cmu.edu/~pegasus/index_htm_files/504.png
- [26] <http://mahout.apache.org/images/mahout-logo-brudman.png>
- [27] https://dato.com/images/dato_logo.svg
- [29] <http://wikibon.org/w/images/c/cb/Mapreduce.jpg>
- [30] <https://upload.wikimedia.org/wikipedia/commons/thumb/6/6c/MapReduce2.svg/500px-MapReduce2.svg.png>
- [32] <http://bigdata-mining.org/bigmine-15/>
- [33] <http://www.eunis.org/eunis2016/>
- [34] <http://emoocs2016.eu/>

Danke.

