TAC-POT #3

PowerQuery

pandas

Überblick

tac

PowerQuery vs. Pandas

1. Adressierte Problemstellungen – ETL
2. Power Query & Pandas Überblick
3. Power Query in der Microsoft Familie
4. Pro / Cons

Beispiele

Webdaten Download
Lade Ordner mit gleicher File Struktur
Transformation von Daten (Append/Merge)

PowerQuery & Pandas: Adressierte Problemstellung

tac

Primärer Zweck dieser Tools: ETL (Extract, Transform, Load)

- ✓ Daten aus **unterschiedlichen Quellen** werden **regelmäßig** in ein Model laden (**Extract**)
- ✓ Daten müssen **standardmäßig anders dargestellt oder aufbereitet** werden (**Transform**), damit diese Sinnvoll analysiert werden können
- ✓ Daten werden nach standardisierter Aufbereitung in ein „Datenmodel“ geladen oder weiter genutzt (**Load**)

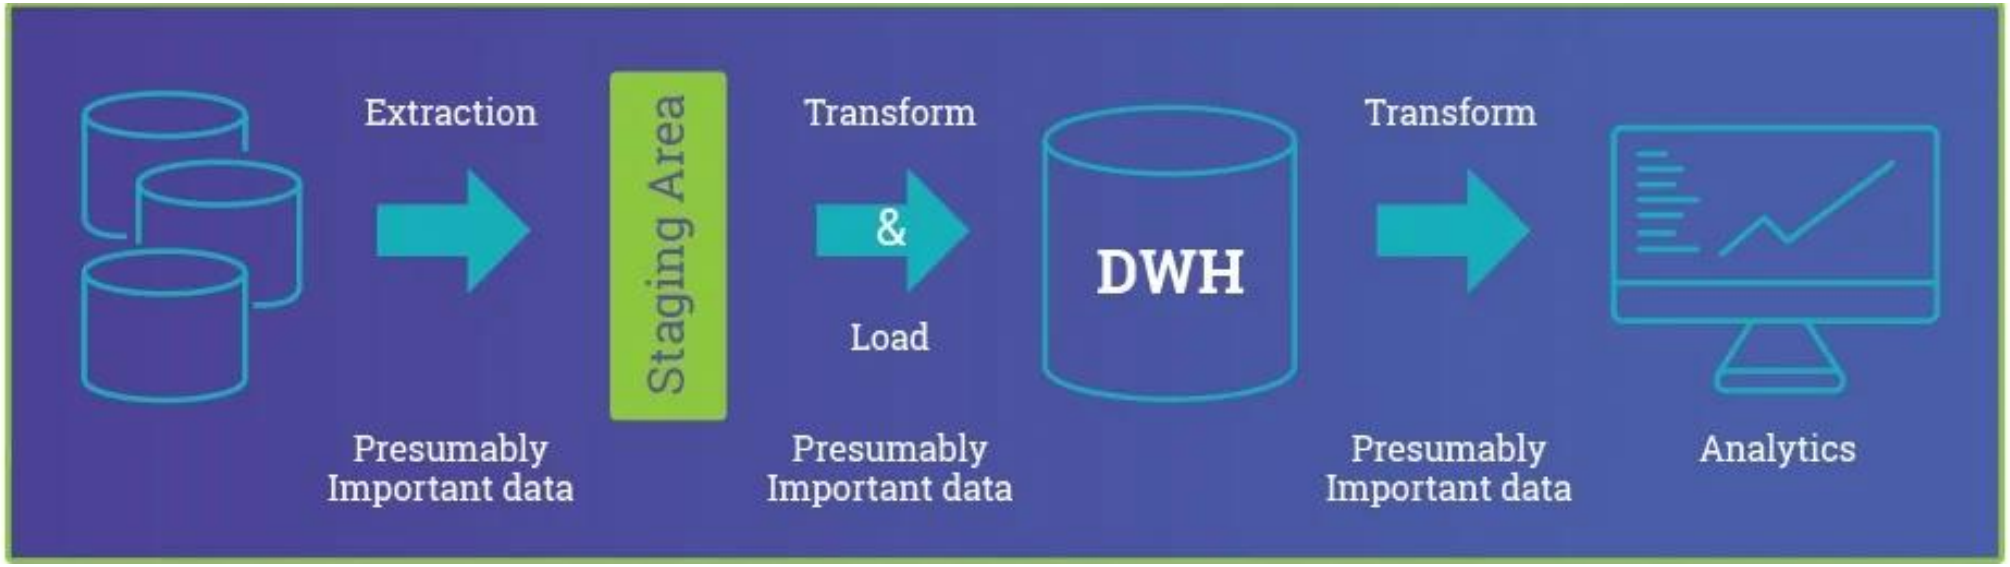

WHAT DATA SCIENTISTS SPEND THE MOST TIME DOING

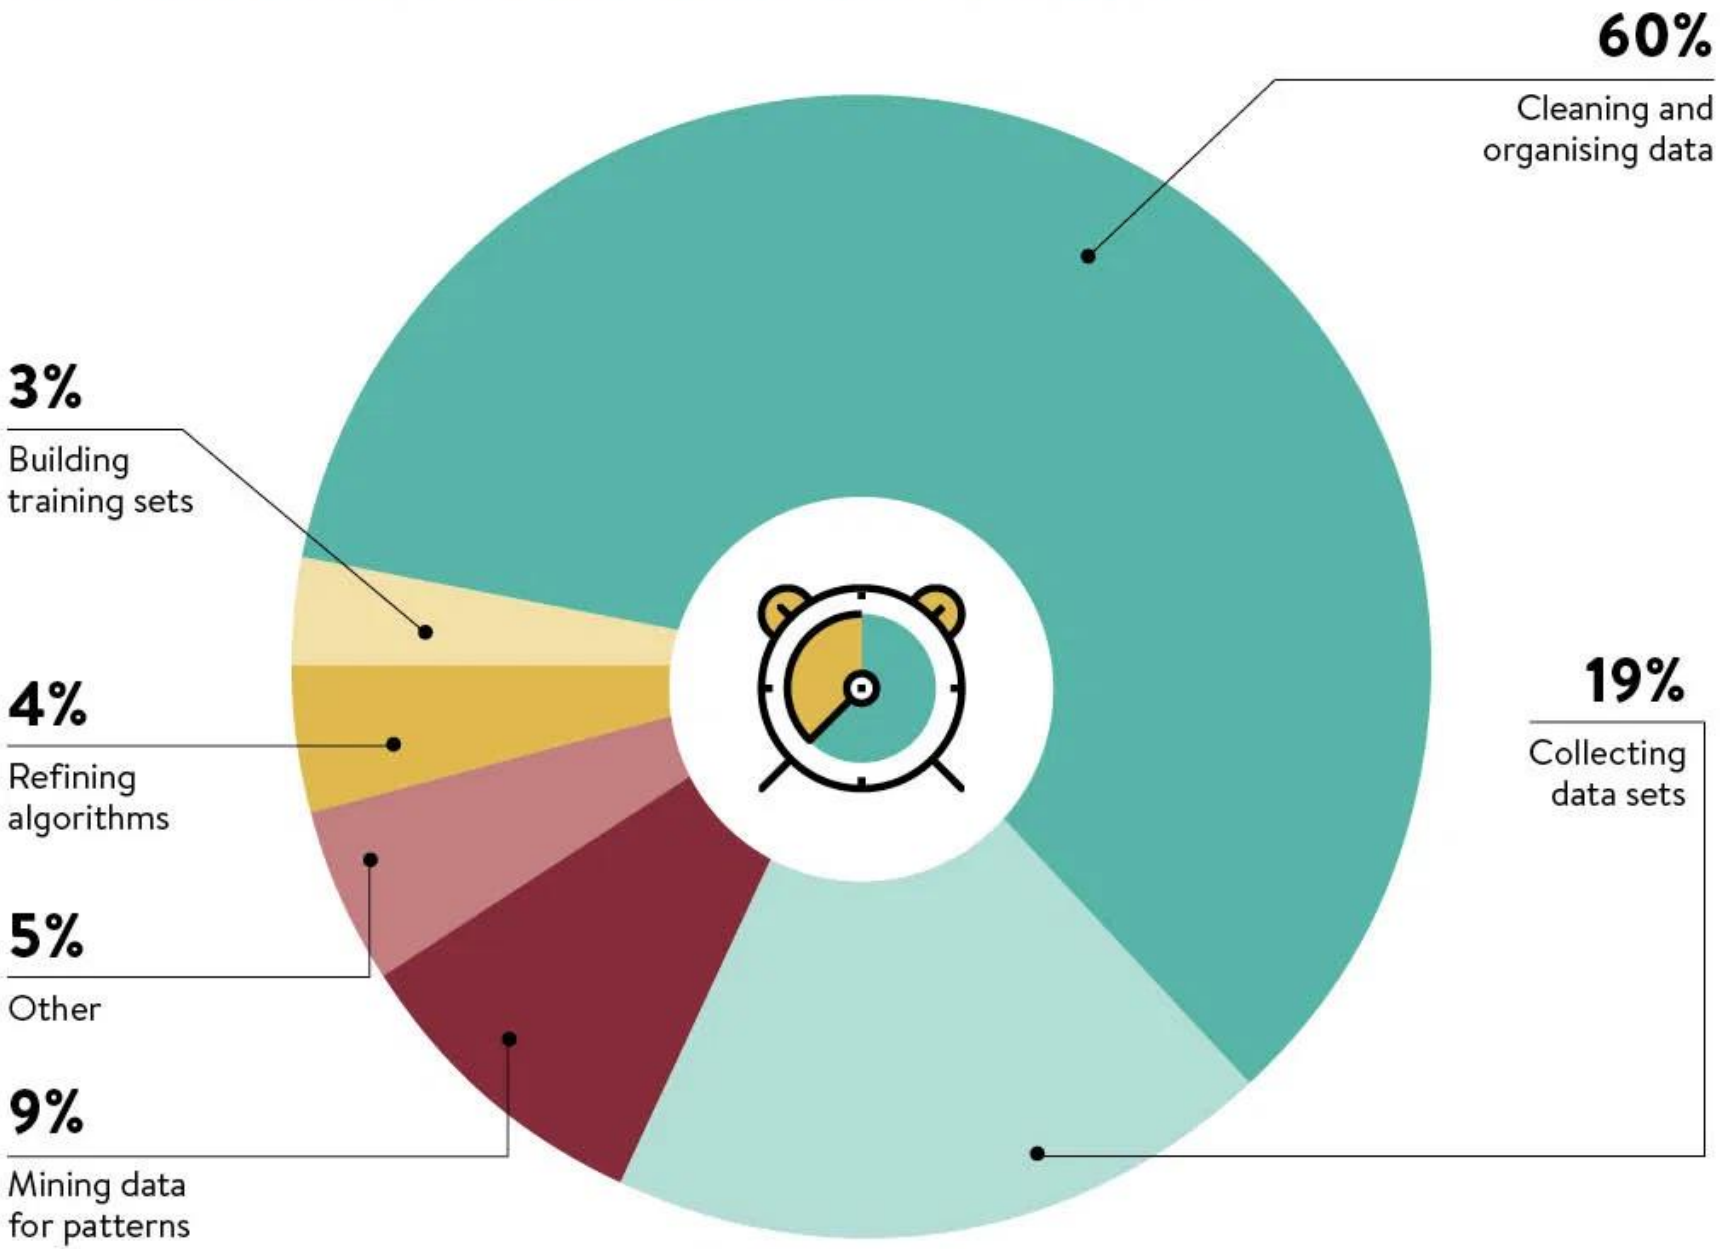

Source: CrowdFlower 2016

PowerQuery

- Standard Modul in Excel seit 2013
- User-Interaktiv mit „Schritt-Anzeige“ zur Anwendung von Datenladen und Transformieren für Excel Daten Model bzw. Flat Files
- Optional: Verwendung von M-Language Code für „Erfahrenere User“

- Verwendung zur ETL in Microsoft Power BI

- Paket / Library für Python
- Anwendung:
  - ➢ Datenlade Funktionen
  - ➢ Gängige Transformation Funktionen & Ausgabe Funktionen
    -> Arbeit mit einem Dataframe (Tabelle mit Header und Index)
- Nur Code basiert
- Hoher Skalierungsgrad -> Anwendung bei mittleren/hohen Automatisierungsgrad oder hoher Datenmenge

Ziel: *Daten aus unterschiedlichen Quellen konsolidieren/laden und ins gewünschte Datenformat des Zielmodels transformieren*

History

2008	Developer Wes McKinney started working on pandas in 2008 while at AQR Capital Management out of the need for a high performance, flexible tool to perform quantitative analysis on financial data. Before leaving AQR he was able to convince management to allow him to open source the library
2012	Another AQR employee, Chang She, joined the effort in 2012 as the second major contributor to the library
2015	In 2015, pandas signed on as a fiscally sponsored project of NumFOCUS, a nonprofit charity in the United States

Library features

tac

pandas

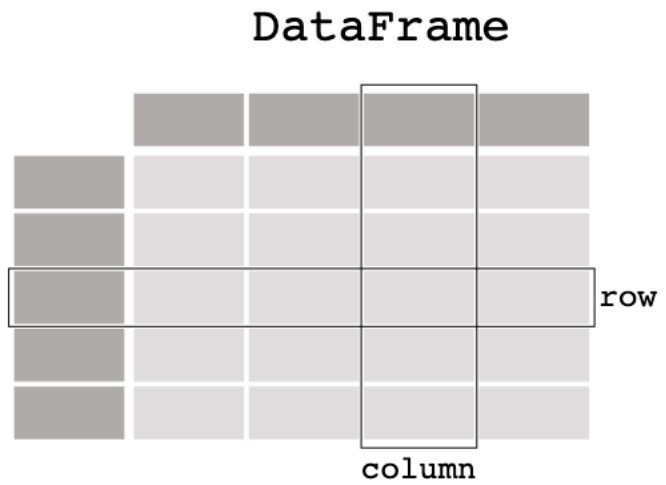

function

- DataFrame object for data manipulation with integrated indexing
- Tools for reading and writing data between in-memory data structures and different file formats
- Data alignment and integrated handling of missing data

- Reshaping and pivoting of data sets
- Label-based slicing, fancy indexing, and subsetting of large data sets
- Data structure column insertion and deletion
- Group-by-engine allowing split-apply-combine operations on data sets
- Data set merging and joining

- Hierarchical axis indexing to work with high-dimensional data in a lower-dimensional data structure
- Time series-functionality: Date range generation and frequency conversion, moving window statistics, linear regressions, date shifting and lagging
- Provides data filtration

language

The library is highly optimized for performance, with critical code paths written in Cython or C

pandas

usage

Pandas is mainly used for data analysis. Pandas allows importing data from various file formats such as comma-separated values, JSON, SQL, Microsoft Excel.

Pandas allows various data manipulation operations such as **merging, reshaping, selecting, as well as data cleaning, and data wrangling features**.

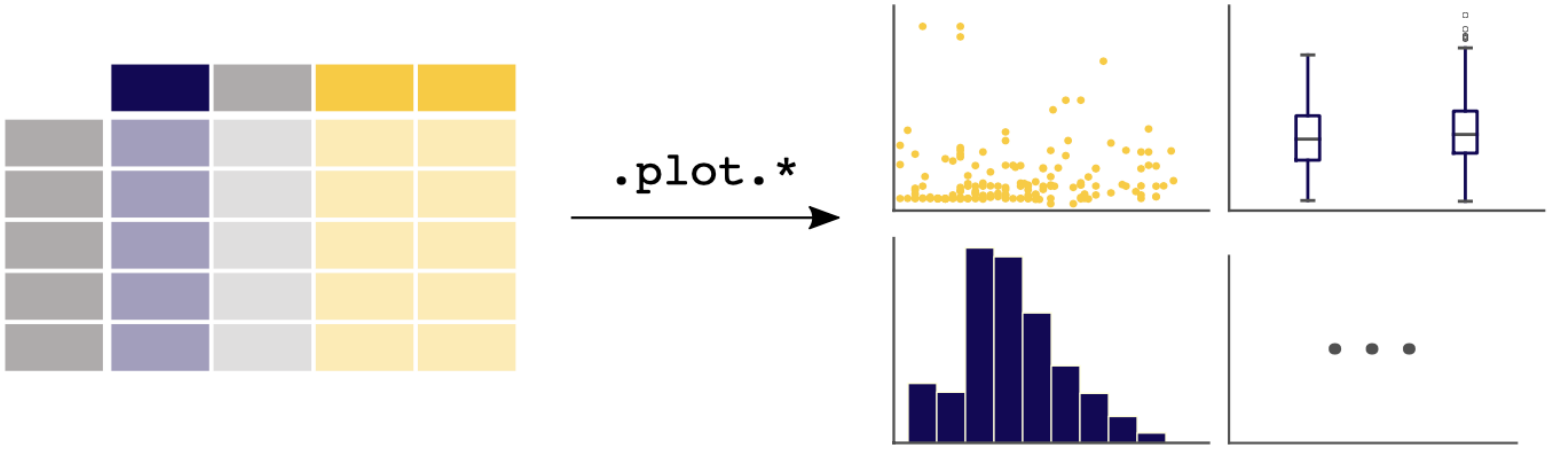

Kurven

```
import pandas as pd
import matplotlib.pyplot as plt
import numpy as np

df = pd.DataFrame(np.random.randn(100, 5), columns=lis
df=df.cumsum()
df.plot()
plt.show()
```

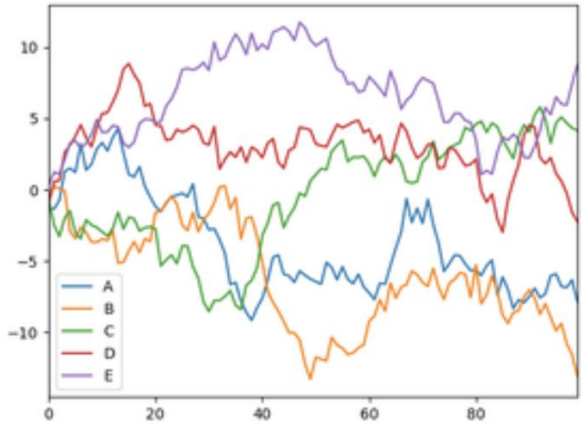

Stabdiagramme

```
df = pd.DataFrame(np.random.rand(10, 5), columns=list('AB
df.plot.bar(stacked=True)
plt.show()
```

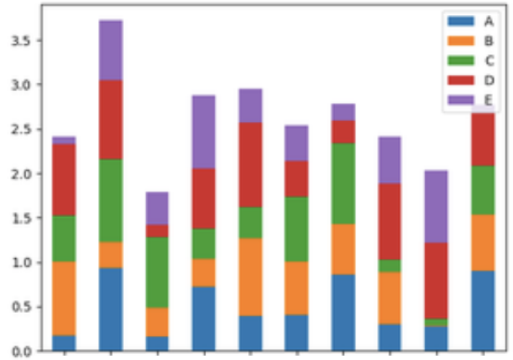

Boxplot

```
df = pd.DataFrame(np.random.rand(7, 5), columns=list('ABCDE'
df.plot.box()
plt.show()
```

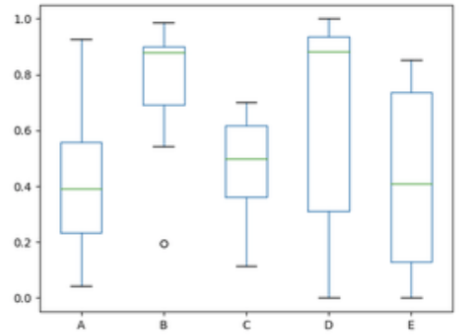

PowerQuery - Einordnung in der Microsoft Familie

tac

Module in Excel

PowerQuery

PowerPivot

PowerView

Excel

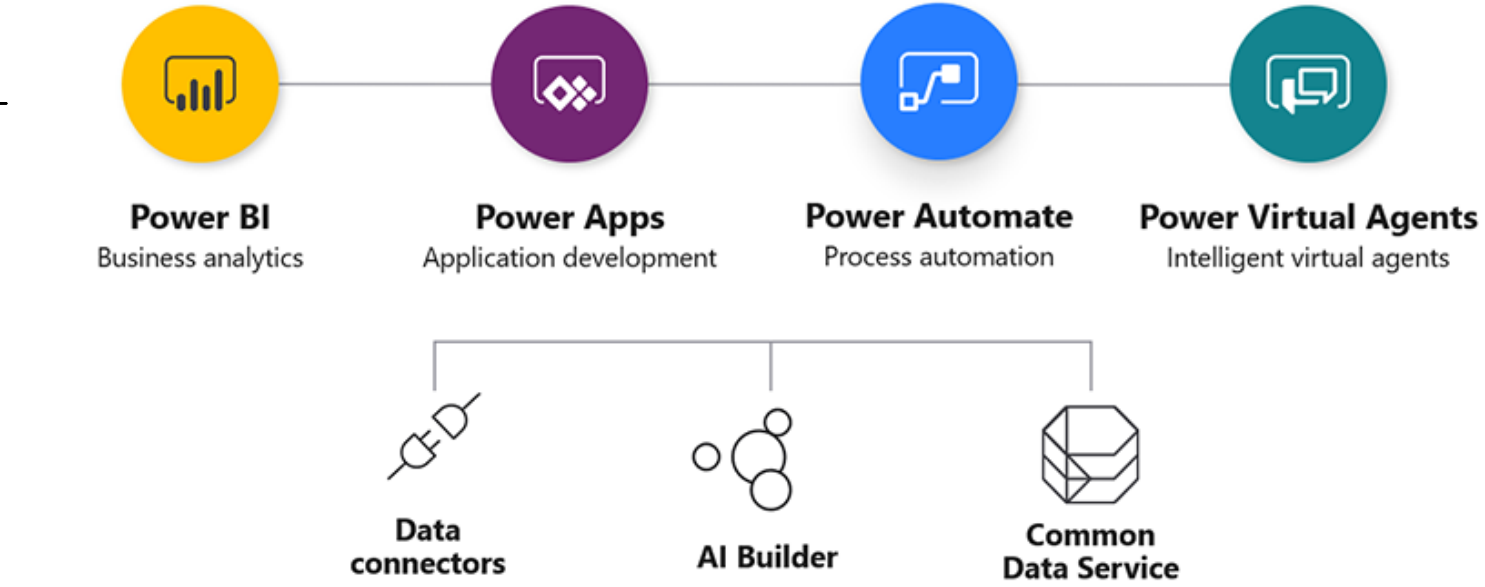

Die alte Corporate Welt:
ELT + Data Model + Visualisierung

PowerQuery – Start in Excel

tac

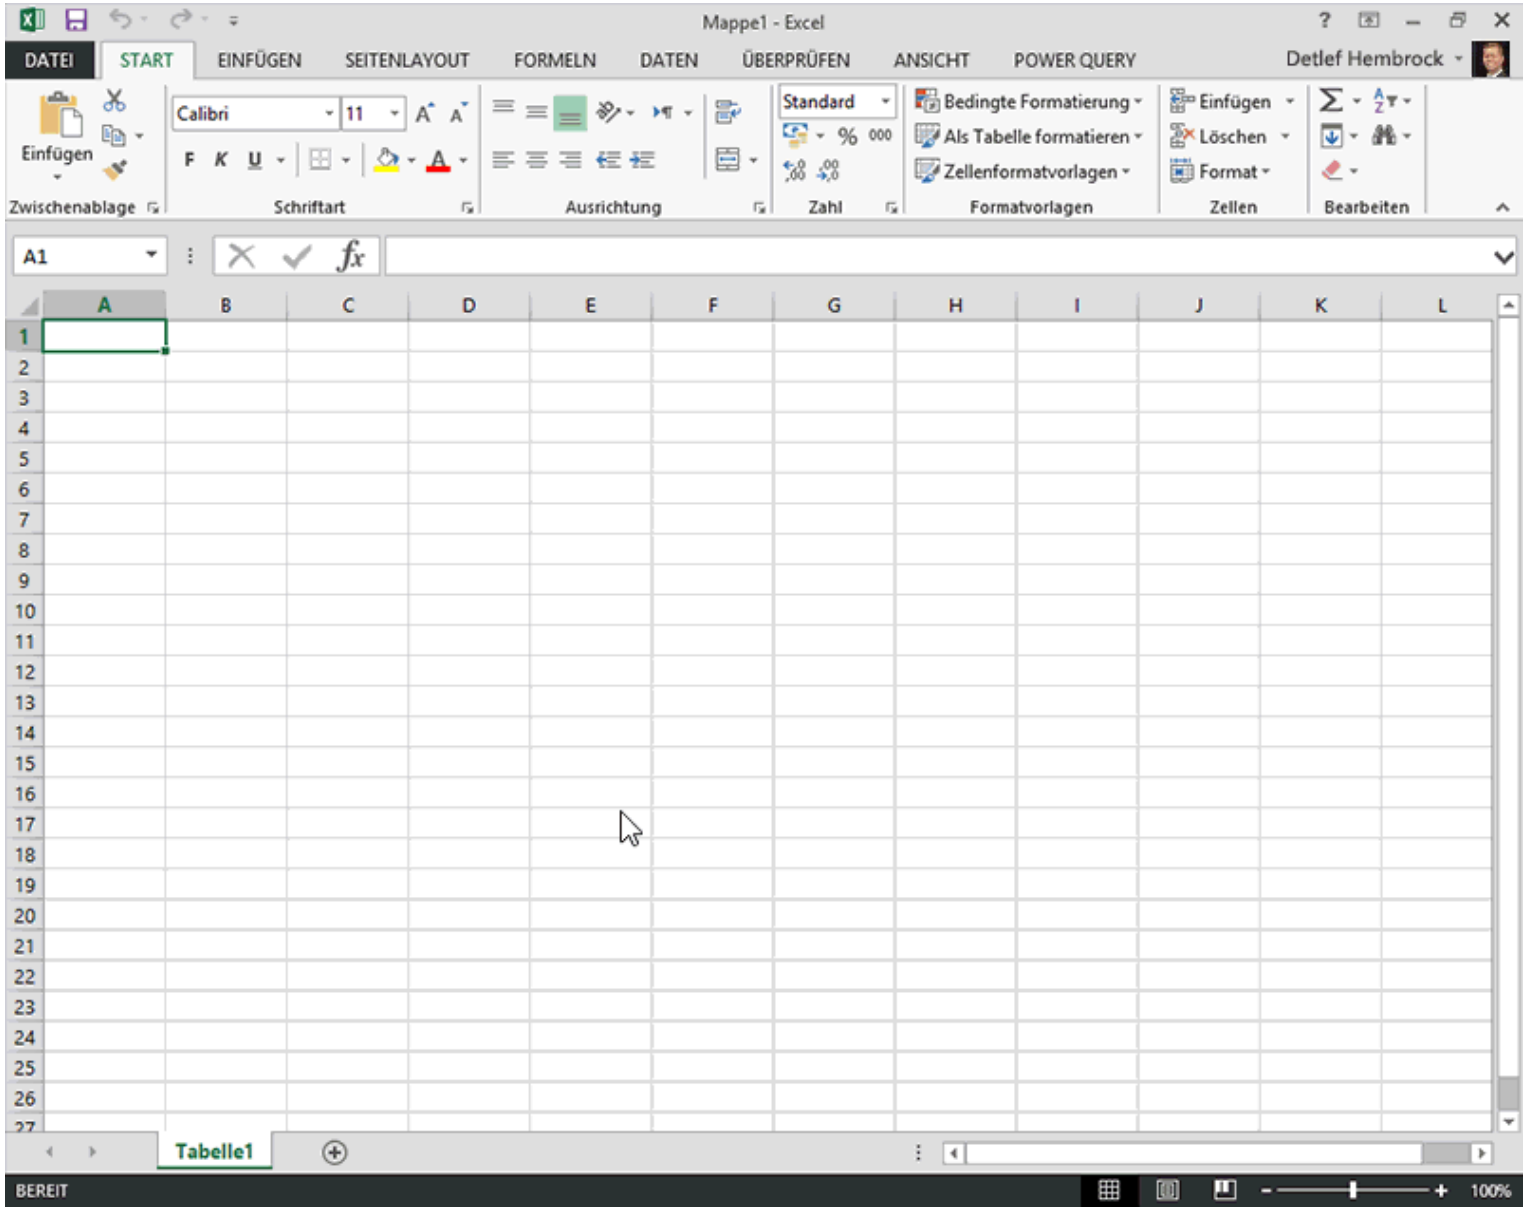

Powerquery in Excel – User UI

tac

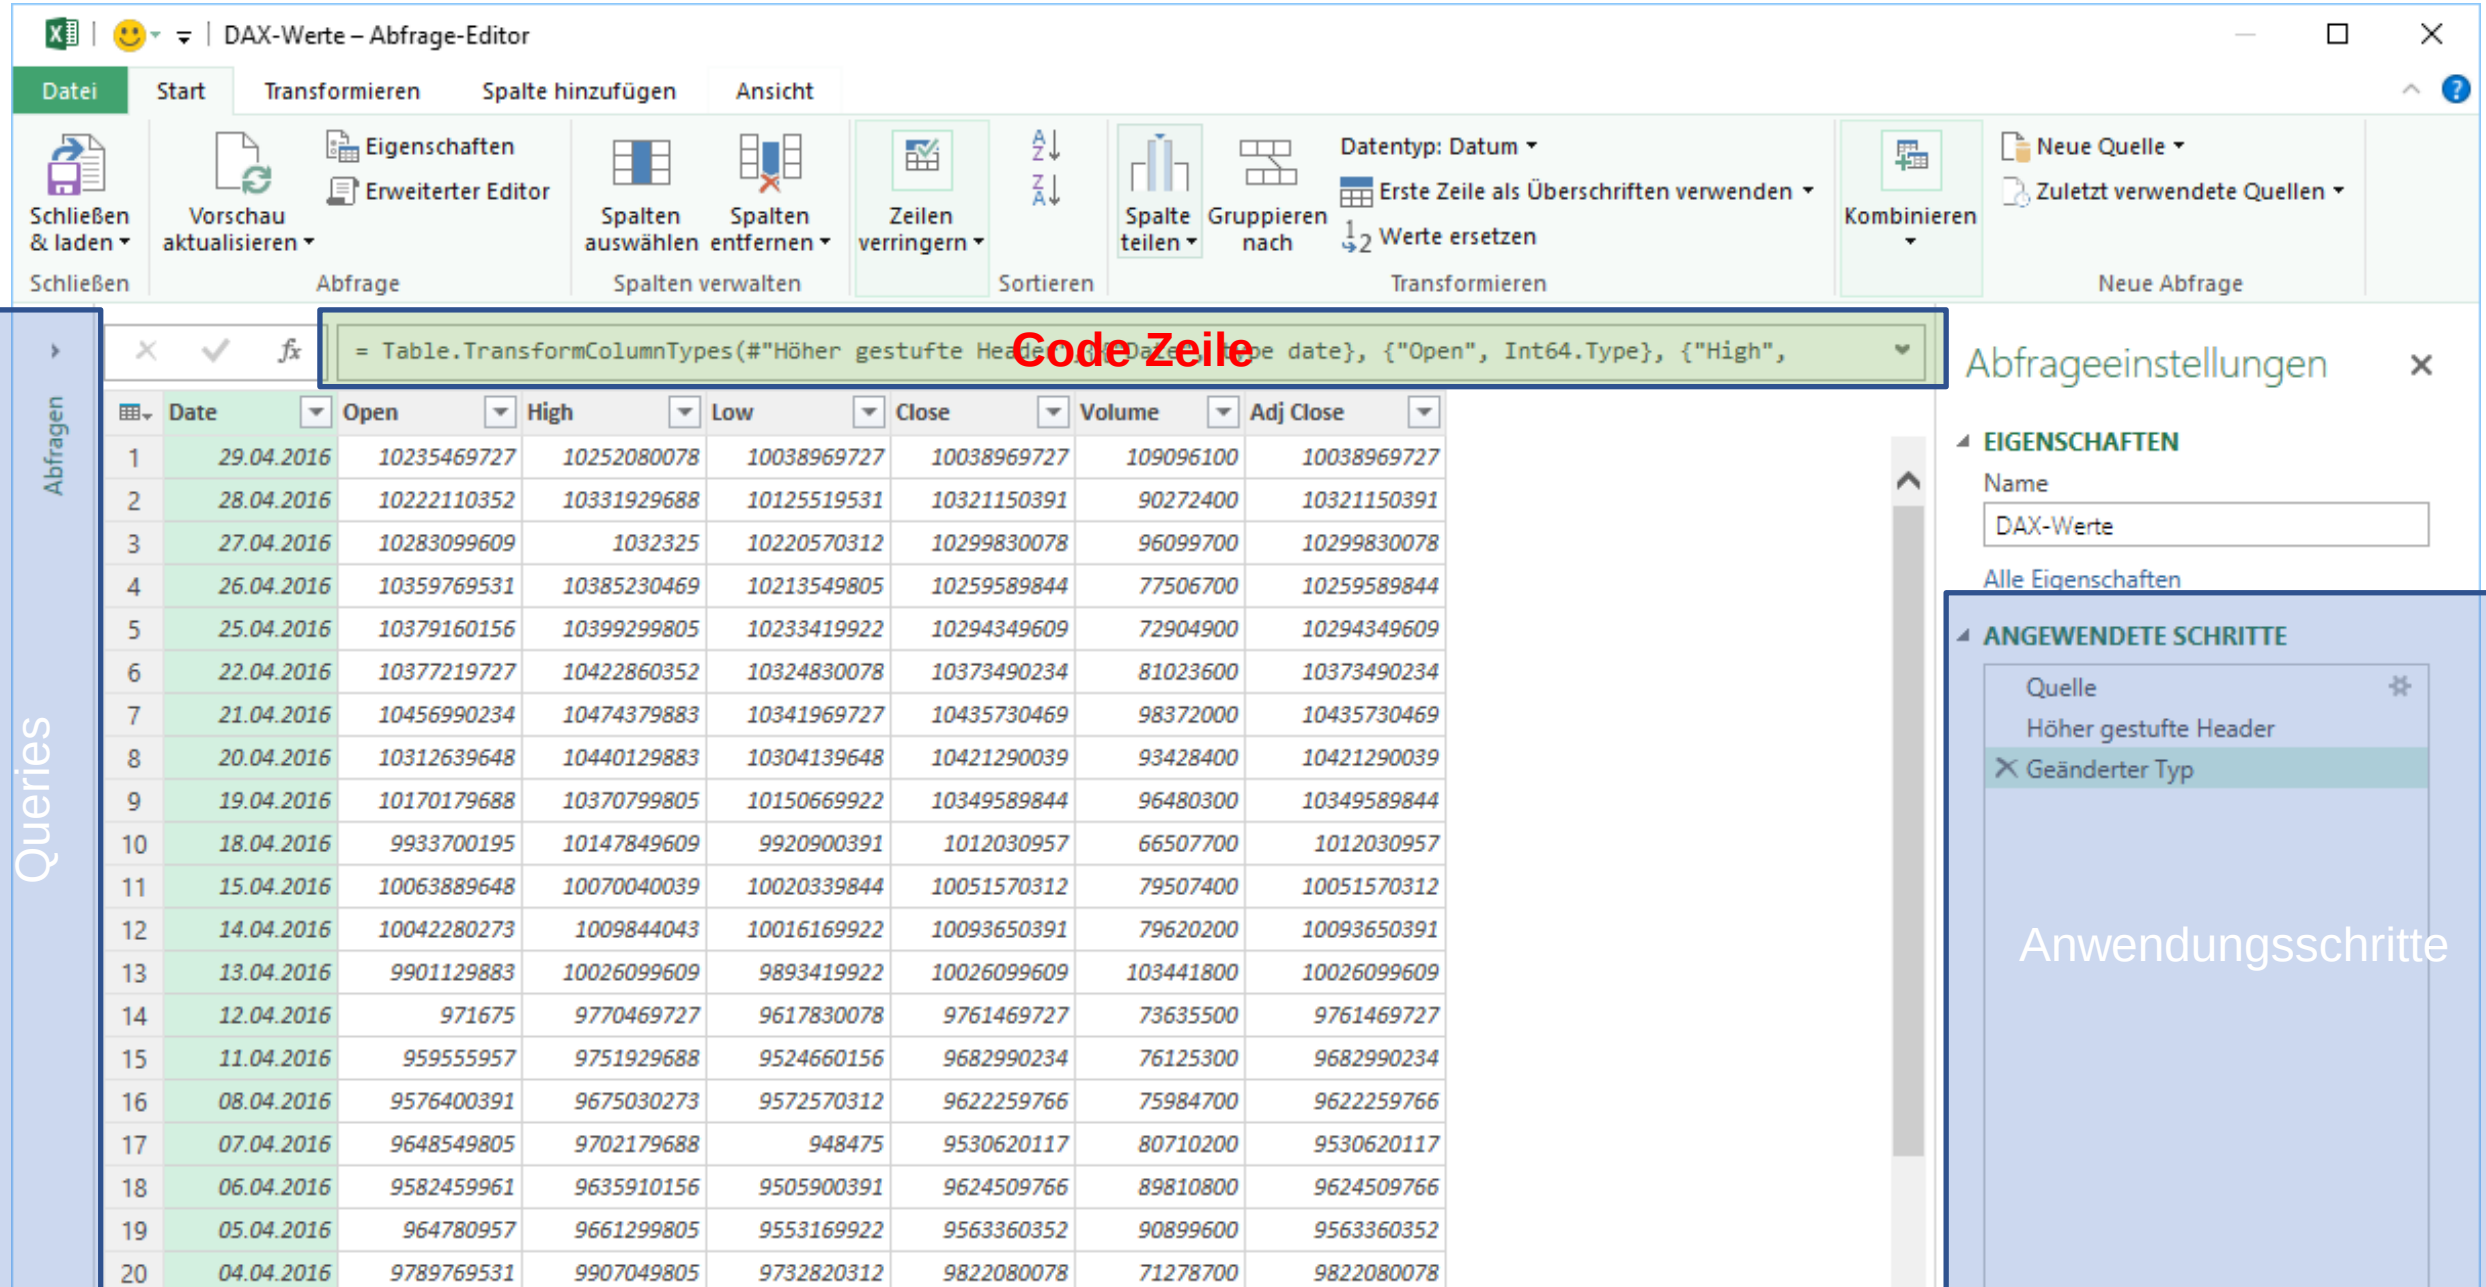

	Date	Open	High	Low	Close	Volume	Adj Close
1	29.04.2016	10235469727	10252080078	10038969727	10038969727	109096100	10038969727
2	28.04.2016	10222110352	10331929688	10125519531	10321150391	90272400	10321150391
3	27.04.2016	10283099609	1032325	10220570312	10299830078	96099700	10299830078
4	26.04.2016	10359769531	10385230469	10213549805	10259589844	77506700	10259589844
5	25.04.2016	10379160156	10399299805	10233419922	10294349609	72904900	10294349609
6	22.04.2016	10377219727	10422860352	10324830078	10373490234	81023600	10373490234
7	21.04.2016	10456990234	10474379883	10341969727	10435730469	98372000	10435730469
8	20.04.2016	10312639648	10440129883	10304139648	10421290039	93428400	10421290039
9	19.04.2016	10170179688	10370799805	10150669922	10349589844	96480300	10349589844
10	18.04.2016	9933700195	10147849609	9920900391	1012030957	66507700	1012030957
11	15.04.2016	10063889648	10070040039	10020339844	10051570312	79507400	10051570312
12	14.04.2016	10042280273	1009844043	10016169922	10093650391	79620200	10093650391
13	13.04.2016	9901129883	10026099609	9893419922	10026099609	103441800	10026099609
14	12.04.2016	971675	9770469727	9617830078	9761469727	73635500	9761469727
15	11.04.2016	959555957	9751929688	9524660156	9682990234	76125300	9682990234
16	08.04.2016	9576400391	9675030273	9572570312	9622259766	75984700	9622259766
17	07.04.2016	9648549805	9702179688	948475	9530620117	80710200	9530620117
18	06.04.2016	9582459961	9635910156	9505900391	9624509766	89810800	9624509766
19	05.04.2016	964780957	9661299805	9553169922	9563360352	90899600	9563360352
20	04.04.2016	9789769531	9907049805	9732820312	9822080078	71278700	9822080078

Power Query M-Language in Powerquery

tac

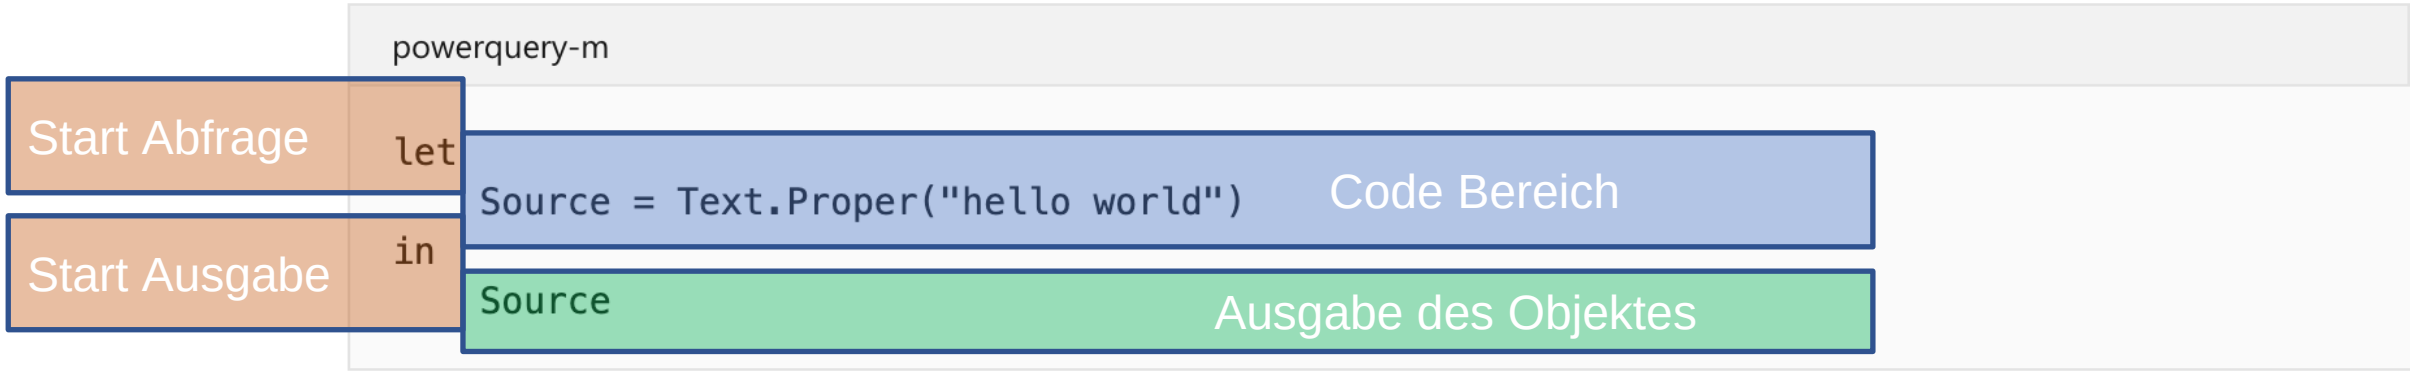

Link https://docs.microsoft.com/de-de/powerquery-m/

Funktionsüberblick in Powerquery

tac

- Power Query M-Funktionen
  - Übersicht über Power Query M-Funktionen
  - Verstehen von Power Query M-Funktonen
  - Zugreifen auf Datenfunktionen
  - Binary functions
  - Kombinationsfunktionen
  - Vergleichsfunktionen
  - Datumsfunktionen
  - DateTime-Funktionen
  - DateTimeZone functions
  - Dauerfunktionen
  - Fehlerbehandlung
  - Ausdrucksfunktionen
  - Funktionswerte
  - Zeilenfunktionen
  - Listenfunktionen
  - Logische Funktionen
  - Nummernfunktionen
  - Datensatzfunktionen
  - Ersetzungsfunktionen
  - Splitter functions
  - Tabellenfunktionen
  - Textfunktionen
  - Zeitfunktionen
  - Typfunktionen
  - URI-Funktionen
  - Value-Funktionen

Vor und Nachteile von Powerquery

tac

Pro

- Nutzerfreundlich/ Intuitive Bedienung (Click&Drop) & Schritteübersicht, welcher in Code gewandelt wird
- **Jeder Corporate User hat Excel als Standard Programm (Python nicht wirklich)**
- Funktionsumfang ist ausreichen, für die meisten Datentransformations- Anwendungen
- Ausgabe der Daten in Excel -> oder Pivot (Komplex in Python) / PowerPivot Datenmodel
- Optional: Native M-Language Anwendung für mehr Komplexere Transformationen
- Power Query in Power BI, bietet Funktionalitäten von Einbindung externen Codes (Python – nur in Power BI Umgebung)

Contra

- Bearbeitung von großen Dateien bringt PowerQuery in Excel schnell an seine Kapazitätsgrenzen. (64Bit Version wir nicht richtig genutzt)
- In Excel: Beschränkt auf gegebene Standard Funktionalitäten (neues nur über Community Feedback Votes)

Vor und Nachteile von Pandas

Pro

- Umfangreise Daten Transformations sowie Daten Analyse Funktionen
- Kann mit ernom großen Datensets umgehen und diese schnell bearbeiten
- Ausführliche Dokumentation und große Community bei Fragestellungen
- Erweiterbar durch Python, um weitere sinnvolle Pakete für Daten Analysen/Visualisierung

Contra

- Python Programmierumgebung erforderlich sowie „generische Programmier Erfahrung“ notwendig

Praxisbeispiel – Data Extract

tac

1) Online Daten Extratieren

-> Beispiel Finanzen.net Aktienkurs Daten

2) Mehrere gleiche Input Daten (Excel) auf einmal verarbeiten und anhängen

3) Merge & Unpivot Funktionen

Quellenangaben

tac

- https://powerbi.microsoft.com/de-de/
- https://support.microsoft.com/de-de/office/einf%c3%bchrung-in-microsoft-power-query-f%c3%bcr-excel-6e92e2f4-2079-4e1f-bad5-89f6269cd605?ui=de-de&rs=de-de&ad=de
- https://de.wikipedia.org/wiki/ETL-Prozess X
- https://resources.fivetran.com/deutsche/der-unverzichtbare-leitfaden-f%C3%BCr-die-datenintegration?campaignid=10265563821&adgroupid=101951711506&network=g&device=c&gclid=CjwKCAjwrcH3BRApEiwAxjdPTbrFvrpuPdP7lLrGDKfMREfuypzqZpor9U7SyBj0hFug-rBl9g--2hoC08wQAvD_BwE

- https://pandas.pydata.org/docs/user_guide/index.html#user-guide

Backup

Users guide 1/2

Users guide 2/2