

# Strojové učenie v podpore spracovania astro/geo dát

Peter Butka

Katedra kybernetiky a umelej inteligencie

Fakulta elektrotechniky a informatiky

Technická univerzita v Košiciach

SPACE TALK

Ústav experimentálnej fyziky SAV, Košice, 9.11.2023

# O čom by to mohlo byť ?

- Témy

- Strojové učenie (Machine Learning = ML) ... stručný pohľad na to „čo to je“
- Využitie strojového učenia v astro/geo doméne
  - Prečo vôbec ? Kde sa už použili ? ...
- Príklady využitia ML na astro/geo dáta v našej skupiny

# Strojové učenie

- 1959 – 1x sa objavuje tento názov (Arthur Samuel)
- Definícia: Tom Mitchell
  - Formálna, konceptuálna definícia, so silným odkazom na prístup k umelej inteligencii definovaný Alanom Turingom

## ALGORITMUS ktorý

zlepšuje **VÝKONNOSŤ** (meranú metrikou)

v riešení **ÚLOHY**


s pribúdajúcimi **SKÚSENOSŤAMI** (dátami)

Príklad:

ÚLOHA = predikcia indexu DST (geomagnetické búrky – Disturbance Storm Index)

VÝKONNOSŤ = chyba predikcie + snaha zmenšiť túto chybu

SKÚSENOSŤ = historické dáta meraní DST indexu



# Strojové učenie (2)

- Strojové učenie je základom systémov AI (Artificial Intelligence = Umelá inteligencia)
  - Prakticky každý známy článok dnes hovoriaci o AI je v skutočnosti aplikáciou strojového učenia
- Strojové učenie ako krok hľadania MODEL-u v procese dátovej analýzy
  - Jeden z krokov (Modelovanie) v rámci procesu Objavovania znalostí (Knowledge Discovery)
  - Cieľom je hľadať štatisticky významné vzťahy (preto aj **štatistické učenie**)
  - Proces pokrývajúci:
    - Pochopenie problému a dát
    - Prípravu / predspracovanie dát
    - Modelovanie (aplikácia ML)
    - Vyhodnotenie
    - Nasadenie

# Typy úloh strojového učenia

- **Kontrolované učenie (Supervised Learning)**
  - Dané: trénovacie dáta s cieľovým atribútom, ktorý je numerický (**regresia**) alebo kategoriálny (**klasifikácia**)
  - Príklad1 (klasifikácia): množina emailov s označením či ide o spam alebo nie
    - Cieľ: rozlišovať spam / nie spam -> následne použiť na nové neznáme emaily
  - Príklad2 (regresia): množina meraní DST indexu
    - Cieľ: predikovať aká bude hodnota DST indexu za 1 hodinu -> použiť na predikciu búrky
- **Nekontrolované učenie (Unsupervised Learning)**
  - Dané: trénovacie dáta bez cieľového atribútu
  - Príklad: množina telekomunikačných zákazníkov popísaných atribútmi o ich chovaní (používanie dát, minúty, sms-ky, atď.)
    - Cieľ: nájsť zaujímavé skupiny zákazníkov s podobným správaním (zhlukovanie do skupín)
- **Učenie posilňovaním / spätnou väzbou/ ... (Reinforcement Learning)**
  - Učenie na báze odmeňovania alebo trestu za vykonanie akcie => dynamické systémy
  - Príklad: riadenie autonómneho auta
    - Cieľ: natrénovať súbor pravidiel / postupov / akcií ktoré má auto vykonať pre úspešnú jazdu

# ... pri spracovaní obrazu

- Stále to môže byť kontrolované učenie a klasifikácia, ale adaptovaná na fakt že máme vstup obrázkov a forma výstupu môže byť špecifickejšia

Obsahuje tento obrázok psa ?

Aké objekty sú na obrázku a kde?


Ktoré pixely patria jednotlivým objektom ?



KLASIFIKÁCIA



DETEKCIA



SEGMENTÁCIA


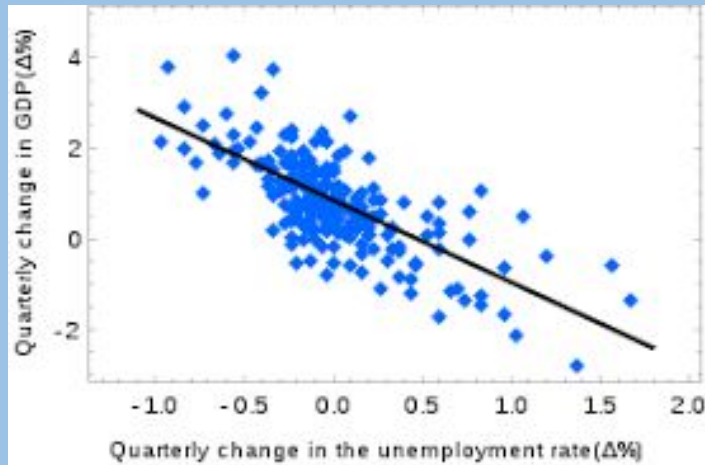
# Algoritmus ML

- Koľko ich je ?
  - Tisíce .... a každý rok pribúdajú stovky nových ...
- Majú niečo spoločné ?
  - Základná štruktúra je v určitom zmysle rovnaká
- Každý algoritmus ML má 3 komponenty
  - Reprezentácia (typ adaptabilnej funkcie / štruktúra modelu)
  - Optimalizácia / prehľadávanie – princíp hľadania optimálneho nastavenia modelu
  - Evaluácia – vyhodnotenie „kvality“ modelu (alebo jeho časti)
- Čo to znamená ?
  - ... ML algoritmus si môžeme v podstate vyskladať z rôznych prvkov
  - + môžeme ešte kombinovať samotné modely a dosahovať takto pri rozumnej aplikácii ešte lepší výsledok




# Reprezentácie

- Numerické funkcie




Regresné  
modely



Neurónové siete

Support  
Vector  
Machines  
(SVM)

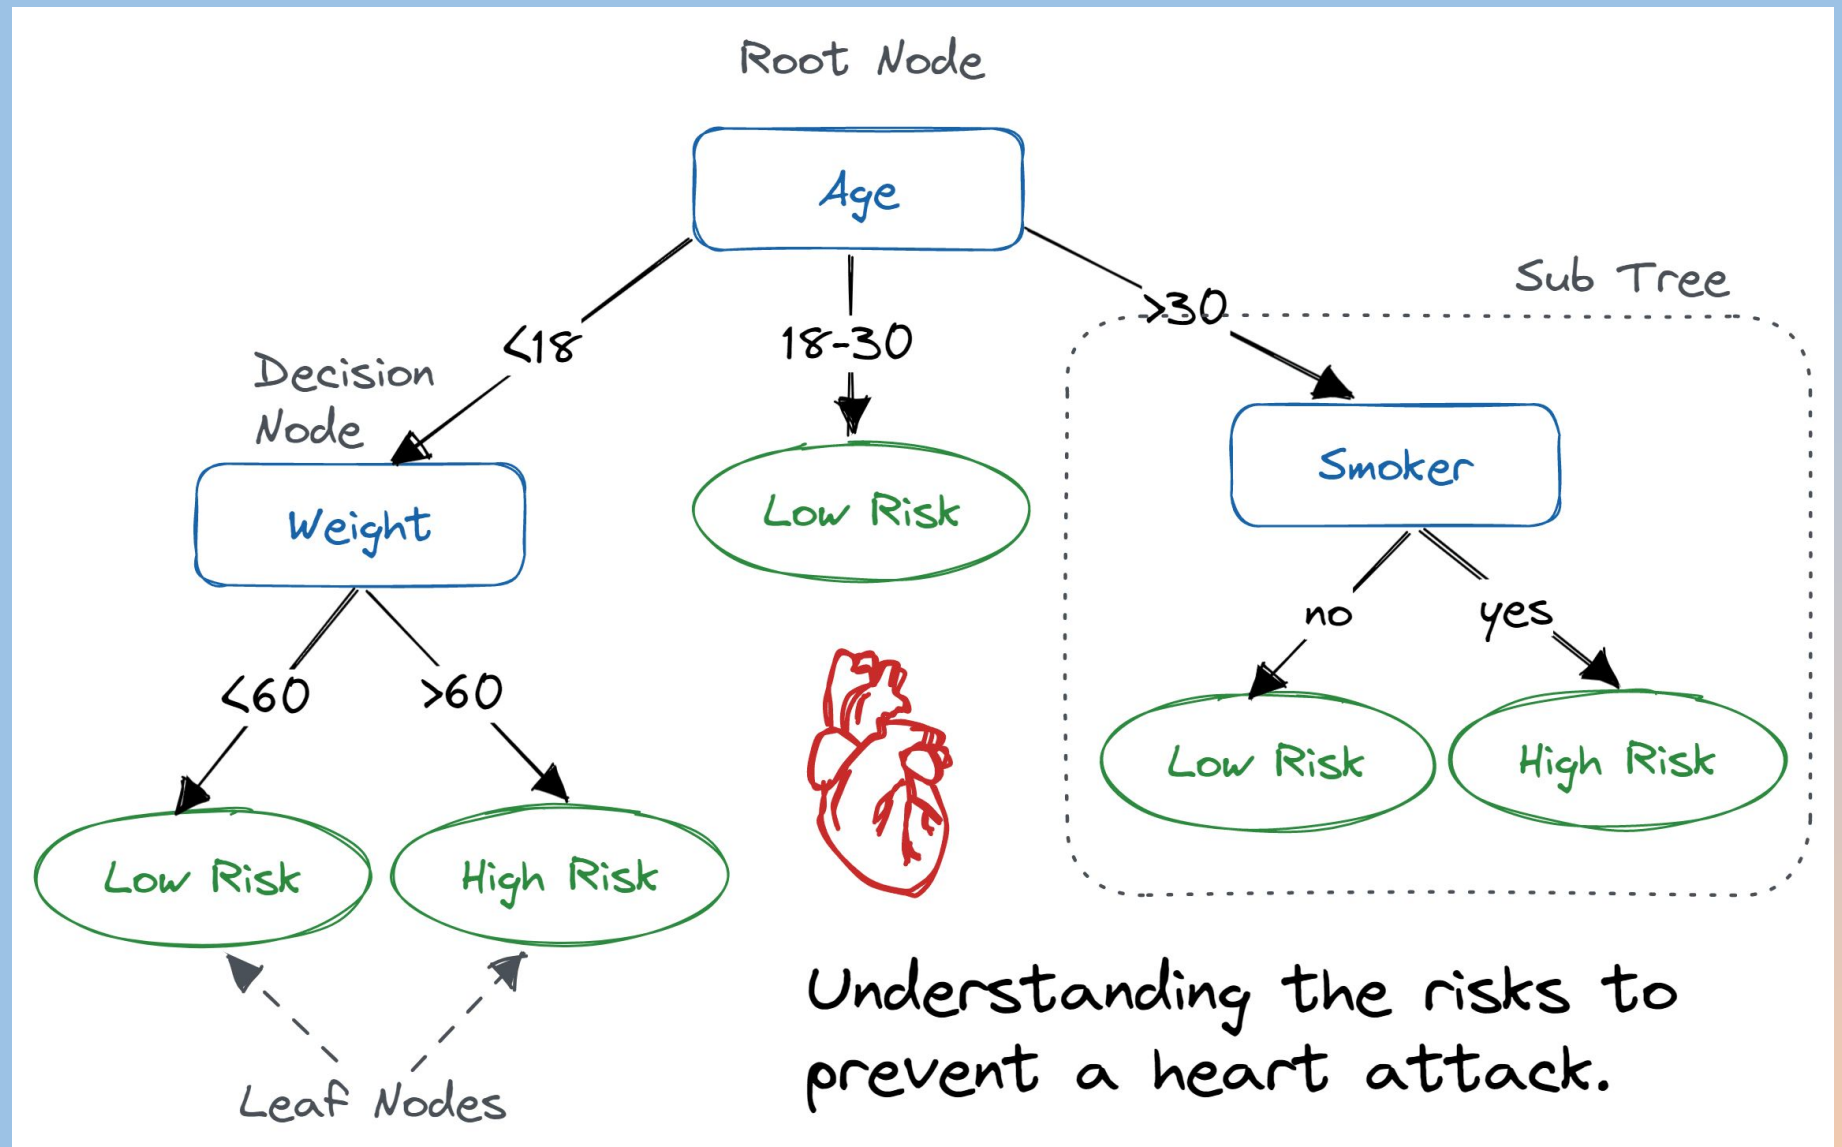




# Reprezentácie

- Symbolické funkcie

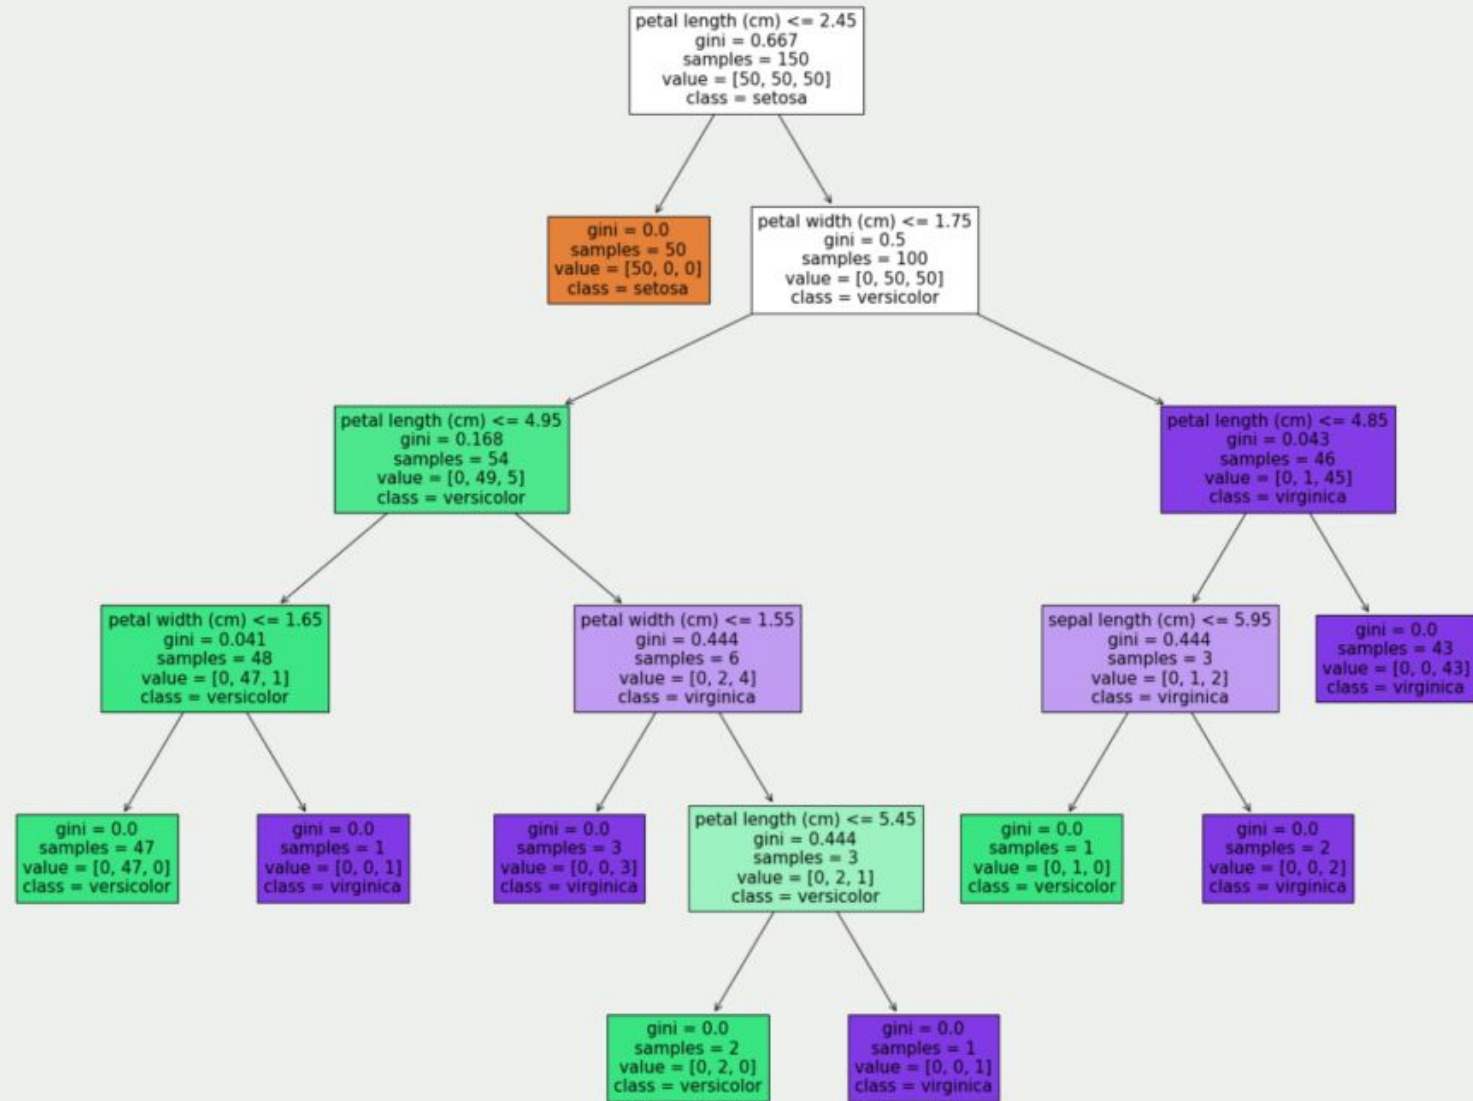
Rozhodovacie stromy



# Reprezentácie

- Symbolické funkcie

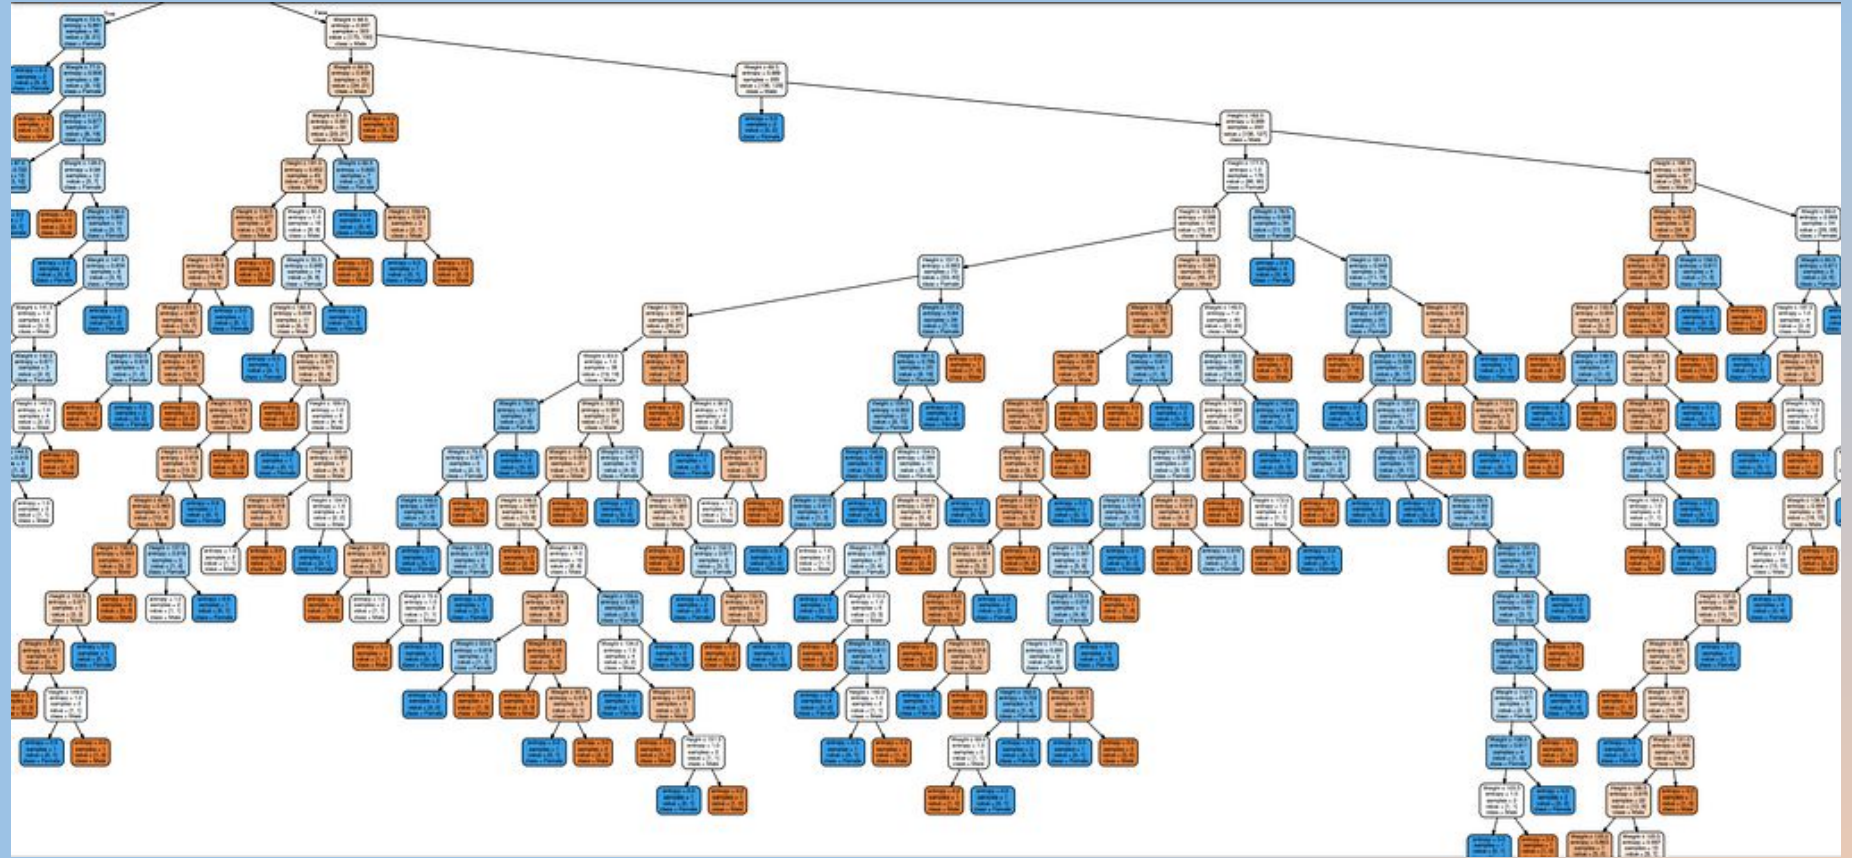
Rozhodovacie stromy



# Reprezentácie


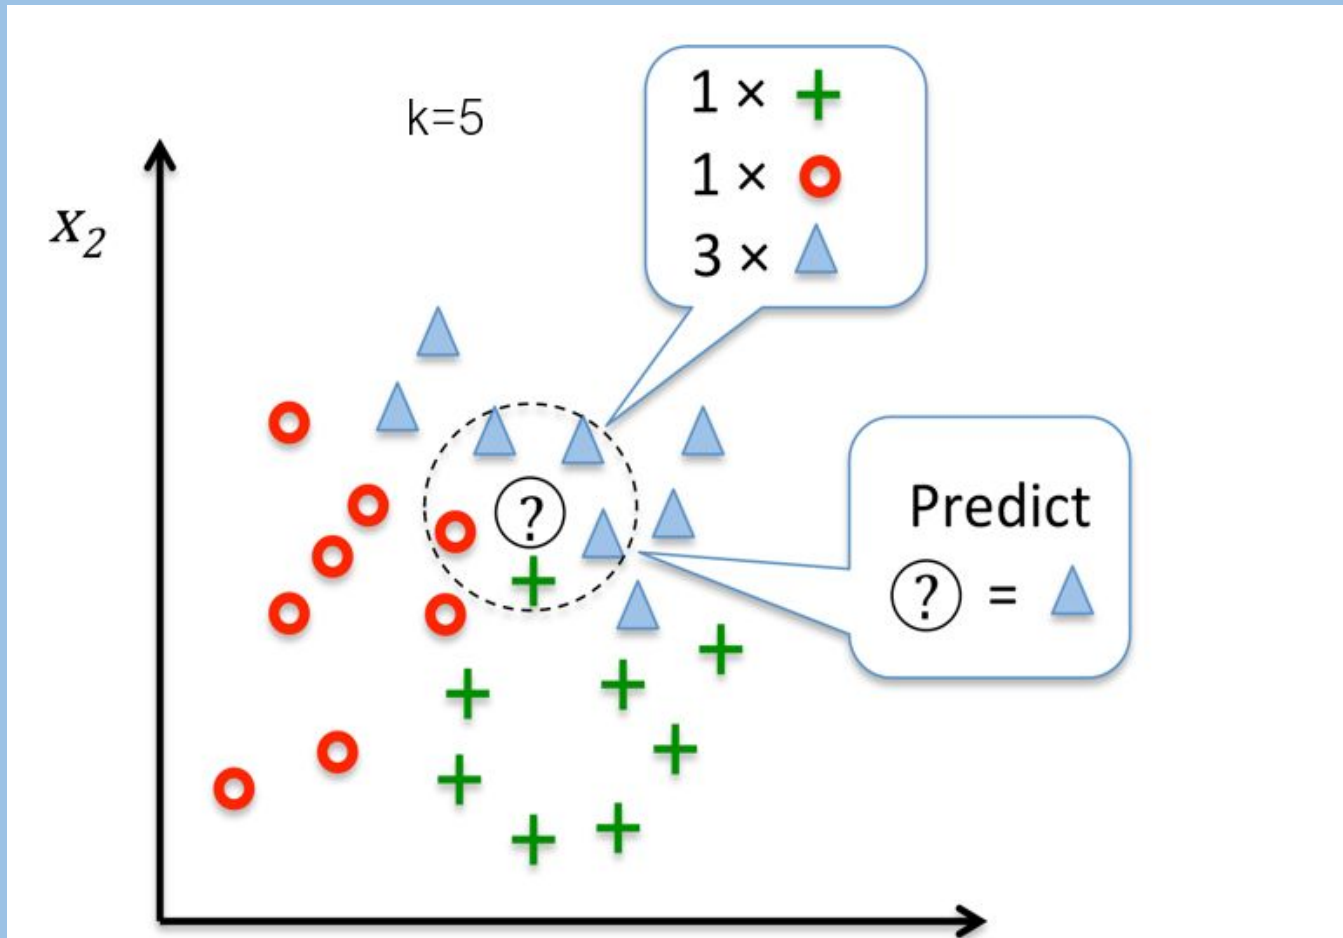
- Symbolické funkcie

Rozhodovacie stromy



# Reprezentácie

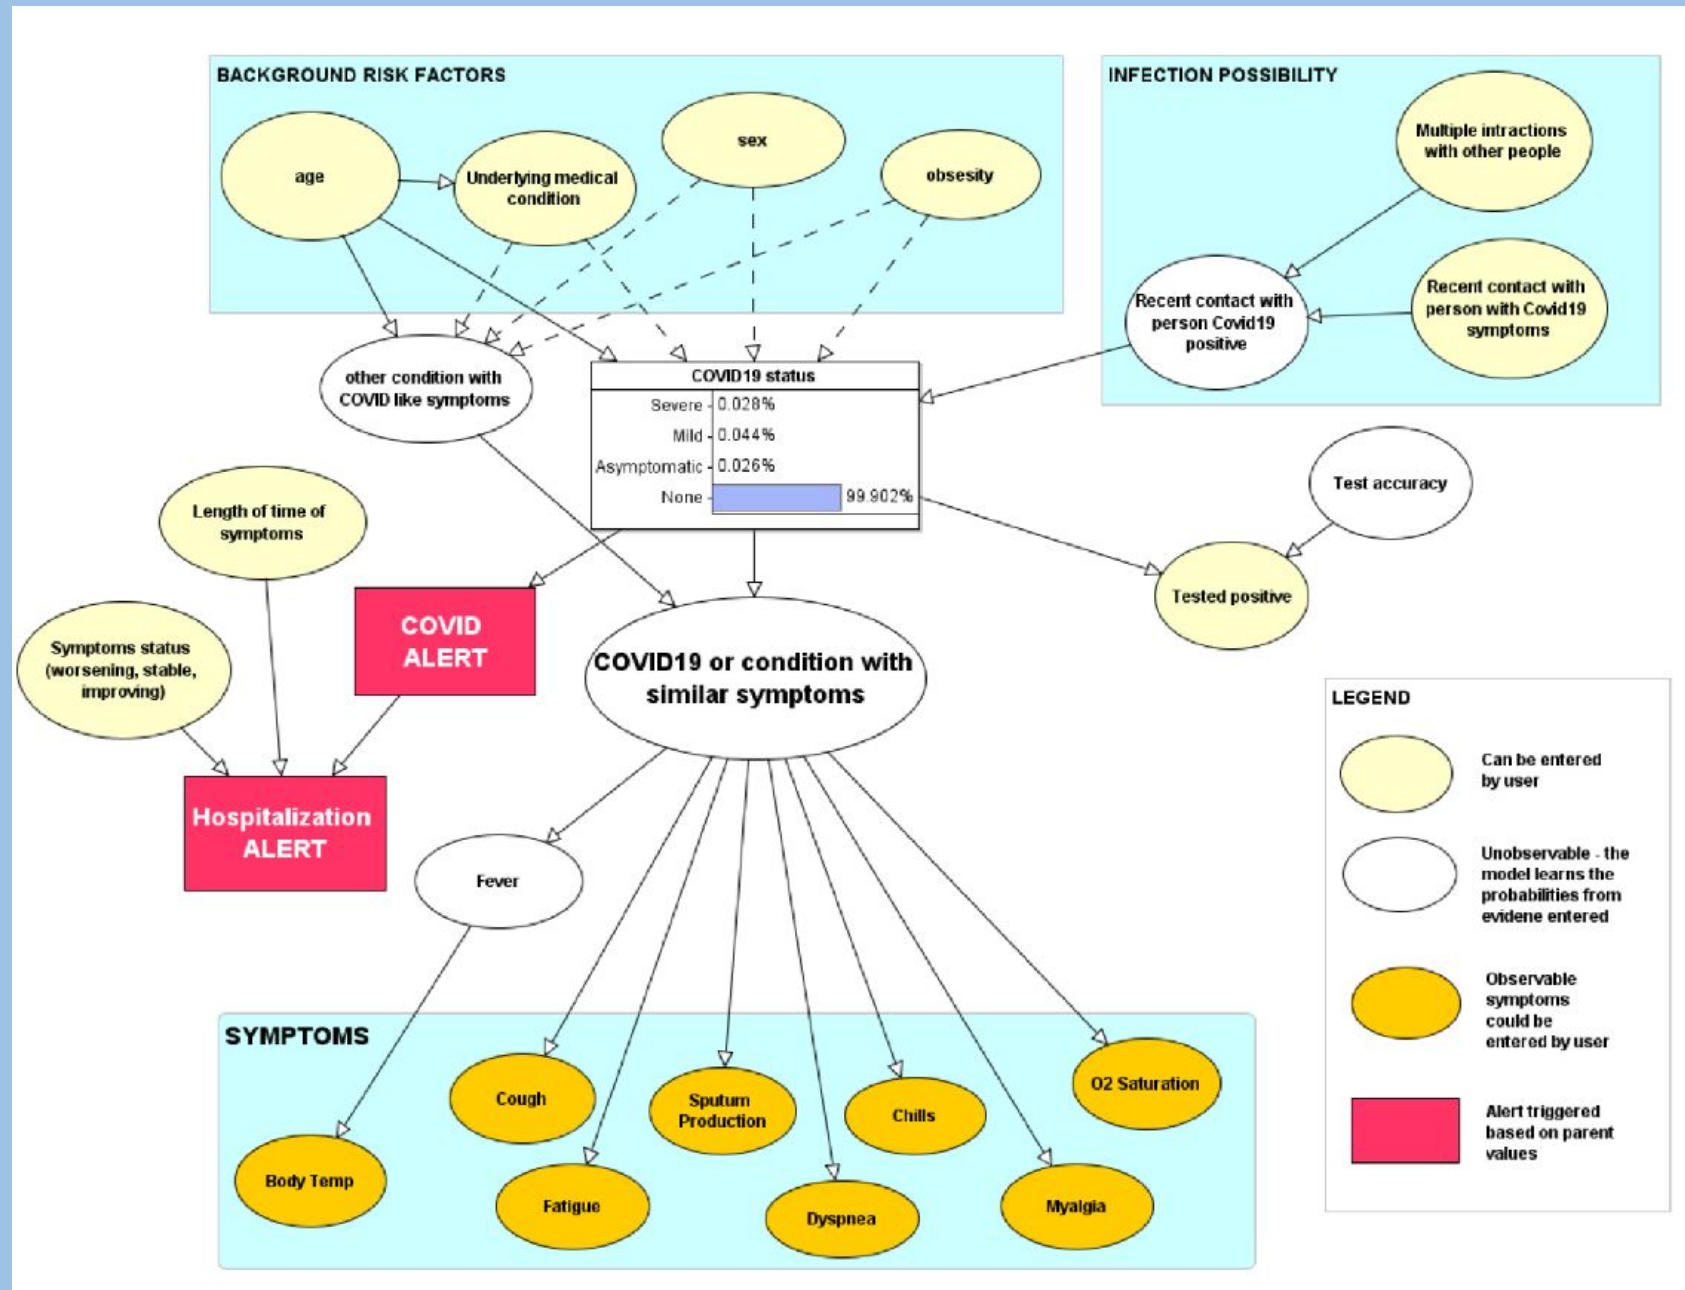
- Inštančné prístupy
  - Napr. k-NN (k najbližších susedov – k nearest neighbors)





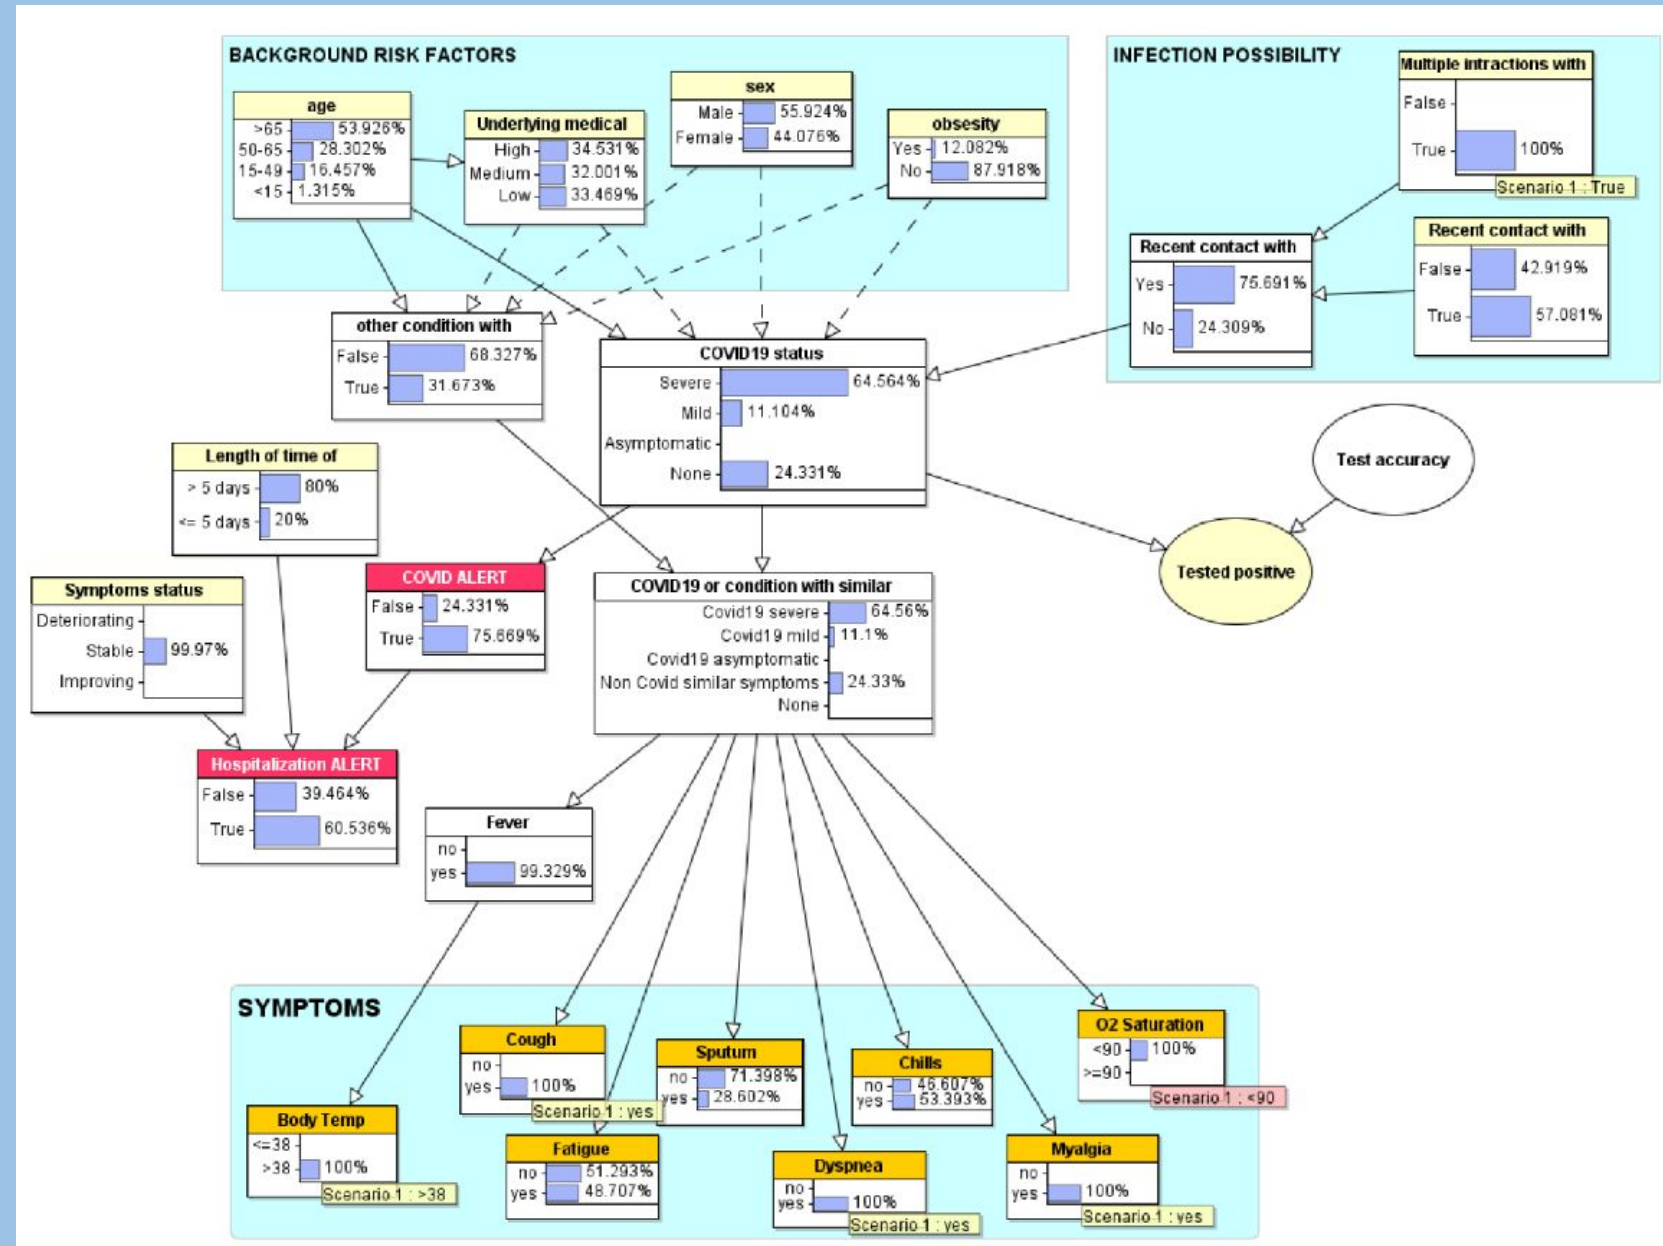
# Reprezentácie

- Probabilistické modely
  - Naive Bayes
  - Bayesovské siete ->
  - Markovovské modely,
  - ...





# Reprezentácie

- Probabilistické modely
  - Naive Bayes
  - Bayesovské siete ->
  - Markovovské modely,
  - ...



# Optimalizácia

- Gradientové metódy ->
- Dynamické programovanie
- Princíp „Rozdeľuj a panuj“
- Heuristické prehľadávanie
- Evolučné prístupy






# Evaluácia

- Úspešnosť klasifikácie
- Presnosť a návratnosť
- F-miera
- Chyba predikcie
- Priemerná kvadratická chyba
- Pravdepodobnosť výskytu
- Zisk / Úžitok
- Entropia
- ...


Skutočná klasifikácia -> ----- Predikcia klasifikátora	Skutočná trieda príkladu emailu = JE SPAM	Skutočná trieda príkladu emailu = NIE JE SPAM
Podľa klasifikátora email: JE SPAM	40 (TP - True Positive)	5 (FP - FALSE POSITIVE)
Podľa klasifikátora email: NIE JE SPAM	10 (FN - FALSE NEGATIVE)	45 (TN - TRUE NEGATIVE)



Accuracy (úspešnosť klasifikácie)

$$\begin{aligned} & (40 + 45) / \\ & (40 + 5 + 10 + 45) \\ & = 85 / 100 \Rightarrow 85\% \end{aligned}$$

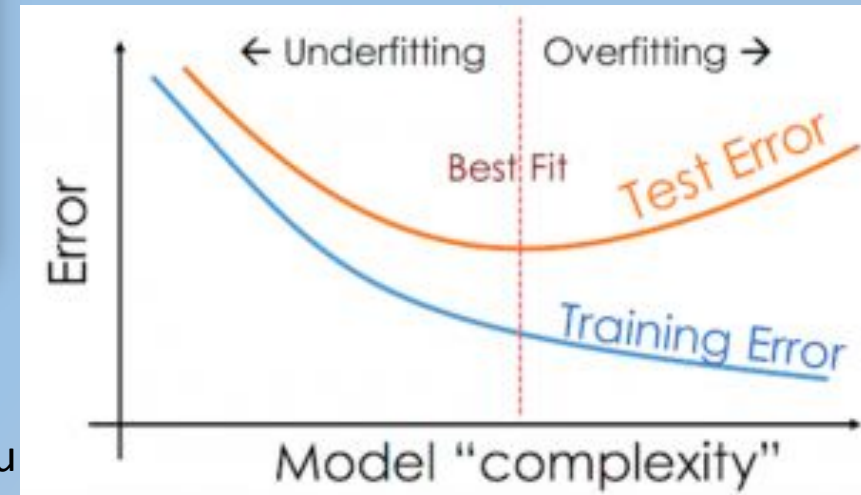
# Problém 1: Podučenie a preučenie




Podučenie (underfitting)  
- jednoduchý model,  
nedostatočne komplexný,  
má veľkú tréningovú aj  
testovaciu chybu

Optimálny model – model  
s dobrou komplexitou a  
varianciou, nízka  
tréningová aj testovacia  
chyba

Preučenie (overfitting)  
- príliš zložitý (komplexný)  
model, má malú tréningovú  
chybu, testovacia chyba je  
ale veľká



Chyba na tréningovej a  
testovacej množine v závislosti  
od úrovne zložitosti modelu



# Prečo ML v spracovaní astro/geo dát ?

- Astro/geo-fyzika generujú obrovské množstvo dát
  - => ML môže vedcom pomôcť spracovať, vyčistiť a extrahovať zmysluplné informácie z týchto veľkých súborov dát
  - ... ktorých bude pribúdať viac a rýchlejšie
- Fúzia dát: Veda často zahŕňa kombinovanie údajov z viacerých zdrojov
  - napr. astrofyzika kombinuje často pozorovania z rôznych teleskopov pozorujúcich v rôznych spektrálnych oblastiach (ultrafialové, optické, infračervené, rádiové, atď.)  
=> ML pomáha integrovať a analyzovať rôzne zdroje pre lepšie pochopenie javov

20 terabytes (20,000 gigabytes)

Amount of data collected each night

60 petabytes (60,000,000 gigabytes)

Total amount of data collected in ten-year survey

~2 million



Images in ten-year survey

60 seconds

Time between image capture and alert generation

~10 million

Alerts per night



SKAO

16 Terabits / sekunda !  
(po redukcii a kompresii)



„ ... Smerujeme k tomu, že 99,9 % nasnímaných obrázkov zo satelitov a pozemných prístrojov nikdy žiadny fyzik neuvidí a osobne nespracuje ... budú to algoritmy ktoré budú hľadať významné prípady pre ich detailnú analýzu ... takže ľudia z oblastí počítačového spracovania dát budú stále dôležitejší, som rád že niektorí tak ako vy aj sami hľadajú cestu, bude to veľmi potrebné ...“





# Aké aplikácie ML napr. v spracovaní astro dát ?

- Klasifikácia hviezd a galaxií - SDSS (Sloan Digital Sky Survey), Galaxy Zoo – detekcia a morfológia galaxií
- Detekcia exoplanét – Kepler, TESS dáta boli skúmané pomocou ML pre hľadanie kandidátov na exoplanéty
- Stelárna spektroskopia a klasifikácia - kategorizácia hviezd do spektrálnych tried, určenie ďalších vlastností – boli použité metódy ako SVM, Random Forest, či neurónové siete
- Detekcia a klasifikácia supernov - automatizácia detekcie supernov a ich charakterizácia, využívajúca napr. hlboké neurónové siete na namerané svetelné krivky
- Analýza mikrovlnného kozmického pozadia – metódy konvolučných a Bayesovských neurónových sietí pre odhad kozmologických parametrov z nameraných dát
- Detekcia gravitačných vln – analýzu signálu z interferometrov LIGO/Virgo významne vylepšili detekčné algoritmy na báze konvolučných a rekurentných neurónových sietí
- Detekcia pulzarov – algoritmy rozhodovacích stromov a neurónových sietí boli použité na redukciiu dát a určenie kandidátov na pulzary
- Odhad červeného posunu galaxií – konvolučné neurónové siete boli použité na predikciu červeného posunu z obrázku galaxie
- Detekcia asteroidov a blízko-zemských objektov – automatizácia detekcie pomocou konvolučných neurónových sietí

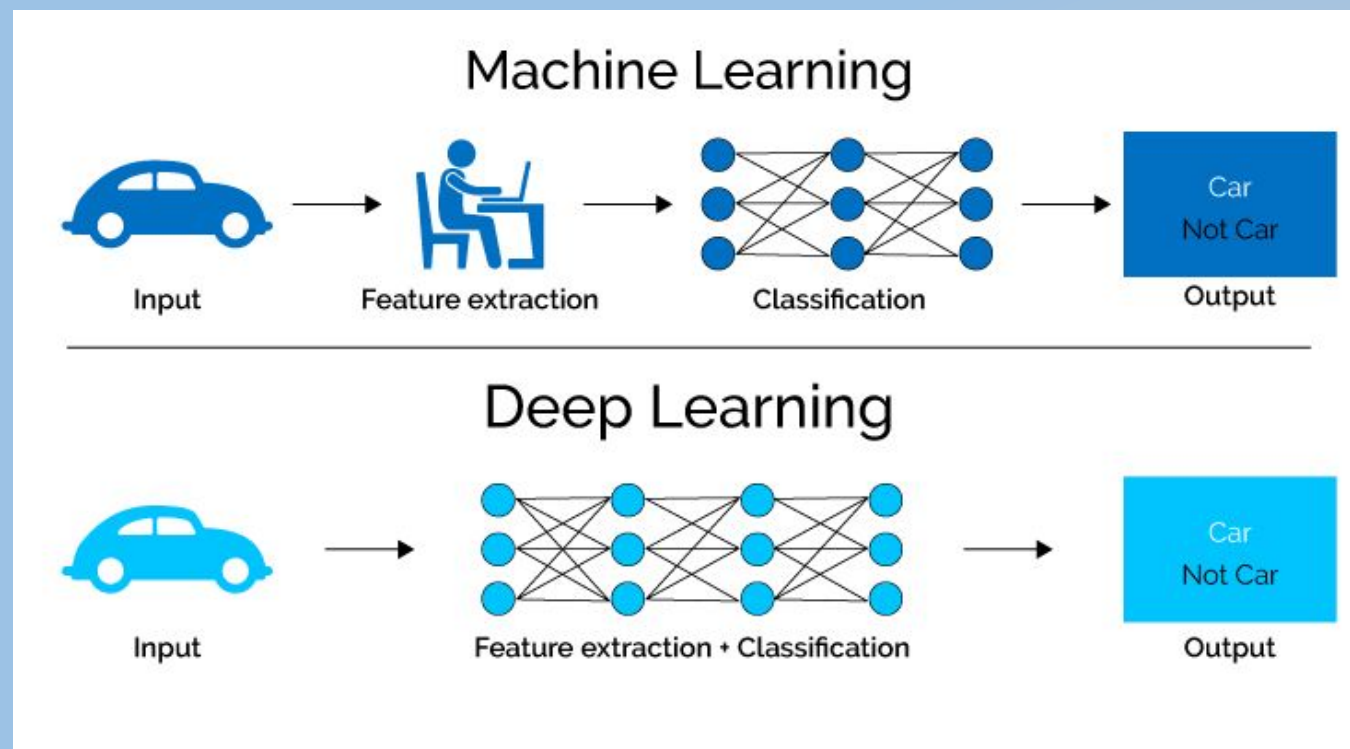
# Často sú tam neurónové siete ... čo to je ?

- Jeden z ML modelov
- Veľká množina veľmi rôznorodých modelov, dnes známa najmä ako hlboké učenie (deep learning)
- 1958 - Rosenblatt
- Perceptrón / jednoduchý (umelý) neurón
- Vrstvy neurónov => vyššia kapacita učenia
- Dopredná neurónová sieť (Feed-Forward NN)



# Problém 2 – Ako získať vhodné atribúty objektov

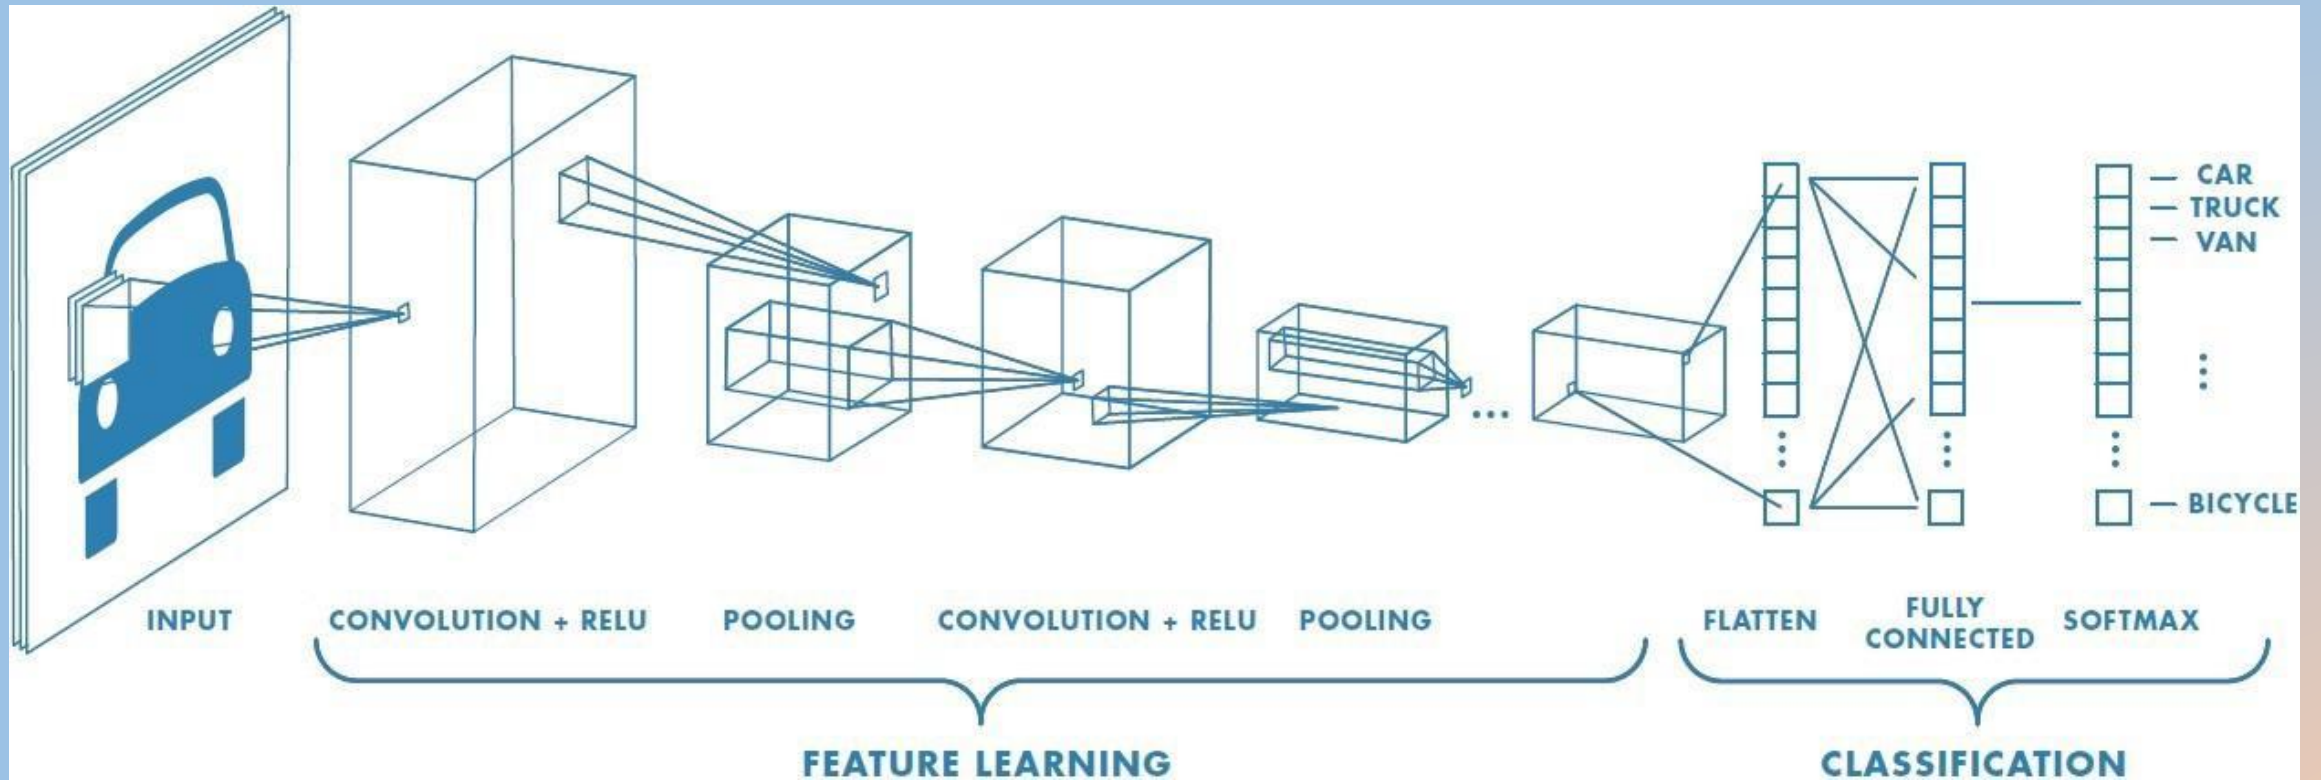
- Tradičný prístup – extrakcia príznakov (atribútov / „vhodných  $x_i$  pre predikciu  $y$ “) sa deje v procese pred aplikáciou ML modelu
- Čo prinieslo hlboké učenie (napr. konvolučné siete) => extrakciu príznakov zabezpečí samotná neurónová sieť






# Konvolučná neurónová sieť

- Využitie konvolučnej siete prinieslo výrazné zlepšenie spracovania obrazu, práve vďaka efektívnemu prístupu učenia príznakov




# Konvolučná neurónová sieť

- Využitie konvolučnej siete prinieslo výrazné zlepšenie spracovania obrazu, práve vďaka efektívnemu prístupu učenia príznakov



# Konvoluční vrstva



0	0	0	0	0	0	0
0	105	102	100	97	96	100
0	103	99	103	101	102	100
0	101	98	104	102	100	100
0	99	101	106	104	99	100
0	104	104	104	100	98	100

Image Matrix

0	-1	0
-1	5	-1
0	-1	0

Kernel Matrix


320				

Output Matrix

$$\begin{aligned} & 0 * 0 + 0 * -1 + 0 * 0 \\ & + 0 * -1 + 105 * 5 + 102 * -1 \\ & + 0 * 0 + 103 * -1 + 99 * 0 = 320 \end{aligned}$$


**Convolution with horizontal and vertical strides = 2**

# *Pooling* vrstva (redukcia výstupných rozmerov)



# Čo získavame na konci konvolučnej časti siete


- Zhustená reprezentácia vstupov ... po naučení z množiny obrázkov máme postup ako pre každý nový obrázok získame kompaktnú menšiu reprezentáciu
  - => v podstate sme obrázok zakódovali vytvorili sme „enkodér“
- Toto môžeme aj otočiť – použijeme dekonvolúciu a up-sampling (opak pooling)
  - => získame tak „dekodér“
- Jednotlivo aj spojené sa tieto časti dajú rôzne využiť na riešenie klasifikačných, detekčných a segmentačných úloh
- Existuje veľa enkodér – dekodér architektúr (napr. U-Net, rôzne typy autoenkodrov, atď.) s veľkým množstvom aplikácií





# Konvolučné siete v praxi



- Na základe konvolučných neurónových sietí je postavených mnoho úspešných klasifikačných, detekčných a segmentačných sietí



VGG 16

Klasifikácia a detekcia

YOLO



U-Net (enkodér-dekodér architektúra)

Segmentácia


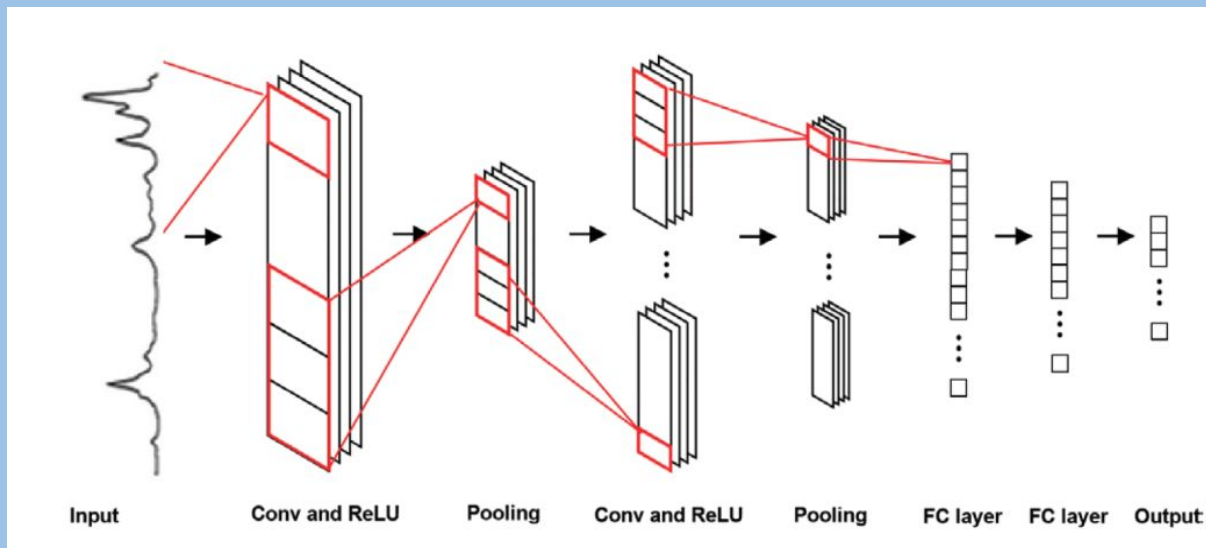
# A čo iné dáta ... napr. postupnosť meraní ?

- Konvolúcia sa dá použiť aj pre časovú radu, nielen pre obrázky => môžeme použiť 1-D konvolúciu
  - dobré najmä pre lokálne zmeny v časovej rade

- Môžeme použiť rekurentné neurónové siete

- LSTM (Long Short-Term Memory) – obsahuje rôzne prvky umožňujúce lepšie si „pamätať“ dlhšie sekvencie
- dobré pre zachytenie elementov ovplyvňujúce od seba vzdialenejšie vstupy (získame viac nelokálnych príznakov )

Tieto prístupy môžeme aj spojiť





# Ďalšie typy sietí

- Postupom času sa dostali do povedomia a výrazného použitia aj ďalšie typy sietí (a princípy fungovania) pre množstvo rôznych úloh
- Z nich dnes najsledovanejšie sú generatívne modely
- Postupne vzniklo veľké množstvo vylepšení, od GAN (Generative Adversarial Networks) sietí až po siete typu Transformer  
... kam patrí aj dnes už svetoznámy Chat-GPT

Ale tým sa venovať nebudeme ...

# Príklady použitia ML – kde by ste ich možno ani nečakali ...

- Adaptívna optika – zlepšenie rozlíšenia adaptívnej optiky pomocou „reinforcement learning“
- Gravitačné vlny – detekcia gravitačných vln detektormi LIGO / Virgo
- Fotografia čiernej diery – Event Horizon Telescope (EHT) a obrázok okolia supermasívnej čiernej diery v galaxii M87

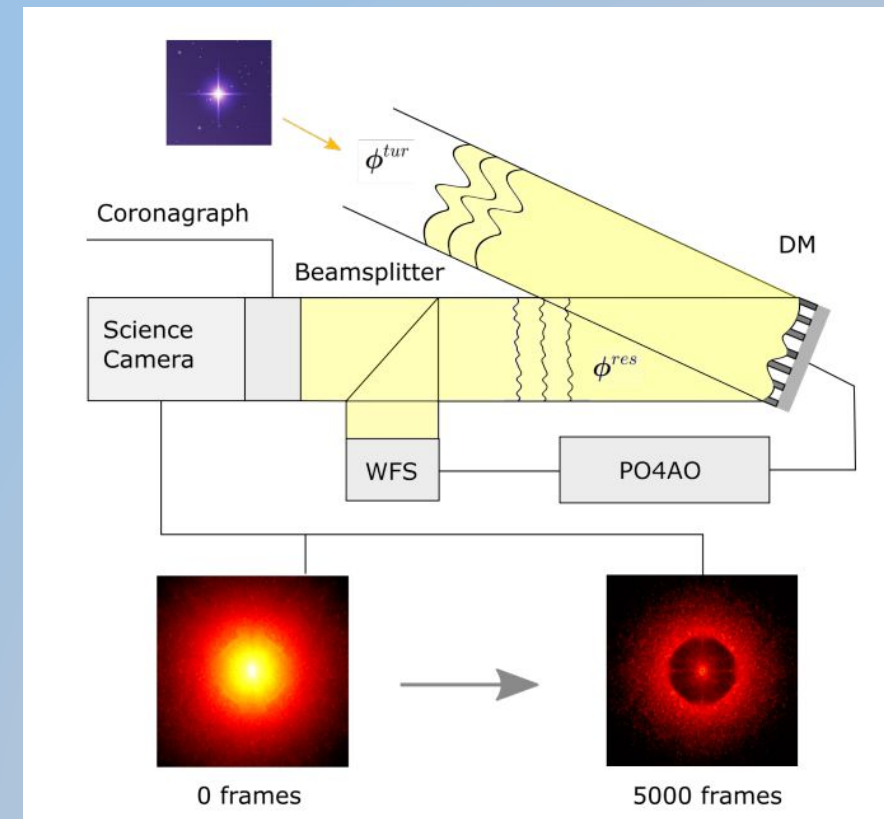

## Toward on-sky adaptive optics control using reinforcement learning

### Model-based policy optimization for adaptive optics

J. Nousiainen<sup>1,3</sup>, C. Rajani<sup>2</sup>, M. Kasper<sup>3</sup>, T. Helin<sup>1</sup>, S. Y. Haffert<sup>4,\*,</sup>, C. Vérinaud<sup>3</sup>, J. R. Males<sup>4</sup>, K. Van Gorkom<sup>4</sup>,  
L. M. Close<sup>4</sup>, J. D. Long<sup>4</sup>, A. D. Hedglen<sup>1,5</sup>, O. Guyon<sup>4,5,6,7</sup>, L. Schatz<sup>8</sup>, M. Kautz<sup>4,5</sup>, J. Lumbres<sup>4,5</sup>,  
A. Rodack<sup>4,5</sup>, J. M. Knight<sup>4,5</sup>, and K. Miller<sup>8</sup>


# RL pre adaptívnu optiku

- Pre pozemné ďalekohľady hrá adaptívna optika významnú rolu
  - Jeden z cieľov – priame pozorovanie exoplanét
- Policy Optimization for Adaptive Optics (PO4AO)
  - Učí dynamický model a optimalizuje kontrolnú neurónovú sieť
  - Rozšírenie už existujúcich postupov na báze NS






# Gravitačné vlny a ML

- Detekcia prítomnosti GW
- Odhad parametrov pozorovaných prípadov
- ... ale aj odhaľovanie „glitches“, redukcia šumu, ...



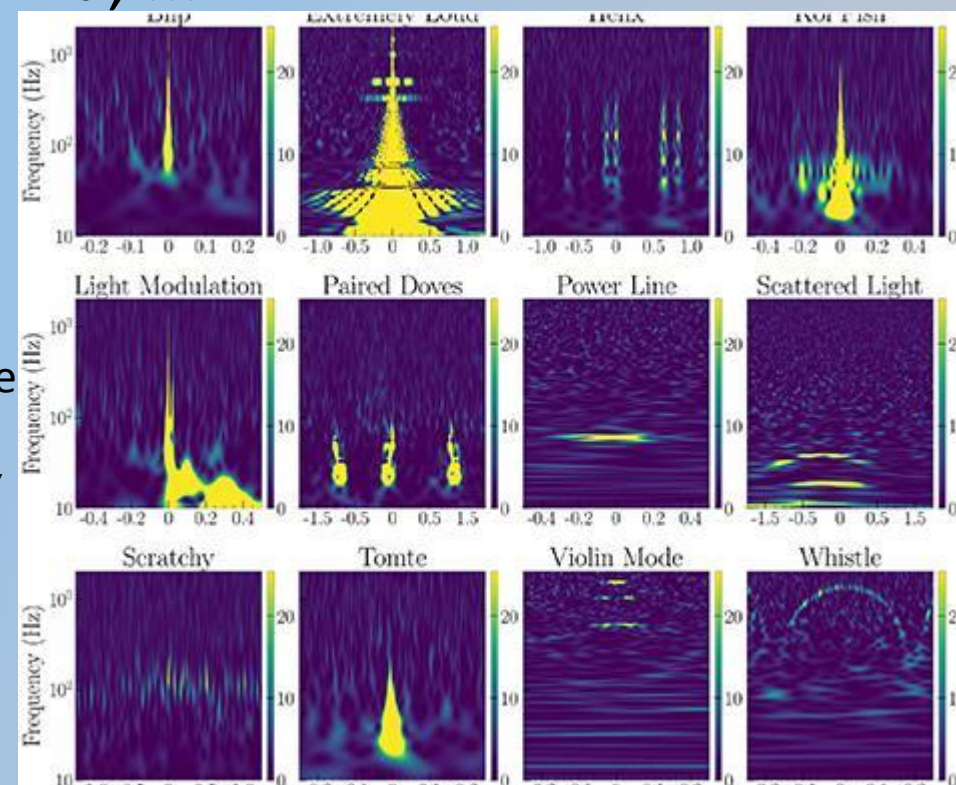
Deep Learning for real-time gravitational wave detection and parameter estimation: Results with Advanced LIGO data  
 Daniel George<sup>a,b,\*</sup>, E.A. Huerta<sup>b</sup>




Input	vector (size: 8192)
1 Reshape	matrix (size: 1 × 8192)
2 Convolution	matrix (size: 64 × 8177)
3 Pooling	matrix (size: 64 × 2044)
4 ReLU	matrix (size: 64 × 2044)
5 Convolution	matrix (size: 128 × 2014)
6 Pooling	matrix (size: 128 × 503)
7 ReLU	matrix (size: 128 × 503)
8 Convolution	matrix (size: 256 × 473)
9 Pooling	matrix (size: 256 × 118)
10 ReLU	matrix (size: 256 × 118)
11 Convolution	matrix (size: 512 × 56)
12 Pooling	matrix (size: 512 × 14)
13 ReLU	matrix (size: 512 × 14)
14 Flatten	vector (size: 7168)
15 Linear Layer	vector (size: 128)
16 ReLU	vector (size: 128)
17 Linear Layer	vector (size: 64)
18 ReLU	vector (size: 64)
19 Linear Layer	vector (size: 2)
Output	vector (size: 2)

Deep filtering

Rôzne nežiadúce javy „glitches“







# Čierna diera v M87

- „Fotka“ čiernej diery v galaxii M87
- EHT (Event Horizon Telescope)
- Radiová interferometria (VLBI – Very Long Baseline Interferometry)





OPEN ACCESS

## First M87 Event Horizon Telescope Results. I. The Shadow of the Supermassive Black Hole

The Event Horizon Telescope Collaboration, Kazunori Akiyama<sup>1,2,3,4</sup> , Anton Alberdi<sup>5</sup> , Walter Alef<sup>6</sup>, Keiichi Asada<sup>7</sup>, Rebecca Azuly<sup>8,9,6</sup> , Anne-Kathrin Baczko<sup>6</sup> , David Ball<sup>10</sup>, Mislav Baloković<sup>4,11</sup> , John Barrett<sup>2</sup>  + Show full author list

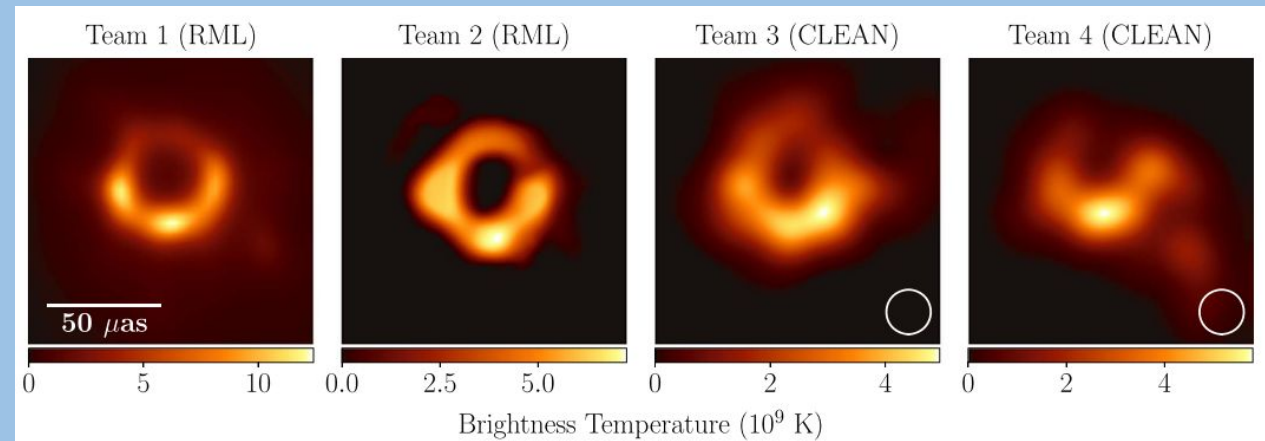
Published 2019 April 10 • © 2019. The American Astronomical Society.

The Astrophysical Journal Letters, Volume 875, Number 1



# Čierna diera v M87

- Prvý obrázok vznikol z raw dát použitím algoritmov ML (2019)
- 4 rôzne nezávislé skupiny pracovali na vytvorení výsledného obrazu => pričom cieľom bolo dosiahnuť výsledok bez predpokladu ako by mal / mohol vyzerat' výsledný obraz => výsledný obraz je ich kombináciou
- Apríl 2023
  - Vďaka overeniu postupu (už máme aj „fotku“ čiernej diery v strede našej galaxie)
  - => Prečo teda nepoužiť simulácie ako ďalší zdroj dát => vďaka tomu dostali lepšie obrázky z rovnakých raw dát



THE ASTROPHYSICAL JOURNAL LETTERS


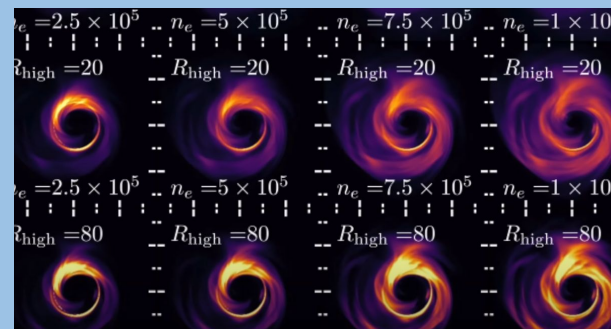
OPEN ACCESS

The Image of the M87 Black Hole Reconstructed with PRIMO

Lia Medeiros<sup>1,2</sup>, Dimitrios Psaltis<sup>3</sup>, Tod R. Lauer<sup>4</sup>, and Feryal Özel<sup>3</sup>

Published 2023 April 13 • © 2023. The Author(s). Published by the American Astronomical Society.

The Astrophysical Journal Letters, Volume 947, Number 1



# Problém 3: Dáta

- Veľa dát bez označenia cieľa (nemáme klasifikáciu obrázkov, označenie príkladov objektov, ...) alebo neoznačené špecifické prípady
  - Riešenie: použitie nekontrolovaných metód, použitie simulovaných dát, prípadne často to vedie na označenie dát



ANOTÁCIA DÁT

- Dát nie je dosť alebo je vhodných obrázkov pre daný jav málo
  - Rozšírenie trénovacej časti dát, napríklad rôznymi verziami existujúcich príkladov, simulovanými príkladmi a ich variantami
  - napr. otočenie obráku, pridanie jasu, šumu, ... => tak aby nedošlo k zmene cieľovej hodnoty (napr. špirálová galaxia zostane špirálovou aj po otočení o 90 stupňov)

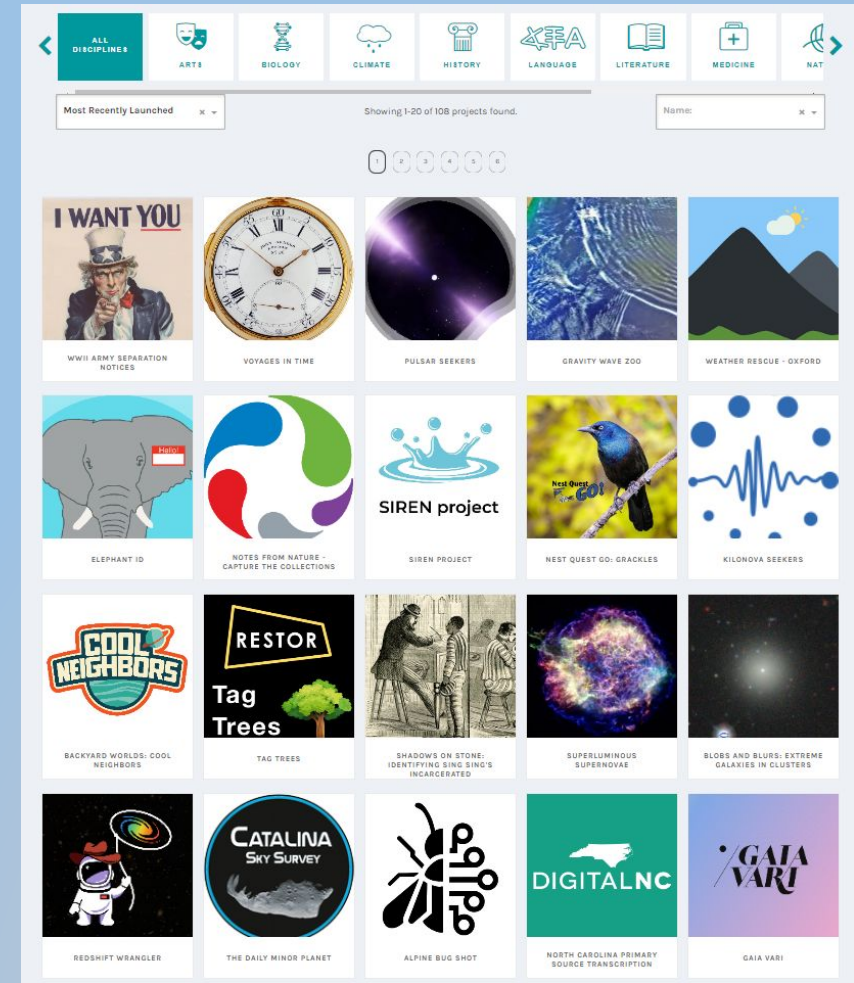
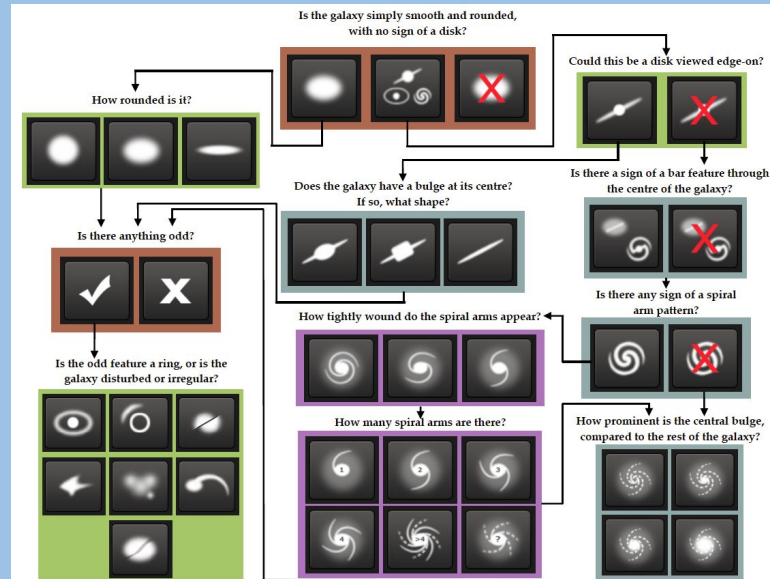


AUGMENTÁCIA DÁT



# Anotácia dát - Galaxy ZOO => Zooniverse

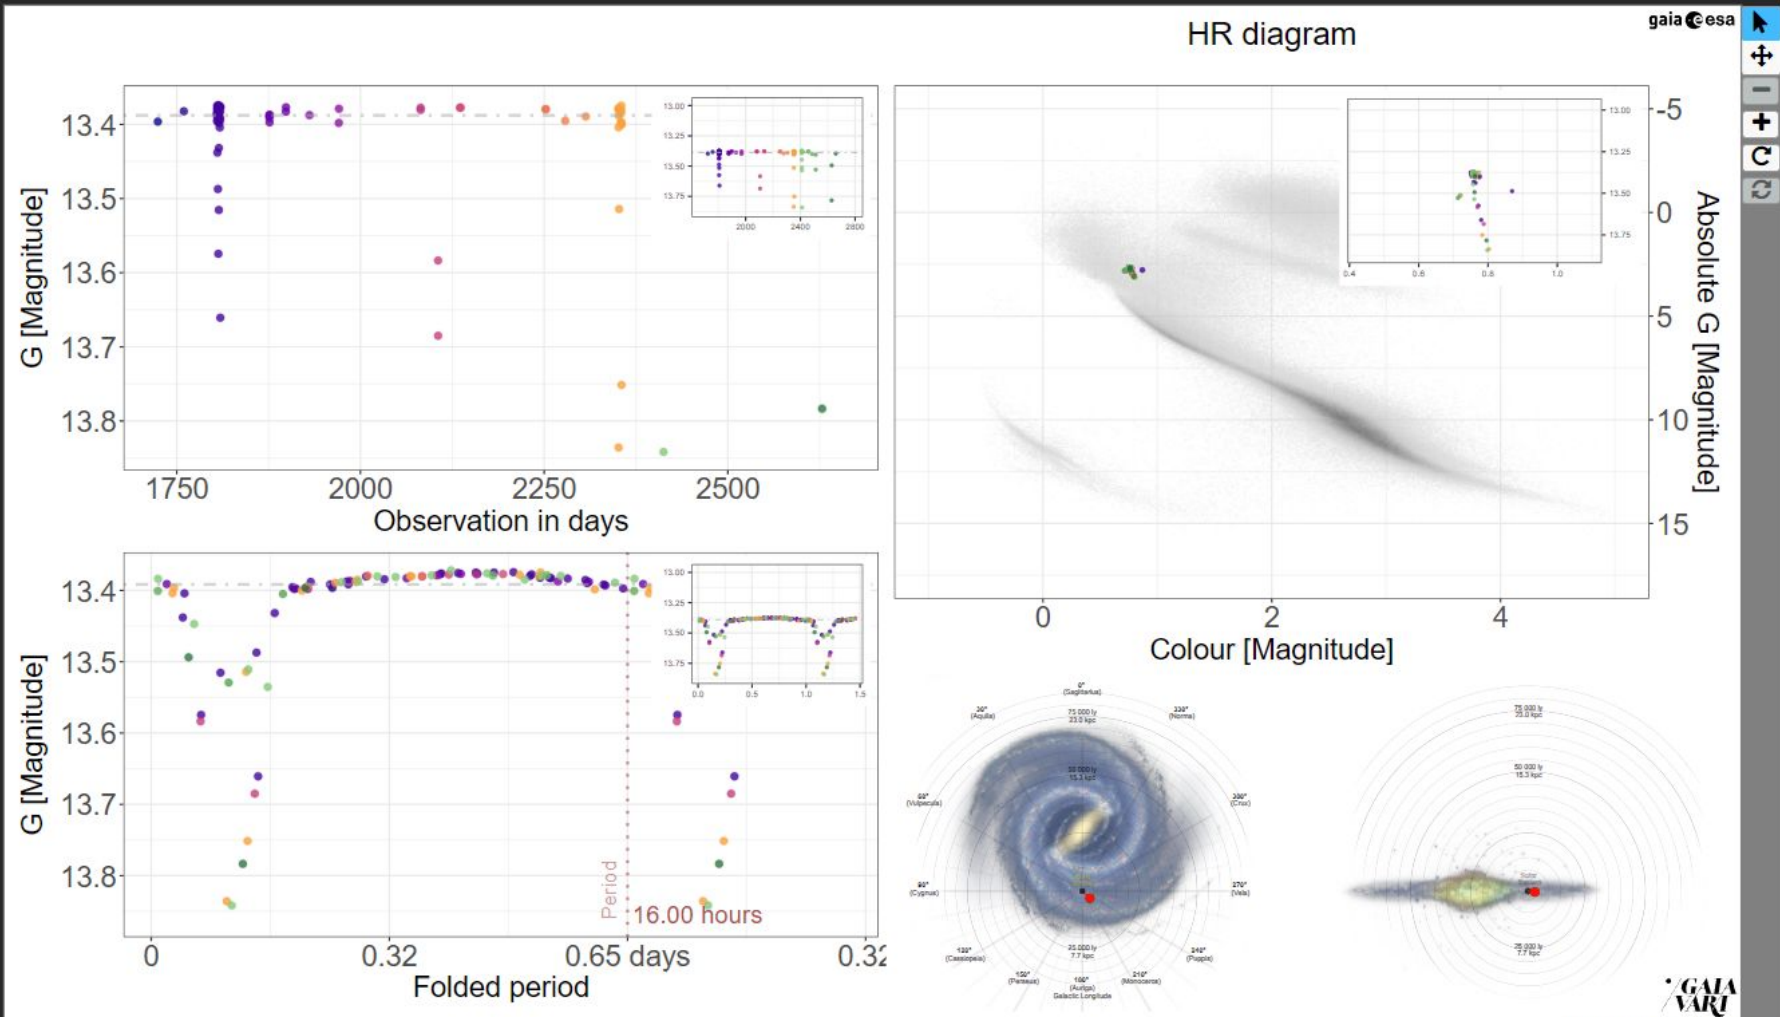
- Klasifikácia galaxií – od jednoduchšej po zložitý rozhodovací proces



Z GalaxyZOO vznikol Zooniverse  
=> platforma na anotovanie dát

# Zooniverse

Check **Gaia Vari Pick** - an interesting source spotted by citizen scientists and dive into discussion:  
<https://www.zooniverse.org/projects/gaia-zooniverse/gaia-vari/talk/subjects/85156015>



TASK

TUTORIAL

What type of variable object is it?

Eclipsing Binary

Cepheid

RR Lyrae

Long Period Variable

None of the above

NEED SOME HELP WITH THIS TASK?

Done & Talk

Done

# Zooniverse

The screenshot displays the Zooniverse interface for the project "Detekcia TLE". The main area shows a dark star field with a large, faint, curved object on the left. A vertical toolbar on the right side of the image contains icons for zooming in (+), zooming out (-), and other actions. The right-hand panel is titled "TASK" and "TUTORIAL". Under "Označ ho" (Label it), there are three items for classification: "Mrkva (Carrot sprite)" with a yellow square icon and "0 drawn", "Stĺp (Column sprite)" with a pink square icon and "0 drawn", and "Fontána (Jet, Starter)" with a cyan square icon and "0 drawn". At the bottom of the panel are "Back" and "Next →" buttons.

Detekcia TLE

ABOUT CLASSIFY TALK COLLECT RECENTS

TASK TUTORIAL

Označ ho

- Mrkva (Carrot sprite) 0 drawn
- Stĺp (Column sprite) 0 drawn
- Fontána (Jet, Starter) 0 drawn

Back Next →


# Príklady z našej skupiny

- Klasifikácia obrázkov SDSS či obsahujú lineárne artefakty (prelet družice, meteoru,...)
- Klasifikácia zemetrasení a explózií v seizmických dátach Fínskej siete
- Zhlukovanie premenných hviezd podľa ich typov
- Klasifikácia rádiových galaxií do rôznych typov
- Segmentácia koronálnych dier a aktívnych oblastí na Slnku + detekcia paralelných erupčných vlákien na Slnku
- Detekcia bleskov v rádiových spektrogramoch (YOLO detektor)
- Detekcia TLE bleskov v snímkach kamery AMOS + detekcia meteorov/satelitov + meteorické ozveny (všetko YOLO detektor)
- Predikcia geomagnetických búrok - DST index
- Predikcia ionosférických scintilácií (projekt ASPIS)
- Klasifikácia typov zákrytových premenných hviezd + odhad parametrov týchto systémov
- Segmentácia galaxií vhodných pre skúmanie galaktického warp-u




# Hľadanie lineárnych objektov v SDSS

- Jeden z prvých pokusov, inšpirovaný spoluprácou s kolegami s Chorvátska, v rámci COST akcie – vytriedenie snímok
- Sloan Digital Sky Survey – raw obrázky
- Lineárne objekty – **meteory**, satelity, ...
- Zooniverse – anotačný projekt
- Klasifikácia – obsahuje alebo neobsahuje



Áno

/



Nie

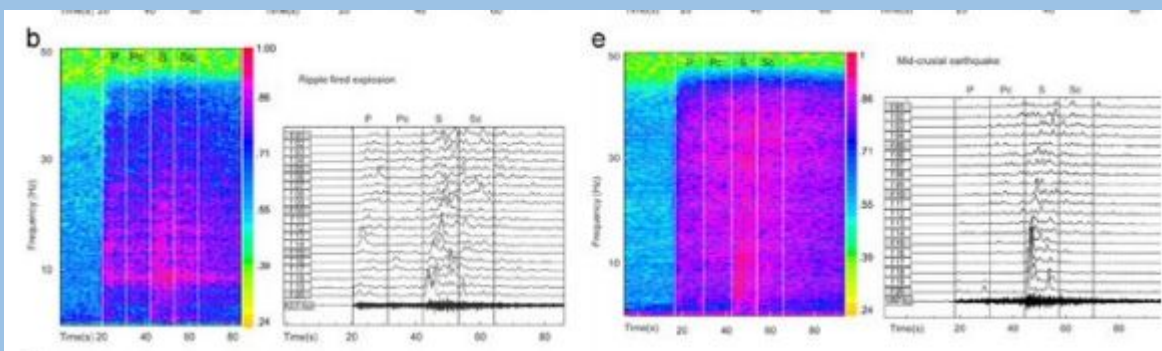
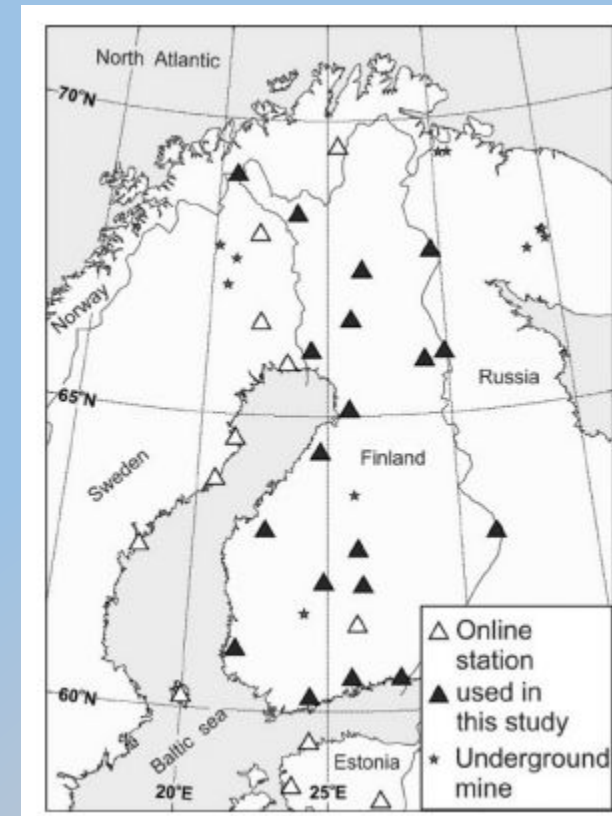
Layer (type)	Output Shape	Param #
zero_padding2d_1 (ZeroPadding2D)	(None, 130, 130, 1)	0
conv2d_1 (Conv2D)	(None, 128, 128, 64)	640
max_pooling2d_1 (MaxPooling2D)	(None, 63, 63, 64)	0
conv2d_2 (Conv2D)	(None, 63, 63, 64)	102464
max_pooling2d_2 (MaxPooling2D)	(None, 31, 31, 64)	0
conv2d_3 (Conv2D)	(None, 31, 31, 64)	36928
conv2d_4 (Conv2D)	(None, 31, 31, 64)	36928
max_pooling2d_3 (MaxPooling2D)	(None, 15, 15, 64)	0
flatten_1 (Flatten)	(None, 14400)	0
dense_1 (Dense)	(None, 96)	1382496
dropout_1 (Dropout)	(None, 96)	0
dense_2 (Dense)	(None, 96)	9312
dropout_2 (Dropout)	(None, 96)	0
dense_3 (Dense)	(None, 2)	194
Total params: 1 568 962		
Trainable params: 1 568 962		
Non-trainable params: 0		

Accuracy  
99,17%



# Klasifikácia zemetrasení a explózií

- Spolupráca s univerzitou v Helsinkách
- Fínska sieť seizmografov
- Výsledky sa podarilo zlepšiť, avšak len minimálne
- Vstupom boli spektrogramy, ktoré boli




Konvulučné neurónové siete

Acc 95%



		Actual	Values
		0	1
Predicted Values	0	1241	59
	1	26	401

Komprimované reprezentácie (definované seizmológmi ako ich určiť)

# Klasifikácia rádiových galaxií



- Khadija El Bouchefry - SARAQ (South African Radio Astronomy Observatory)
- Využitie augmentačných techník pre zlepšenie klasifikácie rádiových galaxií do 4 morfológických typov
- Dataset: 526 označených snímok z katalógu FIRST (Faint Images of the Radio Sky at Twenty Centimeters).
- Klasifikácia do 4 tried:
  - Fanaroff-Riley I (FRI),
  - Fanaroff-Riley II (FR II),
  - bent-tailed (BENT)
  - kompaktné rádiové galaxie (COMPT)
- Bez augmentácií 82%, s augmentáciami 96%



JOURNAL ARTICLE

Morphological classification of compact and extended radio galaxies using convolutional neural networks and data augmentation techniques

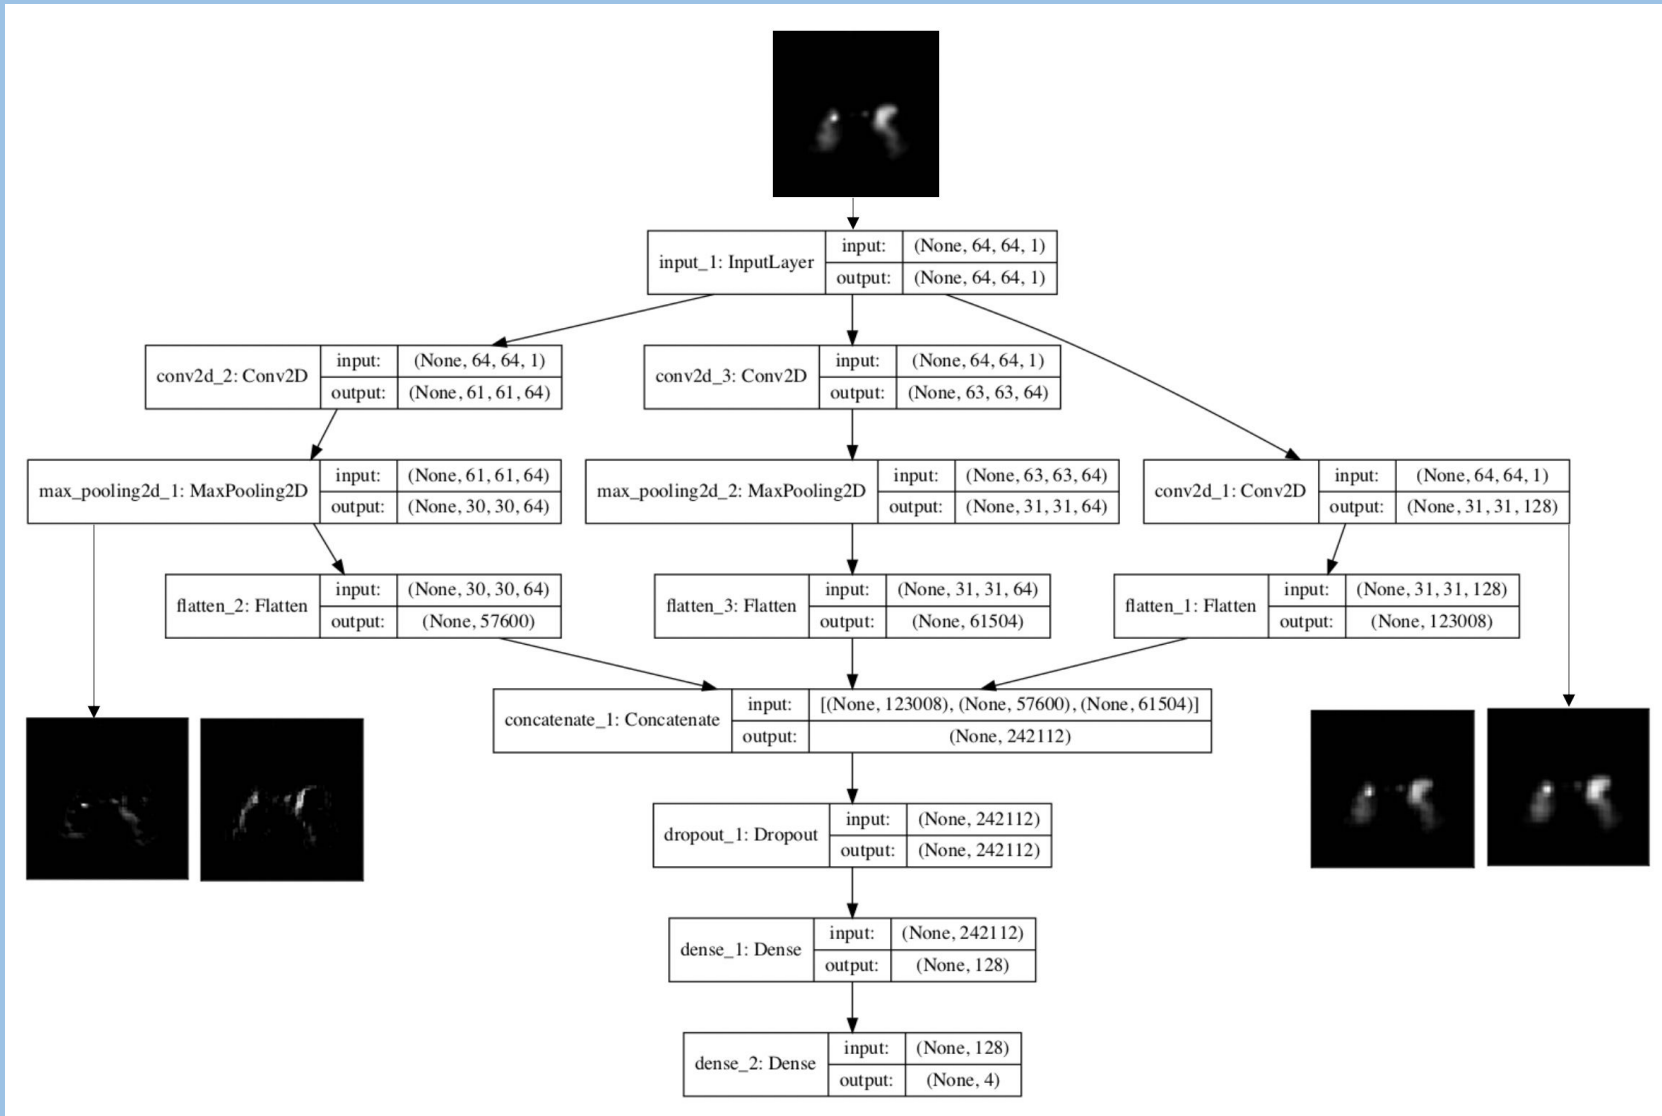
[Get access >](#)

Viera Maslej-Krešňáková, Khadija El Bouchefry, Peter Butka 

*Monthly Notices of the Royal Astronomical Society*, Volume 505, Issue 1, July 2021, Pages 1464–1475, <https://doi.org/10.1093/mnras/stab1400>


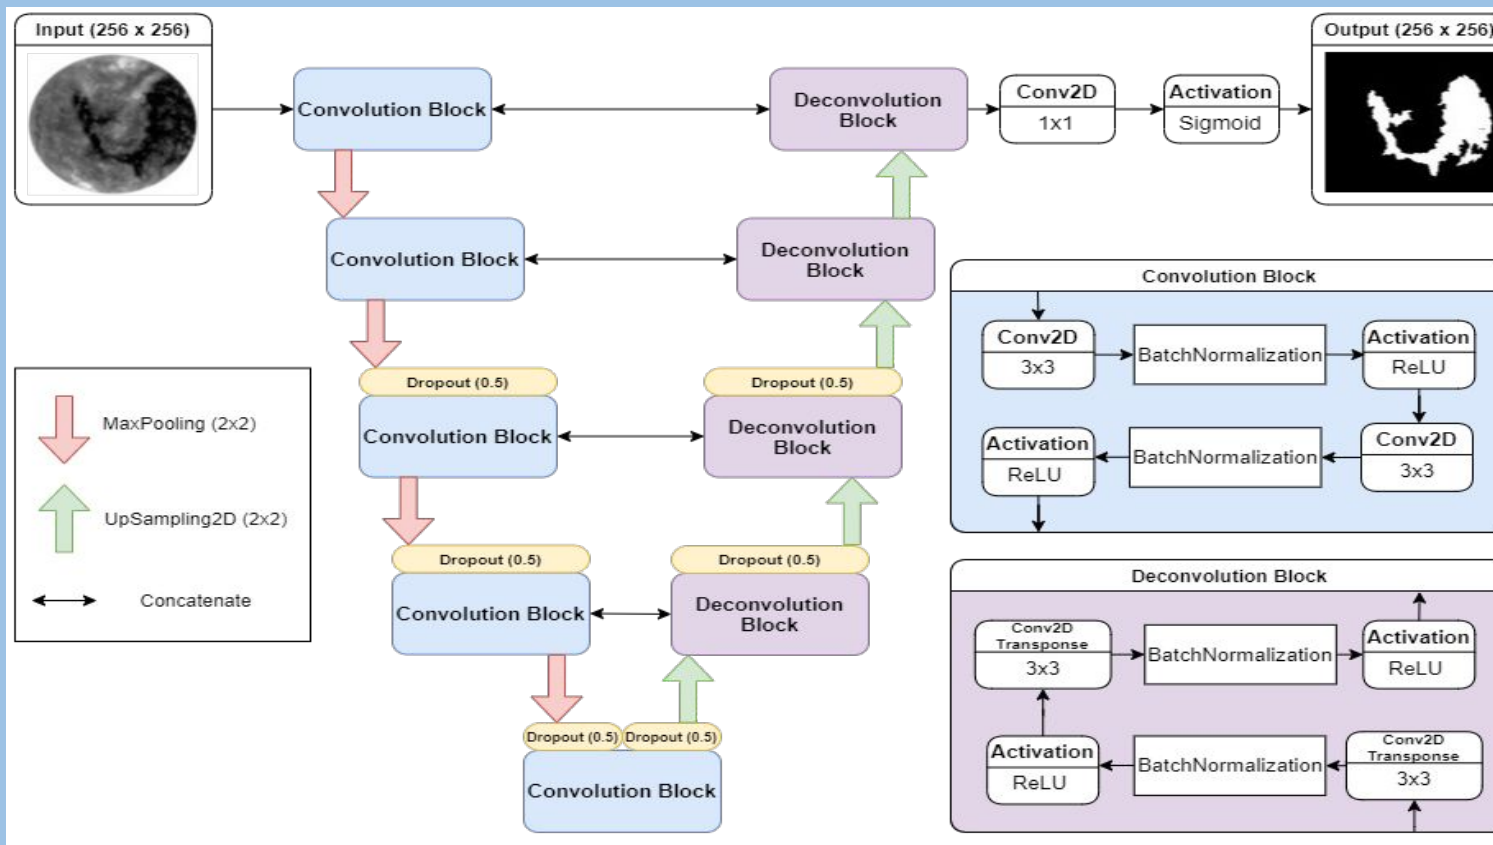

Published: 17 May 2021 [Article history](#) ▼

# Klasifikácia rádiových galaxií



# Segmentácia koronálnych dier a aktívnych oblastí na Slnku (SCSS-Net)



- ÚEF SAV – Šimon Mackovjak
- SDO (Solar Dynamic Observatory) + neskôr SOHO





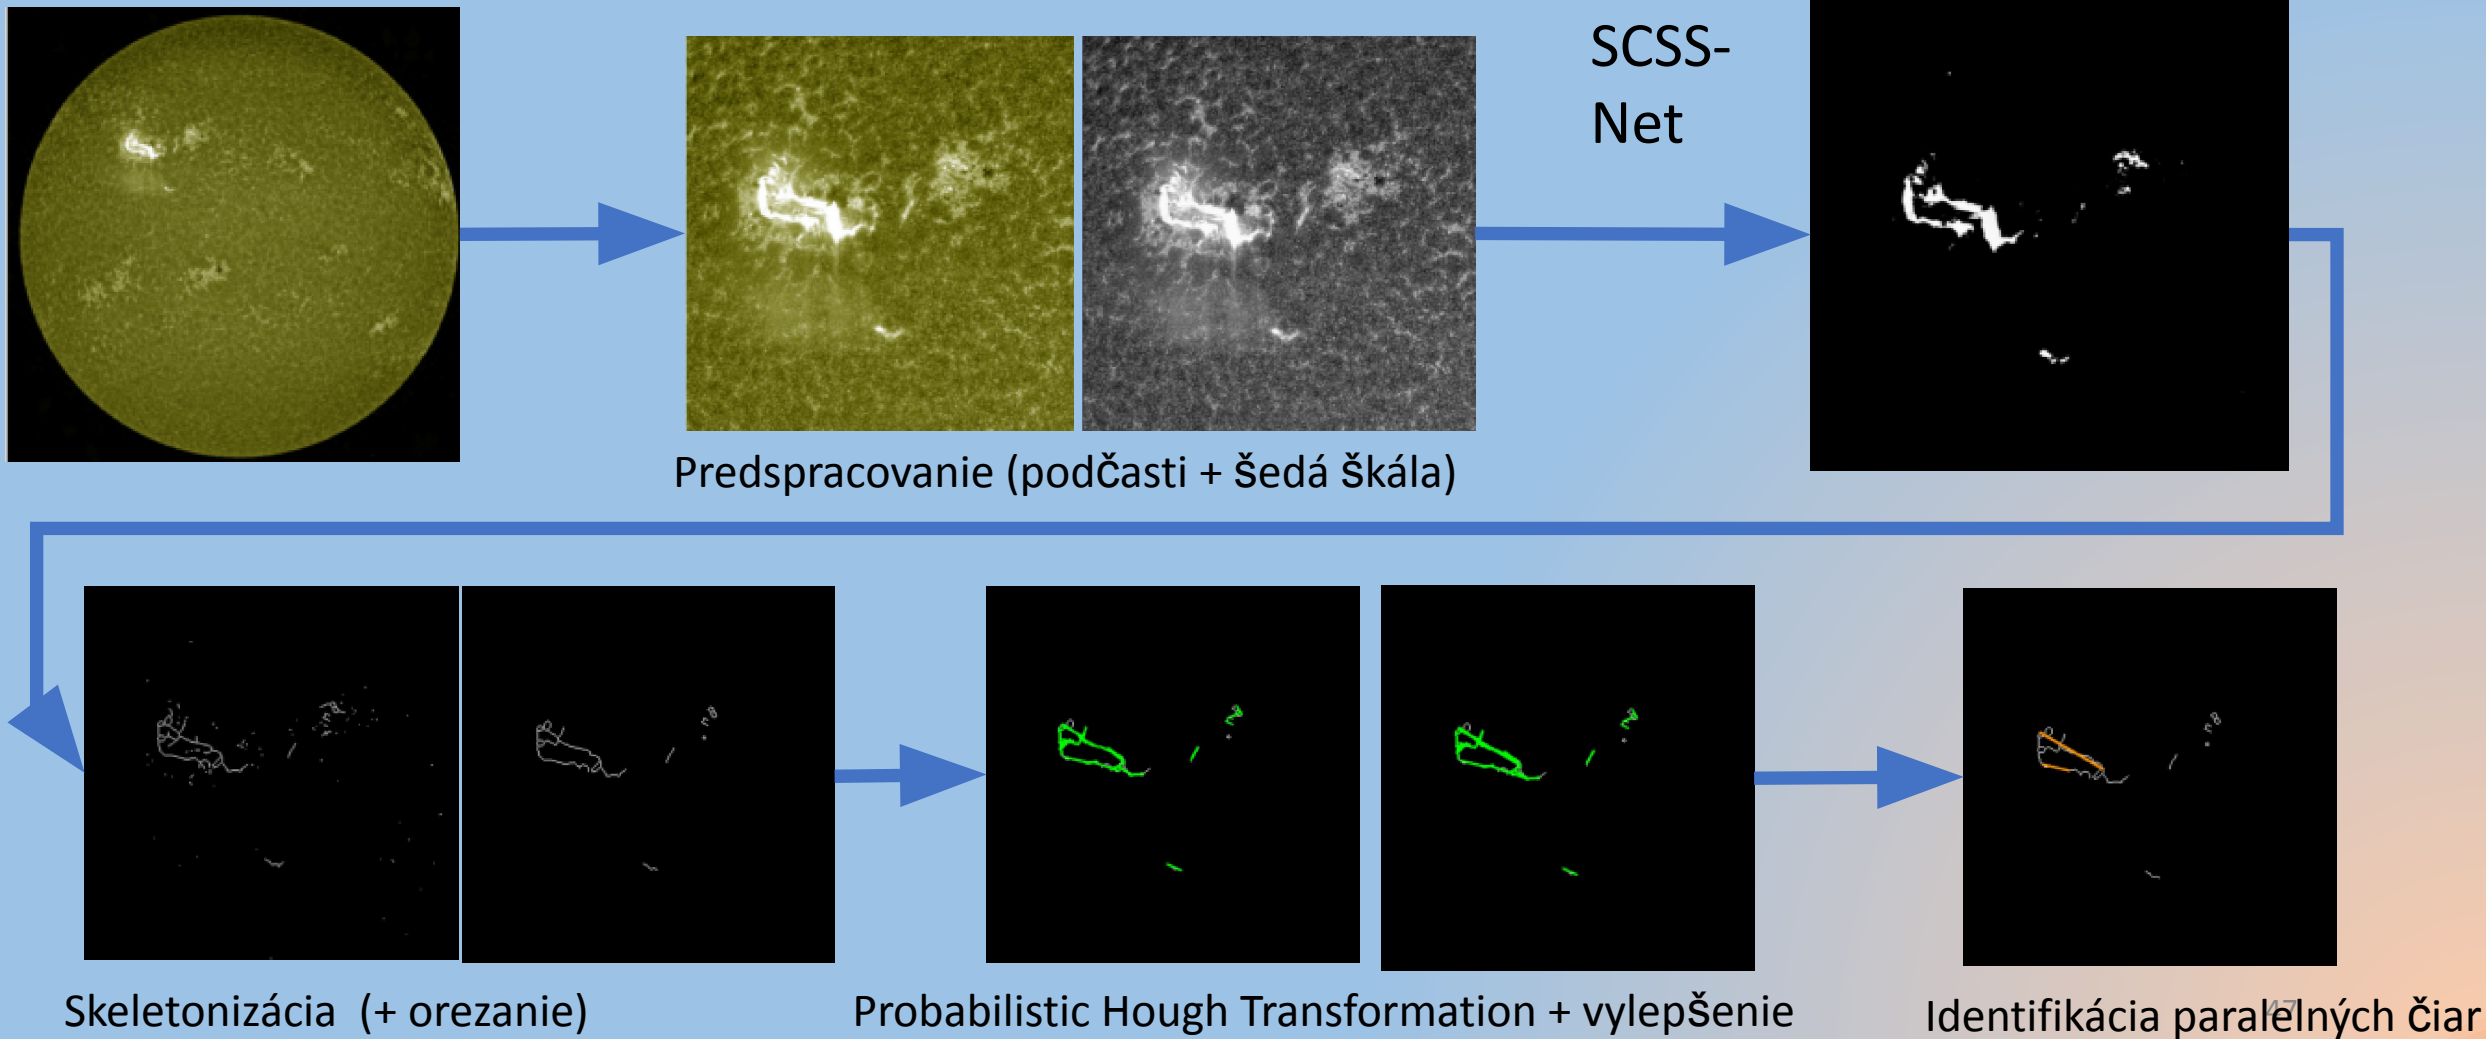
# Detekcia paralelných erupčných vlákien

- Šimon + Astronomický ústav AVČR
- Erupčné vlákna – paralelné štruktúry indikujú veľmi silné erupcie
- Vstupy: SDO / AIA 1600 Å + katalóg erupcií RibbonDB




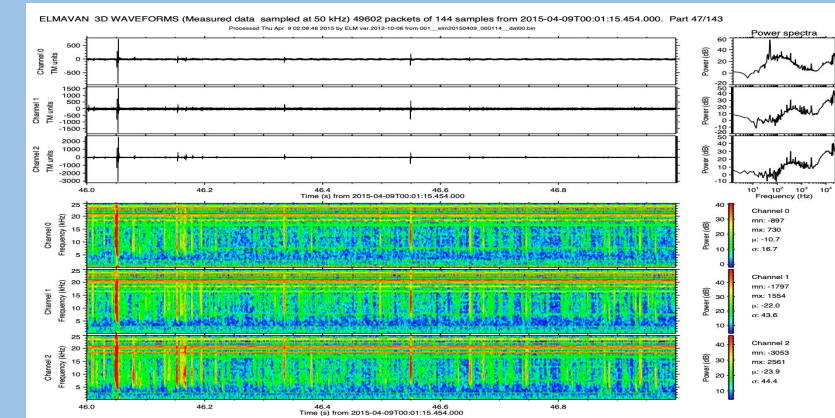


# Detekcia paralelných erupčných vlákien



# Detekcia bleskov v rádiových spektrogramoch

- ÚEF SAV + Inštitút fyziky atmosféry AVČR
- zdroj dát: analyzátor elektromagnetických vln ELMAVAN-G
- každých 24 hodín merania sa získa takmer 2600 snímok, čo je asi 950000 snímok za 1 rok.
- Anotačný projekt Zooniverse: 2300 obrázkov (3200 tweekov, 19000 sférikov)
- Kombinované riešenie: neurónové siete (detekcia, predikcia – sieť YOLO v.5) + deterministický prístup (určenie ďalších vlastností)
- Výsledok: tabuľka vyextrahovaných udalostí bleskov s vlastnosťami (čas, typ, pod/nad 2kHz, ... )




**Earth and Space Science**

Technical Reports: Methods | [Open Access](#) | [©](#) | [i](#) | [d](#) | [s](#)

**Automatic Detection of Atmospheric and Tweek Atmospheric in Radio Spectrograms Based on a Deep Learning Approach**


Viera Maslej-Krešňáková, Adrián Kundrát, Šimon Mackovjak, Peter Butka, Samuel Jaššur, Ivana Kolmašová, Ondřej Santolík

First published: 05 November 2021 | <https://doi.org/10.1029/2021EA002007>




# Dáta AMOS – TLE, meteory/statelity

- TLE (Transient Luminous Events) – bleskové javy v hornej atmosfére
- Niektoré z nich je možné pozorovať na snímkach celo-oblohových meteorických kamier AMOS (Univerzita Komenského v Bratislave, FMFI)



YOLO  
detektor



Zriedkavý jav  
cca 1:1000

Keď už sme  
mali dáta v  
dobrom  
množstve ...  
Vyskúšali sme si  
aj meteory a  
satelity 😊






# Dáta z meteorického radaru

- UK Bratislava / AGO Modra
  - Spektrogramy z radaru
  - Identifikácia meteorických radarových ozvien
  - rôznych typov
- + extrakcia  
času, vlastností,  
statistík, ...

V budúcnosti  
Nasadenie cez  
Raspberry Pi (?)



YOLO  
detektor

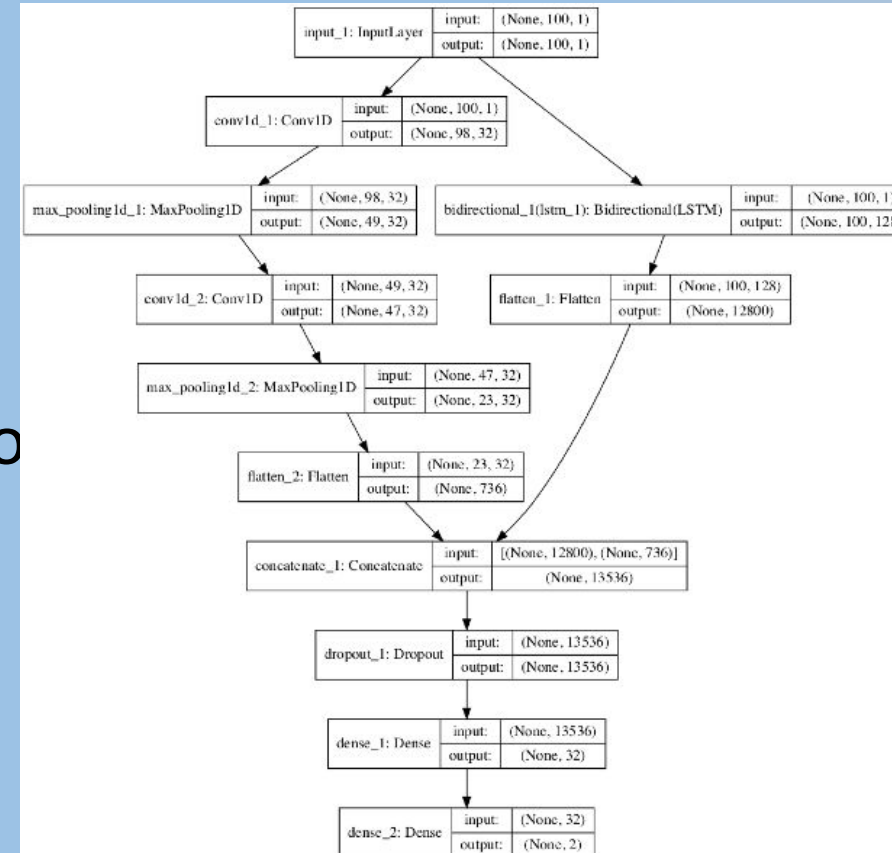




Full length article

# Automatic classification of eclipsing binary stars using deep learning methods

M. Čokina<sup>a</sup>, V. Maslej-Krešňáková<sup>b</sup>, P. Butka<sup>b</sup>, Š. Parimuča<sup>a</sup>

# Zákrytové premenné hviezdy

- Prírodovedecká fakulta UPJŠ
- Klasifikácia typov zákrytových systémov
  - Dotykové vs. Oddelené
  - Úspešné (accuracy – 98-100%)
- Odhad parametrov systému
  - Pomer teplôt, pomer hmotností, ...
  - Menej úspešné – skúšame ďalej
- Použitie softvéru ELISA generujúceho simulované krivky pre rôzne parametre binárneho systému

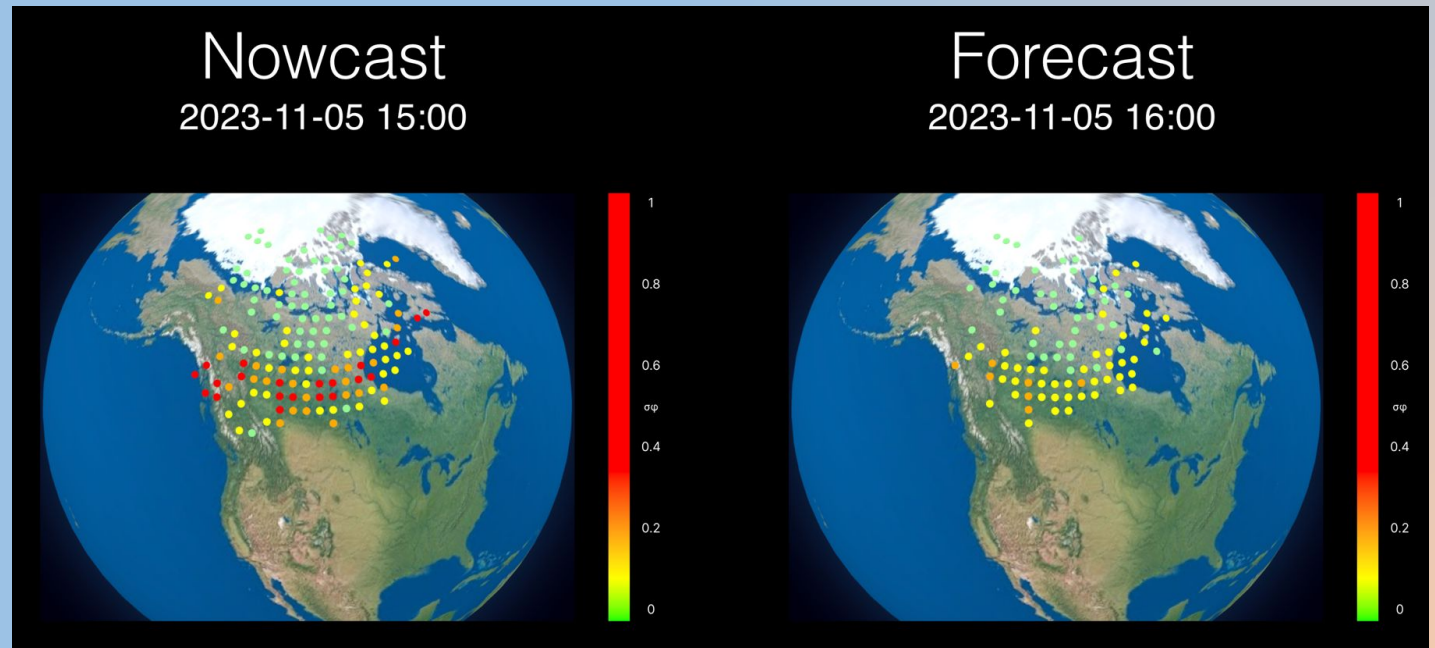



Klasifikačná sieť:  
Kombinácia Conv-1D a LSTM





# ASPIS – predikcia ionosférických scintilácií

- ESA projekt ... ÚEF SAV + KKUI FEI TUKE + Global Logic
- Predikcia toho či nastane scintilácia ... prináša to napr. riziko výpadku navigačných systémov
- LSTM siete pre predikciu scintilačného indexu + služba na predikciu



# Segmentácia galaxií pre skúmanie warp-u

- FMFI UK v Bratislave
- Galaktický warp – disk galaxií je ohnutý
- Chceli by sme pomôcť získať dáta na štúdium warpov
- Prvý krok – segmentácia vhodných galaxií
  - SDSS, „edge-on“ galaxie, s minimálnou kontamináciou hviezdami z našej galaxie
  - Tento krok už je realizovaný
  - **Zooniverse (anotácie) + YOLO + U-Net**
- Druhý krok – určenie warpu segmentovaných galaxií  
(dúfame že už čoskoro sa to opäť rozbehne)



Ďakujem za pozornosť