



UNIVERZITA KOMENSKÉHO V BRATISLAVE
FAKULTA MATEMATIKY, FYZIKY A INFORMATIKY



IDENTIFIKÁCIA ŠKVŔŇ NA HISTORICKOM PAPIERI PRE REŠTAUROVANIE

Diplomová práca

UNIVERZITA KOMENSKÉHO V BRATISLAVE
FAKULTA MATEMATIKY, FYZIKY A INFORMATIKY



IDENTIFIKÁCIA ŠKVŔN NA HISTORICKOM PAPIERI PRE REŠTAUROVANIE

Diplomová práca

Študijný program: Aplikovaná informatika
Študijný odbor: Informatika
Školiace pracovisko: Katedra aplikovanej informatiky
Školiteľ: doc. RNDr. Zuzana Černeková, PhD.



Univerzita Komenského v Bratislave
Fakulta matematiky, fyziky a informatiky

ZADANIE ZÁVEREČNEJ PRÁCE

Meno a priezvisko študenta: Bc. Veronika Bendíková
Študijný program: aplikovaná informatika (Jednoodborové štúdium, magisterský II. st., denná forma)
Študijný odbor: informatika
Typ záverečnej práce: diplomová
Jazyk záverečnej práce: slovenský
Sekundárny jazyk: anglický

Názov: Identifikácia škvŕn na historickom papieri pre reštaurovanie
Stain identification on historical paper for restoration

Anotácia: Reštaurovanie a konzervovanie diel na papieri často zahŕňa aj odstraňovanie rôznych typov škvŕn z povrchu papierového nosiča. Škvŕny môžu byť rôzneho pôvodu: mikrobiologické (huby, ale aj baktérie), trus hmyzu, rôzne atramentové škvŕny a pečiatky. Správne rozpoznanie škvŕn a včasná identifikácia mikrobiálnej kontaminácie, či infestácie sú zásadné pre metódy preventívneho konzervovania a prispieva k optimalizácii procesov konzervovania a reštaurovania papierových dokumentov. Z tohto dôvodu by bolo užitočné mať k dispozícii aplikáciu na včasnú identifikáciu typov škvŕn počas monitorovania zbierok, depozitárov, či počas procesov konzervovania a reštaurovania.

Cieľ: Cieľom práce by bolo využiť strojové učenie a umelú inteligenciu pri štúdiu snímok s cieľom zlepšiť diagnostickú analýzu. Navrhnuť metódu, ktorá umožní jednoduchú identifikáciu škvŕn prítomných na historickom papieri.

Vedúci: doc. RNDr. Zuzana Černeková, PhD.
Katedra: FMFI.KAI - Katedra aplikovanej informatiky
Vedúci katedry: doc. RNDr. Tatiana Jajcayová, PhD.
Dátum zadania: 23.10.2024

Dátum schválenia: 08.11.2024

prof. RNDr. Roman Ďurikovič, PhD.
garant študijného programu

.....
študent

.....
vedúci práce

Čestne prehlasujem, že túto diplomovú prácu som vypracovala samostatne, len s použitím uvedenej literatúry a pod dohľadom môjho školiťa.

Bratislava, 2026

.....
Bc. Veronika Bendíková

Pod'akovanie

Pod'akovanie...

Abstrakt

Reštaurovanie a konzervovanie diel na papieri často vyžaduje odstraňovanie rôznych typov škvŕn z povrchu papierového nosiča. Tieto škvŕny môžu mať rôzny pôvod – mikrobiologický (napr. huby a baktérie), biologický (napr. trus hmyzu) či chemický (napr. atramentové škvŕny a pečiatky). Kľúčovým krokom v preventívnej konzervácii je správna identifikácia a rozpoznanie týchto škvŕn, najmä pri podozrení na mikrobiálnu kontamináciu alebo infestáciu. Včasná diagnostika umožňuje zvoliť vhodné postupy zásahu a optimalizovať reštaurátorské procesy. Preto by bolo prínosné vyvinúť nástroj alebo aplikáciu na automatizovanú a rýchlu identifikáciu typov škvŕn, ktorá by mohla slúžiť ako podpora pri monitorovaní zbierok, depozitárov alebo počas samotných konzervačných a reštaurátorských zásahov.

Kľúčové slová: konzervovanie, reštaurovanie, papier, škvŕny, mikrobiálna kontaminácia, automatická identifikácia, preventívna ochrana, digitalizácia, kultúrne dedičstvo

Abstract

Restoration and conservation of works on paper often requires the removal of various types of stains from the surface of the paper support. These stains can be of various origins - microbiological (e.g. fungi and bacteria), biological (e.g. insect droppings) or chemical (e.g. ink stains and stamps). A key step in preventive conservation is the proper identification and recognition of these stains, especially when microbial contamination or infestation is suspected. Early diagnosis allows to choose appropriate intervention procedures and to optimize restoration processes. Therefore, it would be beneficial to develop a tool or application for automated and rapid identification of stain types that could serve as a support for monitoring collections, depositories or during the actual conservation and restoration interventions.

Keywords: conservation, restoration, paper, stains, microbial contamination, automatic identification, preventive protection, digitization, cultural heritage

Obsah

Úvod	1
1 Prehľad problematiky	3
2 Súčasný stav riešenej problematiky doma a v zahraničí	5
2.1 Analytické metódy	5
2.2 Digitálne metódy: Porovnanie klasického prístupu a metód strojového učenia	6
2.2.1 Dataset	6
2.2.2 Extrakcia kandidátnych oblastí (DLT)	7
2.2.3 Klasifikácia pomocou morfolologickej filtrácie	7
2.2.4 Klasifikácia pomocou modelov strojového učenia	8
2.2.5 Metriky použité na hodnotenie úspešnosti	9
2.2.6 Výsledky a porovnanie modelov	9
2.3 Digitálna analýza a AI	12
2.3.1 Použité vzorky	12
2.3.2 Webové rozhranie na identifikáciu plesní	13
2.3.3 Mobilná aplikácia s využitím AI	14
3 Ciele práce	19
4 Návrh riešenia	21
5 Implementácia	23
5.1 Použité knižnice	23
6 Výskum	25
6.1 Prvý pokus – prototyp klasifikátora	25
7 Dosiahnuté výsledky	29
Záver	31

Zoznam obrázkov

2.1	Príznačky použité na učenie	7
2.2	Výsledky jednotlivých metód strojového učenia	10
2.3	Porovnanie troch metód strojového učenia a morfológického filtrovania	11

Zoznam tabuliek

2.1	Výsledky identifikácie jednotlivých vzoriek pred a po orezaní	14
2.2	Výsledky identifikácie jednotlivých vzoriek pred a po orezaní	15

Úvod

Ochrana a konzervácia historických dokumentov predstavuje jednu z kľúčových úloh pri zachovávaní kultúrneho dedičstva. Papierové artefakty, ako sú listiny, rukopisy, mapy či knihy, sú mimoriadne citlivé na vonkajšie vplyvy prostredia. Počas svojho starnutia podliehajú komplexným fyzikálnym, chemickým a biologickým procesom, ktoré vedú k degradácii materiálu a vzniku škvŕn rôzneho pôvodu [14].

Škvŕny môžu byť rôzneho pôvodu: pôsobenie vlhkosti, mikrobiologické (huby, ale aj baktérie), trus hmyzu, rôzne atramentové škvŕny a pečiatky. Osobitnú kategóriu tvoria tzv. foxing stains – hnedasté bodky typické pre staré papiere, ktorých pôvod sa pripisuje kombinácii biologických a chemických procesov [2]. Správne rozpoznanie typu škvŕny a včasná identifikácia mikrobiálnej kontaminácie či infestácie sú zásadné pre metódy preventívneho konzervovania a prispievajú k optimalizácii procesov konzervovania a reštaurovania papierových dokumentov.

Ako upozorňuje Kostadinovska [7], moderné reštaurovanie sa opiera o princípy neinvazívnosti a reverzibility, ktoré vyžadujú dôkladnú predbežnú analýzu stavu dokumentu. Historické papierové artefakty, ako sú rukopisy, mapy, tlače či knihy, sú totiž citlivé a nenahraditeľné, a preto sa ich skúmanie musí vykonávať nedeštruktívnymi alebo mikrochemickými metódami, ktoré nepoškodzujú originál.

Rozvoj neinvazívnych analytických metód v posledných desaťročiach otvoril nové možnosti v oblasti konzervácie. Techniky ako FTIR, Ramanova spektroskopia či multispektrálne zobrazovanie umožňujú presne charakterizovať chemické zloženie a pôvod škvŕn bez nutnosti odoberať vzorku [12].

Zároveň sa rozvíja aj digitálna analýza obrazu, ktorá prostredníctvom algoritmov spracovania obrazu dokáže klasifikovať a kvantifikovať zmeny v povrchovej štruktúre papiera. Projekty ako Dirty Old Books – Building a Library of Stains with Multispectral Imaging [11] ukazujú potenciál vytvárania databáz škvŕn, ktoré môžu slúžiť ako referenčné vzory pre budúce výskumy a automatizované rozpoznávanie poškodení.

Motiváciou tejto práce je preto prispieť k rozvoju metodík, ktoré umožnia neinvazívnu identifikáciu škvrn pomocou digitálneho spracovania obrazu a optickej analýzy. Takéto riešenie by mohlo byť praktickým nástrojom pre reštaurátorov aj archivárov, pretože zjednodušuje proces hodnotenia stavu dokumentov, znižuje riziko nesprávnych zásahov a podporuje digitalizáciu kultúrneho dedičstva v súlade s princípmi udržateľnosti a ochrany originálu.

Preto je význam tejto práce dvojaký:

1. **Vedecký:** rozvoj metodík, ktoré kombinujú optickú a digitálnu identifikáciu škvrn.
2. **Praktický:** poskytnúť reštaurátorom nástroje a odporúčania, ktoré zlepšia rozhodovanie a ochranu historických dokumentov.

Stručný opis štruktúry práce je uvedený v kapitole 3, kde sú popísané hlavné ciele a obsah jednotlivých kapitol.

Kapitola 1

Prehľad problematiky

Kapitola 2

Súčasný stav riešenej problematiky doma a v zahraničí

V súčasnosti sa výskum tejto problematiky sústreďuje na vývoj neinvazívnych analytických metód, ktoré umožňujú detailnú charakterizáciu materiálu bez poškodenia originálu. [13] Medzi rôznymi technikami, ktoré spĺňajú tieto požiadavky, sú niektoré dostupné vo výskumných laboratóriách a ponúkajú vyšší výkon analýzy a kvalitu údajov; iné sú vzhľadom na svoju cenu a jednoduchosť použitia rozšírenejšie medzi reštaurátormi a konzervátormi, aj keď majú obmedzenejšie možnosti analýzy a nižšiu kvalitu údajov. [13] Tieto techniky poskytujú nielen kvalitatívne informácie o zložení a stave papiera, ale aj kvantitatívne údaje o rozsahu a type poškodenia.

Zároveň dochádza k rozmachu digitálnych a automatizovaných systémov, ktoré využívajú algoritmy umelej inteligencie (AI) a strojového učenia (ML) na spracovanie obrazových dát. Cieľom týchto systémov je automaticky identifikovať a klasifikovať poškodenia, čo môže výrazne zefektívniť reštaurátorskú prax.

Na Slovensku i v zahraničí prebieha niekoľko výskumov, ktoré kombinujú optické metódy, chemickú analýzu a digitálne spracovanie obrazu. Tieto prístupy prispievajú k vytváraniu databáz škvŕn a k budovaniu znalostnej bázy pre budúce automatizované rozpoznávanie poškodení.

2.1 Analytické metódy

Analytické metódy predstavujú základný nástroj pre štúdium fyzikálnych, chemických a mikrobiologických vlastností historických materiálov. Ich cieľom je poskytnúť presné a spoľahlivé informácie o zložení a stave analyzovaných objektov bez ich poškodenia. V súčasnosti sa využíva široká škála techník, od klasických spektroskopických metód

až po pokročilé zobrazovacie a röntgenové prístupy, ktoré umožňujú kvantitatívnu aj kvalitatívnu analýzu.

Podrobné analytické metódy v tejto práci neuvádzame, pretože nie sú priamo relevantné pre cieľ našej práce. Keďže nemáme k dispozícii laboratórne podmienky, tieto metódy by sme v práci ani nemohli prakticky využiť.

2.2 Digitálne metódy: Porovnanie klasického prístupu a metód strojového učenia

Štúdia sa zaoberá problémom identifikácie plesní (mold defects) na umeleckých dielach — konkrétne maľbách — ktoré sú vystavené riziku biologickej degradácie v dôsledku vlhkosti a nepriaznivých podmienok skladovania.

Autori zdôrazňujú, že plesne predstavujú závažný degradačný faktor, ktorý môže spôsobiť nezvratné zmeny v štruktúre a farebnosti umeleckých diel. [9] Tradičné spôsoby identifikácie poškodení sú často subjektívne, časovo náročné a vyžadujú zásah odborníkov. Preto je cieľom výskumu vytvoriť automatizovaný, reprodukovateľný a neinvazívny nástroj, ktorý dokáže rozpoznať plesňové poškodenia z digitálnych snímok umeleckých diel. Hlavným cieľom pre tento nástroj však bude ľahkosť jeho ovládania.

V posledných rokoch sa umelá inteligencia stáva čoraz užitočnejšou v rôznych oblastiach a ani táto problematika nie je výnimkou. Pri úlohách, akou je klasifikácia, dosahuje umelá inteligencia miestami veľmi dobré výsledky. Použitím vhodných algoritmov a metód je možné vytvoriť tzv. asistenta, ktorý by dokázal efektívne podporovať riešenie tejto problematiky. [9] V súčasnosti sa podobné metódy často využívajú pri hodnotení kvality nových výrobkov, ako aj pri posudzovaní kvality ovocia či v mnohých ďalších odvetviach.

Hoci samotné využitie umelej inteligencie v tejto konkrétnej oblasti ako je identifikácia poškodení na maľbách nie je ešte úplne preskúmaná autori veria v jej potenciál. [9]

2.2.1 Dataset

Dataset pre túto štúdiu bol zostavený z 566 obrázkov dvoch umeleckých diel vo vysokom rozlíšení. samotné obrazy boli nasnímané pomocou vysokorozlíšiteľného skenera (Niji-X) vybaveného líniovým senzorom pracujúcim vo viditeľnom spektre svetla, čím sa zabezpečilo zachytenie základných farebných detailov, ktoré sú kľúčové pre analýzu

umeleckých diel.[9] Každý vzorový obrázok má rozmery 256 x 256 pixelov s rozlíšením 650 dpi, čo zodpovedá fyzickej ploche 10 mm x 10 mm. [9] Osoby vykonávajúce hodnotenie potom posúdili vzorky, aby odlíšili skutočné plesne od vlastností maľby.

Z tohto datasetu bolo vybraných 100 obrázkov, ktoré boli rozdelené do skupín na účely učenia, validácie alebo testovania. Z pôvodných 100 obrázkov bolo vybraných 80 obrázkov, ktoré boli zaradené do skupiny obrázkov na účely učenia. Tieto obrázky prešli procesom extrakcie charakteristík, pri ktorom bolo z každého chybného kandidáta identifikovaných 10 príznakov. Každá charakteristika kandidáta na poškodenie bola porovnaná s príslušným referenčným obrázkom a označená ako plesň (MOLD) alebo ne-plesň (NO-MOLD) [9]. Prikladáme aj tabuľku, na ktorom môžeme vidieť jednotlivé vlastnosti [9]:

Feature	Name	Mean	Std	Min	Max
F1	Region Area (pixel area)	36.50	575.94	1	51503
F2	Major Axis Length (pixel length)	7.79	19	1.15	377.29
F3	Minor Axis Length (pixel length)	2.75	6.75	1.15	304
F4	Eccentricity	0.60	0.43	0	1
F5	Filled Area (pixel area)	42.73	661.56	1.00	52329
F6	Extent	0.81	0.27	0.02	1
F7	Perimeter (pixel length)	18.35	84.88	0	3677.51
F8	Equivalent Diameter (pixel length)	3.28	5.98	1.13	256.08
F9	Convex Area (pixel area)	87.82	1161.01	1.00	65536
F10	Solidity	0.90	0.18	0.07	1

<https://doi.org/10.1371/journal.pone.0316996.t001>

Obr. 2.1: Príznyaky použité na učenie

2.2.2 Extrakcia kandidátnych oblastí (DLT)

Na prvý krok, ktorým je extrakcia kandidátnych oblastí autori použili algoritmus Derivative Level Thresholding (DLT), ktorý identifikuje oblasti so zmenami textúry, jasou alebo farebnosti, typickými pre plesne [1]. Na začiatku sa naše vstupné dáta konvertujú na šedoúrovňové obrazy, ktoré potom prechádzajú viacerými úrovňami prahovacích procesov, aby sa vytvorili binárne obrazy. [9] Následne sa analyzujú derivácie intenzity pixelov – teda sledujú sa lokálne zmeny v úrovni šedi. Neoceniteľnou výhodou je aj to, že sa zbavíme prípadného šumu v obraze, ktorý by nám mohol prekážať pri správnej identifikácii.

2.2.3 Klasifikácia pomocou morfolologickej filtrácie

Morfologická filtrácia sa často používa pri binárnych obrazoch ale ľahko ju vieme zovšeobecniť aj na šedotónové obrazy a farebné obrazy. [3] V tejto štúdií si ju autori vybrali z toho dôvodu, že samotná morfolologická filtrácia sa používa pri predspracovaní obrazu (napr. zjednodušenie tvaru obrazu..) ale aj pre popis objektov číselnými charakteristikami (napríklad plocha, obvod..). [3] Samotná metóda je veľmi populárna pre

jej jednoduchosť nakoľko nevyžaduje žiadne matematické operácie. [3]

Táto metóda je príkladom algoritmu založeného na pravidlách (rule-based algorithm), ktoré sa vyznačujú priamou a špecifickou povahou oproti metódam strojového učenia, ktoré vyžadujú trénovacie dáta s ľudským označením. [10]

Autori implementovali metódu pomocou viacerých vrstiev rôznych algoritmov. Konkrétne boli použité tri odlišné vrstvy:

1. Filter veľkosti. Najskôr sa kandidáti na plesne filtrujú podľa veľkosti [9].
2. Filter dier. Filter dier funguje tak, že filtruje skupiny pixelov, ktoré porovnávajú rozdiel medzi vyplnenou oblasťou obrazu a oblasťou obrazu. Vyplnená oblasť obrazu je celkový počet pixelov v tej istej skupine pixelov s vyplnenými dierami. V tejto štúdii je prahová hodnota filtra dier nastavená na 0,1. [9]
3. Líniový filter. Nakoniec sa na obrázky s potenciálnymi plesňami použije líniový filter. V tomto procese sa testuje skupina pixelov, aby sa zistilo, či má pomer plochy k obvodu väčší ako 1,3. [9]

V kontexte morfológického filtrovania, keďže trénovanie a validácia neboli potrebné, na hodnotenie metódy klasifikácie chýb foriem sa priamo použilo len desať vzorových obrázkov z testovacej skupiny.

2.2.4 Klasifikácia pomocou modelov strojového učenia

Klasifikácia strojového učenia ponúka výhodu využitia strojov na učenie sa z označených vlastností, čím sa znižuje potreba ľudského zásahu pri rozlišovaní jednotlivých aspektov klasifikácie samotnej vzorky. Výkon klasifikácie sa zlepšuje s postupným zavádzaním väčšieho množstva dát do systému. V tejto štúdii bolo implementovaných niekoľko modelov strojového učenia, vrátane logistickej regresie (LR), lineárnej diskriminačnej analýzy (LDA), K-najbližších susedov (KNN), klasifikačných a regresných stromov (CART), Gaussovho naivného Bayesa (NB), náhodného lesa (RF), podporných vektorových strojov (SVM) a extrémneho gradientu. [10]

Na zistenie úspešnosti jednotlivých algoritmov bol dataset rozdelený na dve časti:

- 80% datasetu bolo použitých na trénovanie a hodnotenie úspešnosti pre výber najlepšieho modelu
- 20% datasetu bolo použitých na finálnu validáciu modelu

Tento spôsob delenia datasetu je už akýmsi štandardom pri využívaní modelov strojového učenia ale aj pri trénoch neurónových sietí.

Model po natrénovaní vedel spoľahlivo určiť či nejaká konkrétna vzorka je plesen alebo ide o nejakú inú švrnu.

2.2.5 Metriky použité na hodnotenie úspešnosti

V štúdiu boli na hodnotenie úspešnosti použitých metód vybrané rôzne metriky. Boli to dve skupiny metrík. Prvá skupina zahŕňa klasické metriky na vyhodnotenie presnosti klasifikácie, ako sú accuracy (presnosť), sensitivity (citlivosť) a precision (presnosť predikcie), ktoré hodnotia správnu klasifikáciu. Druhá skupina metrík je špecifická pre strojové učenie a je robustnejšia pri hodnotení binárnej klasifikácie, najmä pri nerovnomerne rozložených dátach. Medzi tieto metriky patrí Intersection over Union (IoU), F1-score a Matthews Correlation Coefficient (MCC). [10]

- **Accuracy** udáva podiel správne klasifikovaných pixelov z celkového počtu pixelov.
- **Precision** vyjadruje podiel správne identifikovaných defektov k celkovému počtu pixelov označených ako škvrny.
- **Sensitivity** meria schopnosť metódy správne rozpoznať všetky skutočné defekty.
- **IoU (Jaccardov index)** hodnotí prekrývanie predikovaných a referenčných pixelov, čo je vhodné pri semantickej segmentácii.
- **F1-score (Dice koeficient)** predstavuje harmonický priemer presnosti a citlivosti.
- **MCC** je komplexná metrika zohľadňujúca všetky štyri hodnoty konfúznej matice (TP, TN, FP, FN) a poskytuje spoľahlivé hodnotenie výkonu klasifikácie aj pri nerovnomerných dátach.

Tieto metriky spoločne umožňujú detailné a robustné posúdenie schopnosti metód identifikovať defekty na základe obrazových dát.

2.2.6 Výsledky a porovnanie modelov

Na obrázku nižšie vidíme výkonnosť modelov na základe validačnej sady pre všetky algoritmy strojového učenia uvedené v tejto štúdiu. Poskytuje presnosť každého algoritmu spolu s príslušnou štandardnou odchýlkou a časom potrebným na tréning,

Machine Learning Model	Training Performance			Testing Performance			
	Accuracy	Standard Deviation	Time Taken	Detection	Sensitivity	Precision	Accuracy
Linear Discriminant Analysis (LDA)	0.967685	0.003112	0.545020	100%	0.615854	0.369191	0.930495
Gaussian Naïve Bayes (NB)	0.959545	0.002016	0.284603	90%	0.572442	0.273448	0.921675
Classification and Regression Trees (CART)	0.966429	0.002241	0.969686	80%	0.428373	0.421317	0.954149
Extreme Gradient Boosting (XGB)	0.970681	0.001928	115.716518	80%	0.322591	0.200445	0.925653
Random Forest (RF)	0.975136	0.001482	4.445949	70%	0.377082	0.518940	0.956317
K-Nearest Neighbors (KNN)	0.974326	0.001907	2.271064	50%	0.159770	0.417230	0.955942
Support Vector Machine (SVM)	0.940147	0.005339	96.929111	0	0	-	0.957342
Logistic Regression (LR)	0.975460	0.000994	2.541826	0	0	-	0.953615

Obr. 2.2: Výsledky jednotlivých metód strojového učenia

čím ponúka pohľad na klasifikačnú výkonnosť týchto metód.

Z hľadiska tréningovej presnosti dosiahli najvyššie hodnoty modely Logistic Regression (0.975460), Random Forest (0.975136) a K-Nearest Neighbors (0.974326). Tieto modely zároveň vykazujú nízku štandardnú odchýlku, čo naznačuje stabilné správanie počas viacerých behov. Naopak, model Extreme Gradient Boosting (XGB) bol síce presný (0.970681), ale jeho tréning si vyžadoval výrazne viac času (115 s), čo môže predstavovať nevýhodu pri praktickom nasadení.

Pri testovaní sa ukázalo, že Linear Discriminant Analysis (LDA) dosiahol najvyššiu úroveň detekcie (100%), pričom si udržal veľmi dobrú presnosť 0.930495. Model CART dosiahol vysokú testovaciu presnosť 0.954149, čo ho radí medzi najspoľahlivejšie riešenia v reálnych podmienkach.

Modely SVM a Logistic Regression síce dosiahli vysokú celkovú testovaciu presnosť (0.957342 a 0.953615), no v tabuľke majú uvedenú nulovú detekciu, senzitivitu aj presnosť. Hoci pri SVM neboli zaznamenané žiadne problémy s konvergenciou. Tento jav súvisí s nevyváženosťou datasetu: aj keď model neoznačí žiadnu vzorku ako plesň, môže stále dosahovať vysokú presnosť, pretože väčšina testovacích dát patrí do negatívnej triedy. To však ukazuje zásadné obmedzenia týchto modelov pri praktickej detekcii.

Podobné limity sú viditeľné aj pri modeli K-Nearest Neighbors (KNN). Hoci dosiahol vysokú presnosť v tréningovej (97,4%) aj testovacej fáze (95,6%), tieto hodnoty sú skreslené. Nízka senzitivita (16%) naznačuje, že model správne klasifikuje najmä pozadie, nie cieľové objekty. KNN pritom identifikoval plesň len v 5 z 10 testovacích obrázkov, čo potvrdzuje, že jeho vysoká presnosť nie je výsledkom spoľahlivej detekcie.

Celkovo je možné konštatovať, že nie všetky modely sú vhodné pre úlohu detekcie plesní. Modely LR, SVM a KNN síce dosahujú vysoké hodnoty celkovej presnosti, no nízka detekčná schopnosť a citlivosť odhaľujú ich praktické limity. Naopak, modely LDA, CART a NB poskytujú vyvážený pomer medzi presnosťou a reálnou schopnosťou identifikovať plesň, vďaka čomu sú vhodnejšie pre podrobnejšiu analýzu aj praktické

využitie.

Následne autori porovnali tri najlepšie dosahujúce modely s morfológickou filtráciou. V tabuľke nižšie uvádzame prehľadné zhrnutie získaných výsledkov.

Classification Methods	Mean	Standard Deviation	T-Statistic	p-value
Classification and Regression Trees (CART)	0.9597	0.0169	3.5017	0.00997
Morphological Filtering (MF)	0.9470	0.0238	2.9471	0.02149
Linear Discriminant Analysis (LDA)	0.9209	0.0625	3.1340	0.01652
Gaussian Naïve Bayes (NB)	0.9184	0.0578	3.3754	0.01183

Obr. 2.3: Porovnanie troch metód strojového učenia a morfológického filtrovania

Analýza preukázala štatisticky významné rozdiely pre všetky porovnávané metódy, čo znamená, že každý z klasifikátorov priniesol merateľné zlepšenie oproti pôvodnej, neklasifikačnej metóde. Z hľadiska priemernej presnosti a najnižšej štandardnej odchýlky sa ako najlepší model ukázal CART, ktorý dosiahol $\text{mean} = 0.9597$ a veľmi nízku variabilitu výsledkov ($\text{SD} = 0.0169$).

Napriek tomu všetky štyri testované metódy preukázali signifikantné zlepšenie výkonu, čo zdôrazňuje efektivitu použitia klasifikácie v tejto úlohe. Morfológická filtrácia dosiahla nižšiu priemernú presnosť ako CART, avšak predbehla modely LDA aj NB, čo naznačuje, že aj keď nie je najpresnejšia, predstavuje konkurencieschopnú možnosť. Jej výhodou môže byť najmä jednoduchosť, interpretovateľnosť a menšie nároky na výpočtový výkon.

Tieto výsledky poukazujú na to, že metódy strojového učenia výrazne zlepšujú presnosť detekcie oproti pôvodnému riešeniu a predstavujú efektívny prístup pre daný dataset aj úlohu.

Autori otvorene poukazujú na niekoľko obmedzení:

- **Nerovnováha datasetu:** malý počet pozitívnych vzoriek plesní znižuje schopnosť modelov generalizovať [9].
- **Obmedzený rozsah dát:** dáta pochádzali len z dvoch malieb, čo limituje použiteľnosť modelu pre iné typy umeleckých objektov (papier, pergamen, textil). Autori však zdôrazňujú, že rámec metódy je ľahko prenosný aj na iné materiály, pretože spracúva obrazové dáta nezávisle od typu podkladu. [9]

Význam štúdie spočíva v tom, že predstavuje automatizovaný, objektívny a replikovateľný prístup k identifikácii biologických poškodení na kultúrnych objektoch. Metodika ukazuje, že aj štandardné algoritmy strojového učenia bez hlbokých neurónových sietí dokážu pri vhodnej príprave dát dosahovať vysokú presnosť.

2.3 Digitálna analýza a AI

Okrem výskumu na akademickej pôde existuje viacero komerčných a výskumných aplikácií, ktoré umožňujú automatickú identifikáciu poškodení, napríklad plesní, na rôznych materiáloch. Tieto systémy často využívajú algoritmy strojového učenia, vrátane konvolučných neurónových sietí (CNN), na spracovanie obrazových dát a klasifikáciu poškodení. Každá z týchto metód predstavuje špecifický prístup k analýze papiera a jeho poškodení. Ich kombinácia umožňuje komplexný a spoľahlivý pohľad na stav historických materiálov, čo je predpokladom pre účinnú konzerváciu a reštaurovanie.

Medzi významné prístupy patria:

1. **Webové rozhranie na identifikáciu plesní** – poskytuje používateľovi možnosť nahrávať fotografie poškodených materiálov, ktoré sú následne automaticky analyzované modelom AI [6].
2. **Mobilná aplikácia s využitím AI** – umožňuje reštaurátorom a konzervátorom identifikovať poškodenia priamo v teréne pomocou smartfónu. Model AI využíva predtrénované CNN na klasifikáciu obrazových dát [5].
3. **Konvolučné neurónové siete (CNN)** – tieto modely slúžia ako základ pre vyššie uvedené aplikácie a dokážu automaticky detegovať a klasifikovať rôzne typy poškodení, vrátane plesní a fyzikálnych poškodení papiera [8].

Na vybraných aplikáciách sme realizovali experimenty na vzorkách s rôznou zložitou, vrátane jednoduchých aj náročnejších prípadov, ktoré predstavovali vyššie nároky na rozlíšenie. Výsledky testov a hodnotenie výhod a nevýhod jednotlivých aplikácií sú prezentované v nasledujúcich podkapitolách.


2.3.1 Použité vzorky

Na testovanie vybraných aplikácií boli použité vzorky s rôznou zložitou a charakteristikami. Nakoľko všetky aplikácie deklarujú schopnosť rozpoznávať hlavne plesne, vybrali sme si z našich vzoriek z každej plesne jeden referenčný obraz. Taktiež sme si ale vybrali aj zopár neplesní aby sme vedeli otestovať aj ich.


Pracovali sme s jednotlivými vzorkami:

- Vzorka č. 1: plesň *Alternaria alternata*
- Vzorka č. 2: plesň *Aspergillus ochraceus*
- Vzorka č. 3: plesň *Talaromyces purpureogenus* (rástla 8 dní)
- Vzorka č. 4: plesň *Talaromyces purpureogenus* (rástla 4 dní)


- Vzorka č. 5: baktéria *Sphingomonas aquatilis*
- Vzorka č. 6: baktéria *Rhodococcus degradans*




Vzorka č. 1




Vzorka č. 2




Vzorka č. 3



Vzorka č. 4



Vzorka č. 5



Vzorka č. 6

2.3.2 Webové rozhranie na identifikáciu plesní

V rámci tejto časti sme realizovali šesť sérií experimentov, v ktorých sme testovali jednotlivé vzorky plesní. Každá séria pozostávala z dvoch krokov: najskôr sme vykonali identifikáciu na celej vzorke (ako je znázornené na obrázkoch vyššie) a následne sme z tej istej vzorky vystrihli iba napadnutú oblasť, na ktorej bol experiment zopakovaný. Výsledky vidíme v tabuľke nižšie.

Výsledky naznačujú, že použitie menšej, cielene vybranej napadnutej oblasti má vo viacerých prípadoch pozitívny vplyv na presnosť identifikácie. Pri troch zo štyroch vzoriek sme po orezaní získali vyššiu alebo rovnocennú pravdepodobnosť správneho určenia. Tento efekt je pravdepodobne spôsobený tým, že pri orezaní ostáva v obraze väčší podiel relevantných morfológických znakov, zatiaľ čo rušivé časti vzorky (napr. pozadie, nenapadnutý materiál) sú odstránené. Zároveň pozorujeme, že namerané hodnoty

Tabuľka 2.1: Výsledky identifikácie jednotlivých vzoriek pred a po orezaní

Vzorka	Celá vzorka (%)	Orezaná časť (%)
1	67.50	72.50
2	67.50	67.50
3	70.00	72.50
4	67.50	62.50
5 (nie plesneň)	72.50	62.50
6 (nie plesneň)	62.50	57.50

sa pohybujú prevažne v intervale približne 62–72%, čo poukazuje na limitácie aktuálneho modelu pri presnej klasifikácii. Výsledky sú teda konzistentné, ale len stredne presné. Ďalšou nevýhodou je, že model neposkytuje bližšiu informáciu o konkrétnom type plesne. Výstup je obmedzený iba na pravdepodobnostné vyjadrenie, či ide alebo nejde o plesneň, pričom chýba detailnejšia klasifikácia. To výrazne obmedzuje využiteľnosť modelu v praxi, najmä pri aplikáciách, kde je potrebné rozlíšiť medzi jednotlivými rodmi alebo druhmi plesní. Osobitne dôležité je, že pri vzorke č. 4 došlo po orezaní k poklesu presnosti. To môže naznačovať, že nie každá napadnutá oblasť obsahuje dostatočne rozpoznateľné znaky, alebo že algoritmus citlivo reaguje na zmeny kontrastu a textúry v malých výrezoch. Tento rozdiel zároveň podčiarkuje potrebu štandardizovaného spôsobu výberu orezanej oblasti, aby boli výsledky medzi vzorkami porovnateľné.

Pri vzorke č. 5 a 6, ktoré v skutočnosti neobsahovali žiadnu plesneň, model napriek tomu priradil relatívne vysoké pravdepodobnosti (72,50% a 62,50%). V oboch prípadoch ide o vzorky, ktoré sú bakteriálneho pôvodu, no model ich klasifikoval ako plesne. Ide teda o jasný príklad falošne pozitívnej identifikácie, čo predstavuje zásadný nedostatok aktuálneho riešenia. Z pohľadu praktického nasadenia je to významný problém, keďže môže viesť k mylnému vyhodnoteniu zdravotných alebo hygienických rizík.

2.3.3 Mobilná aplikácia s využitím AI

V ďalšej časti práce sa zameriame na experimentovanie s dostupnou mobilnou aplikáciou na detekciu plesní, ktorú si môže používateľ jednoducho nainštalovať do svojho smartfónu. Ako testovaciu platformu sme zvolili aplikáciu Mold Inspection, ktorá je dostupná pre zariadenia so systémom Android. Aplikácia umožňuje vykonávať jednoduchú analýzu fotiek povrchov a poskytuje používateľovi informáciu o tom, s akou pravdepodobnosťou sa na obrázku nachádza plesneň. Jej použitie je intuitívne a nevyžaduje odborné znalosti, čo z nej robí vhodný nástroj na porovnávacie testovanie v rámci tejto práce.

Experimenty vykonáme rovnakým spôsobom ako v predchádzajúcej časti, aby sme

mohli dosiahnuté výsledky oboch modelov priamo porovnávať. Výsledky vidíme v tabuľke nižšie.

Tabuľka 2.2: Výsledky identifikácie jednotlivých vzoriek pred a po orezaní

Vzorka	Celá vzorka (%)	Orezaná časť (%)
1	90	90
2	70	-
3	90	90
4	75	-
5 (nie plesň)	-	-
6 (nie plesň)	-	-

Ešte predtým, než vyhodnotíme úspešnosť jednotlivých experimentov, je potrebné zdôrazniť kvalitu a prehľadnosť výstupu, ktorý aplikácia poskytuje. Už v úvodnom zobrazení používateľ vidí odhadovanú pravdepodobnosť výskytu plesne. Nižšie sú dostupné aj doplňujúce informácie, ako je predpokladaný typ, farba a textúra, ako aj podrobnosti o raste plesne a jej možných účinkoch na zdravie. Celkový výstup pôsobí veľmi prehľadne a obsahuje množstvo detailných a prakticky využiteľných informácií.

Vzorka č. 1 predstavovala plesň *Alternaria alternata*. Mobilná aplikácia však pri jej analýze neidentifikovala konkrétny rod. Namiesto toho poskytla len všeobecné hodnotenie, pravdepodobne bežná plesň v interiéri (napr. druhy *Cladosporium*, *Aspergillus*). Tento výsledok je síce čiastočne relevantný, keďže uvedené rody sa skutočne často vyskytujú v interiéroch, avšak nejde o správnu identifikáciu druhu, ani o správnu kategóriu.

Aplikácia zároveň priradila vysokú pravdepodobnosť výskytu plesne (90%), čo je z hľadiska samotného rozpoznania prítomnosti plesne správne.

Vzorka č. 2 predstavovala plesň *Aspergillus ochraceus*. Mobilná aplikácia pri prvom experimente v tejto sérii vyhodnotila, že na obrázku sa nachádza plesň so 70% pravdepodobnosťou. Presnejšia špecifikácia však nebola možná – aplikácia uviedla iba to, že pravdepodobne ide o bežne sa vyskytujúcu domácu plesň („likely common household mold“). Pri druhom experimente aplikácia nedokázala identifikovať žiadnu plesň na snímke.

Na základe týchto výsledkov môžeme konštatovať, že aplikácia nebola pri tejto vzorke úspešná. Neposkytla ani spoľahlivú identifikáciu prítomnosti plesne, ani špecifikáciu jej druhu.

Vzorka č. 3 predstavovala plesň *Talaromyces purpureogenus*, ktorá rástla 8 dní.

Mobilná aplikácia pri prvom experimente v tejto sérii vyhodnotila, že na obrázku sa nachádza plesň s 90% pravdepodobnosťou. Presnejšia špecifikácia uvádzala, že by mohlo ísť o bežne sa vyskytujúce domáce plesne, napríklad *Cladosporium* alebo *Alternaria*. Pri druhom experimente aplikácia opäť uviedla 90% pravdepodobnosť, že sa na obrázku nachádza plesň, pričom ako možné druhy označila *Cladosporium*, *Aspergillus* alebo *Penicillium*.

Z uvedeného vyplýva, že ani pri tejto vzorke aplikácia nedokázala spoľahlivo identifikovať konkrétny druh plesne. Na druhej strane však s vysokou pravdepodobnosťou správne určila, že analyzovaný objekt je plesň.

Vzorka č. 4 predstavovala plesň *Talaromyces purpureogenus*, ktorá rástla 4 dní. Mobilná aplikácia pri prvom experimente v tejto sérii vyhodnotila, že na obrázku sa nachádza plesň so 75% pravdepodobnosťou. Presnejšia špecifikácia uvádzala, že by mohlo ísť o bežne sa vyskytujúce domáce plesne, napríklad *Cladosporium* alebo *Alternaria*. Pri druhom experimente aplikácia nedokázala identifikovať žiadnu plesň na snímke.

Môžeme konštatovať, že síce aplikácia dokázala identifikovať, že na obrázku sa nachádza plesň tak presnejšia špecifikácia už nebola možná.

Vzorka č. 5 predstavovala baktériu *Sphingomonas aquatilis*. Mobilná aplikácia pri prvom experimente v tejto sérii nedokázala identifikovať žiadnu plesň na snímke. Pri druhom experimente aplikácia taktiež nedokázala identifikovať žiadnu plesň na snímke.

Na základe týchto výsledkov môžeme konštatovať, že aplikácia správne neidentifikovala plesň tam, kde sa v skutočnosti nenachádzala, čo naznačuje, že v tomto prípade bola úspešná pri rozpoznaní, že ide o iný mikroorganizmus než plesň.

Vzorka č. 6 predstavovala baktériu *Rhodococcus degradans*. Mobilná aplikácia pri prvom experimente v tejto sérii nedokázala identifikovať žiadnu plesň na snímke. Pri druhom experimente aplikácia tiež nedokázala identifikovať žiadnu plesň na snímke.

Výsledky ukazujú, že aplikácia správne vyhodnotila, že na snímke sa plesň nenachádza, čo poukazuje na jej relatívne spoľahlivú schopnosť identifikovať neprítomnosť plesní.

Na základe vykonaných experimentov možno celkovo zhodnotiť, že testovaná mobilná aplikácia vykázala zmiešanú úroveň úspešnosti pri identifikácii plesní. V prípadoch, kde sa na snímkach skutočne nachádzali plesne (vzorky č. 1–4), aplikácia vo väčšine prípadov relatívne spoľahlivo rozpoznala prítomnosť plesne ako takej, pričom pravdepodobnosti sa pohybovali v rozmedzí 70–90%. Na druhej strane však nedoká-

zala presne určiť konkrétny rod ani druh. Vo všetkých plesňových vzorkách poskytla iba všeobecné kategórie alebo uvádzala najčastejšie sa vyskytujúce interiérové plesne, ktoré sa nezhodovali so skutočnou identitou vzoriek.

Pri vzorkách obsahujúcich baktérie (vzorky č. 5 a 6) bola aplikácia úspešná v tom, že v oboch prípadoch správne neindikovala prítomnosť plesne. To naznačuje, že aplikácia je pomerne spoľahlivá pri rozpoznávaní neprítomnosti plesní a dokáže odlíšiť plesneň od iného typu mikroorganizmu.

Celkovo teda možno konštatovať, že aplikácia má primeranú úspešnosť pri detekcii samotnej prítomnosti plesne, avšak jej schopnosť určiť presný rod alebo druh je veľmi obmedzená. Aplikácia je tak použiteľná najmä na základné orientačné posúdenie, či sa na snímke nachádza potenciálna plesneň, nie však na odbornú taxonomickú identifikáciu.

Kapitola 3

Ciele práce

Hlavným cieľom diplomovej práce je vytvoriť metódu založenú na technikách strojového učenia a umelej inteligencie prípadne na klasických metódach používaných pri spracovaní obrazu. Aplikácia umožní spoľahlivú identifikáciu rôznych typov škvŕn na historickom papieri. Takáto identifikácia je významná pre oblasť konzervovania a reštaurovania papiera, keďže správne určenie pôvodcu poškodenia má zásadný vplyv na výber vhodných postupov preventívnej starostlivosti a následného zásahu. Škvŕny na historických dokumentoch môžu mať rôzny pôvod — mikrobiologický (plesne a baktérie), biologický (hmyz), chemický (atramentové škvŕny, pečiatky) či environmentálny. Jednoduchý a rýchly spôsob ich identifikácie môže významne prispieť k optimalizácii procesov monitorovania, diagnostiky a rozhodovania počas reštaurátorských intervencií. V našej práci sa zameriame na identifikáciu plesní.

Aby bolo možné hlavný cieľ naplniť, práca si stanovuje tieto špecifické čiastkové ciele:

1. **Preskúmať existujúce prístupy k detekcii škvŕn a mikrobiálnej kontaminácie na historickom papieri.** To zahŕňa prehľad odborných postupov používaných v reštaurátorskej praxi, ako aj moderných digitálnych metód založených na počítačovom videní, klasifikácii obrazov či hlbokých neurónových sieťach. Cieľom je identifikovať, ktoré prístupy sú relevantné pre návrh riešenia.
2. **Analyzovať typy škvŕn, ktoré sa bežne vyskytujú na historických papierových nosičoch, a vytvoriť vhodnú kategorizáciu pre účely tréningu a testovania modelu.** Pozornosť bude venovaná najmä mikrobiologickým škvŕnám, keďže tie sú z hľadiska dlhodobej konzervácie najrizikovejšie.
3. **Vybudovať dataset obrazových snímok škvŕn, získaných buď z dostupných zdrojov, alebo zachytených v spolupráci s reštaurátormi.** Dataset bude slúžiť ako základ pre tréning a experimentálne overenie navrhovanej metódy.

4. **Navrhnuť a implementovať metódu na identifikáciu škvŕn, ktorá využije techniky strojového učenia alebo počítačového videnia.** Cieľom je vytvoriť klasifikátor schopný rozlišovať medzi jednotlivými kategóriami škvŕn (napr. mikrobiologické, atramentové, iné organické škvŕny).
5. **Experimentálne vyhodnotiť úspešnosť navrhnutej metódy.** Testovanie bude zamerané na presnosť klasifikácie, robustnosť pri rôznych typoch snímok, analýzu chýb a určenie situácií, v ktorých model zlyháva alebo dosahuje vysokú úspešnosť. Súčasťou bude aj porovnanie s existujúcimi nástrojmi, ak sú dostupné.
6. **Zhodnotiť praktickú využiteľnosť navrhnutej metódy v reštaurátorskej praxi.** Cieľom je posúdiť, či je metóda vhodná ako podpora pri rýchlom monitorovaní zbierok, v depozitároch alebo pri rozhodovaní o type zásahu.

Napĺňaním týchto cieľov práca prispeje k vytvoreniu jednoduchšieho, digitálne podporeného prístupu k identifikácii škvŕn na historickom papieri, čo môže predstavovať prínos pre oblasť konzervovania a reštaurovania kultúrneho dedičstva.

Kapitola 4

Návrh riešenia

Kapitola 5

Implementácia

5.1 Použité knižnice

Kapitola 6

Výskum

Cieľom tejto kapitoly je predstaviť experimentálnu časť práce, v ktorej boli overené možnosti automatizovanej identifikácie mikrobiálnych škvrín na historickom papieri. Výskum sa sústreďuje na návrh, implementáciu a testovanie vlastného prototypu klasifikačného systému, ktorý bol postupne vyvíjaný s cieľom analyzovať, ktoré obrazové príznaky a aké modely strojového učenia sú pre túto úlohu najvhodnejšie. V rámci výskumu boli vytvorené a vyhodnotené viaceré experimenty zahŕňajúce spracovanie obrazových dát, extrakciu príznakov, tvorbu modelov a ich validáciu na reálnych vzorkách plesní a baktérií.

Súčasťou kapitoly sú aj vizuálne a analytické výstupy prototypu – grafy, obrázky, ukážky jednotlivých vzoriek, štatistické prehľady úspešnosti či ukážky chybových klasifikácií. Tieto výstupy ilustrujú správanie prototypu v rôznych situáciách a umožňujú transparentne posúdiť jeho silné aj slabé stránky. Kapitola tak poskytuje komplexný prehľad o experimentoch, ktoré boli v rámci práce vykonané, a zároveň vytvára pevný základ pre interpretáciu dosiahnutých výsledkov v nasledujúcej kapitole.

6.1 Prvý pokus – prototyp klasifikátora

V rámci výskumnej časti práce bol vytvorený prototyp klasifikačného systému, ktorého cieľom bolo preskúmať možnosti automatizovanej identifikácie mikrobiálnych škvrín na historickom papieri. Prototyp vznikol ako experimentálne riešenie, ktoré umožnilo otestovať vhodnosť rôznych farebných, textúrnych a geometrických príznakov, overiť ich diskriminačnú schopnosť a zhodnotiť ich použiteľnosť pri jednoduchých modeloch strojového učenia.

Výskum bol realizovaný v prostredí Python a pozostával z troch hlavných častí:

1. návrh vývojového prostredia a použitých technológií,
2. implementácia prvého klasifikačného prototypu,

3. testovanie prototypu na reálnych vzorkách plesní a baktérií.

V prvej fáze výskumu bol vytvorený jednoduchý binárny klasifikátor, ktorého úlohou bolo odlíšiť dve triedy: plesň a baktéria. Cieľom nebolo dosiahnuť maximálnu presnosť, ale naopak overiť, ktoré obrazové príznaky majú najväčšiu rozlišovaciu schopnosť a môžu byť neskôr použité vo finálnom modeli.

Každý extrahovaný príznak bol:

- analyzovaný samostatne,
- otestovaný v jednoduchom klasifikátore,
- vyhodnotený s ohľadom na úspešnosť a stabilitu.

Najúspešnejšie príznaky boli následne zahrnuté do kombinovaného modelu.

Prototyp bol testovaný na rovnakých vzorkách plesní a baktérií, ktoré sú popísané v kapitole 2 (napr. *Alternaria*, *Aspergillus*, *Talaromyces*, *Sphingomonas*, *Rhodococcus*). Tie poskytujú výrazné rozdiely v textúre a farebnosti, čo je vhodné pre prvé experimenty.

V tejto fáze výskumu sme sa zamerali na základné farebné a štatistické príznaky, ktoré je možné extrahovať aj bez zložitej segmentácie. Medzi najdôležitejšie použité príznaky patrili:

- Priemerná farba v RGB priestore – základný indikátor farebnej odlišnosti medzi plesňami a baktériami.
- Štandardná odchýlka farieb v jednotlivých RGB kanáloch – využitá ako aproximácia vizuálnej heterogenity.
- Sýtosť (saturation) z HSV modelu – rozdiely medzi suchými bakteriálnymi škvrnami a dynamickejšími, pigmentovo bohatými plesňami sa prejavili práve v tomto príznaku.

Prvotný model dosiahol celkovú úspešnosť klasifikácie 86 %, pričom 14 % vzoriek bolo klasifikovaných nesprávne. Omyly modelu sa najčastejšie vyskytovali pri: 3kvrnách s nízkym kontrastom, vzorkách s nejasnými hranicami, svetlých žltých a hnedastých oblastiach, ktoré pripomínajú viac než jednu kategóriu.

Tieto problematické prípady naznačujú, že základné farebné príznaky nie sú dostatočné a je potrebné doplniť: textúrne príznaky (napr. Haralickove parametre), príznaky

tvaru, prípadne hlbšie modely extrahujúce komplexnejšie štruktúry.

Napriek týmto obmedzeniam prototyp splnil svoj účel – umožnil identifikovať najdôležitejšie príznaky a ukázal, v ktorých situáciách základná metóda zlyháva. Zistenia z tejto časti výskumu tvoria základ pre návrh finálneho riešenia, ktoré bude uvedené v nasledujúcich podkapitolách.

Kapitola 7

Dosiahnuté výsledky

Záver

Literatúra

- [1] Andre Backes, Maurício Escarpinati, and Bruno Travençolo. A derivative based algorithm for image thresholding. 11 2016.
- [2] Francisca Figueira, Marta Matos, Aida Nunes, Mariana Afonso, Ana Rocha, Joana Campelo, and Teresa Ferreira. Considerations about foxing stains in three paper collections ranging from the 16th to the 20th century. *Conservar Património*, 35, 05 2020.
- [3] Iveta Gladišová, Jan Mihalik, and Peter Hanzély. *Morfologická filtrácia obrazov*. 01 2018.
- [4] Douglas Goltz, Michael Attas, Gregory Young, Edward Cloutis, and Maria Bedynski. Assessing stains on historical documents using hyperspectral imaging. *Journal of Cultural Heritage - J CULT HERIT*, 11:19–26, 03 2010.
- [5] MoldAI Inc. Mold detection mobile application, 2024. Online; prístup 28. 10. 2025.
- [6] MoldAI Inc. Mold detection web application, 2024. Online; prístup 28. 10. 2025.
- [7] Maja Kostadinovska. Non-destructive characterization of paper artifacts in conservation treatments: A critical minireview. 12 2015.
- [8] Chenshu Liu, Songbin Ben, Chongwen Liu, Xianchao Li, Qingxia Meng, Yilin Hao, Qian Jiao, and Pinyi Yang. Web-based diagnostic platform for microorganism-induced deterioration on paper-based cultural relics with iterative training from human feedback. *Heritage Science*, 12:1–13, 2024.
- [9] Hilman Nordin, Bushroa Razak, Norrima Mokhtar, Fadzil Jamaludin, and Adeel Mehmood. Automated mold defects classification in paintings: A comparison of machine learning and rule-based techniques. *PLOS ONE*, 20, 01 2025.
- [10] Hilman Nordin, Bushroa Razak, Norrima Mokhtar, Fadzil Jamaludin, and Adeel Mehmood. Automated mold defects classification in paintings: A comparison of machine learning and rule-based techniques. *PLOS ONE*, 20, 01 2025.

- [11] Kathlin Smith. “dirty” old books: Building a library of stains with multispectral imaging. CLIR [online], June 2018. Cit. k dñu 2025-10-16.
- [12] Mattia Titubante, Claudia Marconi, Lucia Citiulo, Adriano Conte, Claudia Mazzuca, Francesco Petrucci, Olivia Pulci, Manuel Tumiatì, Shan Wang, Laura Micheli, and Mauro Missori. Analysis and diagnosis of the state of conservation and restoration of paper-based artifacts: A non-invasive approach. *Journal of Cultural Heritage*, 55:290–299, 05 2022.
- [13] Mattia Titubante, Claudia Marconi, Lucia Citiulo, Adriano Mosca Conte, Claudia Mazzuca, Francesco Petrucci, Olivia Pulci, Manuel Tumiatì, Sha Nong Wang, Laura Micheli, and Mauro Missori. Analysis and diagnosis of the state of conservation and restoration of paper-based artifacts: A non-invasive approach. *Journal of Cultural Heritage*, 2022.
- [14] Yueer Yan, Yi Tang, and Yuliang Yang. Chemical conservation of paper-based cultural heritage. *Molecules*, 30:122, 12 2024.

Príloha A: obsah elektronickej prílohy

V elektronickej prílohe priloženej k práci sa nachádza kompletný zdrojový kód, manuál... Zdrojový kód a ostatné spomínané súbory sú zverejnené aj v on-line repozitári na adrese https://github.com/saraguzi/grid_optimization.