


11.9.2025 Technical Computing Camp 2025

Detekcie anomálií v signálových a obrazových dátech



Michal Blaho

blaho@humusoft.sk

www.humusoft.cz

info@humusoft.cz

www.mathworks.com

Prečo uvažovať o detekcii anomálií?



Monitorovanie procesov

- Zlepšenie dostupnosti zariadenia
- Sledovanie spotreby energie
- Spravovanie zásob



Kontrola kvality

- Diagnostika defektov na výrobnéj linke
- Optimalizácia zisku



Prediktívna údržba

- Predikcia porúch na zariadeniach
- Skracovania prestojov



Dátová analytika

- Odstránenie zlých meraní snímačov
- Pochopenie problémov s činnosťou

Anomálie v prediktívnej údržbe

**Funguje moje
zariadenie
správne?**

Detekcia anomálií

Potrebujem pomoc.

**Prečo sa moje
zariadenie správa
abnormálne?**

**Detekcia porúch
(Diagnostika)**

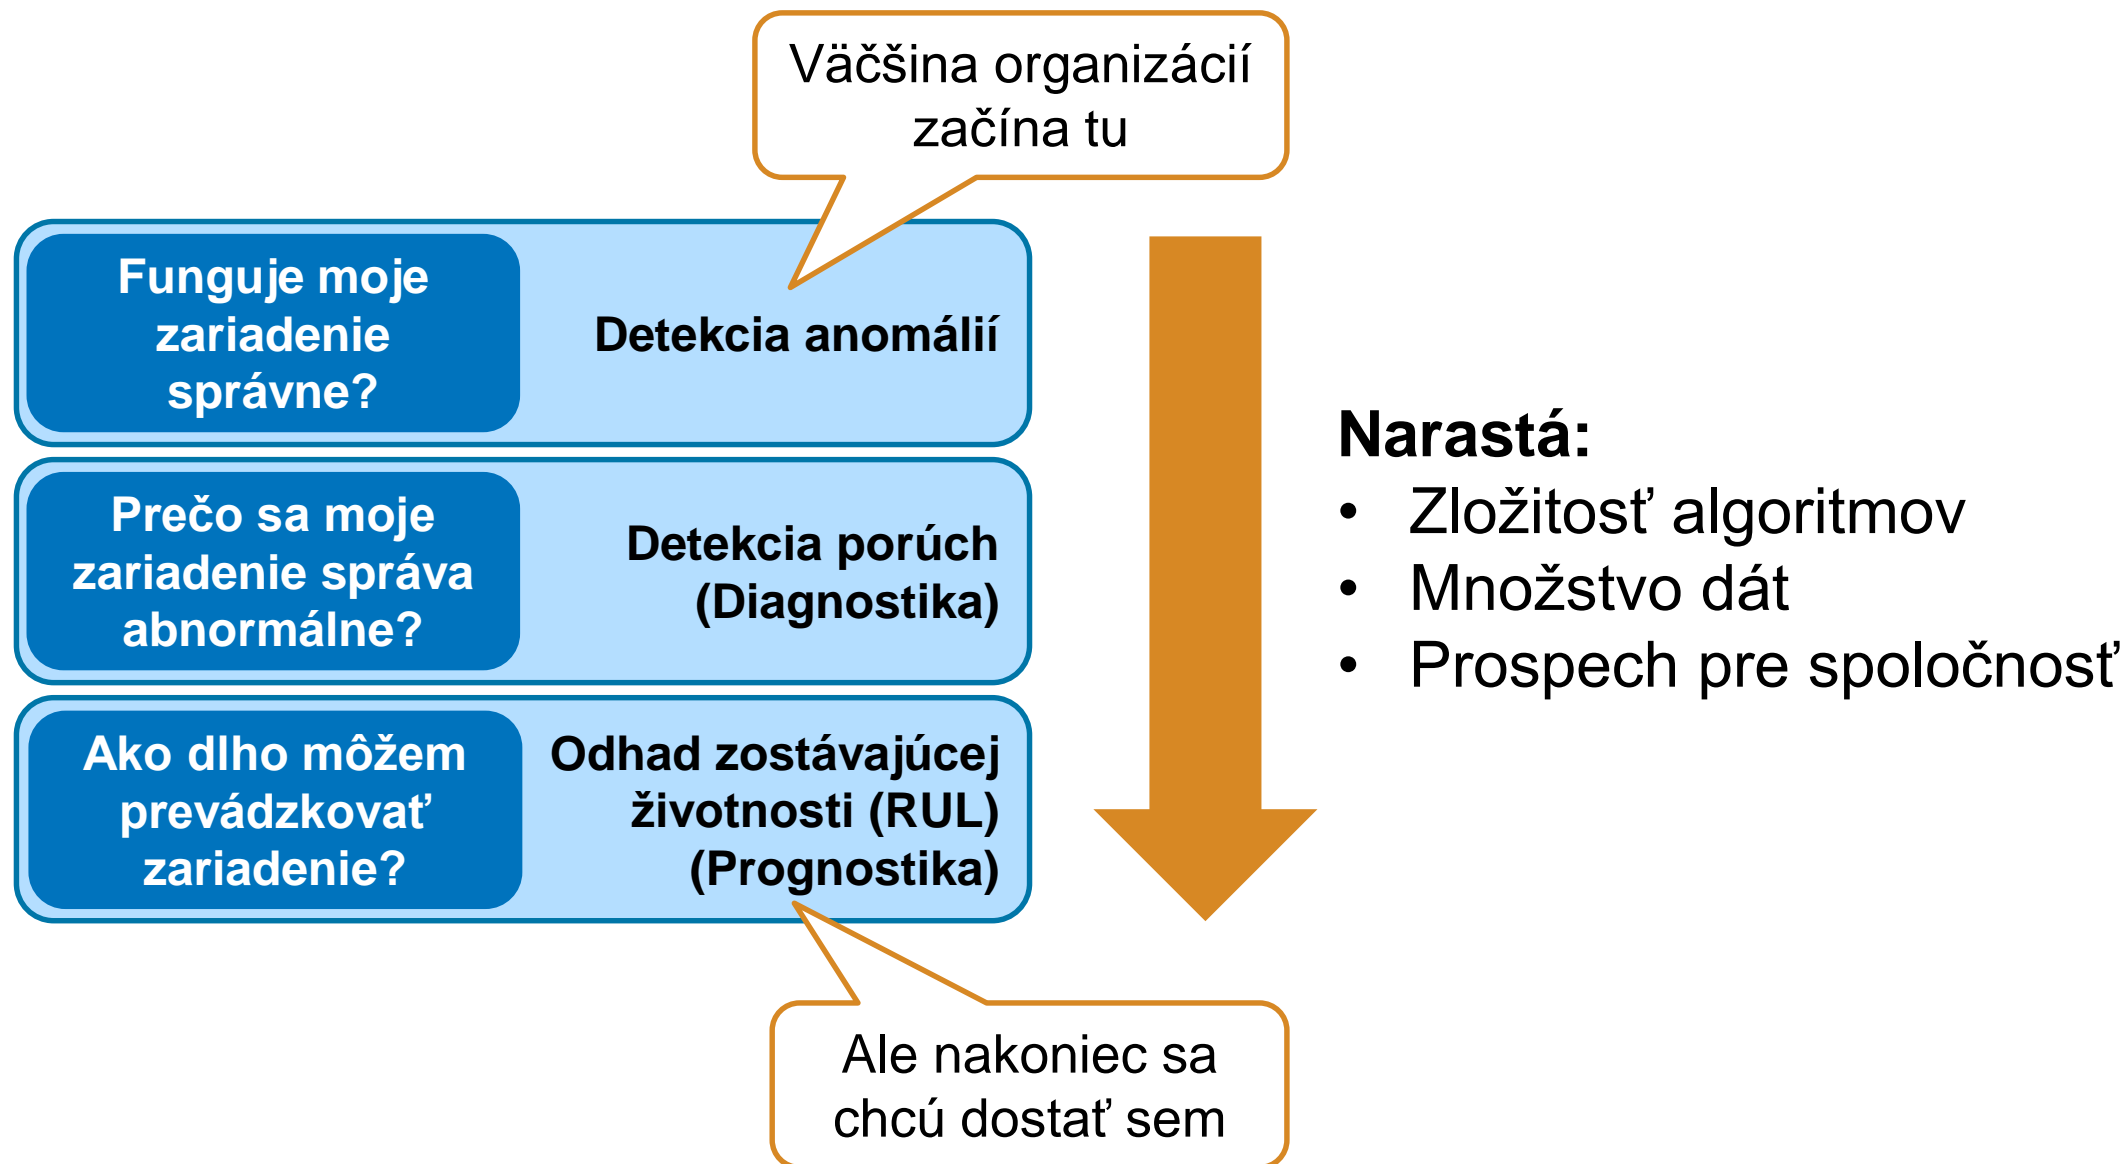
Jeden z mojich valcov je zablokovaný.

**Ako dlho môžem
prevádzkovať
zariadenie?**


**Odhad zostávajúcej
životnosti (RUL)
(Prognostika)**

Linka sa vypne o 15 hodín.


Anomálie v prediktívnej údržbe



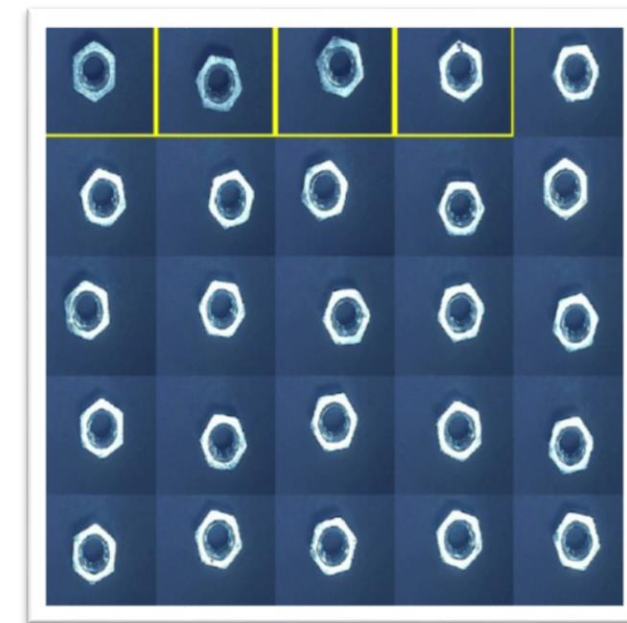
Anomálie – správanie odchyľujúce sa od „normálu“



Krátke jednotlivé anomálie v signáloch



Kolektívne anomálie vo viacerých signáloch

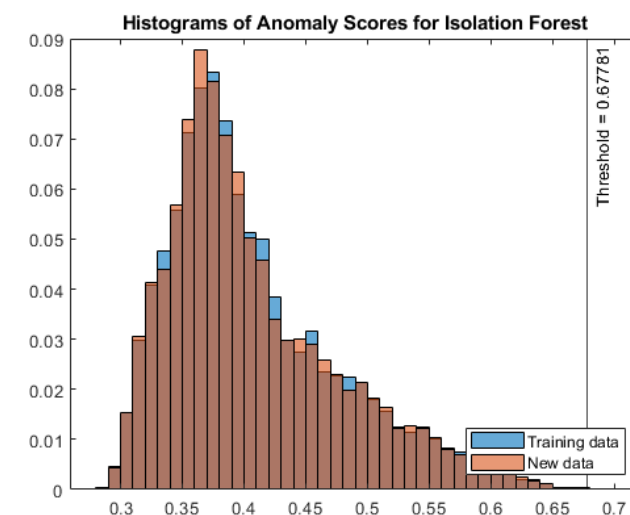



Vizuálne anomálie v obrázkoch

Deje sa niečo, čo sa diať nemá?

Prístupy detekcie anomálií v signáloch

- Štatistika & vzdialenosť
 - changepoint detection, outlier detection, robust covariance, mahalonobis distance, matrix profile
- Špecializovaná AI modely, One-Class AI
 - TCN network, CNN network, dual-encoder, ...
 - autoencoders, one-class SVM, isolation forest
- Zoskupovanie (Clustering)
 - k-means, gaussian mixture models, self-organizing maps, ...



Prístupy detekcie anomálií v signáloch

Skúmanie dát

Skúmanie vzorov a anomálií v existujúcich historických dátach

Možné ciele:

- Pochopenie správania sa systému v minulosti
- Skúmanie kvality a vhodnosti dát
- Označenie historických dát
- Rozhodovanie sa na základe dát



Tvorba AI algoritmu

Trénovanie AI modelu na historických dáta a rozhodovanie na nových dátach

Možné ciele:


- Tvorba automatizovaného monitorovacieho systému pre zariadenia
- Nasadenie algoritmov na zariadenia
- Rýchla odpoveď na anomálie



Detekcia anomálií porovnávaním vzdialeností

R2024b

- Detekcia opakujúcich sa vzorov anomálií v časových radách
- Indikácia anomálií
 - motifs – bežné opakované sekvencie
 - discords – jedinečné sekvencie
- Nevyžaduje
 - trénovanie modelu, označovanie dát
- Funkcie
 - similarityDistance
 - distanceProfile
 - matrixProfile
 - findDiscord, findMotif



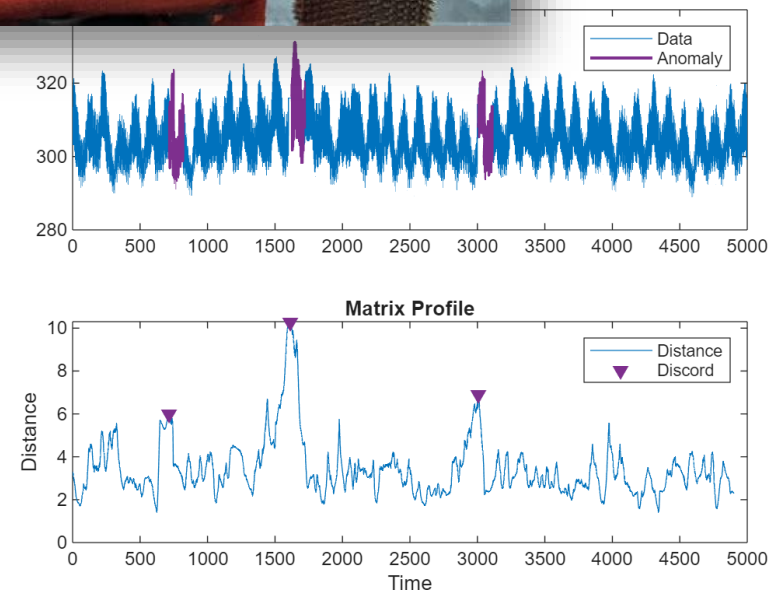

Ukážka: Anomálie v prúde servomotora

- Úloha

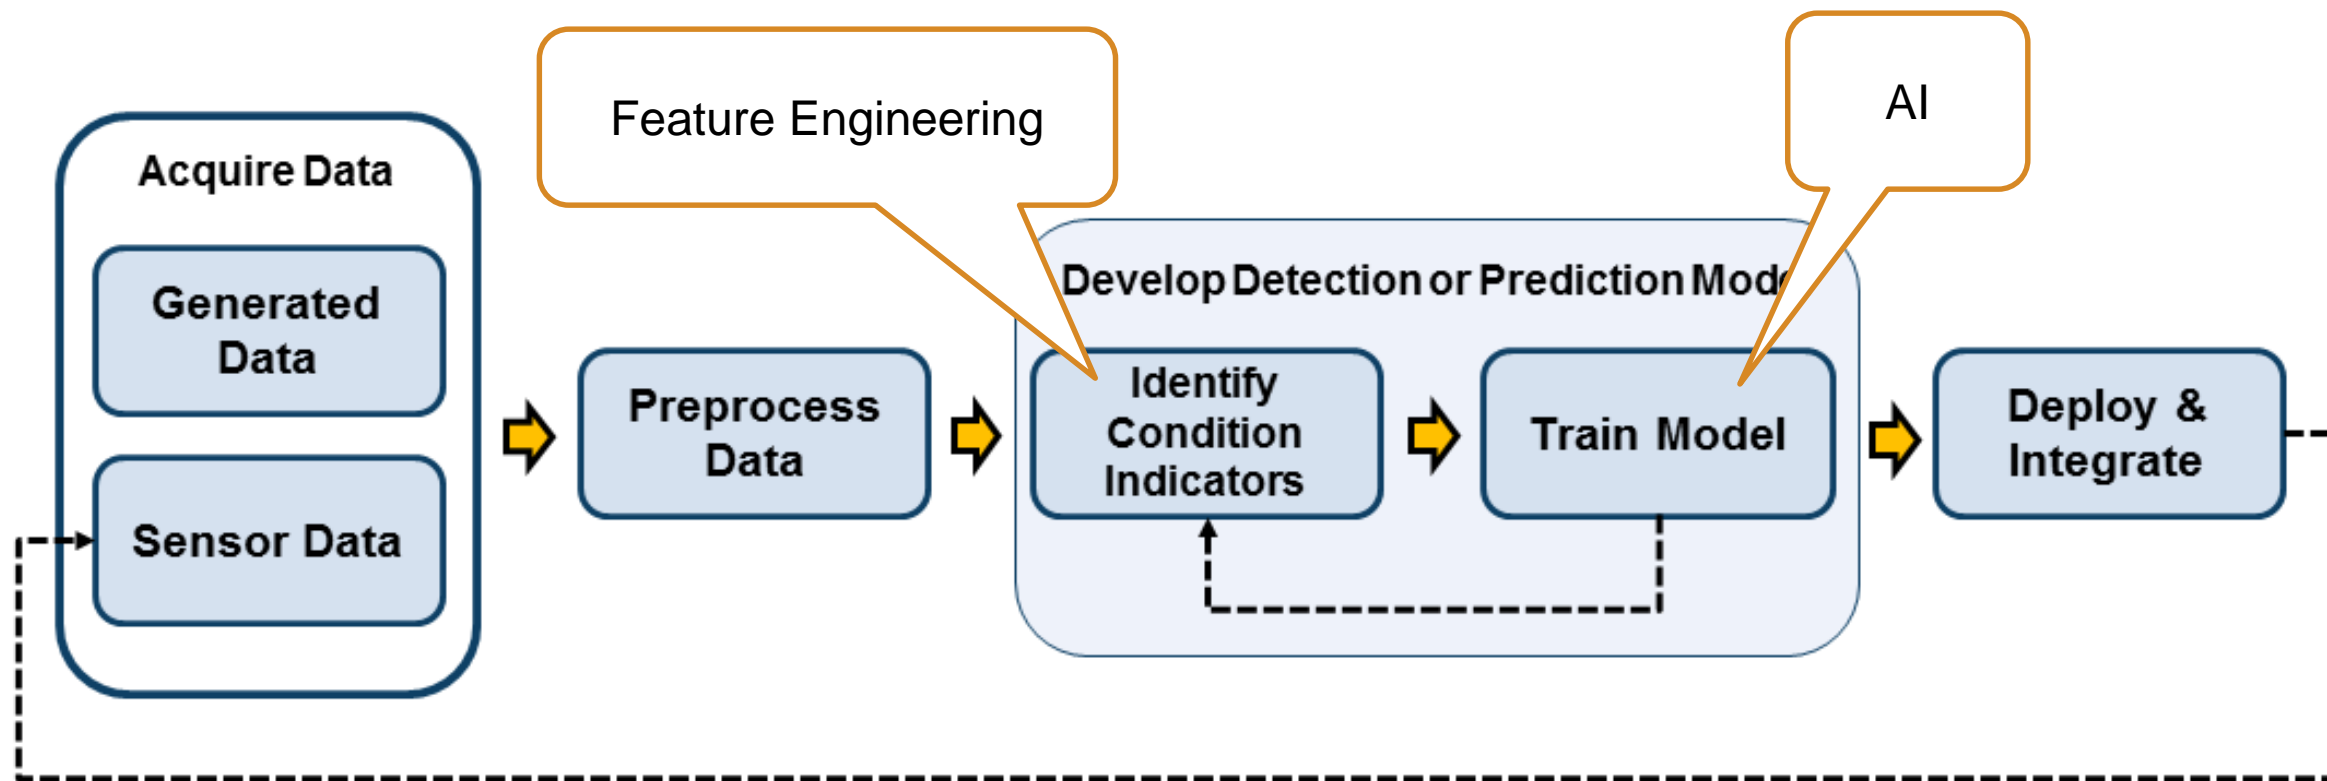
- nájsť anomálie v historických dátach
- časová rada prúdu servomotora
- anomálie sú v časti dát

- Riešenie

- stanovenie dĺžky okna
- skúmanie dát interaktívne
 - distanceProfile
- identifikácia oblastí najvýraznejších anomálií
 - matrixProfile


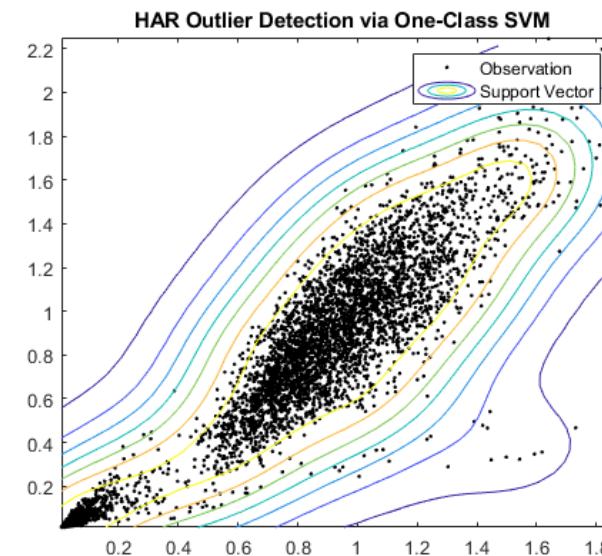


Detekcia anomalií pomocou AI



Detekcie anomálií pomocou One-Class AI

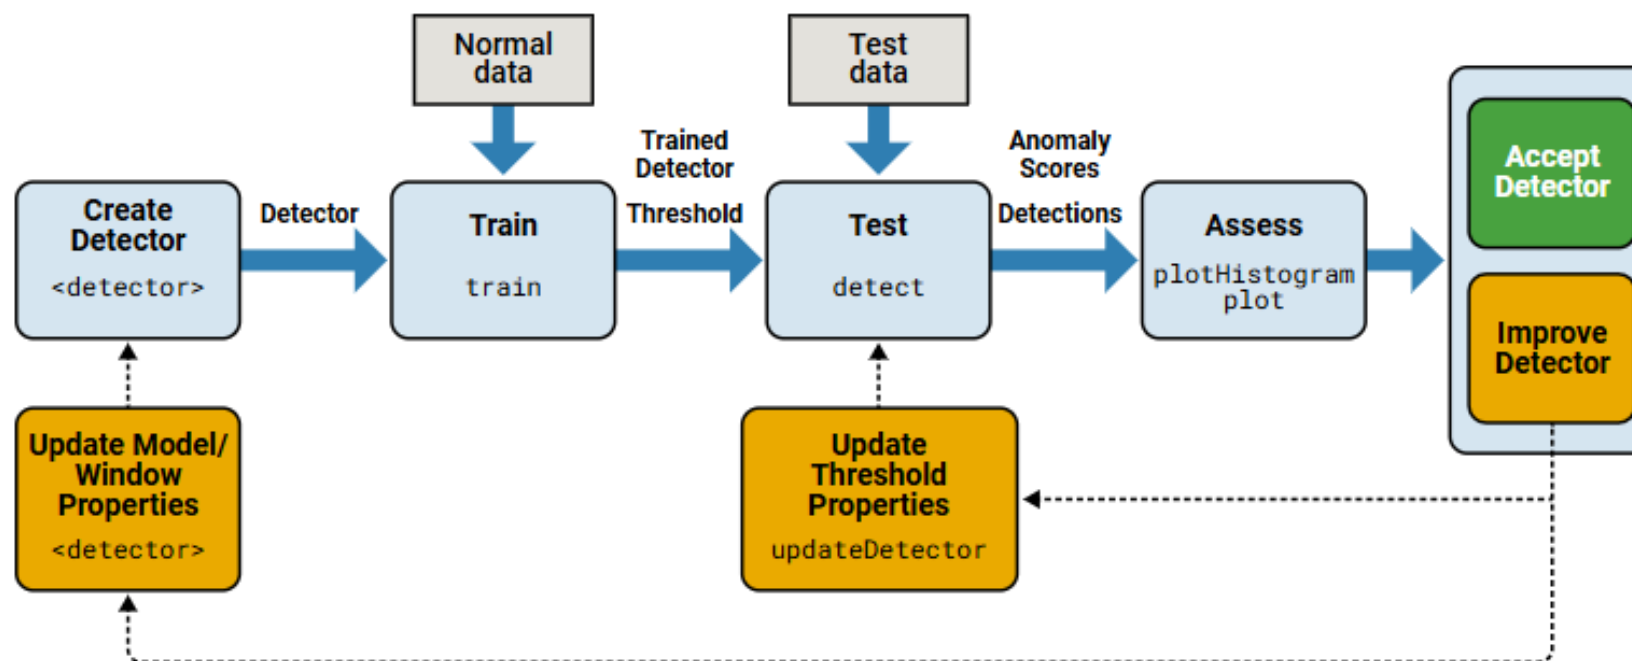
- One-Class Support Vector Machine (SVM)
 - identifikuje hyperplochu, ktorá dobre zachytáva normálne dáta a oddeľuje ich od anomálií
- Isolation Forest
 - rekurzívne rozdeľuje binárne dáta; anomálie vyžadujú menej delení pre oddelenie od normálnych dát
- LSTM Autoencoder
 - využíva neurónovú sieť uses na kompresiu a rekonštrukciu normálnych dát; anomálie sa identifikujú chybou pri rekonštrukcii



Detekcia anomálií pomocou Deep Learning modelov

R2025a

- Predpripravené detektory – Predictive maintenance toolbox
 - tcnAD (TCN network), usAD (unsupervised dual-encoder network)
 - deepantAD (CNN network), vaelstmAD (variational autoencoder + LSTM)




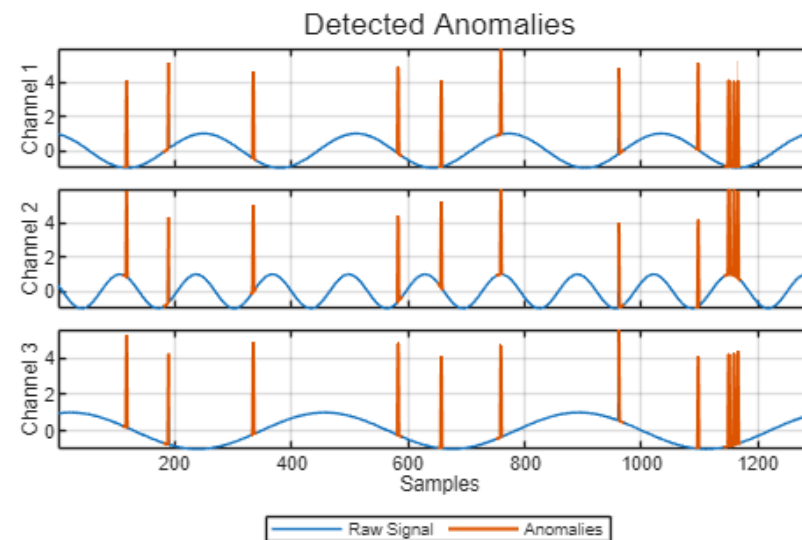
Ukážka: Trénovanie TCN detektora anomálií

- Úloha

- detegovať anomálie v signáloch
- trénovať a testovať TCN detektor

- Riešenie

- načítať signály (normálne, s anomáliami)
- vytvorenie objektu detektora
- natrénovanie detektora
- využitie detektora na identifikáciu anomálií
- zobrazíť výsledky



Čo je to automatizovaná vizuálna inšpekcia?

*“Automatizovaná vizuálna inšpekcia je **obrazová** alebo **vizuálna kontrola** výrobných dielov, pri ktorej kamera skenuje testované zariadenie z hľadiska **porúch** a **chýb v kvalite**.”*

Automated Defect Detection

Machine Vision

Optical Inspection

Automated Inspection

Typický systém vizuálnej inšpekcie

Inspection Cameras





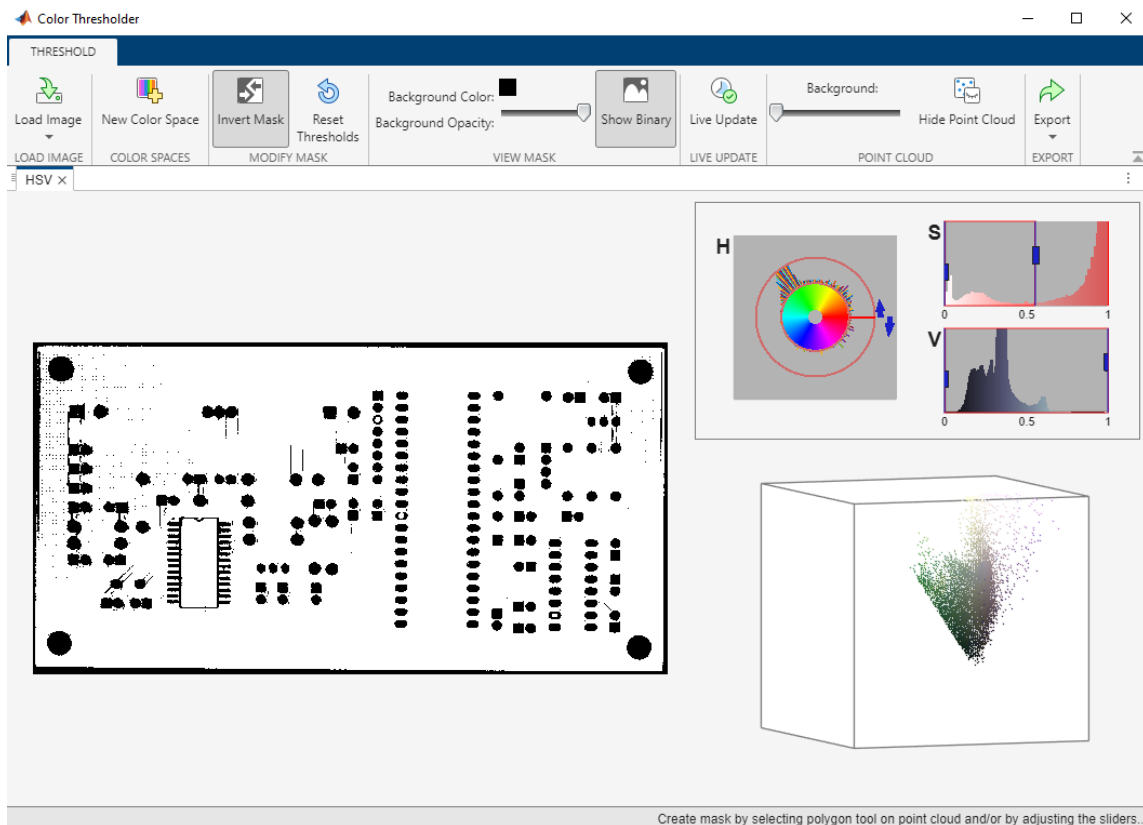


Image Analysis



Defective Parts

Klasické spracovanie obrazu



Color Thresholder

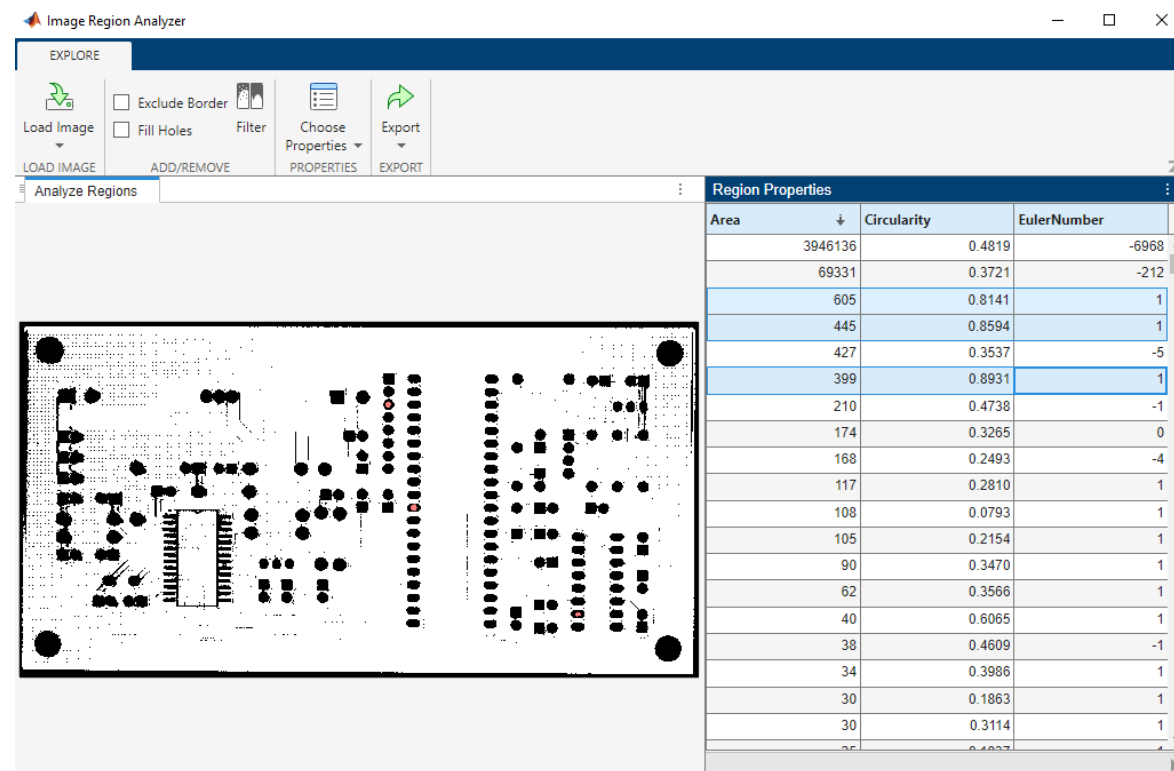

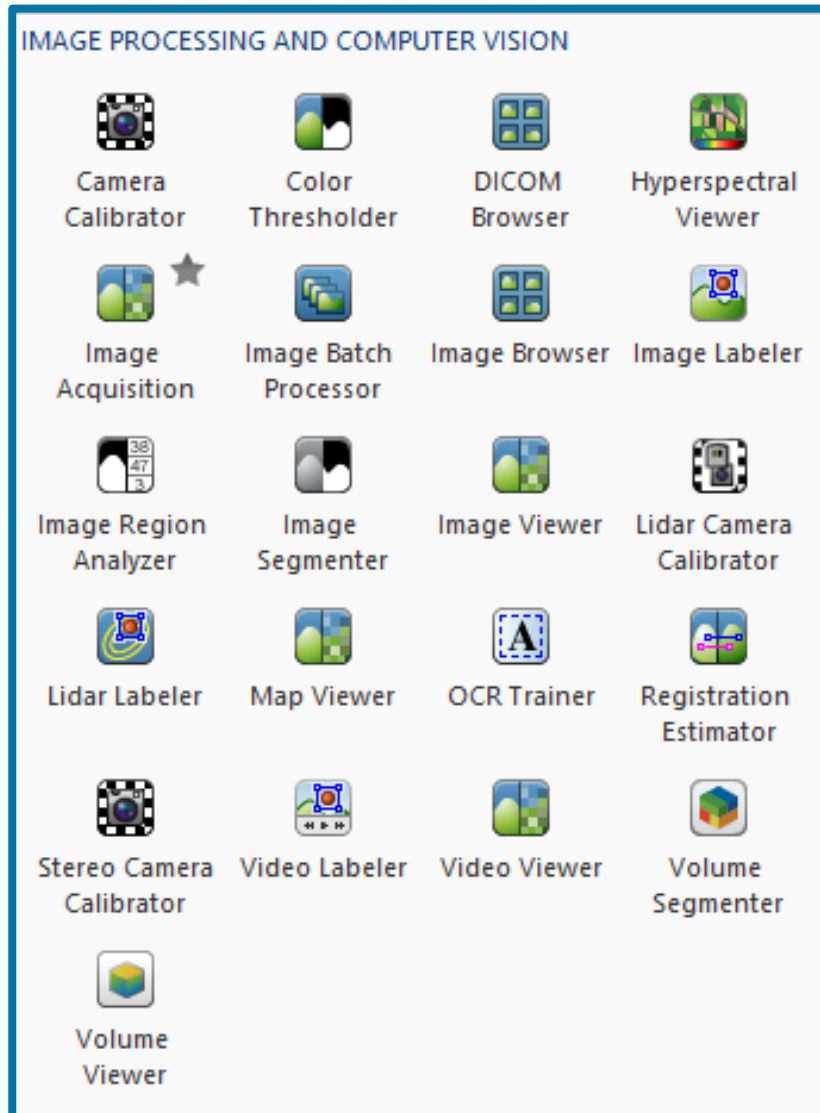
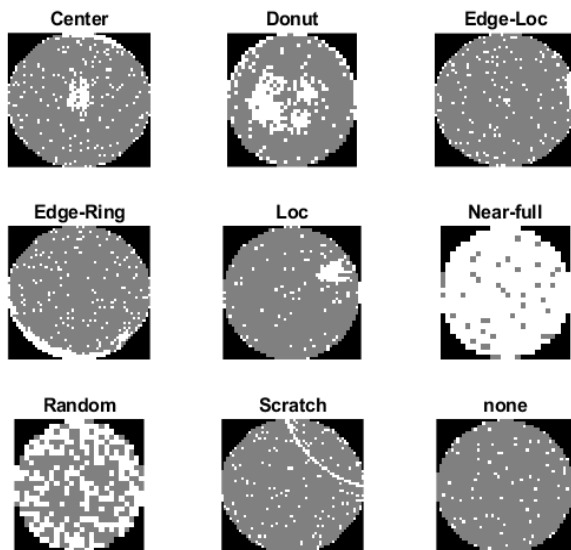


Image Region Analyzer

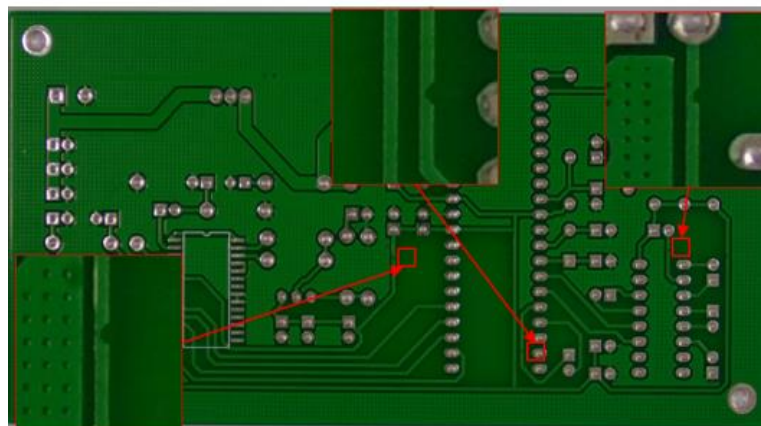
Aplikácie na uľahčenie práce



Typy detekcie defektov

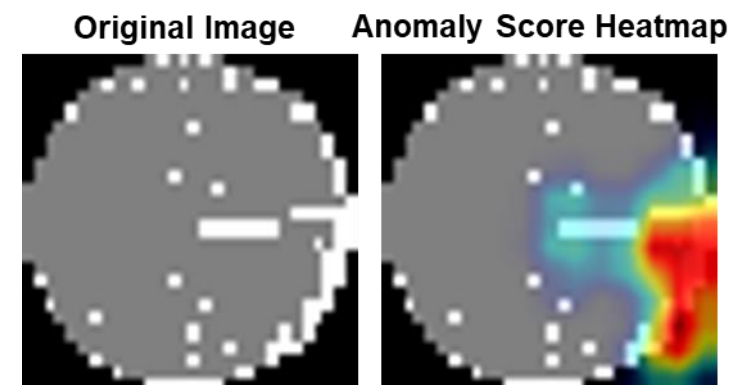


Klasifikácia defektov



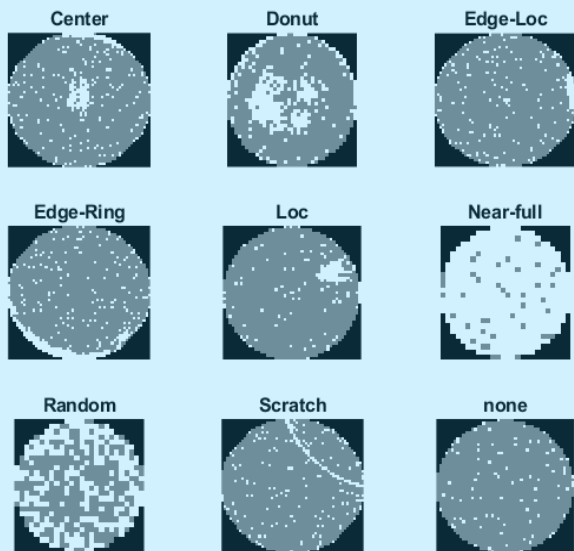
(a) PCB with mouse bite.

Počítanie, prítomnosť a lokalizácia objektov




Detekcia anomálií

Klasifikácia defektov




Klasifikácia defektov




(a) PCB with mouse bite.

Počítanie, prítomnosť a lokalizácia objektov




Detekcia anomálií

Vytvorenie CNN v prostredí MATLAB



Deep Network Designer



Pripravené funkcie

```
layers = [imageInputLayer(inputSize)
convolution2dLayer(filterSize,numFilters)
reluLayer()
maxPooling2dLayer(poolSize)
fullyConnectedLayer(numClasses)
softmaxLayer()];
```

Prispôsobenie na mieru

učenie
v rámci
aplikácie

```
options = trainingOptions('sgdm');
net = trainnet(data, layers, lossFcn, options);
```

```
scores = minibatchpredict(net, newData);
label = scores2label(scores, classNames)
```

vhodné pre väčšinu úloh

užívateľské slučky pre učenie sietí
automatická diferenciácia
zdieľané váhy
užívateľské stratové funkcie
...

GAN, CGAN, siamské siete, ...


Príklad: Tvorba jednoduchej siete

- Úloha

- klasifikovať defekty v betóne
- vytvoriť jednoduchú CNN sieť

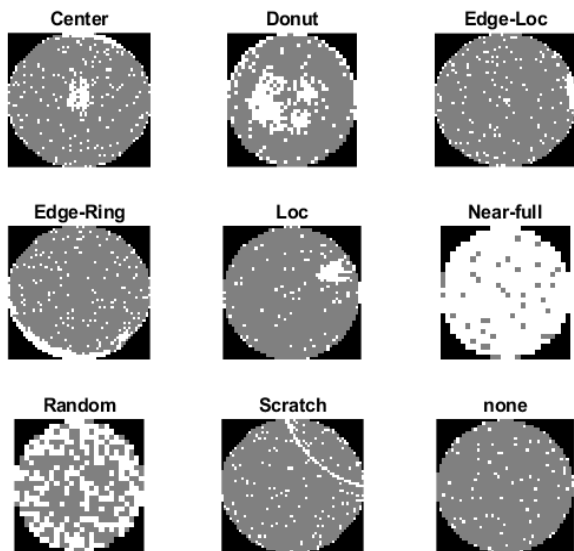
- Riešenie

- načítanie a vizualizácia dát
- rozdelenie dát na tréningové a testovacie
- definícia vrstiev siete
- nastavenie vlastností tréningovania
- tréningovanie siete
- vyhodnotenie presnosti siete




True Class	Negative	113	12
	Positive	5	120
		Negative	Positive
		Predicted Class	

Počítanie, prítomnosť a lokalizácia objektov




Klasifikácia defektov




(a) PCB with mouse bite.

Počítanie, prítomnosť a lokalizácia objektov



Detekcia anomálií

Počítanie, prítomnosť a lokalizácia objektov



(a) PCB with mouse bite.

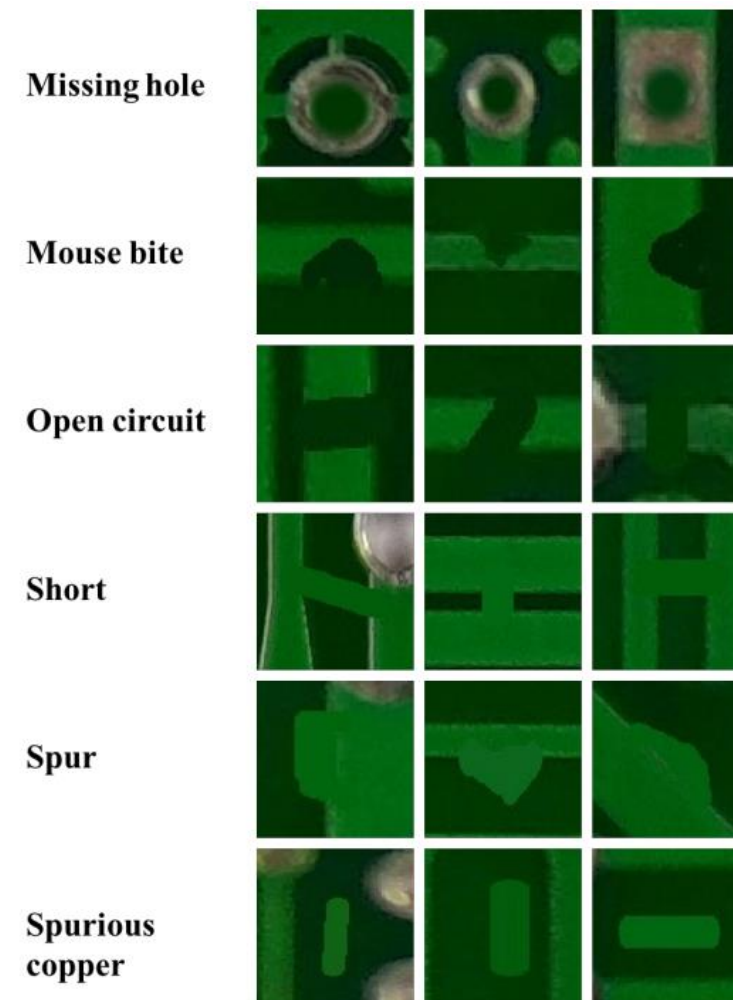




Fig. 11. An example of the training data for neural network. All the resolutions of the images are resized to 64×64 .

Detektory objektov

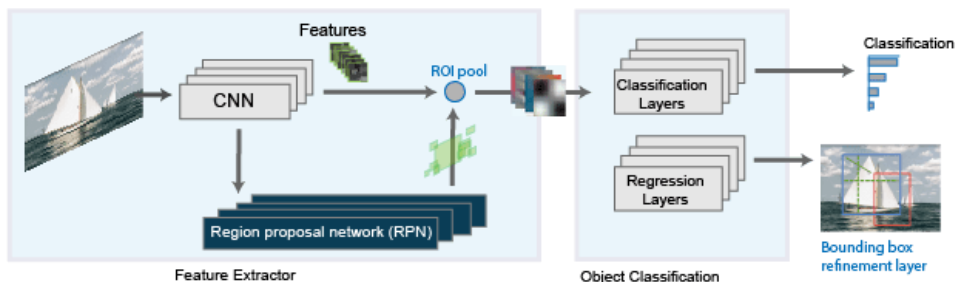
SSD



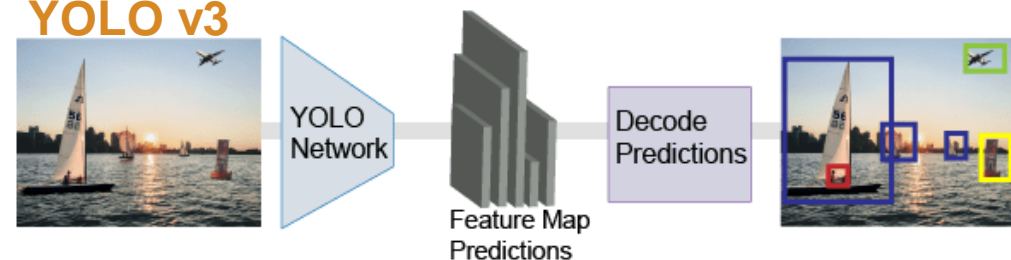
YOLO v2



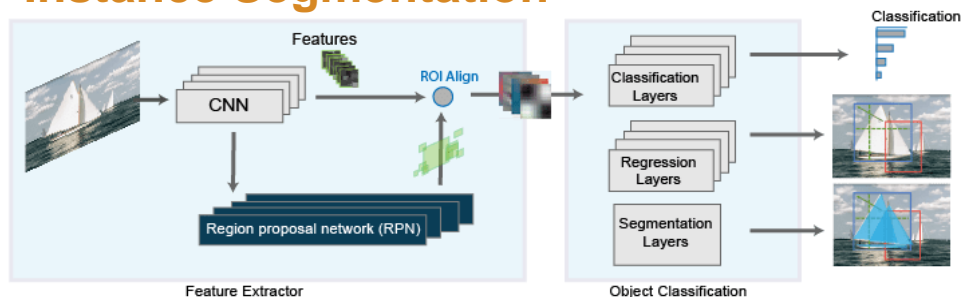
Faster R-CNN



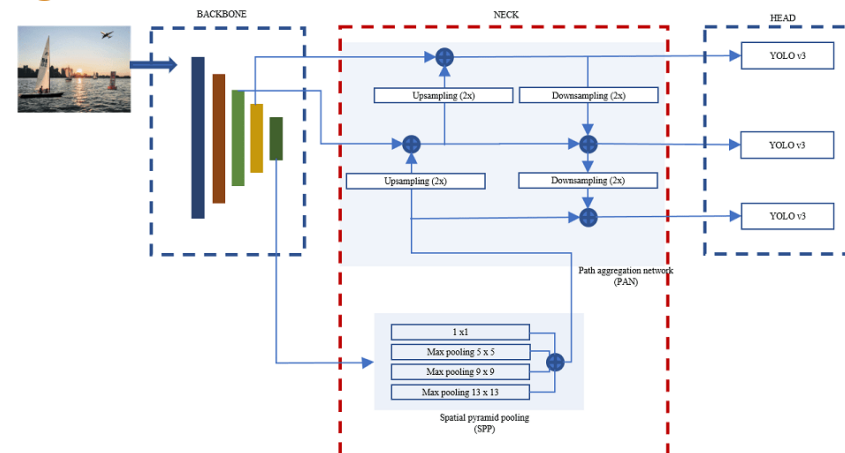
YOLO v3



Instance Segmentation





YOLO v4



Detekcia objektov s YOLOX

YOLOX Network

- decoupled head, anchor-free



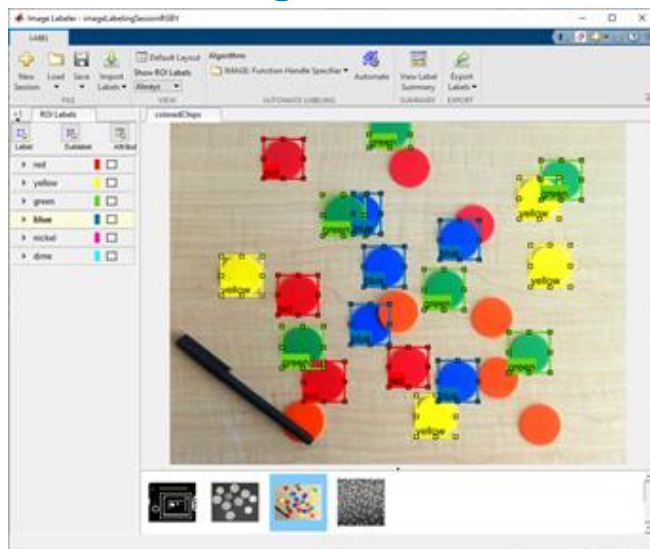
```

detectorIn = yoloxObjectDetector();
detector= trainYOLOXObjectDetector(dsTrain,detectorIn,...);
detectionResults = detect(detector,dsTest);

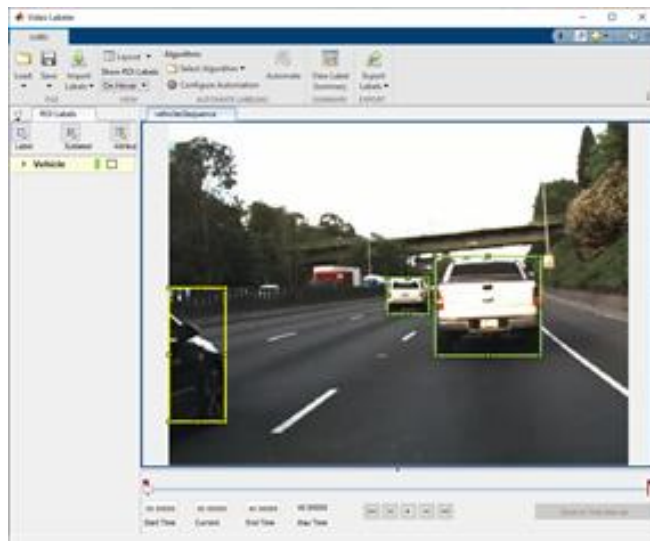
```


Ako označíme naše dáta

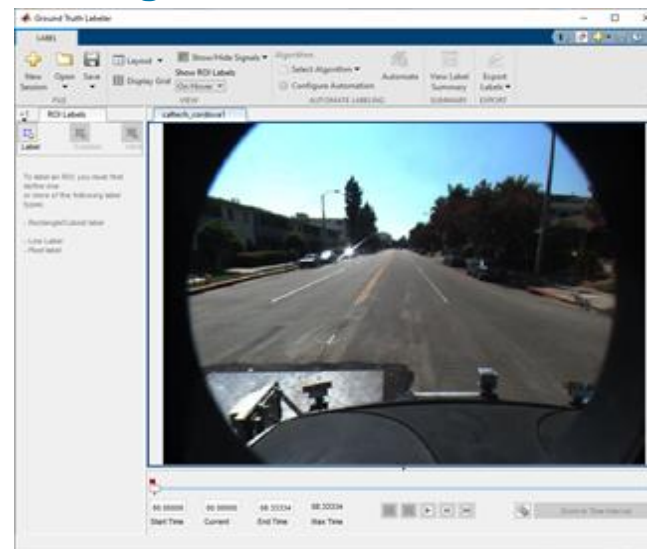
imageLabeler




videoLabeler



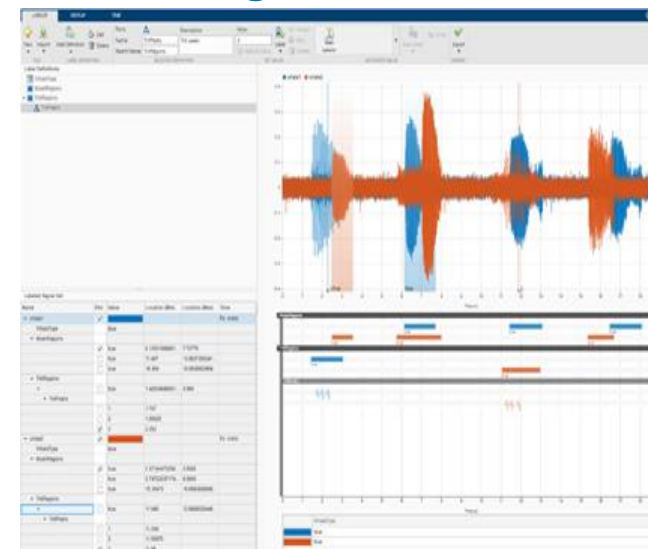
groundTruthLabeler



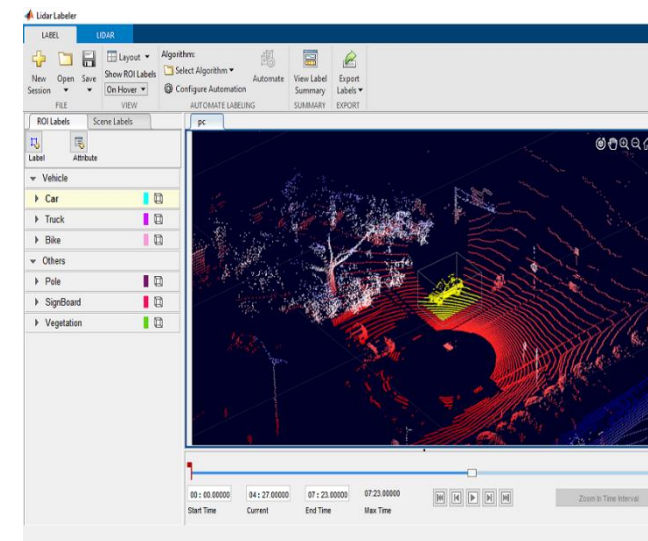
blockedImage Labeler



signalLabeler


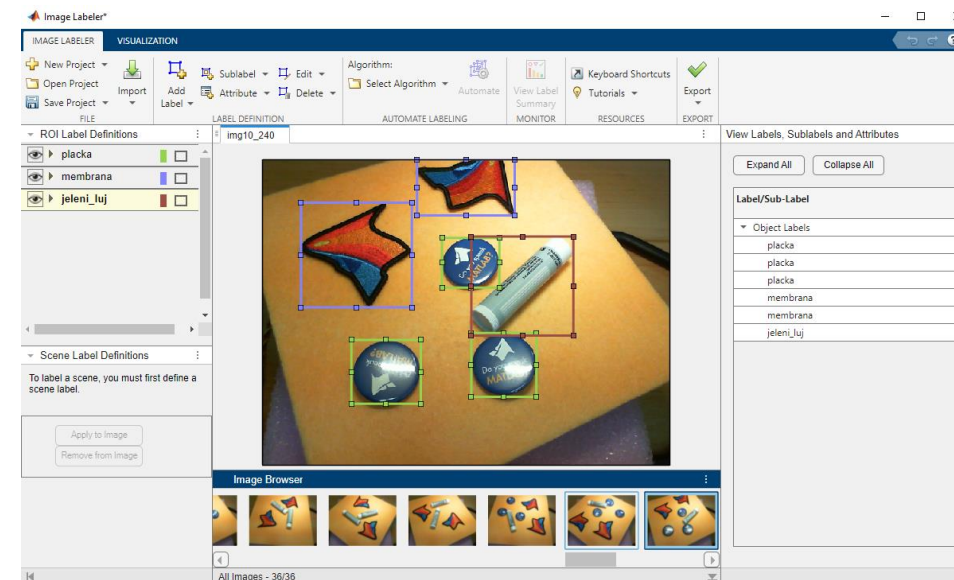


lidarLabeler

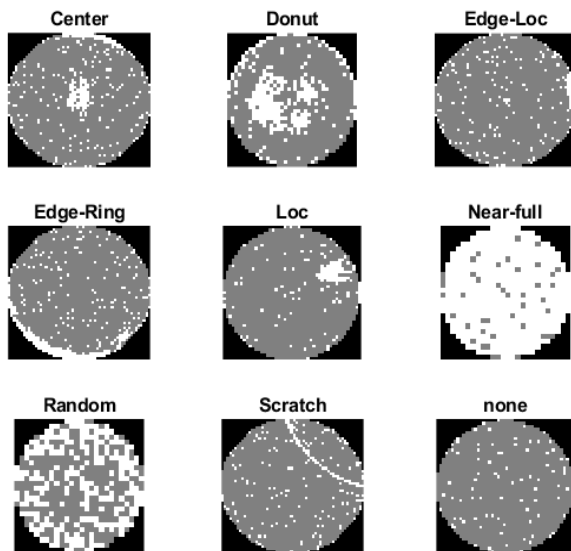


Ukážka: Detekcia objektov


- Úloha
 - hľadanie objektov v obrázku
 - tréovanie YOLOX detektora
- Riešenie
 - označenie obrázkov na tréovanie
 - príprava dát na tréovanie
 - tvorba detektora objektov
 - natréovať detektor
 - vyhodnotiť presnosť
- Alternatíva – Detect Defects on PCB



Detekcia anomálií




Klasifikácia defektov



(a) PCB with mouse bite.

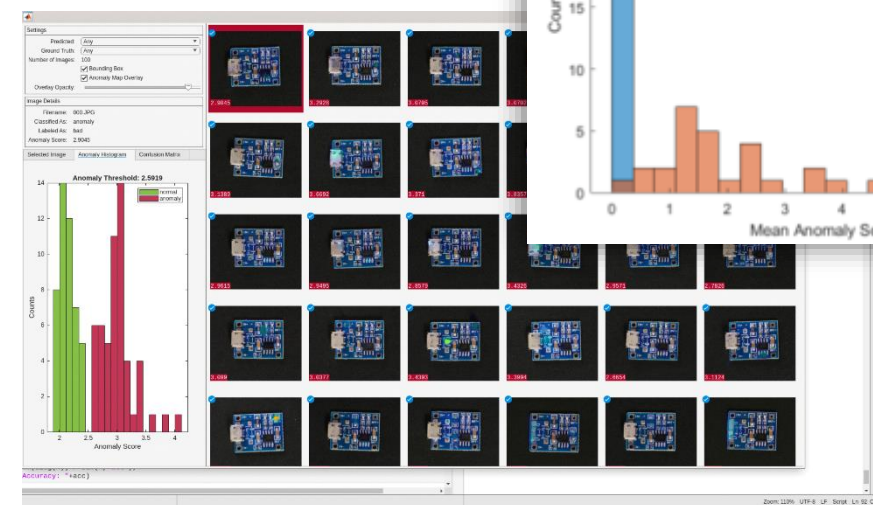

Počítanie, prítomnosť a lokalizácia objektov



Detekcia anomálií

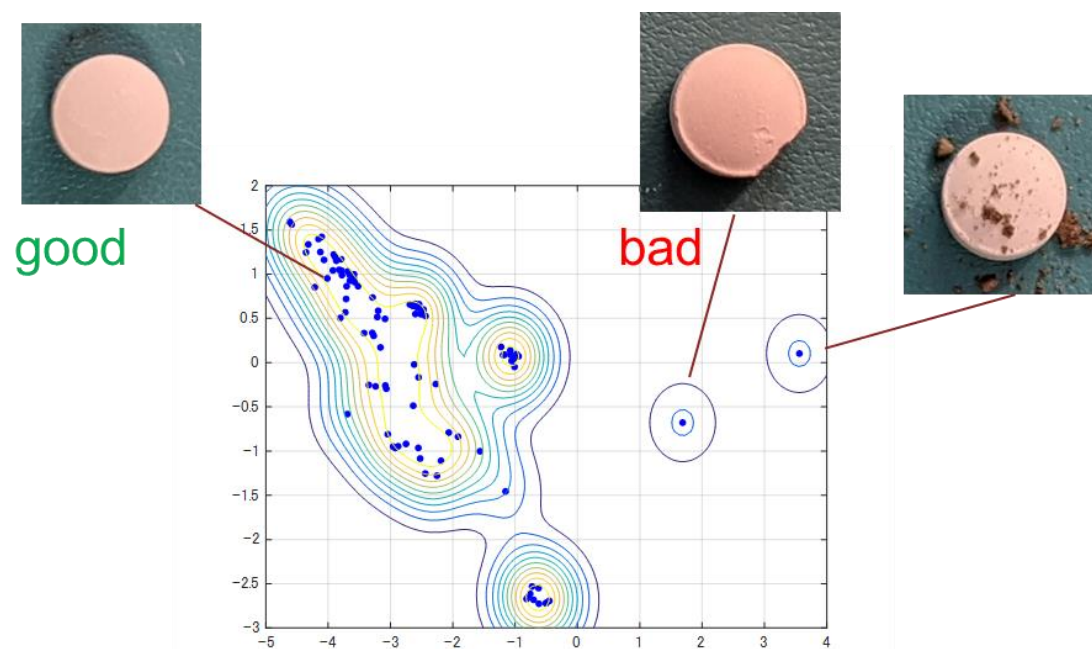
Automated Visual Inspection Library

- Doplnok Computer Vision Toolbox
- Práca s detekčnými sieťami
 - EfficientAD
 - PatchCore
 - FastFlow
 - FCDD
 - YOLOX
- Vyhodnotenie
 - zobrazovanie výsledkov a metriky
 - prahovanie, mapa anomálií
- Príklady, vrátane tréovania po častiach

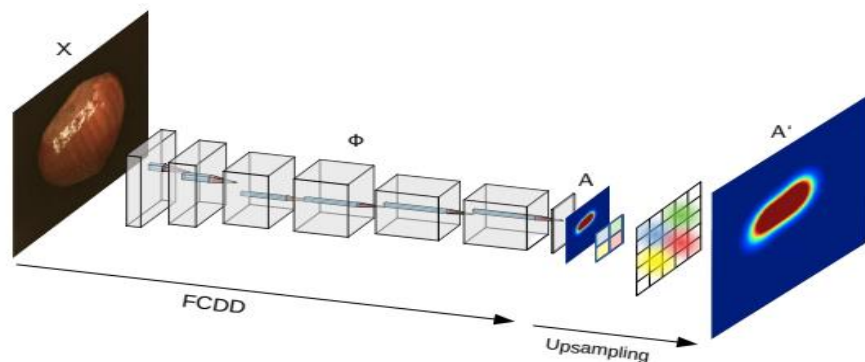


Detekcia anomálií pre nevyvážené dáta


- Len **dobré** obrázky na trénovanie
- Automatické nastavenie prahu anomálií
- Predikcia **dobré/zlé** počas inferencie
- Podporované prístupy
 - EfficientAD
 - FCDD (malé množstvo chybných)
 - FastFlow
 - PatchCore
 - PaDiM
 - One-class SVM



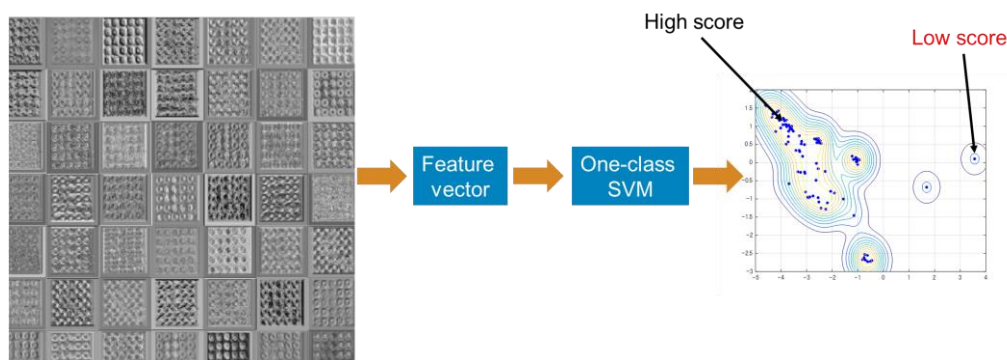
Vybrané detektory anomálií



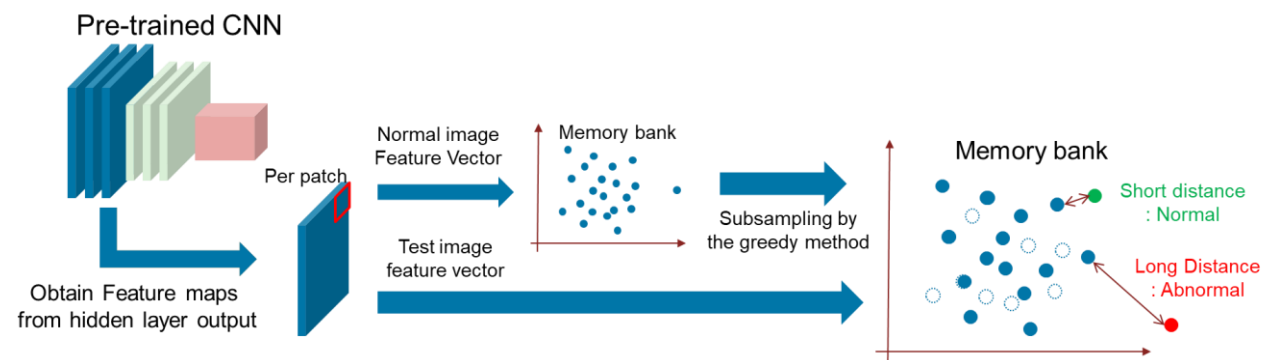
Fully convolutional data description (FCDD)



EfficientAD



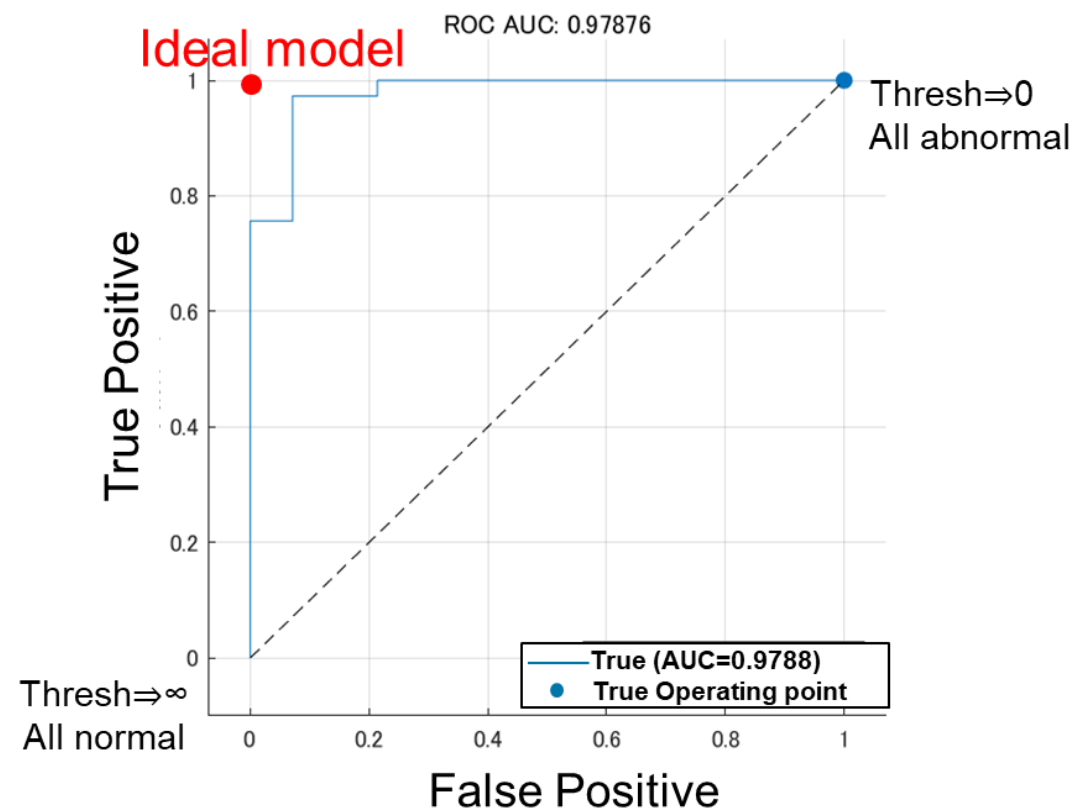
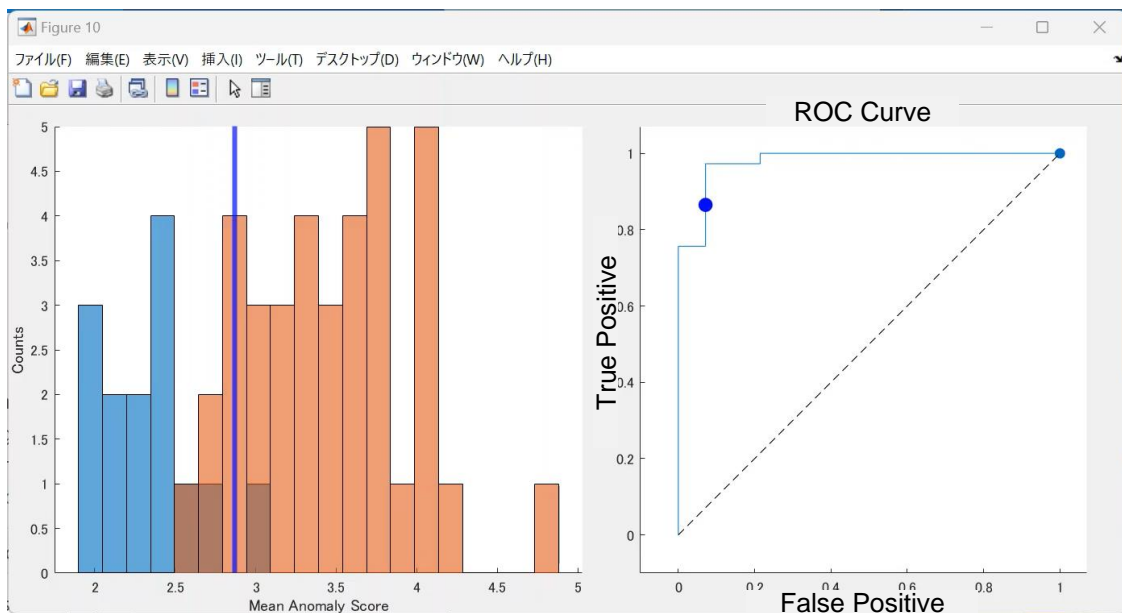
One-class SVM



PatchCore

Hľadanie prahov

- anomalyThreshold
 - založené na ROC krivke




Vizualizácia a analýza výsledkov

Kvantitatívne vyhodnotenie

[evaluateAnomalyDetection](#)

- Confusion matrix
- precision, recall, f1score

Accuracy: 0.91176

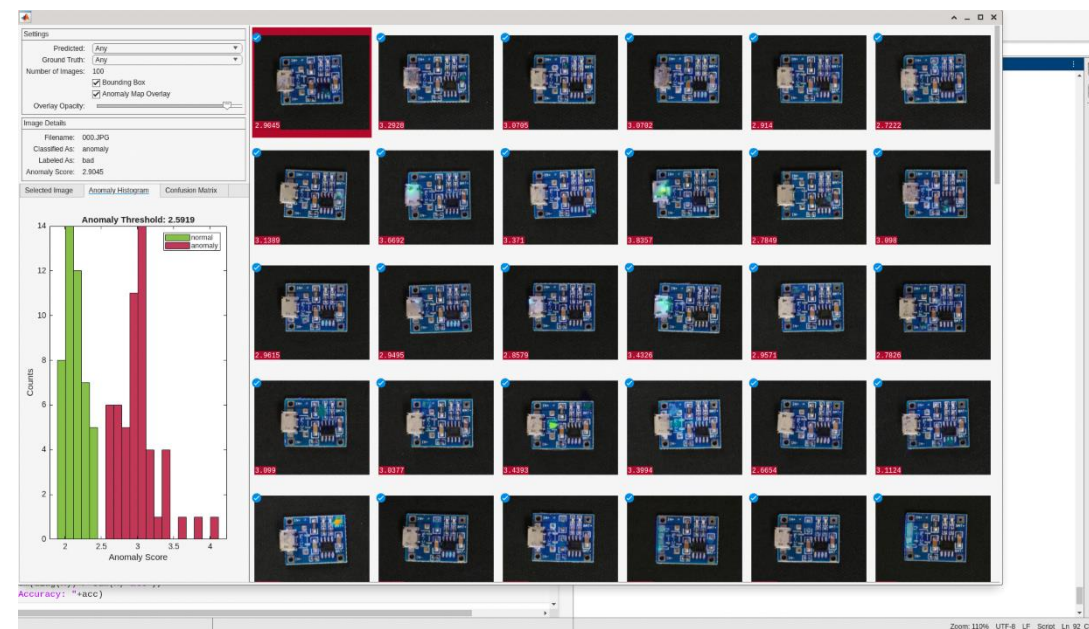


GlobalAccuracy	MeanAccuracy	Precision	Recall	Specificity
0.91176	0.87431	0.91447	0.96528	0.78335

Kvalitatívne hodnotenie

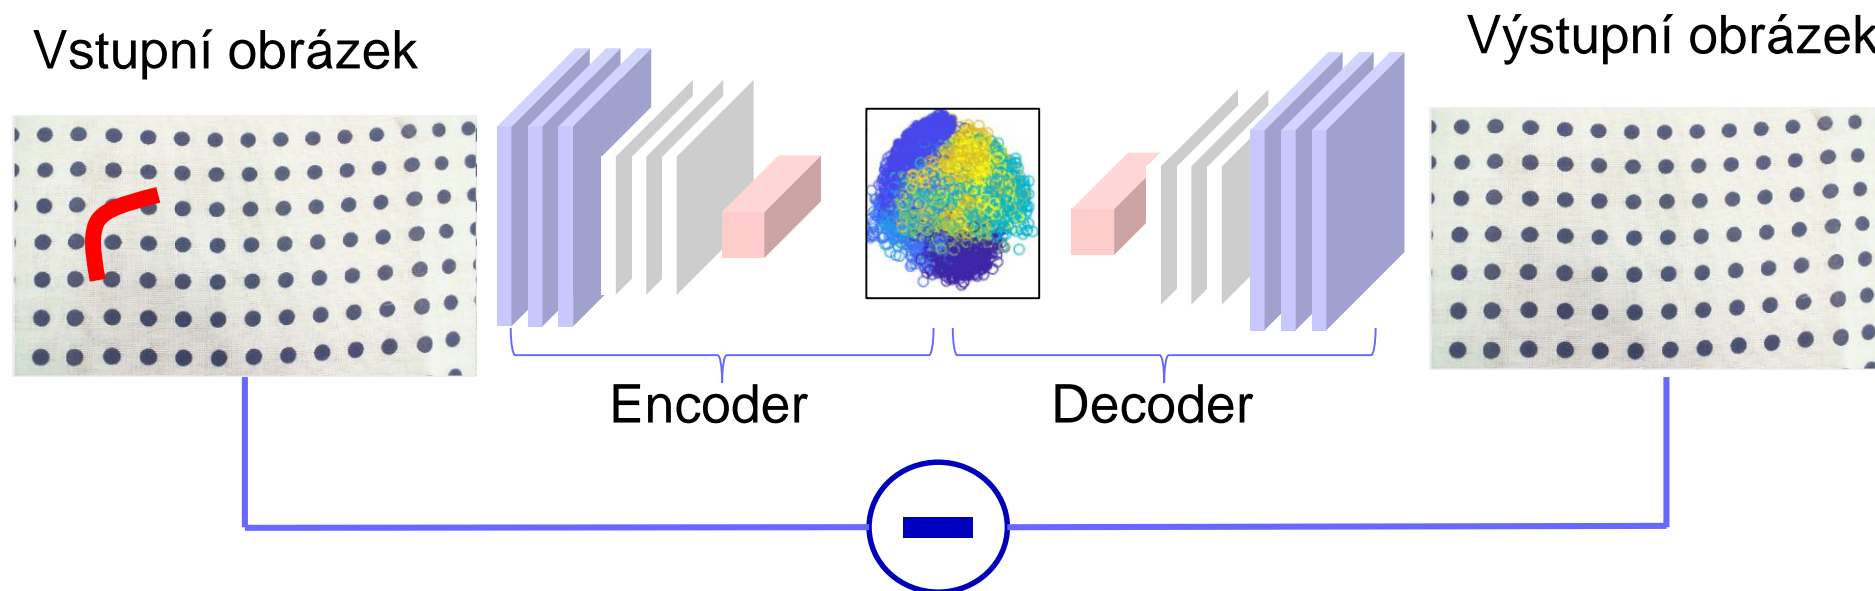
[viewAnomalyDetectionResults](#)

- Zobrazenie obrázkov a máp anomálií
- Histogram, Confusion Matrix



Detekcia anomálií

- Stratégie detekcie a Autoenkódery



Pri inferencii...

Normálny obrázok
 → rekonštruovaný korektne
 → rozdiel ide k nule



Abnormálny obrázok
 → rekonštrukcia nie je korektná
 → nájdenie anomálie v rozdielovom obrázku





Ukážka: Detekcia anomálií

- Úloha

- detekcia a lokalizácia anomálie
- tréovanie detekčných sietí

- Riešenie

- načítanie a rozdelenie dát
- definícia detektora
- tréovanie detektora
- nastavenie prahu
- vyhodnotenie modelu

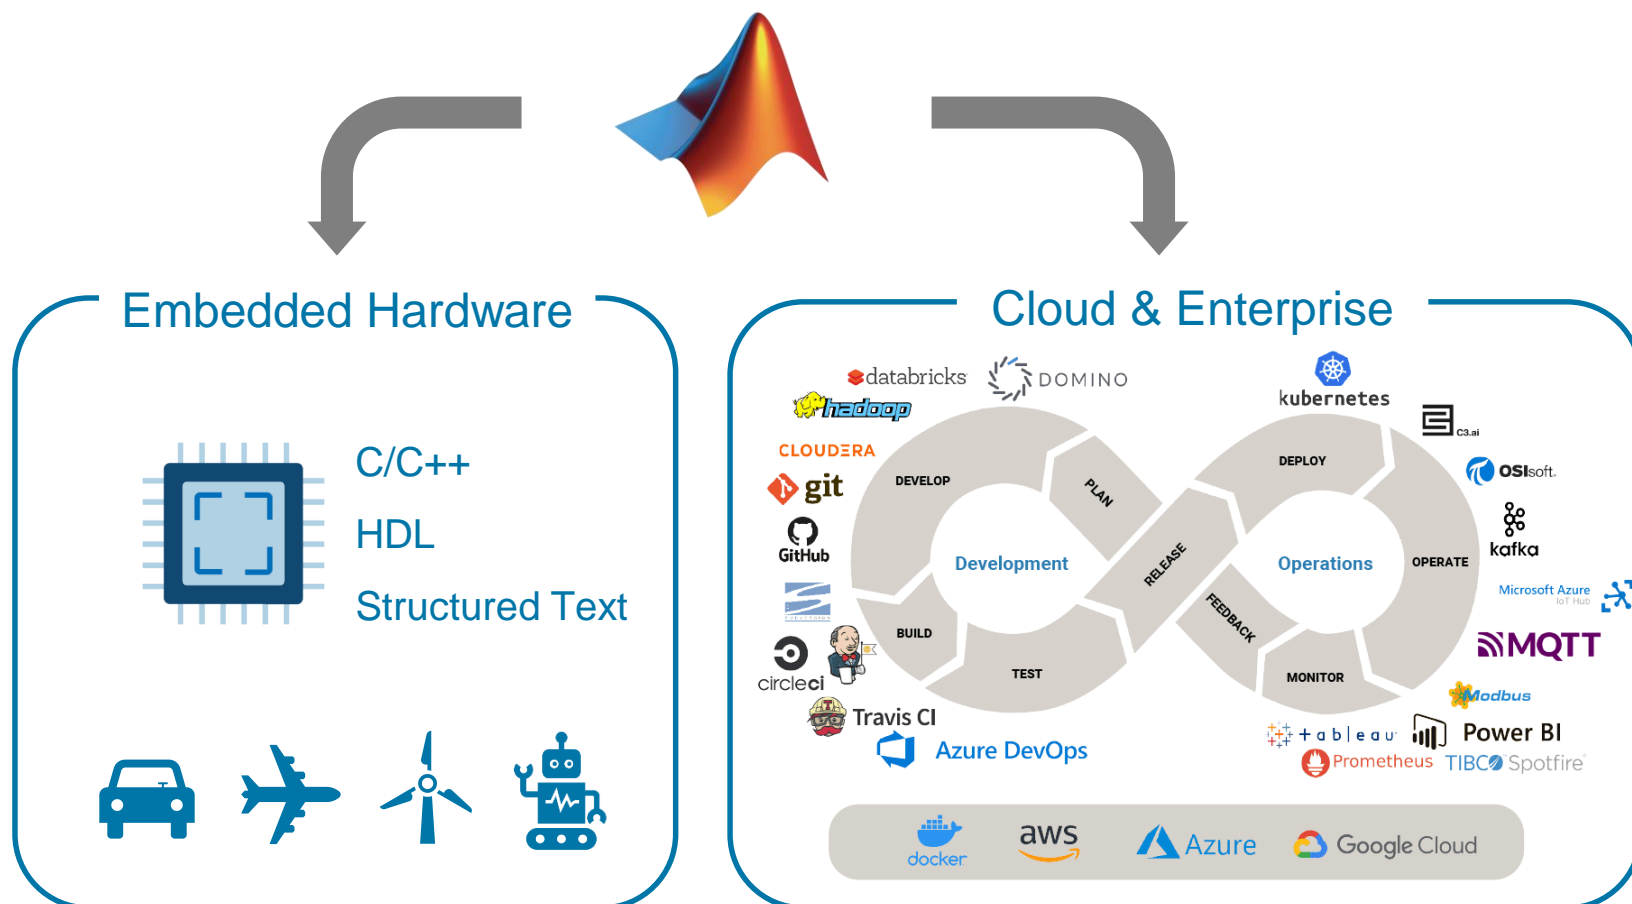


Nasadenie na hardvér a rôzne platformy



Nasadenie algoritmov

Integrácia s IT/OT systémami
v cloude, generovanie C/C++
kódu pre spracovanie v
realnom čase



Ďakujem za pozornosť