



06.11.2018
MÜNCHEN, W-JAX 2018

Die Best Practices der Data Scientists

#Big Data & Machine Learning

#Software Architecture

Markus Harrer
Software Development Analyst

INNOQ

I ♥ legacy code!

Markus Harrer
Software Development Analyst

IMDQ

Blog: feststelltaste.de

Twitter: [@feststelltaste](https://twitter.com/feststelltaste)

Folien: speakerdeck.com/feststelltaste



Data Science

Was ist ein Data Scientist?

"... einer, der Statistik am Mac macht."

"...eine Statistikerin, die in San Francisco lebt."

"...ist besser in Statistik als ein Entwickler und besser in Softwareentwicklung als ein Statistiker."

Worum geht es im „data“?

“Without **data** you're just another person with an **opinion**.”

W. Edwards Deming

=> Belastbare Erkenntnisse mittels **Fakten** liefern

Worum geht es im „science“?


“The aim of science is to seek the simplest explanations of complex facts.”

Albert Einstein

=> Neue Erkenntnisse verständlich herausarbeiten

Data Science

Venn Diagramm von
Drew Conway



== Softwareentwicklung!

Einsatz von Data Science

in der Softwareentwicklung





- Wo verletzen wir Architekturvorgaben?
- Weshalb schlagen unsere CI-Builds sporadisch fehl?
- Woher kommen die vielen DB-Calls?
- Welcher Entwickler kennt sich wo im Code aus?
- Wo gibt es sich gegenseitig überschreibenden Zustand?
- Ist unsere Software richtig geschnitten?
- ...

Ein Praxisbeispiel

Beispiel: Fragestellung

„Wie gut passt der fachliche Schnitt zur Entwicklungsaktivität?“



Legende

A B
C fachliches Modul

Entwicklungsaktivität

Beispiel: Idee

Heuristik

„Werden *Änderungen* innerhalb einer *Komponente* *zusammengehörig* vorgenommen?“

- Änderungen => **Commits** aus Versionsverwaltung
- Komponenten => Teil von **Dateipfad**

Beispiel: Daten

Commit und Dateipfad

```
git log --numstat --format=...
```

commit_id	filepath
#59a26	.../todo/Get.java
#59a26	.../todo/New.java
#34af9	.../site/Main.java
...	...

Beispiel: Analyse

Pivot-Tabelle mit Commits für jede Datei

	#59a26	#35e25	#34af9	...
.../todo/Get.java	1	1	0	...
.../todo/New.java	1	1	0	...
.../site/Main.java	0	0	1	...
...	...	...	...	...

=> pro Datei ein **Vektor** (=> reine Mathematik)

Beispiel: Modell

Ähnlichkeitsberechnung

=> **Cosinus-Ähnlichkeit** zwischen Vektoren / Dateien

	.../todo/Get.java	.../todo/New.java	.../site/Main.java	...
.../todo/Get.java	1	0.8	0.3	...
.../todo/New.java	0.8	1	0	...
.../site/Main.java	0.3	0	1	...
...	...	...	...	...

Beispiel: Visualisierung (1/2)

Informationsreduzierung

- **Multidimensionale Skalierung** reduziert n Dimensionen auf zwei Dimensionen unter Beibehaltung der Abstände
- Aus Dateipfad lässt sich **Komponente** extrahieren
 - Beispiel: `.../todo/Get.java` => **todo**


filepath	x	y	komp
.../todo/Get.java	0.14	0.67	todo
.../todo/New.java	0.13	0.70	todo
.../site/Main.java	0.31	0.50	site
...	...	...	...

Beispiel: Visualisierung (2/2)

Erzeugung interaktiver Grafik


- Dateien des Softwaresystems
=> Punkte
- Dateien, die gemeinsam geändert werden
=> Nähe der Punkte zueinander
- Komponenten des Softwaresystems
=> Farben der Punkte

Beispiel: Erkenntnis



Demo

„Der Schnitt-Check“



<https://www.youtube.com/watch?v=XAxseWdu5YA>

„Sehr schön!“

**„Aber ein paar
Schritte zurück!“**

„Wie geht sowas?“



Markus Harrer

@feststelltaste



Antwort an [@rotnroll666](#)

Thanks for the kind words! But I'm just
hacking my way through all the data with
pure stubbornness 🙄

 Tweet übersetzen

10:25 - 20. Apr. 2017

1 „Gefällt mir“-Angabe



BEST PRACTICES

Data Science on Software Data

Problemfixierung

„Wenn ich **eine Stunde** habe,
um ein Problem zu lösen,
dann beschäftige ich mich
55 Minuten mit dem **Problem**
und **5 Minuten** mit der **Lösung.**“


Albert Einstein

0. Fragestellung

Wie komme ich auf ein Problem?

Problemidentifikation

- Kneipe
- Retrospektiven / Pre-Mortems
- Code-Happiness-O-Meter




<https://bit.ly/2PbJiPM>

Wie komme ich auf die Ursache?

Ursachenanalyse

- Lösungsreflex unterdrücken
- Zuhören, nachfragen, ergründen
 - Tiefensuche mit „**Warum?**“
 - Breitensuche mit „**Was noch?**“
- **Hotspots** vornehmen

=> Auswirkungen quantifizieren



1. Idee

Datenzentriertes Denken

Frage stellen

- „Woran **erkenne** ich, dass sich etwas **geändert** hat?“

=> Vorhandenen Datenquellen bewusster wahrnehmen

2. Daten

Softwaredaten und Metadaten



statisch



Laufzeit



Community



chronologisch

Eigenheiten der Datenarten

zumindest der meisten...

Geschäftsdaten

- ✗ Lückenhaft
- ✗ Qualität durchwachsen
- ✗ Durcheinander
- ✓ Einfache Struktur
- ✓ Direkt
- ✓ Wenig detailliert

Softwaredaten

- ✓ Vollständig
- ✓ Qualität gut
- ✓ Formatiert
- ✗ Komplexe Strukturen
- ✗ Indirekt
- ✗ Sehr feingranular

Best Practices im Umgang mit Daten

Geschäftsdaten

- *Daten aufwendig säubern*
- *Komplexere Modelle nutzen*
- *Unsicherheit offenlegen*

Softwaredaten

- *Datenherkunft angeben*
- *Heuristiken nutzen*
- *Annahmen offenlegen*

Datenlieferanten intelligent nutzen

Ausgaben richtig formatieren

- `cloc ./ --quiet --csv`

Grundlegende Vorverarbeitung auf Werkzeug legen

- `git log --no-merges --no-renames --since=...`

Vorhandene Datenquellen nutzen

- **Jenkins** Remote Access API (Build-Logs, Test-Reports, ...)
- **SonarQube** Web API (Code Smells, Metriken, ...)

Best Practices für tabulare Daten


Single Responsibility Principles

- Pro **Variable** eine **Spalte**
- ≡ Für jede **Beobachtung** eine **Reihe**
- ▦ Für alle **zusammengehörigen Variablen** eine **Tabelle**
- ✎ Für jede **Tabelle** einer Analyse eine **verlinkende Spalte**

Best Practices für komplexe Daten


Vernetzte Strukturen

- Auf einen Aspekt festlegen
- Extrem denormalisieren



Vielfältige, feingranular Daten

- Verschneiden (=joinen)
- Filtern (=reduzieren)
- Aggregieren (=verdichten)




Demo

„Code Smells Analyse mit jQAssistant/Neo4j“

Class(1)

HAS_BUG(2)



<https://www.youtube.com/watch?v=SOREr0QPT4I>

Weitere Details zu jQAssistant/Neo4j

<https://easychair.org/publications/preprint/893N>

Towards an Open Source Stack to Create a Unified Data Source for Software Analysis and Visualization

Richard Müller*, Dirk Mahler[†], Michael Hunger[‡], Jens Nerche[§] and Markus Harrer[¶]

*Leipzig University, Germany

Email: rmueller@wifa.uni-leipzig.de

[†]buschmais GbR, Dresden, Germany

Email: dirk.mahler@buschmais.com

[‡]Developer Relations, Neo4j Inc., Malmö, Sweden

Email: michael.hunger@neo4j.com

[§]Application Development, Kontext E GmbH, Dresden, Germany

Email: j.nerche@kontext-e.de

[¶]Software Development Analyst, Freelancer, Roth, Germany

Email: contact@markusharrer.de

Abstract—The beginning of every software analysis and visualization process is data acquisition. However, there are various sources of data about a software system. The methods used


Creating, storing, and querying the data captured by such graphs is very challenging. Diehl et al. summarize the most important questions in this respect [3].

3. Analyse

**Automatisierte,
nachvollziehbare
Datenanalysen**

Automatisierung

Automatisierung



Einfacher Ansatz

⊕ Automatisierung

Vorgehen zur Automatisierung

- 1 x per Hand Analyse durchführen
- Reflektieren
- Nachcodieren (= automatisieren)

Existierende Möglichkeiten nutzen

✔ Automatisierung

Kommandozeilen-Werkzeuge voll ausschöpfen

- `mvn dependency:analyze-duplicate`
- `git shortlog -ns -- *ViewModel.java`
- `cloc ./ --by-file --quiet --csv`

Web-APIs direkt anbinden

- Jenkins, SonarQube, Jira, BitBucket, ...

Demo

„Software Archäologie mit Git“

```
/mnt/c/dev/repos/dropover
```

```
$
```

<https://www.youtube.com/watch?v=ZaKYrvvLj0A>

Nachvollziehbarkeit

Nutzung konventioneller Tools

⊗ Nachvollziehbarkeit



Elemente offener Analysen

⊕ Nachvollziehbarkeit

- Rohdaten und Datentypen sind beschrieben
- Analyse-Code verfügbar
- Endergebnisse verständlich

Automatisierung

- Keine manuellen Eingriffe möglich / nötig

Einheitlicher Analyse-Aufbau

⊕ Nachvollziehbarkeit

Inhaltsverzeichnis

- Titel
- Motivation / Kontext
- Idee und verfügbare Daten
- Analyse
- Schlussfolgerung
 - Inkl. nächste Schritte

Glaubwürdigkeit herstellen

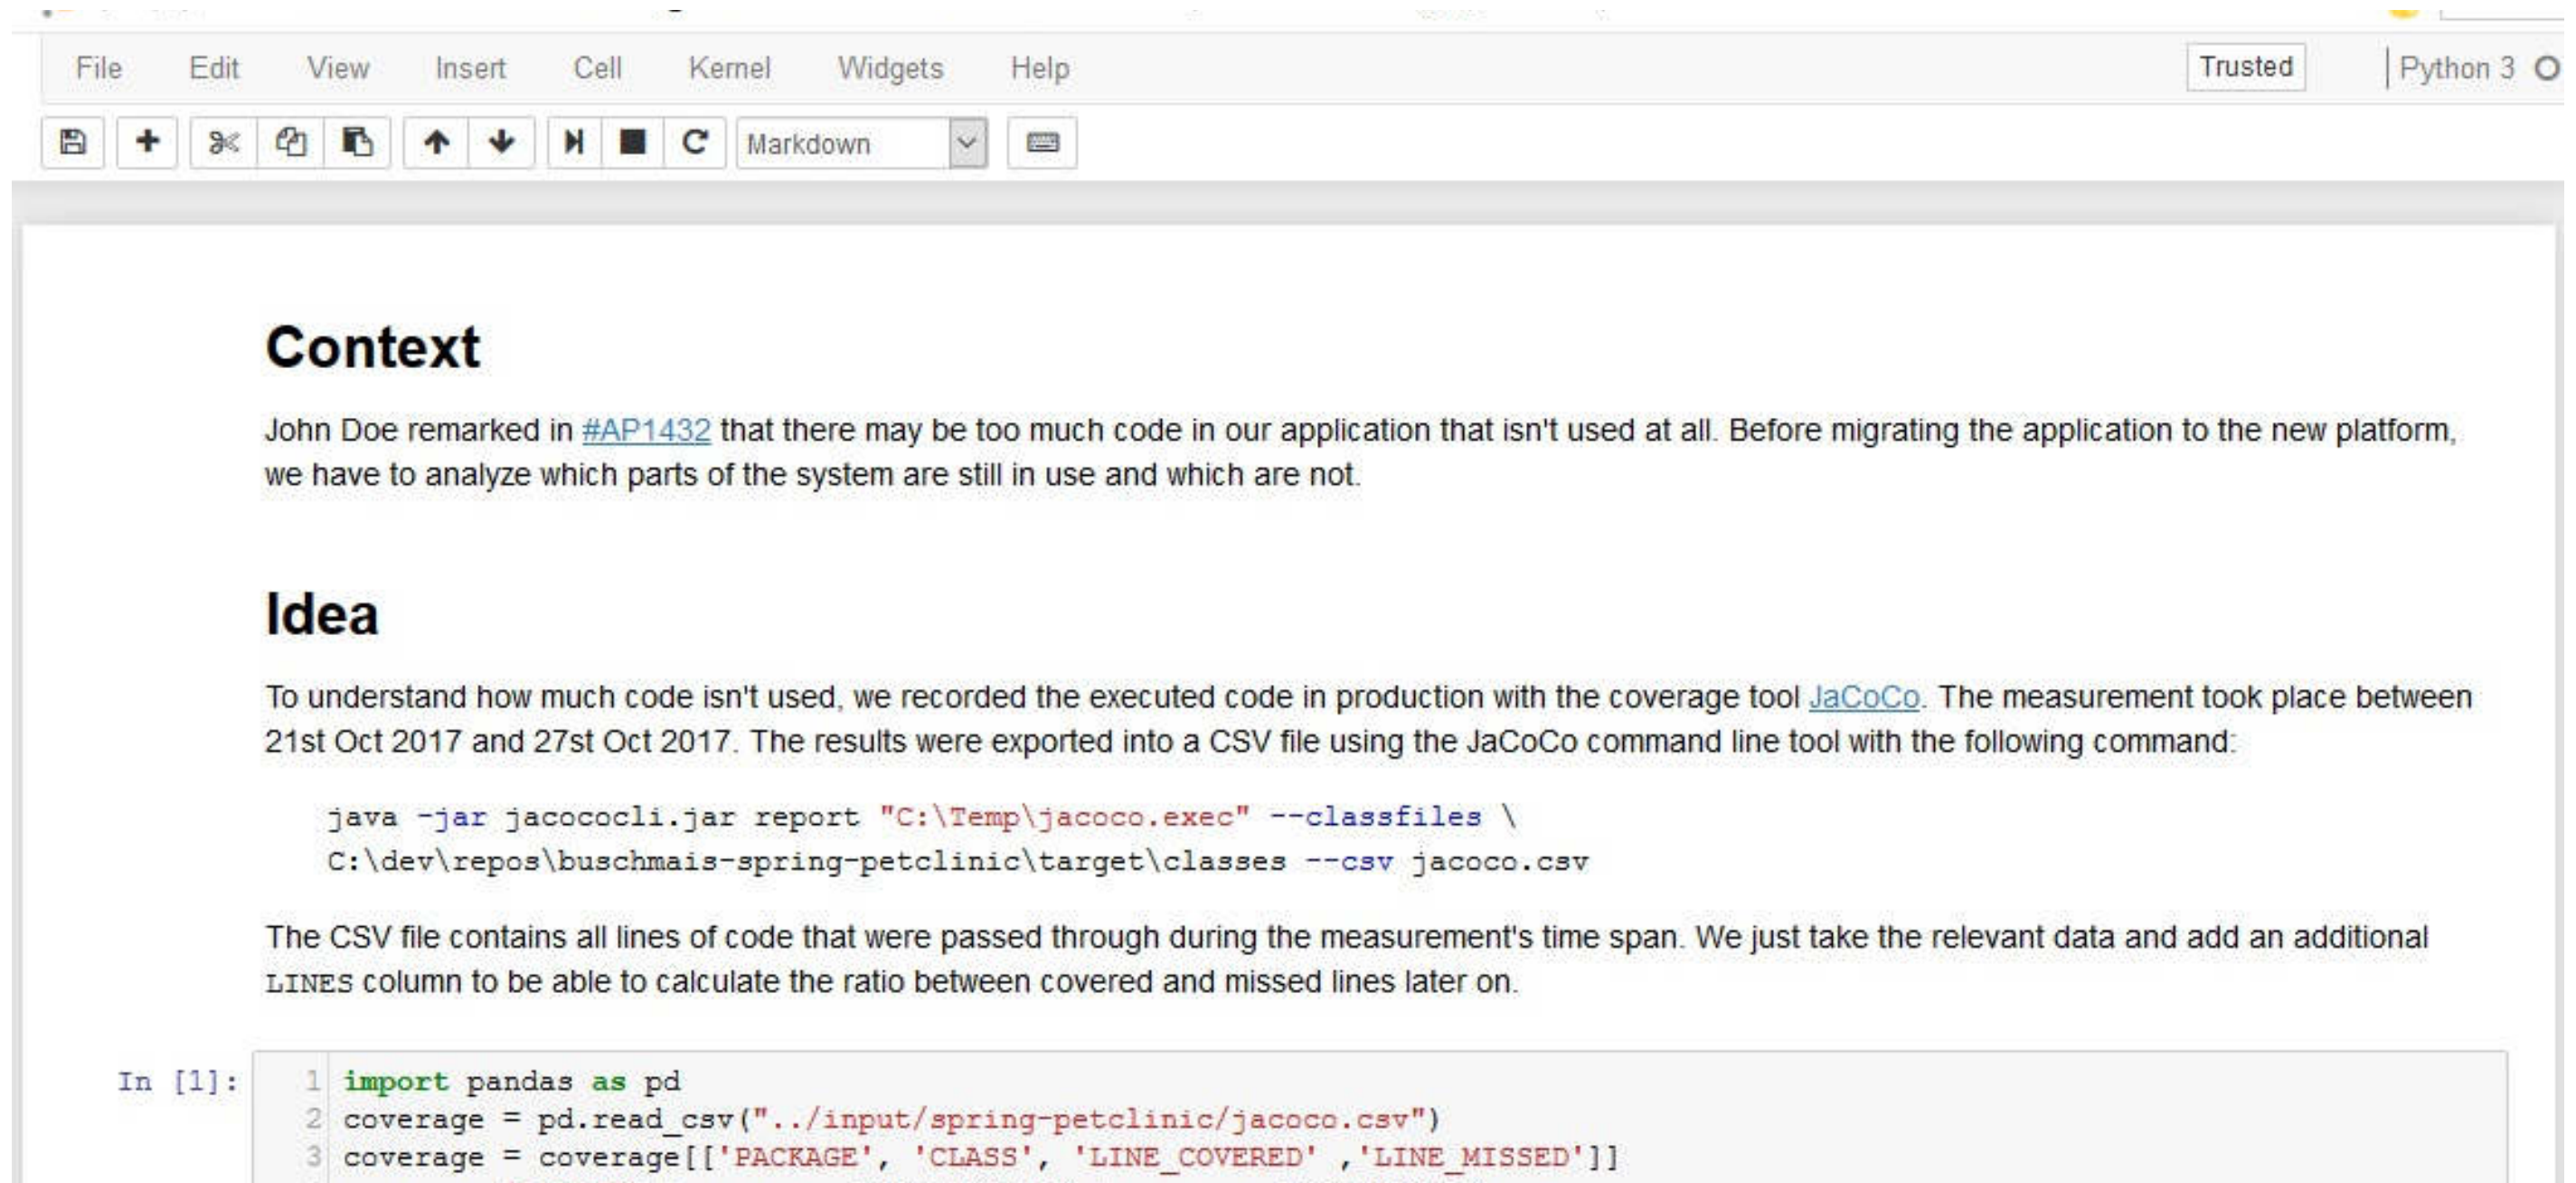
⊕ Nachvollziehbarkeit

Offenheit

- Filtern nur mit Begründung
- Zusammenfassen mit Erklärung
- Beschreibung, Code & Ergebnis pro gedanklichen Schritt
- Unterstützung mittels Visualisierungen

Notizbuch-Ansatz

✔ Nachvollziehbarkeit



The screenshot shows a Jupyter Notebook interface. The top menu bar includes 'File', 'Edit', 'View', 'Insert', 'Cell', 'Kernel', 'Widgets', and 'Help'. On the right, it says 'Trusted' and 'Python 3'. Below the menu is a toolbar with icons for saving, adding cells, undo, redo, and navigation. The notebook content is as follows:

Context

John Doe remarked in [#AP1432](#) that there may be too much code in our application that isn't used at all. Before migrating the application to the new platform, we have to analyze which parts of the system are still in use and which are not.

Idea

To understand how much code isn't used, we recorded the executed code in production with the coverage tool [JaCoCo](#). The measurement took place between 21st Oct 2017 and 27st Oct 2017. The results were exported into a CSV file using the JaCoCo command line tool with the following command:

```
java -jar jacococli.jar report "C:\Temp\jacoco.exec" --classfiles \
C:\dev\repos\buschmais-spring-petclinic\target\classes --csv jacoco.csv
```

The CSV file contains all lines of code that were passed through during the measurement's time span. We just take the relevant data and add an additional `LINES` column to be able to calculate the ratio between covered and missed lines later on.

In [1]:

```
1 import pandas as pd
2 coverage = pd.read_csv("../input/spring-petclinic/jacoco.csv")
3 coverage = coverage[['PACKAGE', 'CLASS', 'LINE_COVERED', 'LINE_MISSED']]
```

4. Modell

Einfache Modelle verwenden

- **Heuristiken** statt 100%-Lösung
- Neue **Perspektiven** auf kleinteilige Daten schaffen
 - Verschiedenen Datenquellen verschneiden
 - Tabellen drehen / pivotieren
 - Gruppierungen vornehmen
 - Fachliche Bereiche, technische Komponenten, ...
 - Teams, Zeiträume, ...

=> **Kommunikation** mit Nicht-Technikern ermöglichen


Beispiel

„Strategic Redesign“

Teil 1: Modell

Strategic Redesign

Verbesserung von Quellcode, der auch wirklich genutzt wird



Strategic Redesign

Verbesserung von Quellcode, der auch wirklich genutzt wird

Subdomain	Invest	Usage	Size
Vet	75	17%	313
Visit	90	37%	472
Pet	169	49%	746
Owner	96	51%	531
crossfunctional	57	57%	268
Clinic	26	89%	110
Person	5	100%	53
Specialty	5	100%	28

=> Fachliche Sicht auf technische Messwerte


5. Visualisierung

Effektive Visualisierungen

- Wenige, verständliche Informationen darstellen
- Zwischenergebnisse visualisieren
- Grafiken programmatisch aus Ergebnissen generieren

`top10_authors.plot.pie()` =>

author




Beispiel

„Strategic Redesign“

Teil 2: Visualisierung

Strategic Redesign

Verbesserung von Quellcode, der auch wirklich genutzt wird



=> Management-Sicht auf technische Messwerte

6. Erkenntnis

Kommunikation der Resultate


- Analyse-Notebooks und Daten bereitstellen
- Vorstellung mit **Visualisierung** und **Kernaussagen** starten
 - Bei Bedarf Rückweg bis zu den Rohdaten schildern
- Was immer dabei sein muss:
 - **Zusammenfassung** mit Schlussfolgerung
 - **Nächste Schritte** (=> Aktionen lostreten)

Demo

„No-Go-Areas“

```
2 top10.plot.pie()
```

Out[6]: <matplotlib.axes._subplots.AxesSubplot at 0x25948362278>




Getting Started

Eigenen Stand bzgl. Analysen klären


Analyse-Reifegrad

1. Bekannt
2. Genutzt
3. Definiert
4. Wiederholt
5. Integriert



Analyse-Pipeline einführen

Beispiel



Loslegen!

Literatur

- Adam Tornhill: Software Design X-Ray
- Wes McKinney: Python For Data Analysis
- Leek, Jeff: The Elements of Data Analytic Style
- Christian Bird, Tim Menzies, Thomas Zimmermann:
The Art and Science of Analyzing Software Data
- Tim Menzies, Laurie Williams, Thomas Zimmermann:
Perspectives on Data Science for Software Engineering

Software

- Python Data Science Distribution: anaconda.com
- jQAssistant: github.com/JavaOnAutobahn/spring-petclinic
- GitHub-Repo: github.com/feststelltaste/software-analytics
- Mini-Tutorial: feststelltaste.de/mini-tutorial-git-log-analyse-mit-python-und-pandas

Blog: feststelltaste.de

Zusammenfassung

Zusammenfassung

1. **Methoden und Werkzeuge** sind da
2. **Kommunikation** kniffliger Probleme möglich
3. **Best Practices** helfen beim Einstieg

Danke!



Markus Harrer
markus.harrer@innoq.com

 +49 175 5753640

 @feststelltaste

 <https://feststelltaste.de>



**Heute und morgen
am INNOQ-Stand!**

innoQ Deutschland GmbH

Krischerstr. 100
40789 Monheim am Rhein
Germany
+49 2173 3366-0

Ohlauer Str. 43
10999 Berlin
Germany

Ludwigstr. 180E
63067 Offenbach
Germany

Kreuzstr. 16
80331 München
Germany

innoQ Schweiz GmbH

Gewerbestr. 11
CH-6330 Cham
Switzerland
+41 41 743 01 11

Albulastr. 55
8048 Zürich
Switzerland

QUESTION



ASK 'EM ALL

Auch gerne heute und morgen
am INNOQ-Stand!

**// Tools only
find, people
have to find
out!"**

Markus Harrer

Software Development Analyst
bei innoQ Deutschland GmbH



- Datenanalysen in der Softwareentwicklung
- Architektur-, Design- und Code-Reviews
- Reverse- und Re-Engineering von Legacy-Code

Anhang: Werkzeuge



Interaktives Notebooksystem

- Dokumentenzentrierte Analysen
- Ausführbare Codeblöcke
- Direkt sichtbare Visualisierungen




Programmiersprache für Data Science

- ✓ Einfach
- ✓ Effizient
- ✓ Schnell

pandas

$$y_{it} = \beta' x_{it} + \mu_i + \epsilon_{it}$$




Pragmatisches Datenanalysewerkzeug

✓ Das programmierbare Excel-Arbeitsblatt

- Richtig schnell
- Flexibel
- Ausdrucksstark

➔ Sehr gute Integration mit anderen Bibliotheken



Visualisierungsbibliothek

Ermöglicht die programmatische Erstellung von Grafiken

- Erstellung von Balken-, Linien-Diagrammen und mehr
- Gute Integration mit **pandas** & Co.

➔ Direkte Ausgabe in **Jupyter** Notebooks

Python Ökosystem

Datenanalysen


- NumPy
- scikit-learn
- TensorFlow
- Dask
- Py2neo
- Pygments

Visualisierung / Präsentation

- pygal
- Bokeh
- python-pptx
- RISE

Other

- Scrapy, Selenium, Flask



Data Science Python Distribution

✓ All-Inclusive Paket (kostenlos!)

- Bringt alles mit, was für den Start gebraucht wird
- Mitgelieferte Pakete sind untereinander abgestimmt und für das jeweilige Betriebssystem optimiert

➔ Downloaden, installieren, loslegen!

Die Spezialisten für vernetzte Daten



Your Software. Your Structures. Your Rules.

i Framework zur statischen Architektur- und Code-Analyse auf Basis von Softwaredaten

[:SPEICHERT_IN]



i Graph-Datenbank zur Ablage und Analyse stark vernetzter Daten



www.innoq.com

SERVICES

Strategy & technology consulting
Digital business models
Software architecture & development
Digital platforms & infrastructures
Knowledge transfer, coaching & trainings

FACTS

~125 employees
Privately owned
Vendor-independent

OFFICES

Monheim
Berlin
Offenbach
Munich
Zurich

CLIENTS

Finance
Telecommunications
Logistics
E-Commerce
Fortune 500
SMBs
Startups