

# Identifikácia škvŕn na historickom papieri pre reštaurovanie

Filip Tuch

15. mája 2026

- Historické dokumenty sú často poškodené škvrnami, ktoré môžu byť spôsobené baktériami, plesňami alebo inými faktormi.
- Správna a včasná identifikácia typu škvrny je zásadná pre voľbu správnej metódy konzervovania a reštaurovania dokumentu.



Obr.: Príklad škvrny na historickom papieri. Zdroj: *DIBCO dataset*.

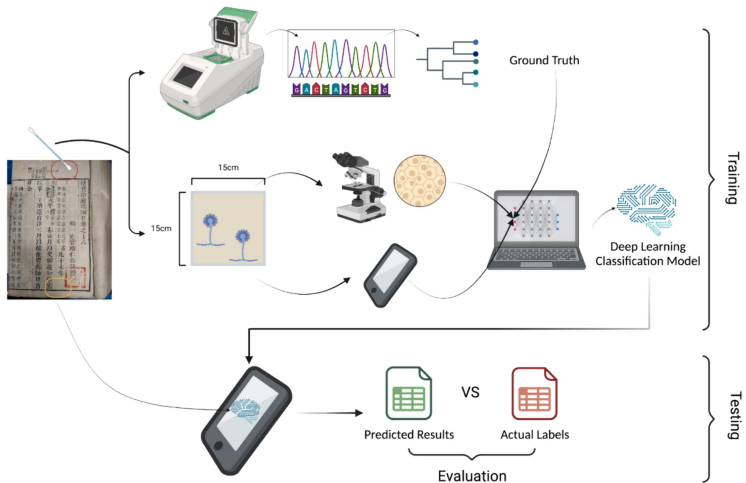
- Vytvoriť nástroj/aplikáciu založenú na strojovom učení na identifikáciu typu škvrny (12 tried) na historickom papieri.
  - 6 baktérií: Arthrobacter, Curtobacterium, Exiguobacterium, Micrococcus, Rhodococcus, Sphingomonas
  - 6 plesní: Alternaria, Aspergillus, Claudosporium, Epicoccum, Penicillium, Talaromyces
- Zlepšiť proces reštaurovania dokumentov tým, že poskytne konzervátorom presné informácie o type škvrny a navrhne vhodné metódy na odstránenie škvrny.

## Web-based diagnostic platform for microorganism-induced deterioration on paper-based cultural relics with iterative training from human feedback

Chenshu Liu a kol., Máj 2024, DOI: 10.1186/s40494-024-01267-5

- **Problém:** tradičná identifikácia mikroorganizmov na papieroch = laboratórne testy, časovo náročné, drahé, invazívne...
- **Cieľ:** vyvinúť webovú platformu na identifikáciu mikroorganizmov (4 druhy) na papieroch (z mikroskopických snímok)
  - A. Niger, A. Oschraceus, Claudosporium, P. Polymyxa
- **Metóda:** kombinácia strojového učenia (CNN - ResNet50, VGG16) a ľudskej spätnej väzby
- **Výsledok:** platforma, ktorej diagnostická presnosť sa postupne zlepšuje vďaka spätnej väzbe
  - priemerná testovacia presnosť = 90.29 %

# Kľúčový vedecký článok I



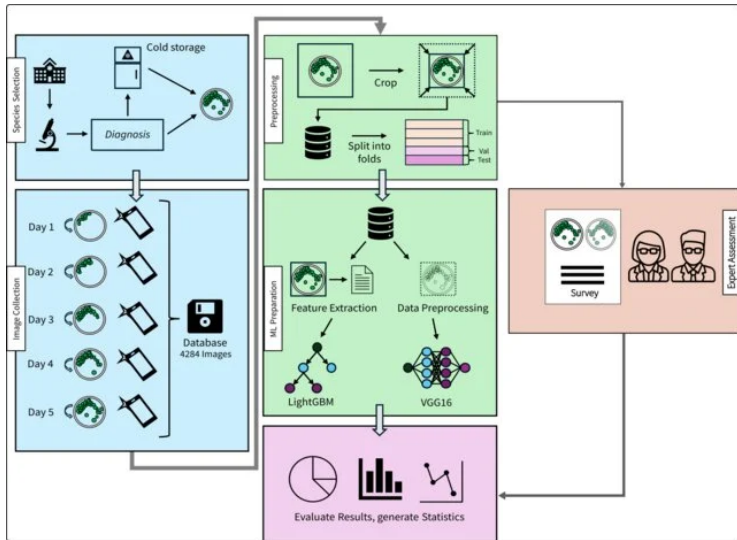
Obr.: Pipeline od Chenshu Liu a kol.

## Advancing mold identification in the routine laboratory: Performance of smartphone-based imaging and a newly developed Convolutional Neural Network

Lukas Weber a kol., November 2025, DOI:  
10.1128/spectrum.02924-25

- **Problém:** identifikácia plesní na kultúrach vyžaduje mikroskopické vybavenie
- **Cieľ:** vyvinúť systém na identifikáciu plesní (4 druhy) pomocou smartfónu
  - *Penicillium* spp., *Aspergillus* spp., *Fusarium* spp., *Cladosporium* spp.
- **Metóda:** zber snímok plesní (so smartfónom), tréningovanie CNN na klasifikáciu plesní, vyhodnotenie odborníkmi
  - dokopy  $\approx 4000$  snímok, dual VGG16
- **Výsledok:** systém dosahuje presnosť 72 %, čo je porovnateľné s odborníkmi

# Kľúčový vedecký článok II




Obr.: Pipeline od Lukas Weber a kol.

- **Knižnice:** Python, PyTorch, OpenCV, Numpy, Matplotlib
- **Pipeline:**
  - detekcia škvŕn na dokumente (bounding box)
  - klasifikácia škvŕn do 12 tried
- **Dataset:** využiť techniky augmentácie na rozšírenie (obmedzeného) datasetu

- Prvotná klasifikácia škvrn na dostupných dátach.
- Problémy najmä pri menej zastúpených triedach (nevyvážený dataset).

<b>Model</b>	<b>Acc</b>
KNN	54 %
SVM	16 %
ResNet-18 (scratch)	84 %
ResNet-18 (ImageNet)	96 %




Obr.: Príklad plesne z datasetu.


# Súčasný stav II

- Augmentácia dát (rotácie, zmeny jasů, farby, kontrastu, atď') pre zväčšenie a vyváženie datasetu.

Model	Acc (pôvodný)	Acc (augmentovaný)
KNN	54 %	54 %
SVM	16 %	31 %
ResNet-18 (scratch)	84 %	96 %
ResNet-18 (ImageNet)	96 %	98 %



(a) Pôvodný




(b) Augmentovaný


Obr.: Ukážka augmentácie dát

# Sučasný stav III

- Použitie Grad-CAM na verifikáciu, že model sa zameriava na škvrny a nie na pozadie.




Grad-CAM Overlay




Prediction: *Alternaria-alternata*  
Ground Truth: *Alternaria-alternata*




Grad-CAM Overlay



Prediction: *Micrococcus-sp*  
Ground Truth: *Micrococcus-sp*



Grad-CAM Overlay



Prediction: *Aspergillus-ochraceus*  
Ground Truth: *Epicoccum-layunese*

- **Súbežný výskum:** analýza rizík „halucinácií“ modelov pri obnove degradovaných dokumentov
  - porovnanie generatívnych (Pix2Pix) a diskriminačných (DRUNet, DnCNN) sietí
- **Zistenie:** niektoré modely síce zlepšujú vizuálny dojem, ale môžu do dokumentov vkladať/meniť písmená
  - zdôraznenie dôležitosti manuálneho reštaurovania a konzervovania
- 3. miesto na ŠVK a cena za najlepšiu prezentáciu na CESC G 2026
  - za článok „Evaluating Deep Neural Networks for Faithful Restoration of Historical Documents“

- **Výzvy:** nedostatok dát (dokopy 968 obrázkov), nevyvážené triedy
- **Plán:**
  - zber ďalších dát (spolupráca s VŠVU a SAV)
    - aj z reálnych kníh a dokumentov
  - experimentovať s augmentáciou
  - skúmať pokročilejšie modely a techniky
    - few-shot learning
    - data-efficient image transformers (DeiT)
    - foundation models
    - ...