




Data Science Lifecycle

Prof. Dr.-Ing. Marina Tropmann-Frick

Motivation – What is Data Science?



Drew Conway
Data Science Venn Diagram

- Statistics
- Exploratory Data Analysis and Visualization
- High-Performance Computing technologies for dealing with Big Data
- Machine Learning
- Predictive Analytics
- Mixed Reality
- ...
- Domain Knowledge

Motivation – Appreciating Data

- Daten für Informatiker – oft nur Material (*just stuff to run through a program*)
 - Der übliche Weg, die Performanz der Algorithmen zu testen: “random data”
 - Schaffen von sauberen und organisierten Umgebungen – der Fokus liegt auf Technologien, nicht auf Daten
- Unsere natürliche Umgebung ist oft kompliziert und unordentlich
- Fast nichts ist vollständig wahr oder falsch (1 oder 0)
- Naturwissenschaftler fühlen sich wohl bei dem Gedanken, dass Daten fehlerhaft sind; Informatiker nicht
 - Interessante Datensätze sind eine knappe Ressource; verbunden mit harter Arbeit und Vorstellungskraft


It is all about data:

- Wissen extrahieren
- Richtige Fragen stellen
- Antworten / Erklärungen finden
- Daten in Erkenntnisse verwandeln

Engineering/Computation

Effizientes:


- Datenmanagement
- Datenverarbeitung




Data Science Lifecycle

80% der Zeit

- finden
- bereinigen
- transformieren
- mergen / integrieren
- ...



Data Science Lifecycle




7 stages of a data science lifecycle

Data Science Lifecycle

Domain Analysis

1. Mit Stakeholdern sprechen
2. Ziele des Projekts / der Analyse klären
 - Umsatzprognose?
 - Anomalie-Erkennung?
 - ...
3. Das Problem verstehen
 - Expertenmeinungen erfragen
 - richtige Fragen stellen
4. Use Cases definieren
5. Entscheidungen dokumentieren



Data Science Lifecycle

Data Acquisition

1. Datenquellen ermitteln

- databases
- sensors
- social media
- internet
- loggings



2. Datenmanagement



3. Achten auf:

- ausreichend Daten für die Modellierung?
- Datenqualität?
- Aktualität der Daten?

Run Analytics

- Spark
- MapReduce
- Impala
- Python




Architektur? Rechenpower? Speicheranforderungen?

Data Science Lifecycle

Data Preparation

1. Datenbereinigung (80 % der Zeit)
 - Fehlende Werte
 - Ausreißer
 - Unterschiedliche Formate
 - Errors
 - Groß-/Kleinschreibung
 - Abkürzungen
 - Rechtschreibfehler
 - Entfernen irrelevanter Daten
 - Formatierung von Artefakten
2. Datenfusion
 - Daten verknüpfen
 - Annotieren
3. Daten-Indizierung




Data Science Lifecycle

Explorative Analysis

1. Tiefes Verständnis von Daten entwickeln
2. Visualisierung von Datenbeziehungen und Trends
3. Statistiken zusammenfassen und visualisieren
4. Erkennen von Mustern
5. Erkennen von Anomalien und Ausreißern
6. Unzureichende Datenbereinigung erkennen
7. Wichtige Merkmale hervorheben



Welches Diagramm?



Wertschätzung der Kunst / Darstellung – was sieht besser aus?

→ Entwicklung einer besonderen visuellen Ästhetik



images: Wikipedia


Data Science Lifecycle

Visual Analytics

1854




2011



Data Science Lifecycle

Feature Engineering

1. Normalisierung
2. Korrektur fehlender Werte
3. Auswahl von Merkmalen (features)
 - relevante Merkmale und Zielvariablen bestimmen
 - Dimensionsanpassung (Reduktion)
 - irrelevante Merkmale entfernen
 - Regularisierung
4. Merkmalsanpassung
 - Domänenspezifische Features hinzugügen
 - Feature-Transformation
 - Summe, Differenz, Produkt, ...




$$(z_1, z_2, z_3) = (x_1^2, x_2^2, \sqrt{2}x_1x_2)$$

<http://yosinski.com/mlss12/MLSS-2012-Fukumizu-Kernel-Methods-for-Statistical-Learning/>

Data Science Lifecycle

Data Modelling

1. Herangehensweise?
 1. Supervised
 2. Unsupervised
 3. Semi-supervised
 4. Self-supervised
2. Evaluation unterschiedlicher Modelle
 - geeignete Trainings- und Testsätze auswählen
3. Das “beste” Model für die Daten finden
4. Unterschiedliche Metriken vergleichen (accuracy, ...)



- Computational analysis readily finds patterns and correlations in large data sets
But when is a pattern significant?


“All models are wrong,
- George Box, 1976
...but some are useful”


- Modellierung ist der Prozess der *Kodierung / Einkapselung* von Informationen zu einem Model, das für unterschiedliche Zwecke als Instrument benutzt werden kann
 - Data Science: *building, fitting, and validating the model*
 - The “*Occam’s Razor*” philosophical principle: “the simplest explanation is the best”
 - In Bezug auf die Modellierung (in Data Science) bedeutet dies oft eine Minimierung der Parameterzahl in einem Modell
- First principle models: basieren auf der Grundlage einer theoretischen Erklärung der Funktionsweise des Systems
- Data-driven models: basieren auf beobachteten Datenkorrelationen zwischen Eingabeparametern und Ergebnisvariablen
- Gute Modelle sind in der Regel eine Mischung aus beidem

Data Science Lifecycle

Deployment

1. Echtzeit- oder Batch-Analyse
 2. Technologieauswahl
 - Python, R, ...
 - Scala, TensorFlow, ...
 - GPU - Beschleunigung?
 3. BigData?
Z.B. high data frequency (sensors)
 4. Service-Bereitstellung
 - Reporting, Visualisierung
 - Interaktive Exploration
 5. Monitoring und Anpassung





**Human
in the Loop**

Explainability

- ✓ Nachvollziebarkeit
- ✓ Verständlichkeit
- ✓ Akzeptanz
- ✓ Legitimierung
- ✓ Vertrauen
- ✓ Sicherheit
- ✓ Ethik



Komplexität der Problemstellungen → undurchsichtige Modelle (Black-Box)

1. Confidence

Zuversicht in ein System wird geschaffen, indem es explizit zeigt, dass seine Entscheidung durch Erkennung von Mustern entsteht, die für den Nutzer nachvollziehbar sind und logisch erscheinen

2. Trust

3. Safety

4. Ethics

Xie, N., Ras, G., van Gerven, M., Doran, D.:
Explainable deep learning: A field guide for the uninitiated (2020)

Komplexität der Problemstellungen → undurchsichtige Modelle (Black-Box)

1. Confidence

2. Trust

3. Safety

4. Ethics

Ein System wird als vertrauenswürdig eingestuft, wenn die Ausgaben vor ihrer tatsächlichen Anwendung nicht validiert werden müssen

Xie, N., Ras, G., van Gerven, M., Doran, D.:
Explainable deep learning: A field guide for the uninitiated (2020)

Komplexität der Problemstellungen → undurchsichtige Modelle (Black-Box)

1. Confidence

2. Trust

3. Safety

4. Ethics

- i. konsistent
- ii. keine negativen Auswirkungen
- iii. hohe Verlässlichkeit auch unter außerordentlichen Bedingungen
- iv. Rückmeldung bei neuen Einflussfaktoren

Xie, N., Ras, G., van Gerven, M., Doran, D.:
Explainable deep learning: A field guide for the uninitiated (2020)

Komplexität der Problemstellungen → undurchsichtige Modelle (Black-Box)

1. Confidence

2. Trust

3. Safety

4. Ethics

kulturelle / individuelle / rechtliche / moralische
Unterschiede

Xie, N., Ras, G., van Gerven, M., Doran, D.:
Explainable deep learning: A field
guide for the uninitiated (2020)

Ansätze


- 1. Visual Analytics**
- 2. Model Distillation**
- 3. Intrinsische Methoden**

Explainability

Visual Analytics

- Interaktive Beteiligung des Nutzers / Experten in der Analysephase
- Untersuchung der Gradientensignale
- Variation des Inputs

1. Aktivierungsmaximierung



<http://calhounpress.net>





<https://deepdreamgenerator.com/>

Erhan, D., Bengio, Y., Courville, A., Vincent, P.: Visualizing higher-layer features of a deep network. Technical Report, Université de Montréal (2009)

Explainability

Visual Analytics

2. Class Activation Maps



Zhou, B., Khosla, A., Lapedriza, A., Oliva, A., Torralba, A.:
Learning deep features for discriminative localization
(2015)

Explainability


Visual Analytics

3. Deconvolution



Zeiler, M.D., Fergus, R.: Visualizing and understanding convolutional networks (2013)

33. Zeiler, M.D., Taylor, G.W., Fergus, R.: Adaptive deconvolutional networks for mid and high level feature learning (2011)



Privacy & Ethics

- Es ist wichtig, den potenziellen Schaden zu verstehen, den datengesteuerte Modelle verursachen können.
- *Correlation is not causation*, aber so trainierte Modelle können Aktionen und Feedback-Mechanismen auslösen, was zu sich selbst erfüllenden Prophezeiungen führt
- Jeder Data Scientist muss sich die Zeit nehmen, konstruktiv über gesellschaftliche Fragen / Folgen nachzudenken
- Totale Online-Privacy ist grundsätzlich unmöglich - aber wahrscheinlich auch nicht das, was angestrebt wird

Privacy vs. Security vs. Anonymity

- **Privacy – freedom from intrusion, observation or attention**
 - no one can see you
- **Security/Safety – freedom from danger or harm**
 - you are safe
- **Anonymity – freedom from identification or recognition**
 - nobody knows who you are

Tradeoff → Kompromiss zwischen dem Nutzen des Teilens und dem Risiko der Offenlegung

- Menschenwürde
 - nicht auf eine Zahl zu reduzieren, nicht zu kaufen und zu verkaufen
- Vertrauen
 - wichtige Währung in der Informationswirtschaft

GI-Fachgruppe „Informatik und Ethik“ – <https://gewissensbits.gi.de>

Buch „Gewissensbisse – Ethische Probleme der Informatik. Biometrie – Datenschutz – geistiges Eigentum“. 2009.

Vielen Dank!