



EVROPSKÁ UNIE
Evropské strukturální a investiční fondy
Operační program Výzkum, vývoj a vzdělávání

MS
MT
MINISTERSTVO ŠKOLSTVÍ,
MLÁDEŽE A TĚLOVÝCHOVY



Název projektu	Rozvoj vzdělávání na Slezské univerzitě v Opavě
Registrační číslo projektu	CZ.02.2.69/0.0./0.0/16_015/0002400

Dolování dat

Úvodní informace a požadavky na absolvování

Jan Górecki



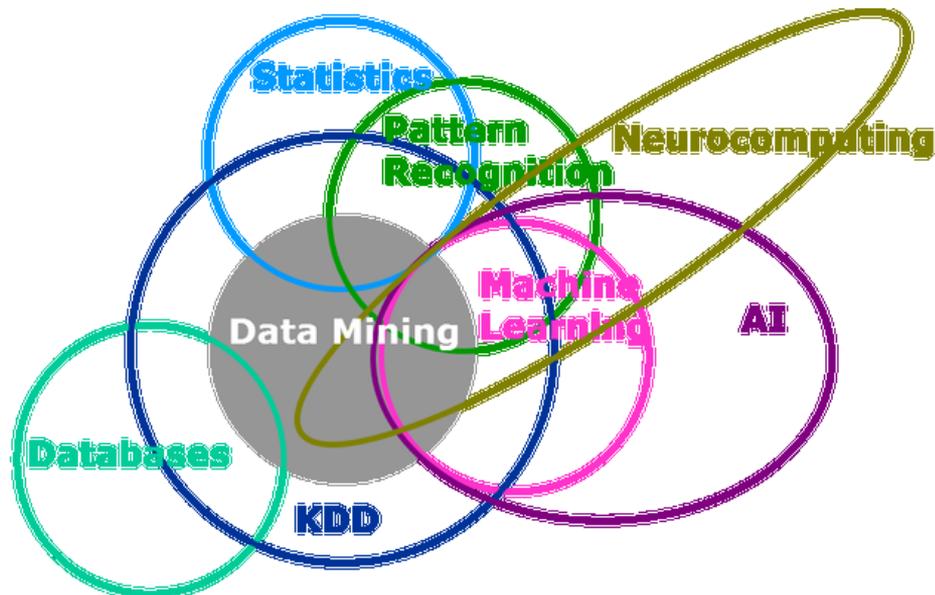
**SLEZSKÁ
UNIVERZITA**
OBCHODNĚ PODNIKATELSKÁ
FAKULTA V KARVINĚ

Dolování dat (Data mining)



SLEZSKÁ
UNIVERZITA
OBCHODNĚ PODNIKATELSKÁ
FAKULTA V KARVÍNĚ

Non-trivial process of identifying valid, novel, potentially useful and ultimately understandable patterns from data (Fayyad a kol., 1996)



The Rise of Deep Learning

'Deep Voice' Software Can Clone Anyone's Voice With Just 3.7 Seconds of Audio

Using snippets of voices, Baidu's 'Deep Voice' can generate new speech, accents, and tones.



with DEEPMIND STARCRIFT TRIUMPH FOR

Let There Be Sight: How Deep Learning Is Helping the Blind 'See'



Technology outpacing security measures

Facial Recognition | Features and Interviews



AI beats docs in cancer spotting

A new study provides a fresh example of machine learning as an important diagnostic tool. Paul Binger reports.



AI Can Help In Predicting Cryptocurrency Value



'Creative' AlphaZero leads way for chess computers and, maybe, science

Former chess world champion Garry Kasparov likes what he has to say about a computer that could be used to find cures for diseases



How an A.I. 'Cat-and-Mouse Game' Generates Believable Fake Photos

By CADE METZ and KEITH HOLENIA - JAN. 2, 2018



AI: Faked Data



Human faces show how far AI image generation has come in just four years

People on the right aren't real: they're the product of machine learning



Stock Predictions Based On AI: Is the Market Truly Predictable?



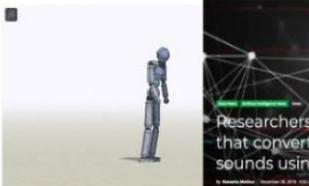
Neural networks everywhere

New chip reduces neural networks' power consumption by up to 95 percent, making them practical for battery-powered devices.

Deep Learning | Boston | Comment by Kerry Walker - Digital Reporter - @RandPhugase

After Millions of Trials, These Simulated Humans Learned to Do Perfect Backflips and Cartwheels

George Siu | MIT News | 1/18/18



Researchers introduce a deep learning method that converts mono audio recordings into 3D sounds using video scenes

By Rebecca Fiala | MIT News | 12/14/17



Automation And Algorithms: De-Risking Manufacturing With Artificial Intelligence

Sarah Goehke Contributor | Manufacturing | Focus on the industrialization of additive manufacturing

TWEET THIS The two key applications of AI in manufacturing are pricing and manufacturability feedback

Complex of bacteria-infecting viral proteins modeled in CASP-13. The complex consists of 12 proteins that were modeled individually. PROTEIN DATA BANK

Google's DeepMind aces protein folding

By Robert F. Service | Dec. 6, 2018, 12:05 PM





Dolování dat:

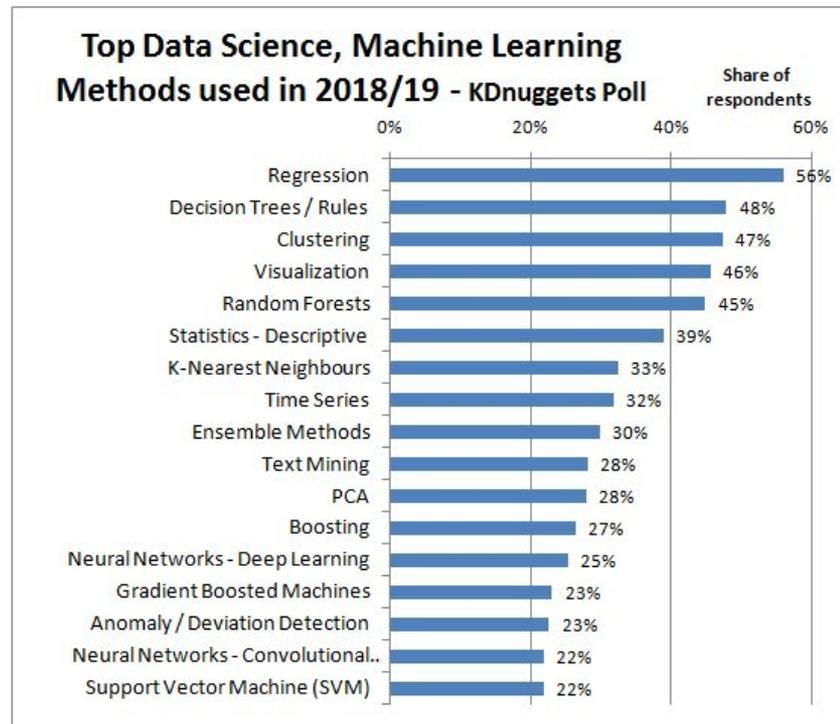
- **Prezenční forma: 13 přednášek a 12 seminářů,**
 - **Kombinovaná forma: 3 přednášky**
 - **zakončena zkouškou**
-

Stručná anotace předmětu



**SLEZSKÁ
UNIVERZITA**
OBCHODNĚ PODNIKATELSKÁ
FAKULTA V KARVINĚ

- **Proces dolování dat**
Dolování dat, úlohy dolování dat, metodiky pro dolování dat
- **Statistika v kontextu dolování dat**
Kontingenční tabulky, regresní analýza, diskriminační analýza, shluková analýza
- **Strojové učení**
Základní pojmy, principy strojového učení, typy strojového učení, formy strojového učení, trénovací data, atributy, chybová funkce
- **Metody dolování dat**
Rozhodovací stromy, Rozhodovací pravidla, Neuronové sítě, Genetické algoritmy, bayesovské metody, metody založené na analogii
- **Evaluace modelů**
kritéria, deskriptivní úlohy, klasifikační úlohy, vizualizace modelů, vizualizace klasifikací, porovnávání modelů, volba nejvhodnějšího algoritmu, kombinování modelů
- **Předzpracování dat**
Příprava dat, strukturovaná data, více vzájemně propojených tabulek, odvozené atributy, příliš mnoho objektů, příliš mnoho atributů, numerické atributy, kategoriální atributy, chybějící hodnoty



Požadavky na absolvování předmětu – prezenční forma

- **docházka na semináře min. 60% (10 % hodnocení),**
- **zpracování seminární práce (30% hodnocení),**
 - **Analýza vybraných dat dle metodiky CRISP-DM pomocí metod dolování dat (alespoň 5 metod celkově, z nichž alespoň 2 statistické a alespoň 3 ze strojového učení) – odevzdání přes odevzdávárnu v IS SU do 20.12.2023 23:55**
- **zkouška (60% hodnocení)**

Celkem maximum: 100

Požadované minimum: 60

Požadavky na absolvování předmětu – kombinovaná forma

- **docházka se nevyžaduje (ale je hodnocena až 10% hodnocení)**
- **zpracování seminární práce (30% hodnocení),**
 - **Analýza vybraných dat dle metodiky CRISP-DM pomocí metod dolování dat (alespoň 5 metod celkově, z nichž alespoň 2 statistické a alespoň 3 ze strojového učení) – odevzdání přes odevzdávárnu v IS SU do 20.12.2023 23:55**
- **zkouška (60% hodnocení)**

Celkem maximum: 100

Požadované minimum: 60



- **Veškeré elektronické materiály je možné nalézt na školní síti: L:\gorecki\public\NPDOD-NKDOD\
(přes <https://raimundo.opf.slu.cz/NetStorage/> popř. files.opf.slu.cz)**
-

Povinná:

- BERKA, P. a GÓRECKI, J., 2017. *Dolování dat*. Skripta SU OPF, Karviná.
- BERKA, P., 2003. *Dobývání znalostí z databází*. Praha: Academia. ISBN 80-200-1062-9.

Doporučená:

- CLARK, B., E. FOKOUE a H. H. ZHANG, 2009. *Principles and theory for data mining and machine learning*. New York: Springer. ISBN 978-0-387-98134-5.
 - MURPHY, K. P., 2012. *Machine learning: A probabilistic perspective*. London, England: The MIT Press. ISBN 978-0-262-01802-9.
-

Software



- **MATLAB**
 - Statistics and Machine Learning Toolbox
 - <https://www.mathworks.com/solutions/data-science.html>
 - trial verze z mathworks.com
 - Octave – free verze MATLABu
- Python
- R
- RapidMiner





- **Nejlépe vlastní**
 - **UC Irvine Machine Learning Repository**
<https://archive.ics.uci.edu>
 - **Kaggle: Your Home for Data Science**
<https://www.kaggle.com>
 - **KEEL - dataset repository**
<http://www.keel.es> a tam KEEL-dataset
-



EVROPSKÁ UNIE
Evropské strukturální a investiční fondy
Operační program Výzkum, vývoj a vzdělávání



MINISTERSTVO ŠKOLSTVÍ,
MLÁDEŽE A TĚLOVÝCHOVY

Název projektu	Rozvoj vzdělávání na Slezské univerzitě v Opavě
Registrační číslo projektu	CZ.02.2.69/0.0./0.0/16_015/0002400

Dolování dat

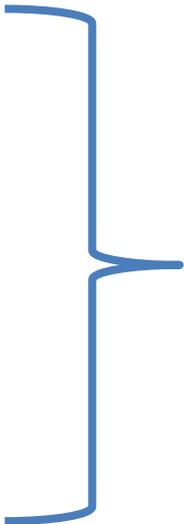
Dolování dat

Jan Górecki



**SLEZSKÁ
UNIVERZITA**
OBCHODNĚ PODNIKATELSKÁ
FAKULTA V KARVINĚ

- Definice ...
- Historie ...
- Úlohy ...
- Příklad ...
- Postupy (metodiky) ...
- Software pro ...



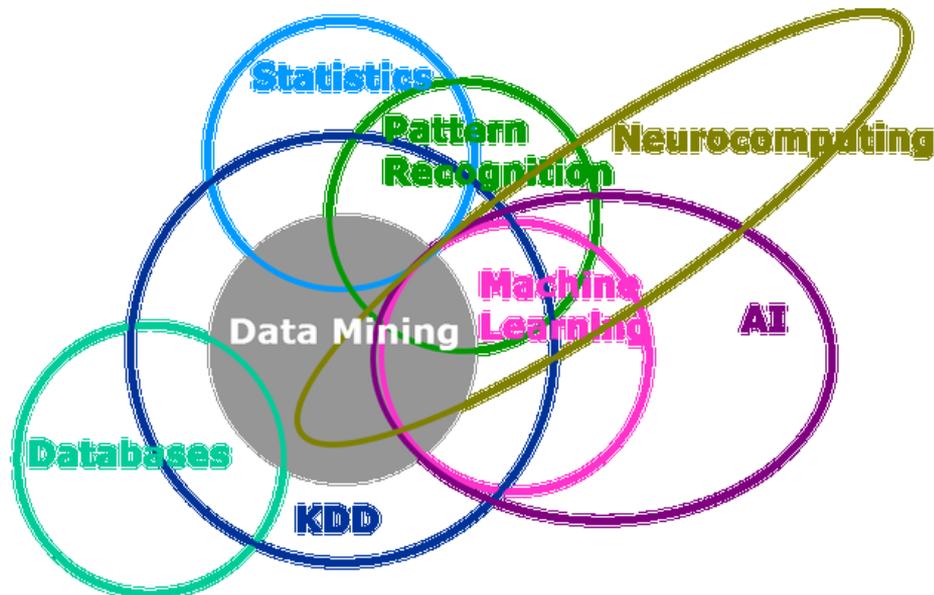
... Dolování dat

Dolování dat (Data mining)



SLEZSKÁ
UNIVERZITA
OBCHODNĚ PODNIKATELSKÁ
FAKULTA V KARVÍNĚ

Non-trivial process of identifying valid, novel, potentially useful and ultimately understandable patterns from data (Fayyad a kol., 1996)

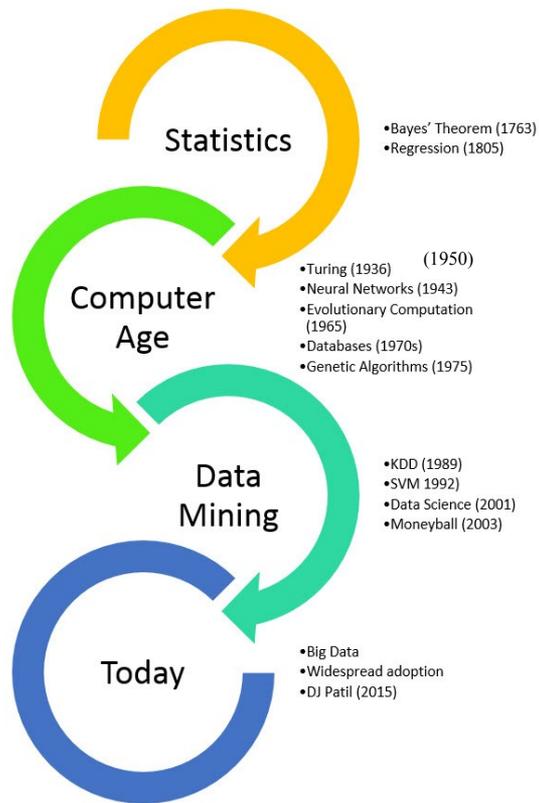


Trocha historie



**SLEZSKÁ
UNIVERZITA**
OBCHODNĚ PODNIKATELSKÁ
FAKULTA V KARVINĚ

Data Mining

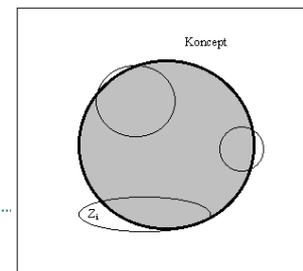
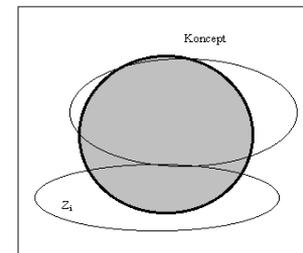
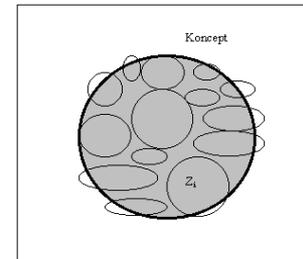


Úlohy dobývání znalostí



**SLEZSKÁ
UNIVERZITA**
OBCHODNĚ PODNIKATELSKÁ
FAKULTA V KARVÍNĚ

- **Klasifikace/Predikce**
 - **Cíl:** Nalézt znalosti použitelné pro klasifikaci nových případů.
 - **Příklad:** Predikce akciových cen, klasifikace e-mailů jako spam nebo ne-spam.
- **Deskripce**
 - **Cíl:** Nalézt dominantní strukturu nebo vazby skryté v datech. Dáváme přednost menšímu počtu méně přesných avšak srozumitelných pravidel.
 - **Příklad:** Analýza sociálních médií odhalila, že pozitivní recenze na film často korelují s vyššími prodeji vstupenek v prvním týdnu promítání.
- **Hledání „Nugetu“**
 - **Cíl:** Nalézt dílčí překvapivé (vzácné, cenné) znalosti.
 - **Příklad:** Odhalení neobvyklých nákupních vzorců v datech o prodeji.



1. Shromažďování Trénovacích Dat:

- **Příklad:** Sbíráme 1000 e-mailů, z nichž 500 je označeno jako spam a 500 jako ne-spam. Data jsou anonymizována, aby byly odstraněny všechny osobní informace.

2. Předzpracování Dat:

- **Příklad:** E-maily jsou pročištěny od nepotřebných dat, jako jsou hlavičky e-mailů, a text je převeden na malá písmena. "KUP TEĎ!!!" se stane "kup teď".
-

Detekce Spamů - Analýza Dat (metoda Naivní Bayes)



SLEZSKÁ
UNIVERZITA
OBCHODNĚ PODNIKATELSKÁ
FAKULTA V KARVÍNĚ

3. Analýza Dat s Naivním Bayesem:

- **Základní Idea:** Naivní Bayes je statistický klasifikační model založený na Bayesově teorému. Je "naivní", protože předpokládá nezávislost mezi jednotlivými slovy (nebo rysy) ve zprávě, což ve skutečnosti nemusí být vždy pravda.

Příklad Použití Naivního Bayese:

- **Trénovací Data:** Máme trénovací data, kde jsou e-maily již označeny jako spam nebo ne-spam. Model se učí z těchto dat, jak rozpoznat charakteristiky spamových a ne-spamových e-mailů.
 - **Výpočet Pravděpodobnosti:** Model vypočítá pravděpodobnost, že daný e-mail je spam nebo ne, na základě frekvence slov v e-mailu. Například, e-mail obsahující slova jako "sleva", "klikněte" a "zdarma" může mít vyšší pravděpodobnost být označen jako spam.
 - **Klasifikace:** E-mail je klasifikován jako spam nebo ne-spam na základě vypočítané pravděpodobnosti.
-

Detekce Spamů - Aplikace Modelu a Výsledek



SLEZSKÁ
UNIVERZITA
OBCHODNĚ PODNIKATELSKÁ
FAKULTA V KARVÍNĚ

4. Výsledek Analýzy:

- **Příklad:** Model je nyní schopen s přesností 95% identifikovat, zda je nový e-mail spam nebo ne, na základě jeho obsahu a charakteristik.

5. Aplikace Modelu:

- **Příklad:** Model je integrován do e-mailového systému. Když přijde nový e-mail obsahující "kup teď", je automaticky přesunut do složky se spamem.

6. Aktualizace Modelu:

- **Příklad:** Model se pravidelně aktualizuje s novými daty, aby se zlepšila jeho přesnost. Pokud některé spamové e-maily projdou, uživatelé je mohou manuálně označit jako spam, což pomáhá modelu se učit a zlepšovat.

7. Výsledek:

- **Příklad:** Uživatelé vidí výrazné snížení spamů v jejich doručené poště, což jim umožňuje se soustředit na důležité e-maily a zvyšuje jejich produktivitu.
-

Aplikační oblasti pro dobývání znalostí



**SLEZSKÁ
UNIVERZITA**
OBCHODNĚ PODNIKATELSKÁ
FAKULTA V KARVINĚ

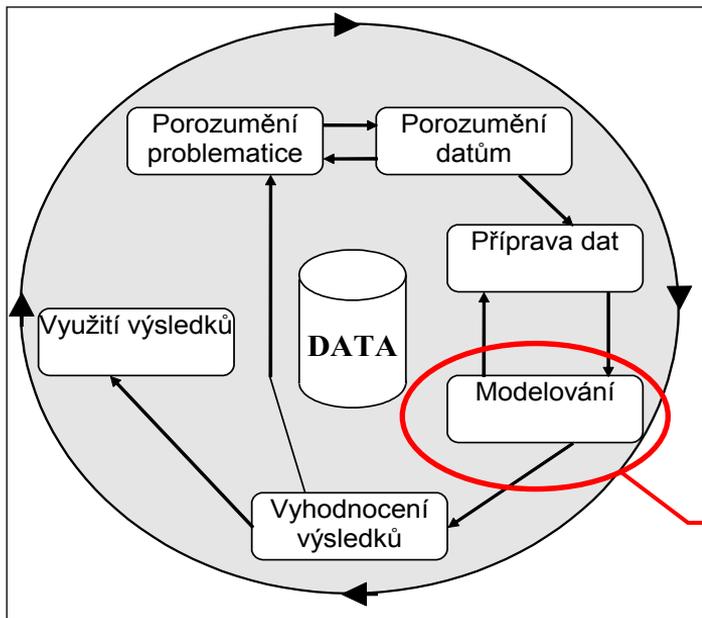
- Segmentace a klasifikace klientů banky (např. rozpoznání problémových nebo naopak vysoce bonitních klientů),
 - Predikce vývoje kursů akcií,
 - Predikce spotřeby elektrické energie,
 - Analýza příčin poruch v telekomunikačních sítích,
 - Analýza důvodů změny poskytovatele nějakých služeb (internet, mobilní telefony),
 - Segmentace a klasifikace klientů pojišťovny,
 - Určení příčin poruch automobilů,
 - Rozbor databáze pacientů v nemocnici,
-

Metodika CRISP-DM



**SLEZSKÁ
UNIVERZITA**
OBCHODNĚ PODNIKATELSKÁ
FAKULTA V KARVINĚ

V současnosti de-facto standard podporovaný většinou systémů pro dobývání znalostí



Business Understanding	Data Understanding	Data Preparation	Modeling	Evaluation	Deployment
Determine Business Objectives <i>Background Business Objectives Business Success Criteria</i>	Collect Initial Data <i>Initial Data Collection Report</i>	<i>Data Set Data Set Description</i>	Select Modeling Technique <i>Modeling Technique Modeling Assumptions</i>	Evaluate Results <i>Assessment of Data Mining Results w.r.t. Business Success Criteria</i>	Plan Deployment <i>Deployment Plan</i>
Assess Situation <i>Inventory of Resources Requirements, Assumptions, and Constraints Risks and Contingencies Terminology Costs and Benefits</i>	Describe Data <i>Data Description Report</i>	Select Data <i>Rationale for Inclusion / Exclusion</i>	Generate Test Design <i>Test Design</i>	Review Process <i>Review of Process</i>	Plan Monitoring and Maintenance <i>Monitoring and Maintenance Plan</i>
Determine Data Mining Goals <i>Data Mining Goals Data Mining Success Criteria</i>	Explore Data <i>Data Exploration Report</i>	Clean Data <i>Data Cleaning Report</i>	Build Model <i>Parameter Settings Models Model Description</i>	Determine Next Steps <i>List of Possible Actions Decision</i>	Produce Final Report <i>Final Report Final Presentation</i>
Produce Project Plan <i>Project Plan Initial Assessment of Tools and Techniques</i>	Verify Data Quality <i>Data Quality Report</i>	Construct Data <i>Derived Attributes Generated Records</i>	Assess Model <i>Model Assessment Revised Parameter Settings</i>	Review Project <i>Experience Documentation</i>	
		Integrate Data <i>Merged Data</i>			
		Format Data <i>Reformatted Data</i>			

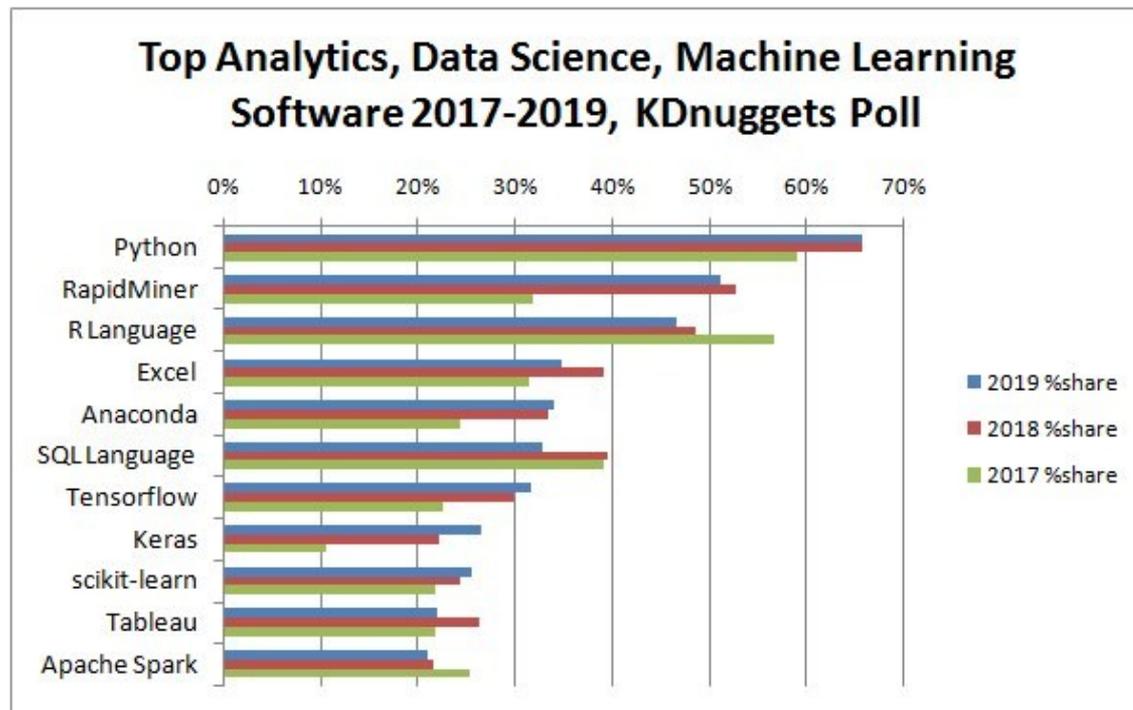


- pokrývají celý proces dobývání znalostí (od předzpracování po interpretaci),
 - nabízejí více algoritmů pro analýzu (než „jednoúčelové“ systémy strojového učení),
 - kladou důraz na vizualizaci (ve způsobu práce se systémem i při interpretaci výsledků).
-

Systemy pro dobývání znalostí z databází



SLEZSKÁ
UNIVERZITA
OBCHODNĚ PODNIKATELSKÁ
FAKULTA V KARVINĚ



Děkuji za pozornost

Některé snímky převzaty od:
prof. Ing. Petr Berka, CSc. berka@vse.cz

Rozpoznání činnosti uživatele



SLEZSKÁ
UNIVERZITA
OBCHODNĚ PODNIKATELSKÁ
FAKULTA V KARVÍNĚ

Machine Learning

Machine learning uses **data** and produces a **program** to perform a **task**

Task: Human Activity Detection

