Azure MachineLearning (ML) und R

Was, wie und warum? Ein Crash-Kurs.

Mario Schnalzenberger

About me – Mario Schnalzenberger

- Informatiker, Statistiker und Volkswirt
- Forscher (Uni Linz)
  - Forschung im Bereich Gesundheit, Alterung, Pensionen und vielem mehr
  - Veröffentlichungen in Klinischer Forschung, Economics und Econometrics
- Bei cubido unterstütze ich Kunden im Bereich
  - DWH und Business Intelligence
  - Predictives in Richtung Industrie 4.0 und Marketing Intelligence
  - Big Data und verwandten Themen
  - SQL Server, Cubes, MDX, R, C#, SAP Infinite Insights, MCSA, MCSE BI, uvm.
- m.schnalzenberger@cubido.at

Agenda

Was?
Big Data?

Wie?
Demo

Warum?
Use Cases

Ausblick!
Mit Cubido

Was?

Big Data – nur größer

Big Data – Wirklich?

- 4 V's (Big Data)
- 4 A's (Predictive Analytics)
- 6 C's (of Trusted Data)
- Big Data als Schlagwort MachineLearning als (ein) Weg

Statistics, Analytics, MachineLearning

Erst durch Auswertung der Daten entsteht der Mehrwert, egal ob Small, Medium oder Big Data.

Sammeln und Aufbereiten – in der Cloud?

Big Data

- Entsteht durch das Sammeln von Daten
  (Cloud als einfacher Partner zum Scale out)
- Sammeln und das IoT ist erst im entstehen
  (Cloud - anpassungsfähig und hochverfügbar)
- Aufbereitung der Daten für die Analyse bedarf
  (kurzfristig) hoher Kapazitäten
  (Hadoop o.ä. Technologien, Cloud?)
- Analyse und Synthese mit Rechenkapazitäten

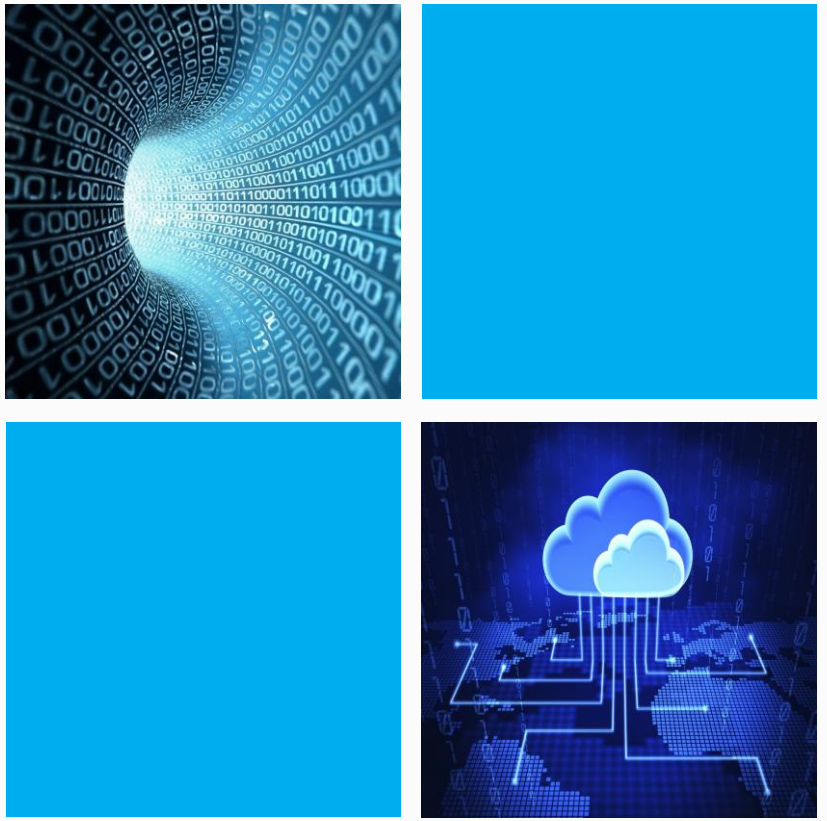

Analytics – Das haben wir doch schon?

Analytics?

- Berichte, die descriptive Analytics, meist keine statistische Analyse, *Daten haben keinen zusätzlichen Wert, wenn Sie niemand sieht*
- Advanced Analytics – Statistik schon im frühen Stadium. Vieles ist möglich.
  - Automatisierung
  - Fokussierung
  - Interaktion

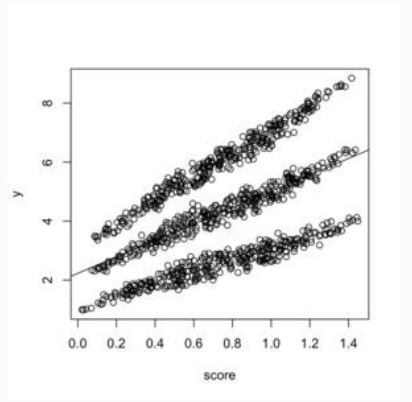

Agility – Prozesse verändern

Vorzeitig mit Analyse beginnen

Analytiker / Statistiker frühzeitig einbinden

Sammeln – Daten und Visionen!

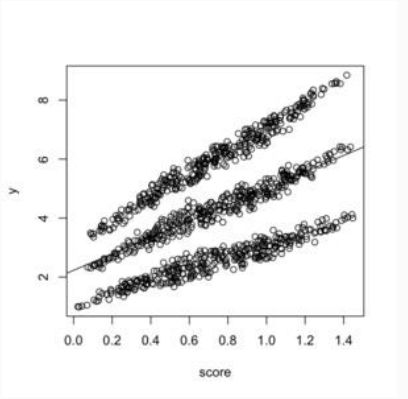

Cloud als einfachen Partner sehen

Langfristig die Prozesse optimieren und aus eigenen Daten lernen

Wie – eine Quasi-Demo

Schon mal geflogen?

- Welchen Flug?
- Welche Airline?
- Welcher Flughafen?
- Welche Uhrzeit?
- Welche Anschlussflüge?

Konzeptuelle Voraussetzungen

Was brauchen wir? Womit arbeiten wir?

- Daten
- Experimente (Modelle)
- Web Services
- (Microsoft Account)

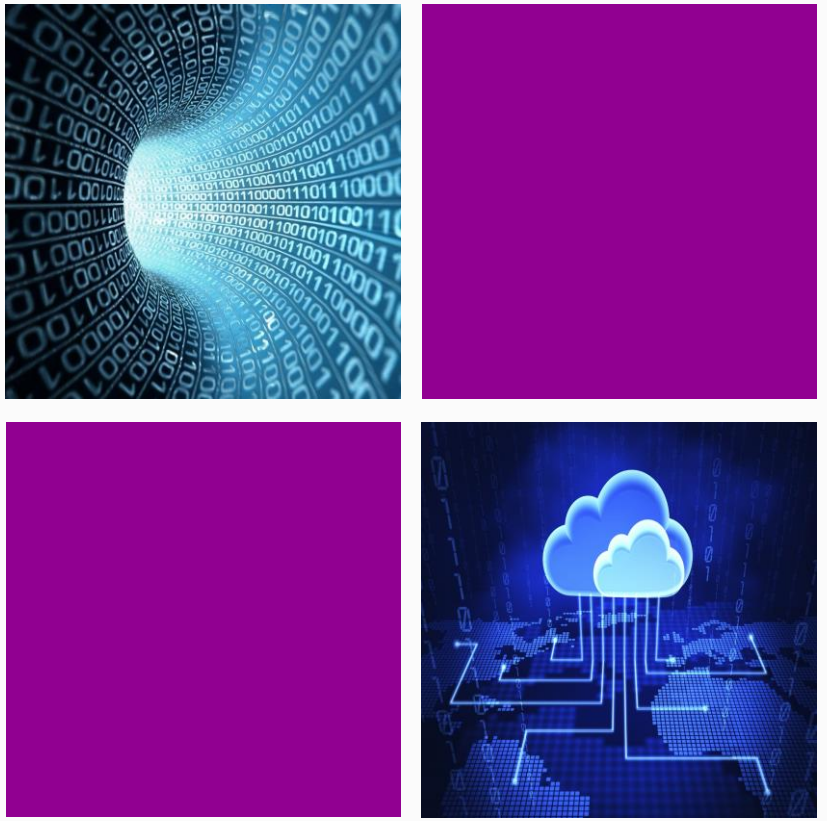

Werkzeuge

- Azure Portal und ML-Workspaces
- ML Studio

ML Studio

- GUI mit vielen Funktionen (Copy/Paste)
- Daten für Experimente hochladen
- Experimente (Modelle) entwickeln und prüfen (validieren)
- Web Services veröffentlichen und freigeben

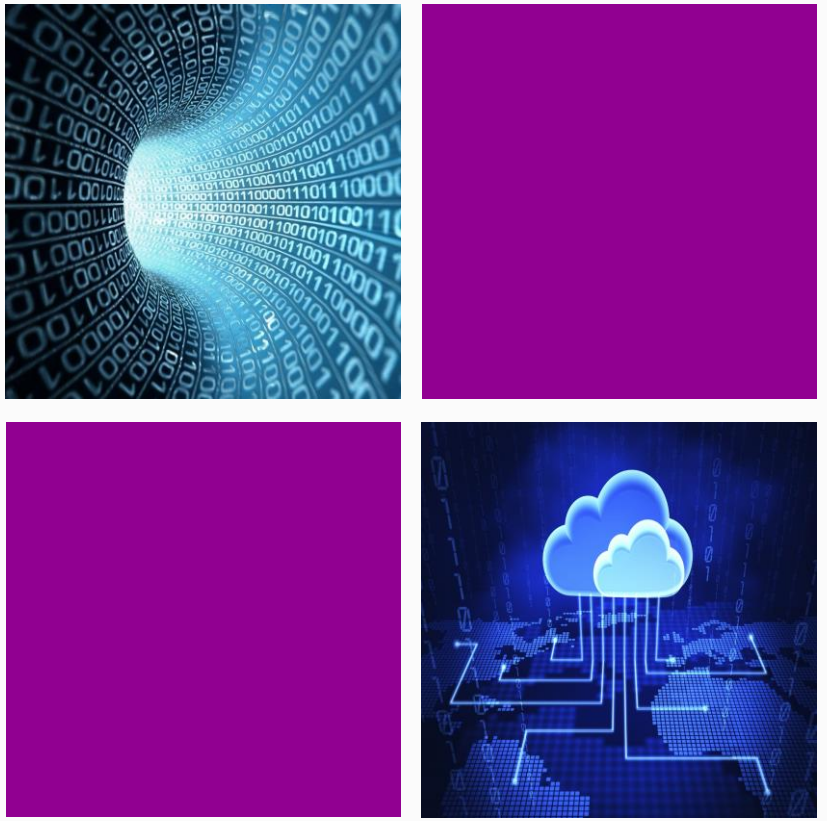

MachineLearning in Azure Portal

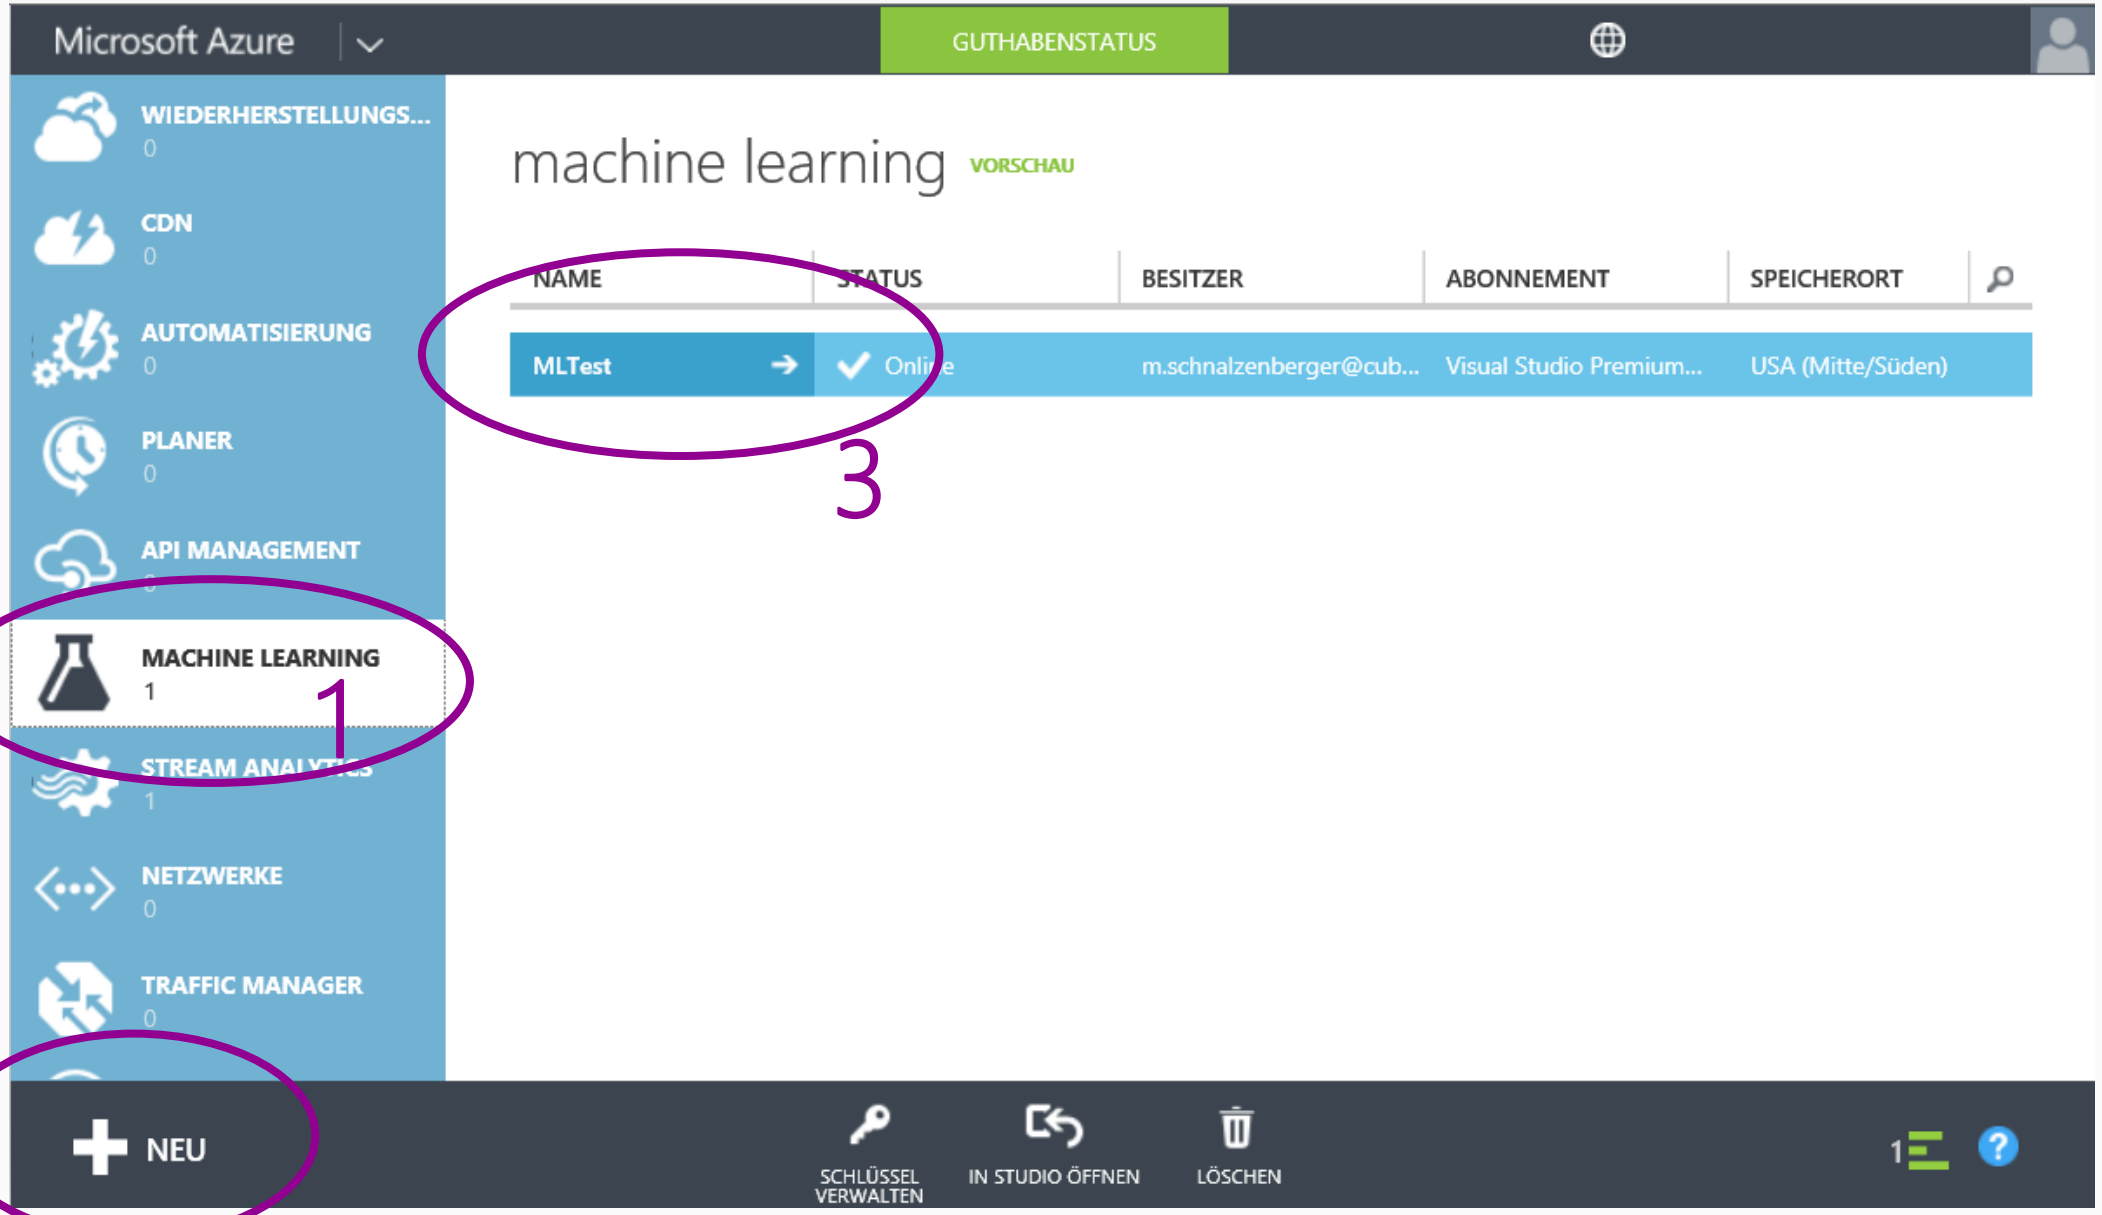

MachineLearning (ML) Studio

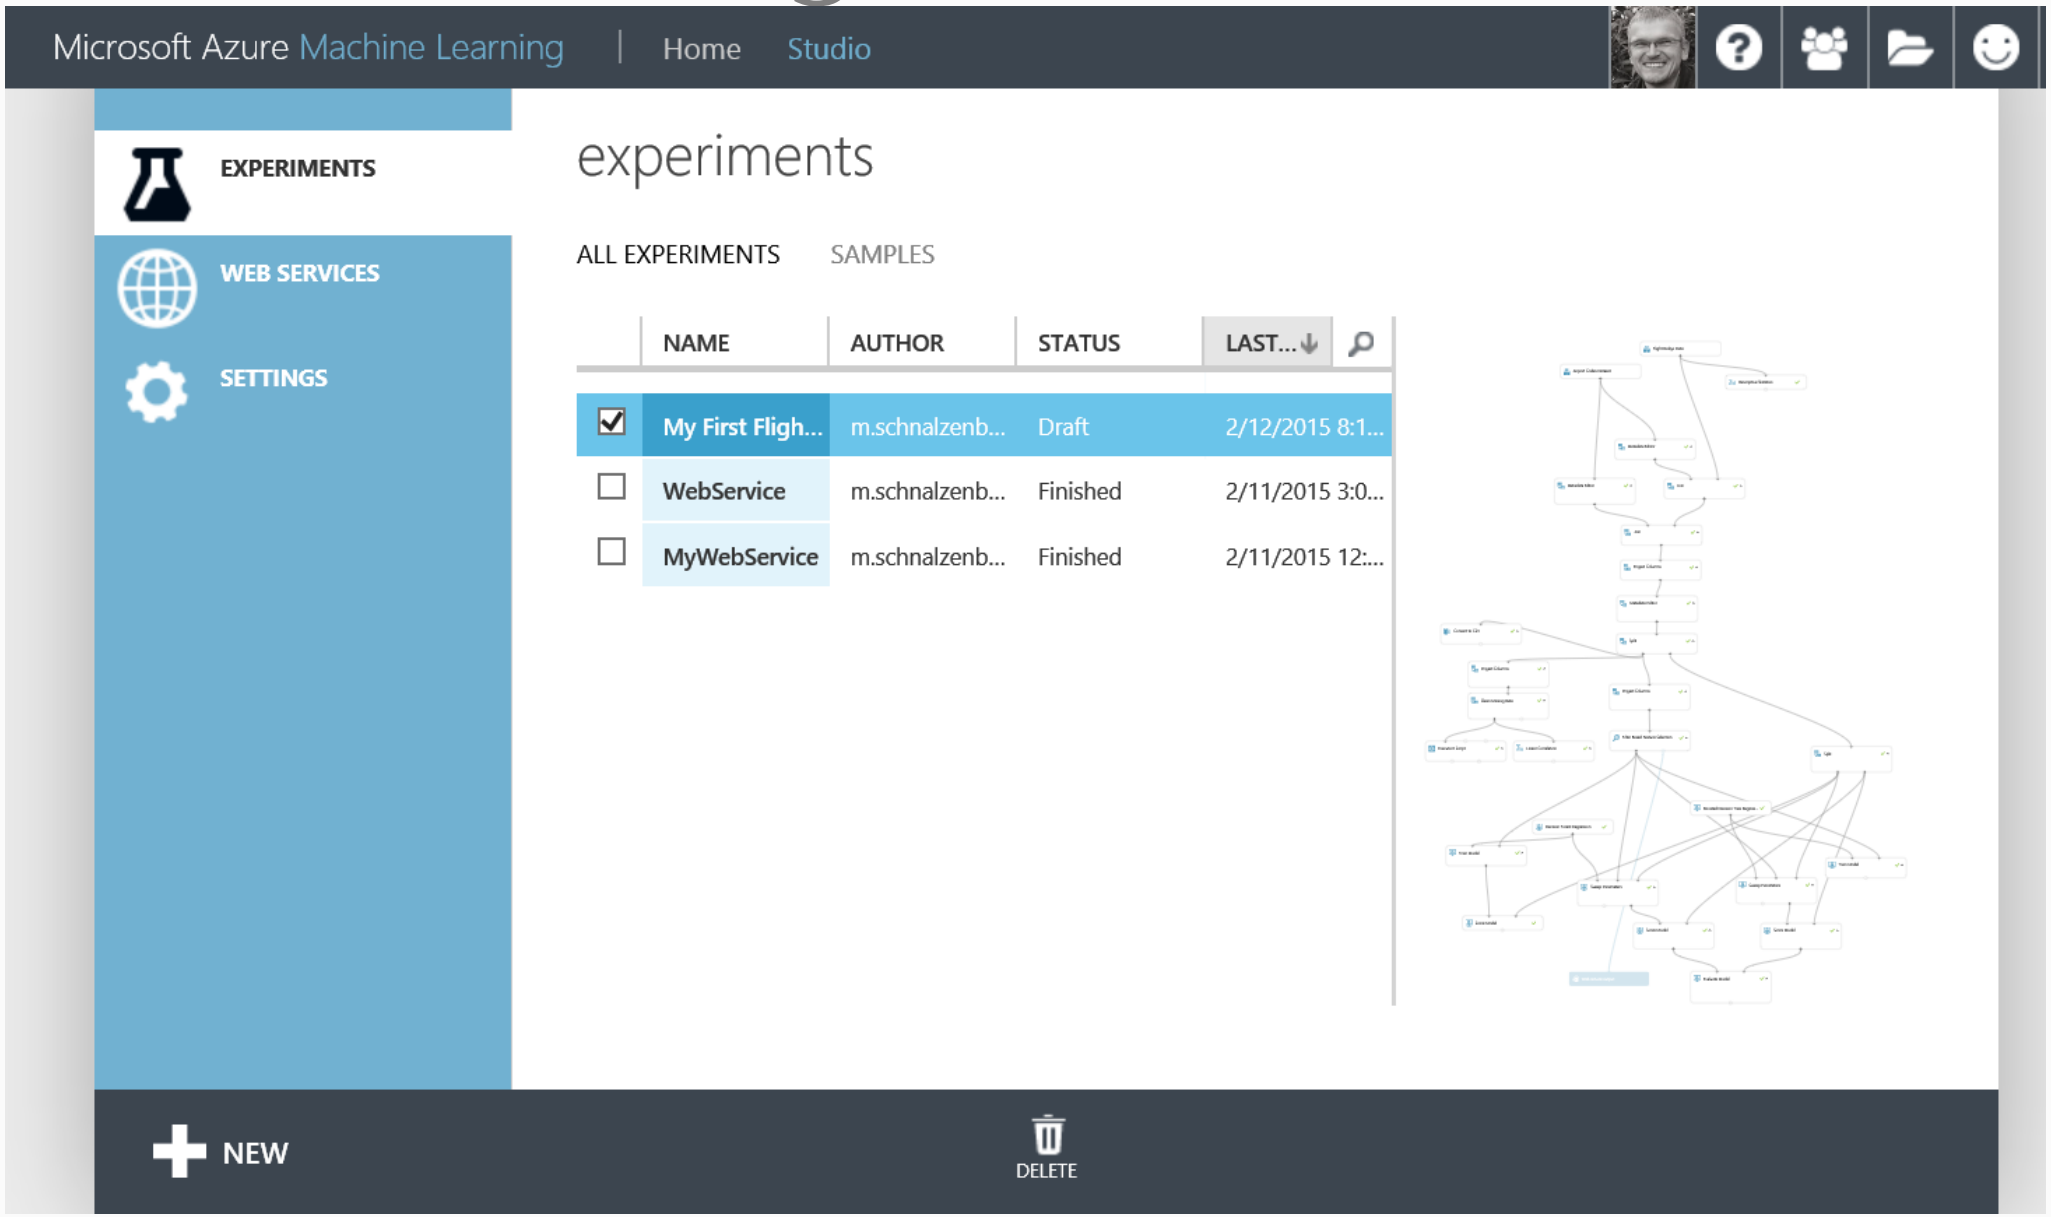

Experiments

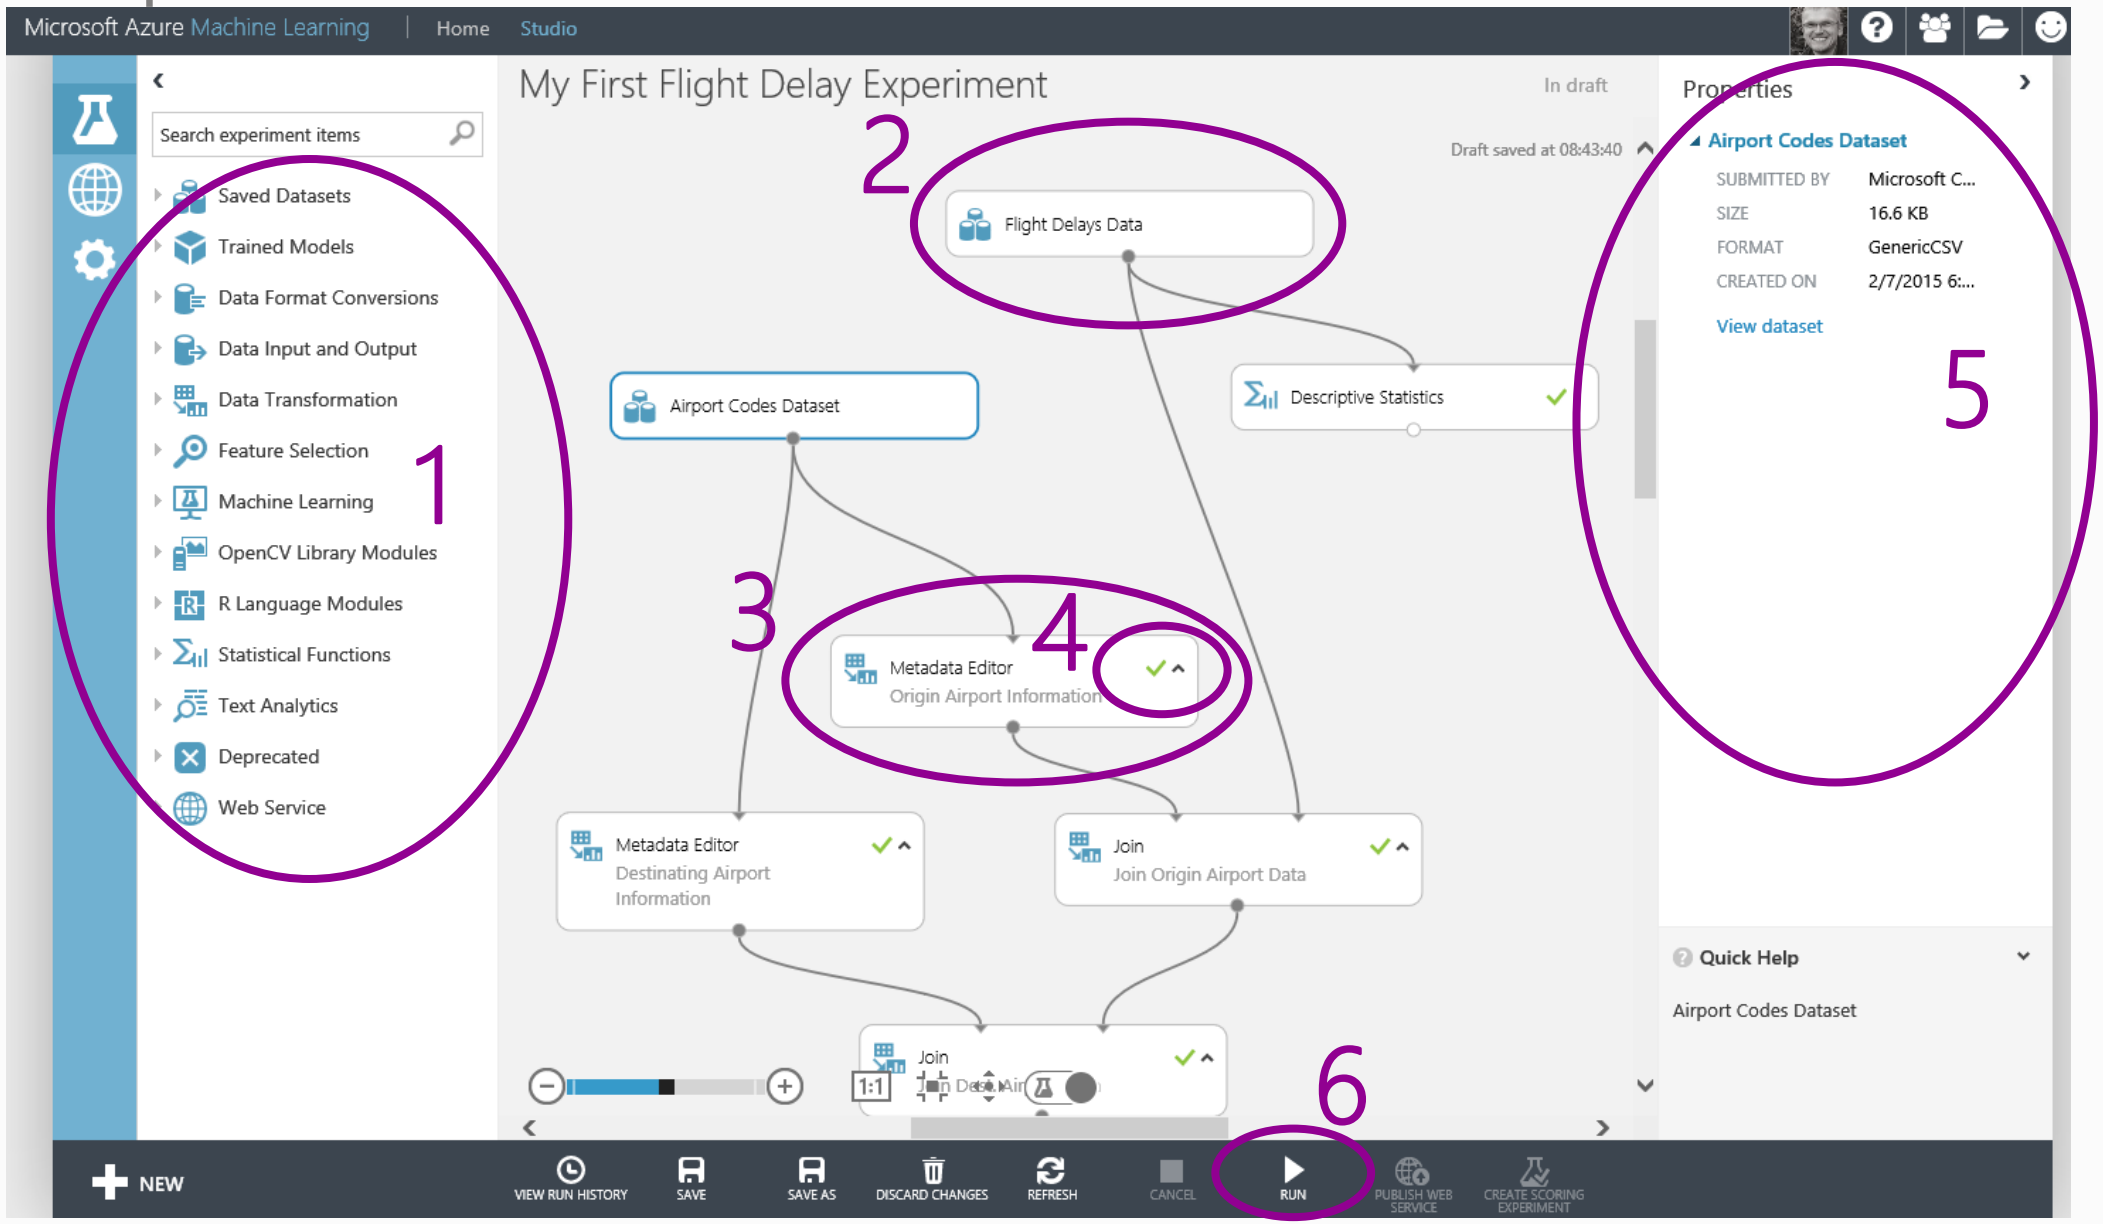

UBIDO
AN ACP GROUP COMPANY

Experiments

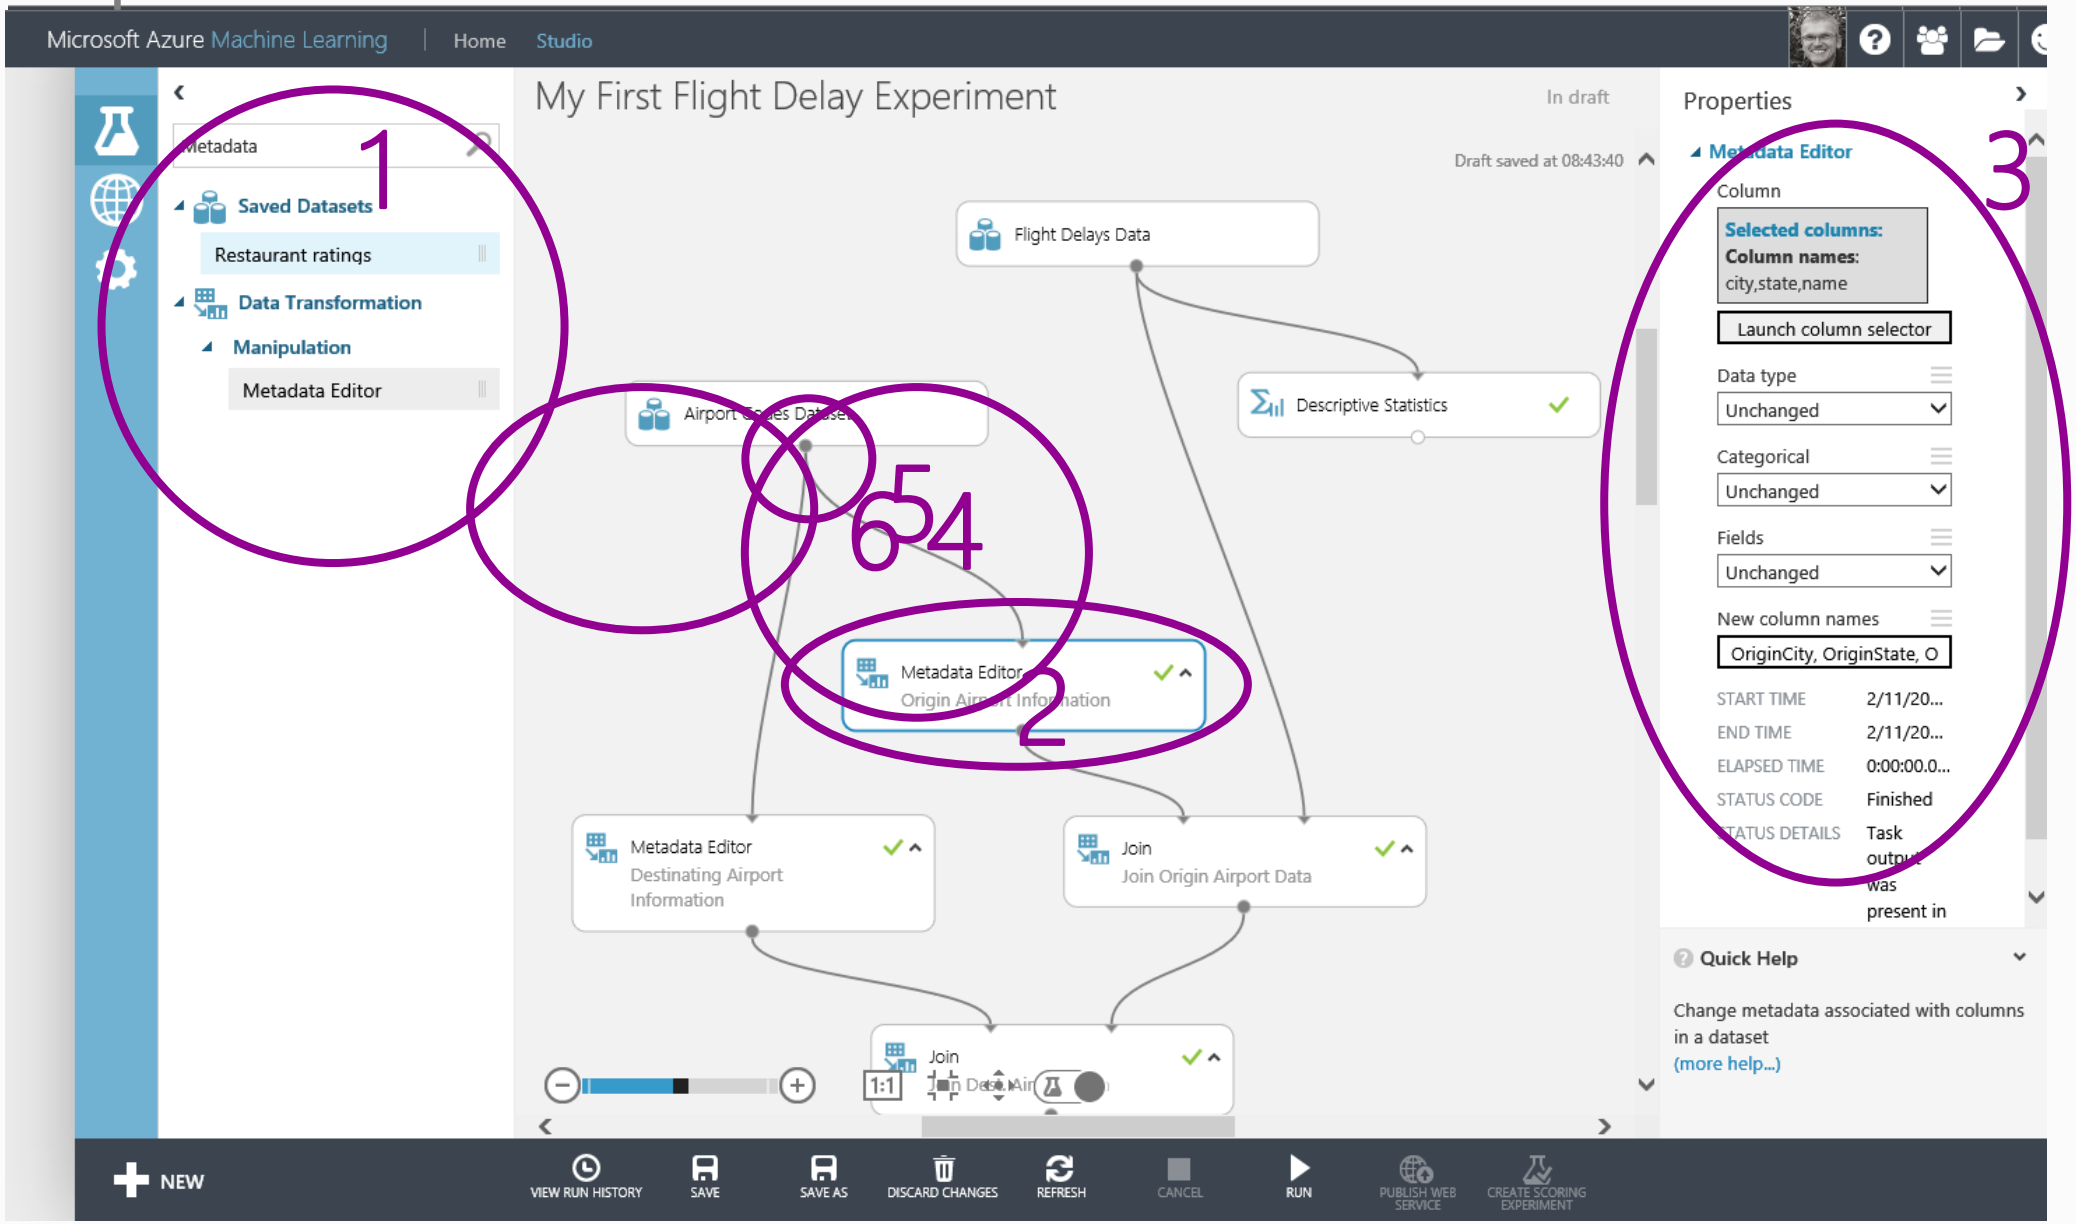

UBIDO
AN ACP GROUP COMPANY

Visualize the Sources and Outputs

My First Flight Delay Experiment › Score Model › Scored dataset

rows 1550068 columns 18

nth	DayofMonth	DayOfWeek	Carrier	CRSDepTime	DepDelay	DepDel15	CRSArrTime	ArrDelay	ArrDel15	Cancelled	Scored Label Mean	Scored Label Standard Deviation
	26	7	DL	1340	-4	0	1457	-8	0	0	-4.32455	19.675623
	18	5	US	1800	-8	0	1915	-8	0	0	-2.916969	18.722552
	25	7	OO	627	22	1	723	17	1	0	-1.520425	17.27603
	23	7	MQ	715	-9	0	950	-16	0	0	8.044899	49.963153
	15	2	WN	1700	10	0	1800	11	0	0	-1.439296	20.535412
	3	5	WN	840	-5	0	935	-8	0	0	0.142071	22.785005
	25	2	VX	1840	363	1	2150	356	1	0	90.110313	106.616985
	11	4	WN	1500	8	0	1510	17	1	0	8.548382	30.016789
	19	3	UA	935	0	0	1131	16	1	0	0.855321	26.883996
	13	2	DL	2125	1	0	544	-1	0	0	-2.41632	23.844859
	24	4	WN	1540	18	1	1705	12	0	0	11.497718	29.919001
	17	1	WN	1510	-1	0	1900	-17	0	0	19.854124	43.148306
	19	5	WN	1710	-4	0	1830	-10	0	0	10.893888	34.347628
	24	3	DL	1030	7	0	1405	-1	0	0	1.16815	28.306764
	20	2	AA	600	-3	0	740	-19	0	0	-3.679286	19.488942
	8	6	AA	930	-2	0	1155	-10	0	0	-1.851285	22.558995
	11	2	UA	1259	117	1	2130	97	1	0	15.173034	42.938912
	26	4	EV	600	-6	0	716	2	0	0	-3.64327	26.246258

Statistics

Mean	6.4836
Median	3.6408
Min	-27.3379
Max	193.2833
Standard Deviation	12.252
Unique Values	1462406
Missing Values	0
Feature Type	Numeric Score

Visualizations

Scored Label Mean

Histogram

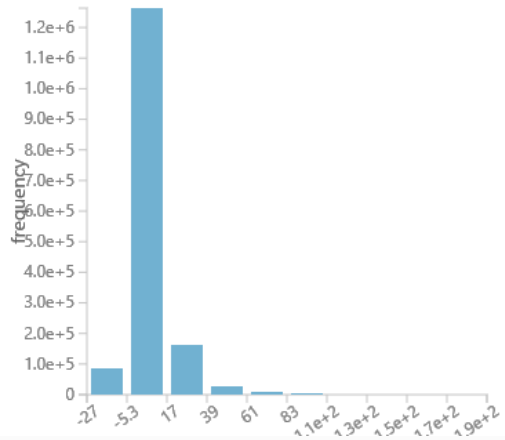

Visualize Results – Ergebnisse anzeigen

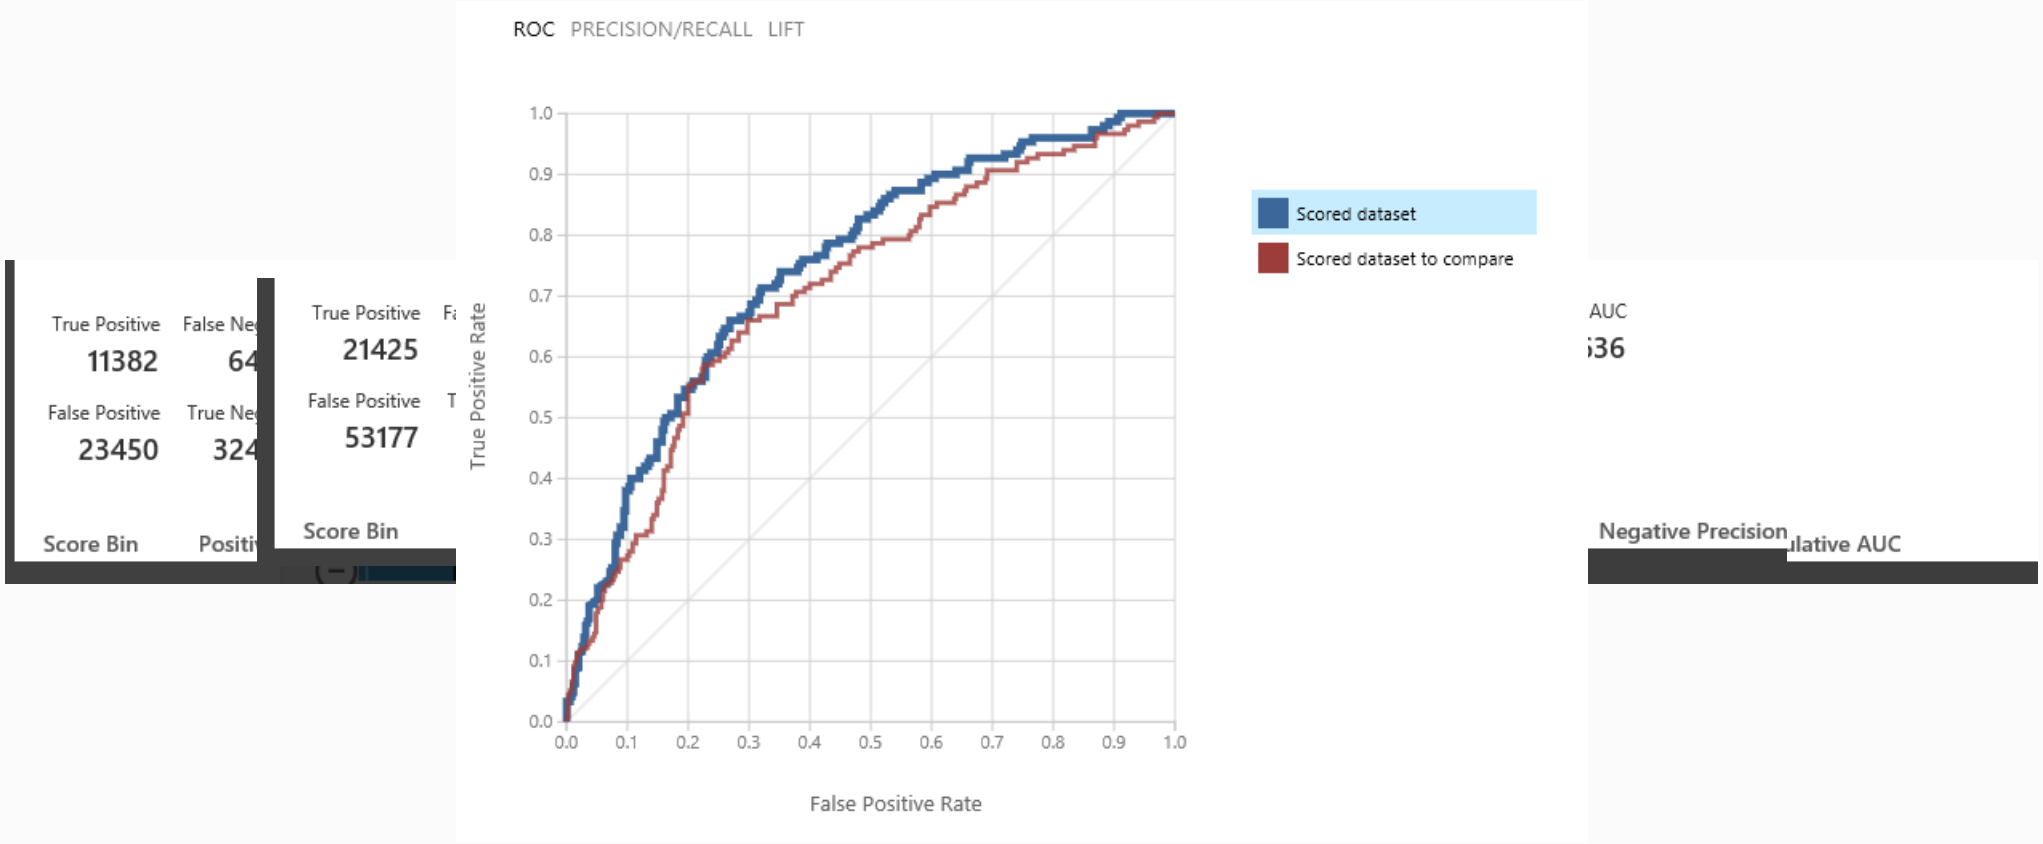

Training-Ergebnisse speichern

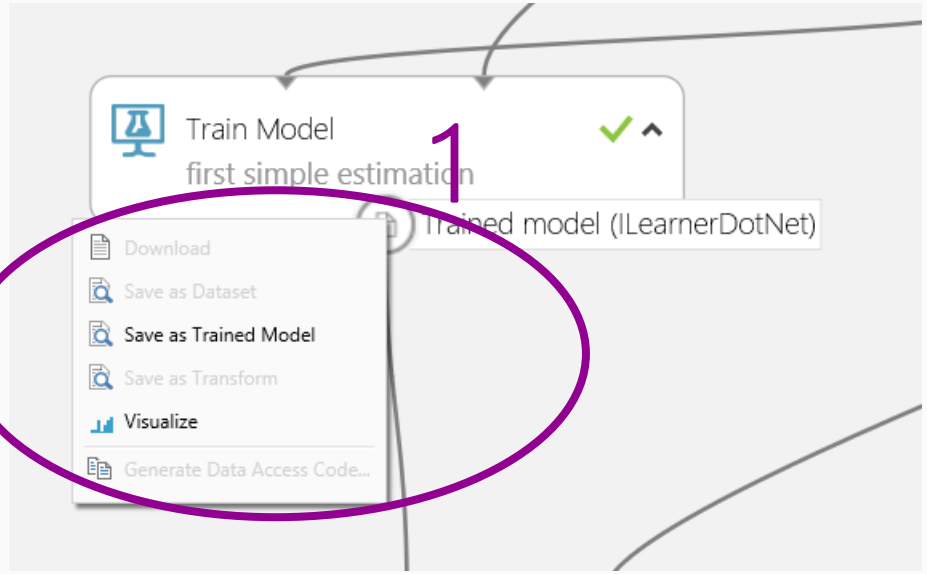

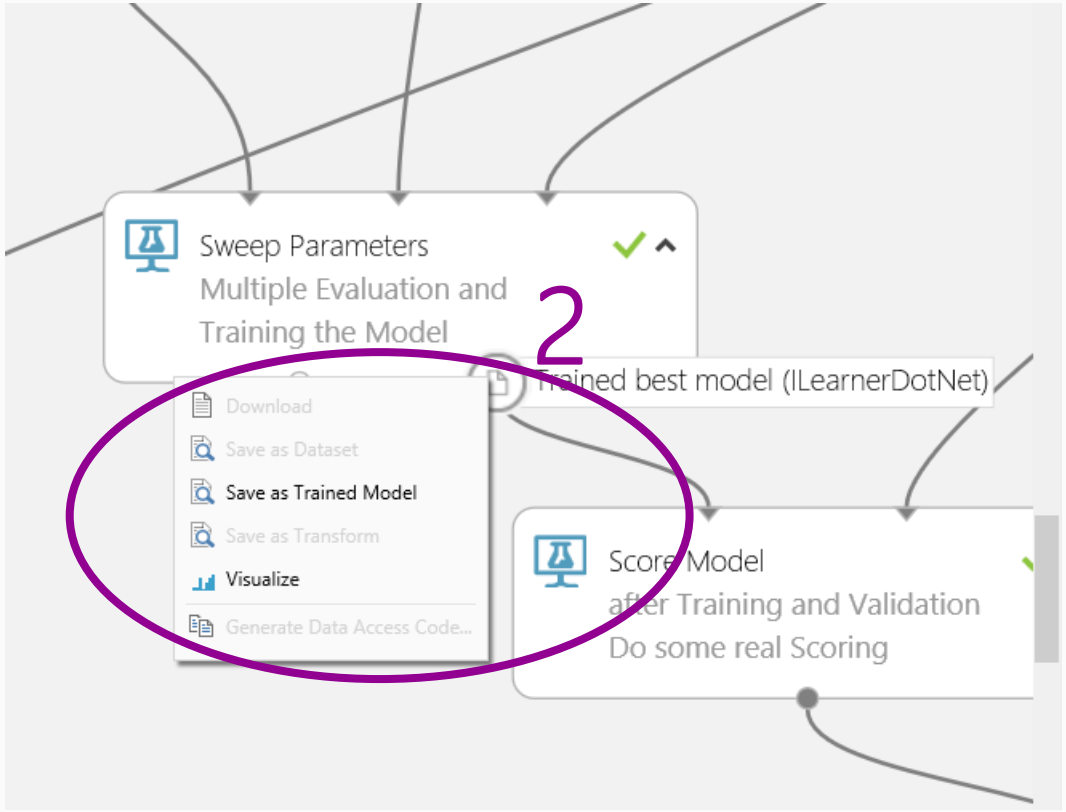

„Deploy a WebService“

Ein neues Experiment:

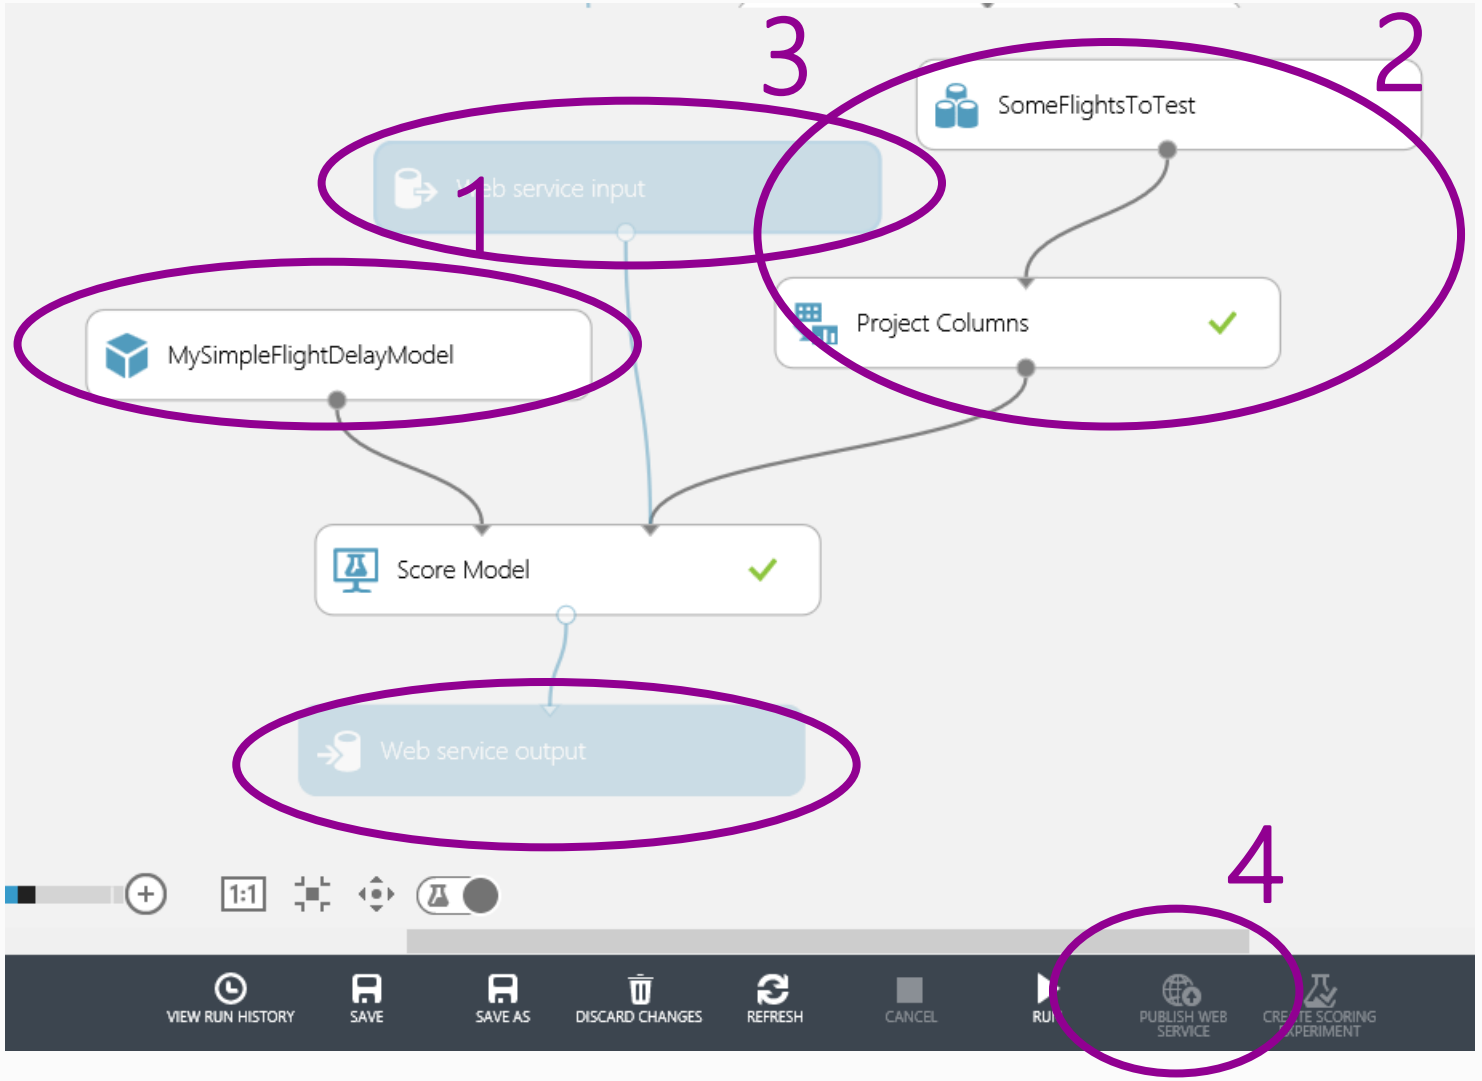

MachineLearning (ML) Studio

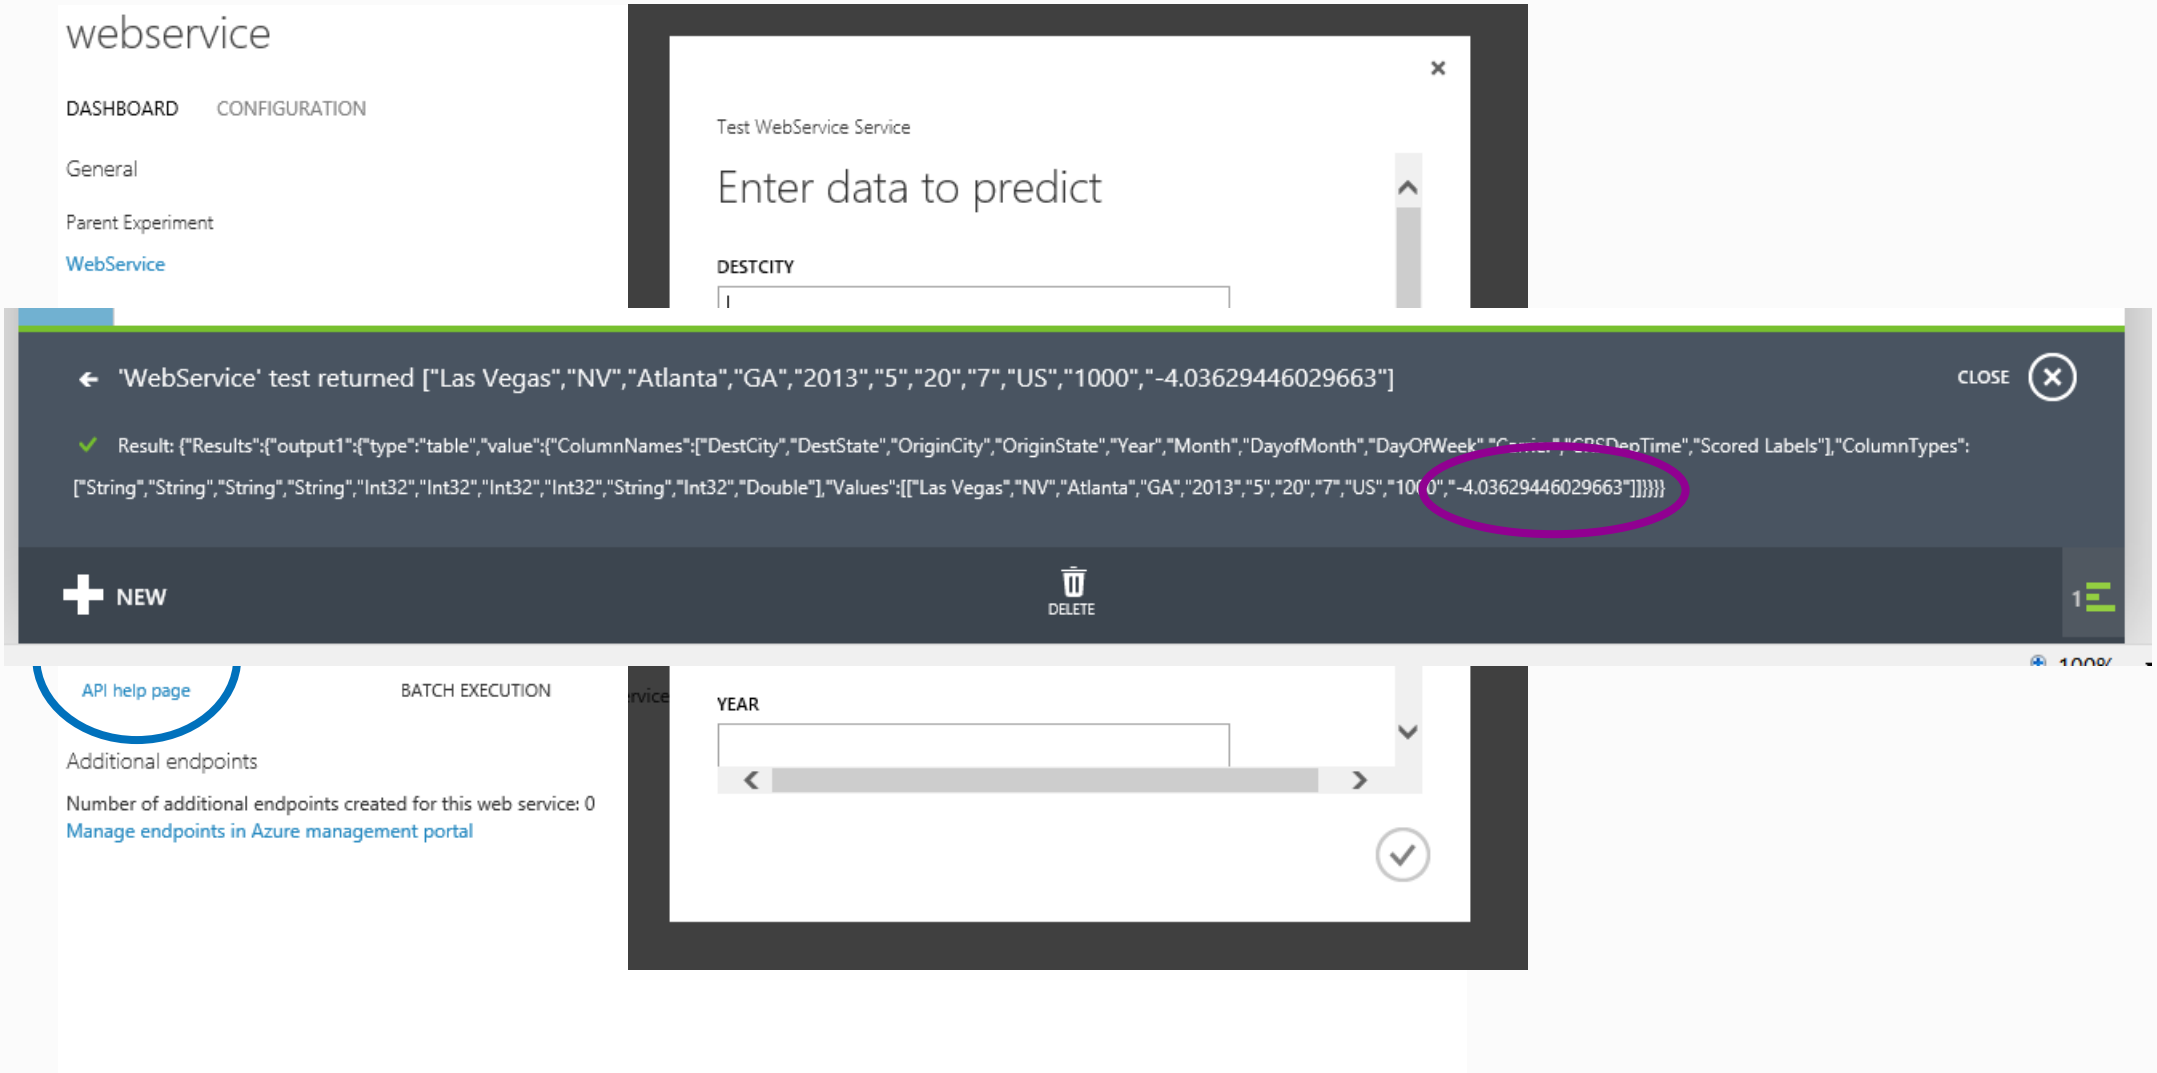

Jetzt noch einfacher

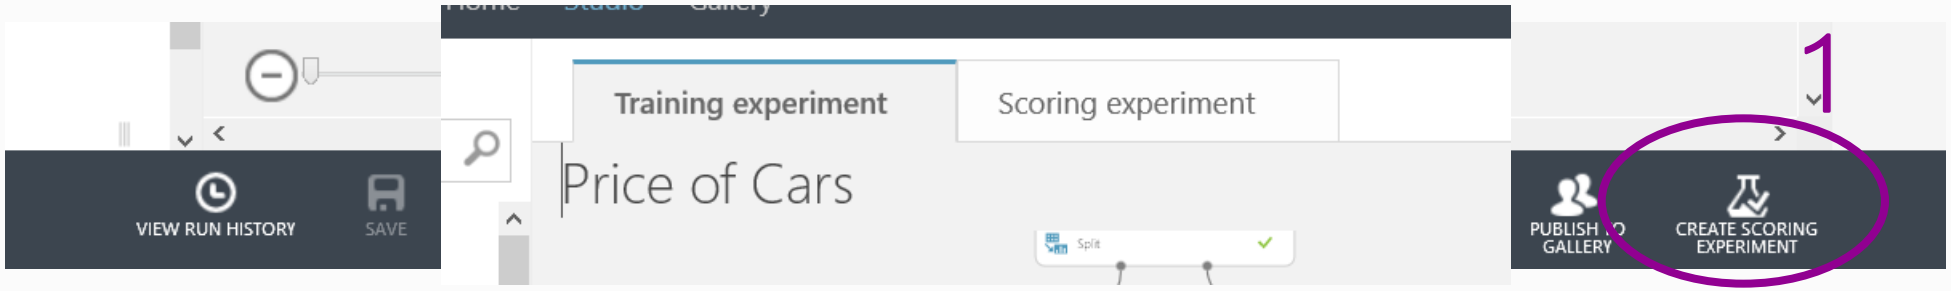

Was ist R?

- Freie Programmiersprache für statistisches Rechnen
- Viele Möglichkeiten auch grafisch auszuwerten
- Interpreter
- Für komplexe Modelle die so noch nicht in Azure enthalten sind

Beispiel und eine (kleine) Demo

Autopreise

R

Und?

Experimenteditor – Best Practice

Design einer Analyse

1. (Roh-)Daten zusammen aufbereiten (viel Arbeit!)
2. Daten ins Azure hochladen (direkt im Editor)
3. Analyse Designen (Statistik)
4. Verschiedene Methoden vergleichen
5. Bestes Modell für weitere Verwendung “speichern”

Offene Punkte

Was würde ich mir wünschen …

1. Ergebnisse im Detail anzeigen
2. Analyse von Modelle im Detail ermöglichen (Statistik Tools)
3. Vergleich Modelle von ML mit R ?
4. Modelle analysieren alle Covariate im Dataset (complex)
5. Predictions von Modellen mit mehr als “nur” Score und SD …
6. Mehr Pakete für R

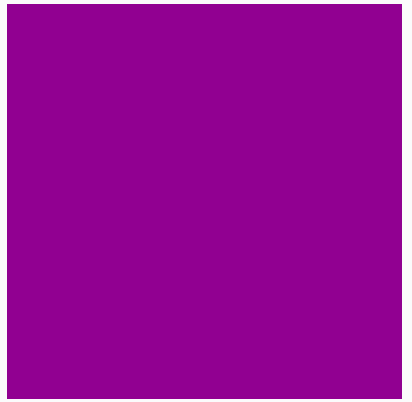

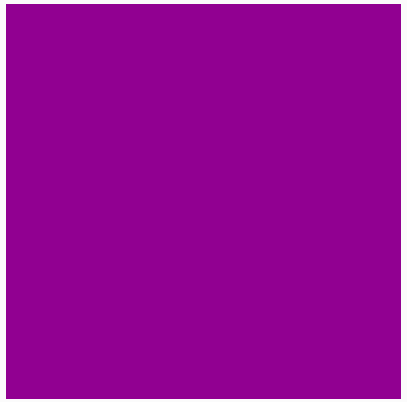

Bitte fundierte statistische Kenntnisse

- Plausiblität
- mathematische Verteilungsaspekte
- mögliche richtige Modelle
- Modelle gegeneinander rechnen lassen
- Modellauswahl treffen

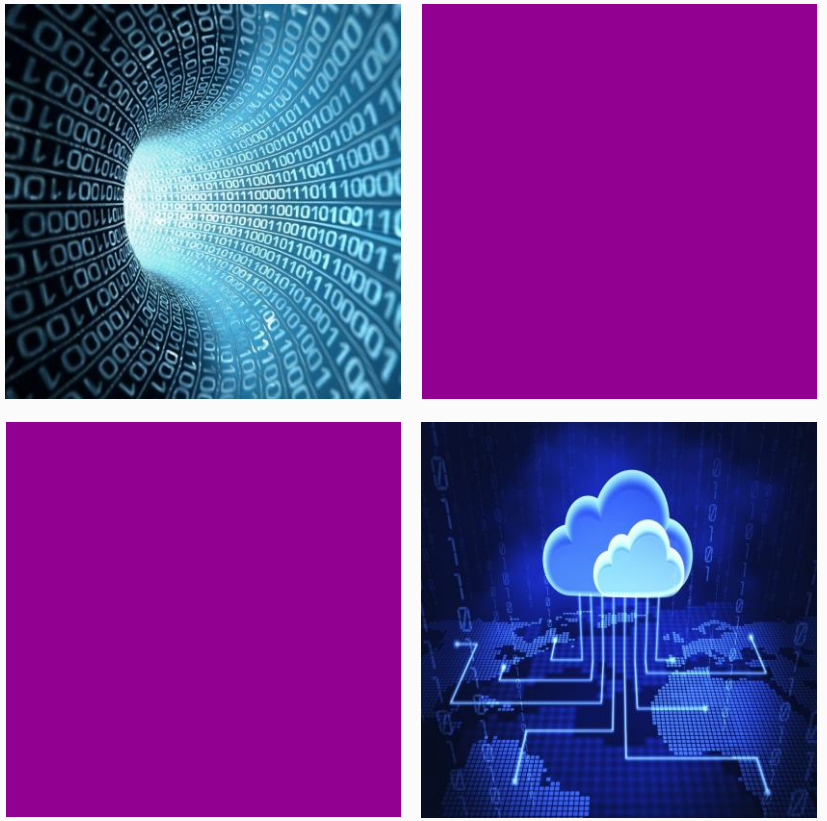

Warum? – Use Cases

CUBIDO

AN ACP GROUP COMPANY

Data Driven Business

Use Cases

Problem und Glaubhaftigkeit

Alle Daten können analysiert werden, daher können wir alles machen?

- Marketing verbessern (bis in einzelne Details)
- Produktion überwachen (Maintenance)
- Qualität überwachen, Fehler verhindern
- Adaptive Lagerhaltung/Logistik (Wetterdaten für Eisladen)
- Recommender
- Churn Analysis (Kundenabgang verhindern)

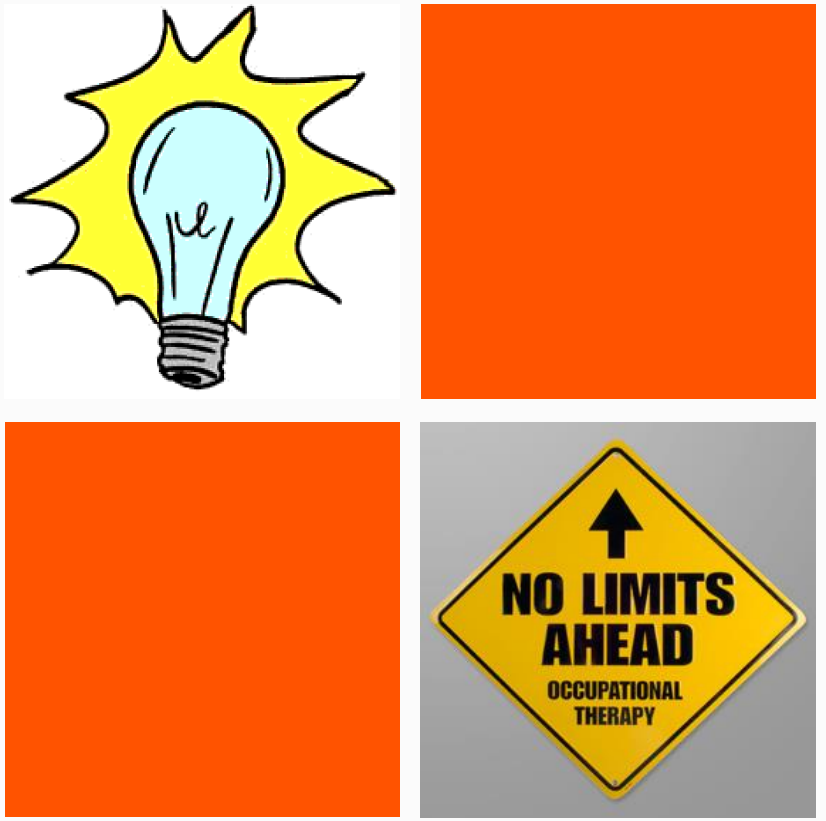

Ausblick – Mit Cubido

CUBIDO

AN ACP GROUP COMPANY

Business Intelligence

Mobile Solutions

Individuelle Softwareentwicklung

Microsoft

Microsoft SQL Server

SharePoint

Windows Azure

evidanza

SAP Business Objects

Fragen?