

Umjetna inteligencija i spektralni *unmixing* u analizi pisane baštine

Damir Modrić¹, Vladimir Cviljušac¹, Alan Divjak², Jana Žiljak Gršić³

¹Sveučilište u Zagrebu Grafički fakultet, Getaldićeva 2, 10000 Zagreb

²Sveučilište Algebra Bernays, Gradišćanska ul. 24, 10000 Zagreb

³Tehničko veleučilište u Zagrebu, Vrbik 8, 10000 Zagreb

Sažetak: *Primjena umjetne inteligencije (UI) u multispektralnoj i hiperspektralnoj analizi značajno proširuje mogućnosti istraživanja pisane kulturne baštine. Klasične metode poput PCA, ICA i linearnih modela spektralnog unmixinga ograničene su pretpostavkom linearnosti i stabilnih spektralnih potpisa, što u povijesnim rukopisima često nije zadovoljeno zbog nelinearnog miješanja pigmenata, utjecaja podloge i degradacije veziva. U radu se analiziraju teorijske osnove spektralne reflektancije, kalibracije (IRF) i multivarijantne obrade podataka te se razmatra doprinos dubokog učenja u modeliranju nelinearnih interakcija pigment-vezivo-podloga. Na primjerima iluminiranih rukopisa 14. i 15. stoljeća pokazuje se kako kombinacija hiperspektralne analize i naprednih algoritama omogućuje precizniju identifikaciju pigmenata, detekciju naknadnih intervencija i poboljšanje čitljivosti degradiranog teksta. Rezultati potvrđuju da UI predstavlja metodološki iskorak u nerazornoj dijagnostici kulturne baštine.*

Ključne riječi: *umjetna inteligencija, hiperspektralna analiza, spektralni unmixing, pisana baština, identifikacija pigmenata*

1. Uvod

Pisana kulturna baština, uključujući iluminirane rukopise, predstavlja složene materijalne sustave u kojima se mikroskopski miješaju pigmenti, veziva i podloge nastali stoljećima primjenom tradicionalnih tehnika i fizikalno-kemijskih procesa degradacije. Analiza takvih objekata zahtijeva nerazorne metode jer je uzimanje uzoraka često neprihvatljivo zbog njihove povijesne i kulturne vrijednosti.

Hiperspektralno snimanje (HSI) omogućuje registraciju reflektancije objekta u velikom broju uskih spektralnih kanala (Slika 1), stvarajući podatkovnu kocku u kojoj se za svaki piksel dobiva potpuni spektralni potpis. Time se dobiva prostorno-spektralna

U kontekstu identifikacije pigmentata u umjetničkim djelima i rukopisima, recentni radovi pokazuju da HSI može biti povezan s metodama strojnog učenja kako bi se izgradili podatkovni modeli koji istovremeno klasificiraju čiste i miješane spektre te omogućuju mapiranje spektralnih obilježja kroz cijelu površinu objekta. Ovi pristupi nadmašuju tradicionalne linearne metode u preciznosti identifikacije i kvantitativnoj procjeni pigmentata, osobito kad su prisutni složeni miješani spektar i varijabilna pozadina materijala [1, 6].

Cilj ovog rada je pružiti teorijsko i metodološko utemeljenje primjene hiperspektralnog snimanja, kombinirano s multivarijantnom analizom i umjetnom inteligencijom, u nerazornoj analizi pisane kulturne baštine. Posebna se pozornost posvećuje problemu spektralnog *unmixinga* i ulozi nelinearnih modela u poboljšanju identifikacije materijala u uvjetima kompleksnih spektralnih interakcija.

2. Fizikalne osnove spektralne reflektancije i hiperspektralnog snimanja

2.1 Spektralna reflektancija i optičke interakcije u slojevima boje

Spektralna reflektancija $R(\lambda)$ definira se kao omjer reflektirane i upadne zračne energije pri određenoj valnoj duljini. U idealiziranom slučaju homogenog pigmentnog sloja reflektancijski spektar primarno ovisi o apsorpcijskim svojstvima pigmentnih čestica. Međutim, u stvarnim povijesnim rukopisima pigmenti su dispergirani u vezivu i nanoseni na podlogu (pergament ili papir), pri čemu dolazi do višestrukog raspršenja i parcijalne transmisije svjetlosti.

U takvim višeslojnim sustavima spektralni odziv rezultat je kombinacije selektivne apsorpcije pigmenta, raspršenja na česticama različite granulacije, refleksije na podlozi, interakcije pigment-vezivo i degradacijskih promjena tijekom vremena.

Optičko ponašanje slojeva boje u umjetničkim djelima detaljno je opisano u literaturi koja povezuje hiperspektralnu analizu s fizikalnim modelima refleksije [2]. Istraživanja mineralnih pigmentata pokazala su da spektralne varijacije unutar iste kromatske zone mogu proizlaziti iz promjene granulacije ili veziva, a ne nužno iz promjene kemijskog sastava [7, 8].

To znači da usporedba izmjerene spektra s referentnim spektrom čistog pigmenta predstavlja tek prvi korak u interpretaciji, ali ne i konačni dokaz identifikacije.

2.2 Linearni i nelinearni modeli spektralnog miješanja

U obradi hiperspektralnih podataka često se primjenjuje linearni model miješanja:

$$r = \sum_{i=1}^n a_i e_i + \varepsilon$$

gdje su:

r – izmjereni spektar,

e_i – spektar i -te čiste komponente (*endmember*),

a_i – udio komponente,

ε – rezidualni signal (šum).

Linearni model pretpostavlja da foton interagira s jednom komponentom prije izlaska iz sustava. U praksi iluminiranih rukopisa ta pretpostavka često nije u potpunosti zadovoljena zbog višestrukog raspršenja i slojevitosti.

Istraživanja spektralnog *unmixinga* na oslikanim artefaktima pokazala su da varijabilnost spektra može biti značajna čak i unutar istog pigmentnog područja, osobito kada su prisutne promjene u podlozi ili debljini sloja [7]. Usporedba linearnih i nelinearnih pristupa u identifikaciji miješanih pigmenata pokazuje da linearni modeli mogu generirati stabilna matematička rješenja, ali ne uvijek fizikalno najtočnija [8].

Nelinearni modeli uključuju dodatne interakcijske članove, ali povećavaju računalnu složenost i zahtijevaju napredne optimizacijske algoritme. Upravo tu umjetna inteligencija, posebno duboko učenje, omogućuje implicitno modeliranje nelinearnih odnosa bez eksplicitnog definiranja funkcionalnog oblika miješanja [9].

2.3 Instrumentalni aspekti hiperspektralnog snimanja

Svaki hiperspektralni sustav karakteriziraju spektralna rezolucija, radiometrijska osjetljivost, *signal-to-noise* omjer i instrumentalna funkcija odziva (IRF).

Izmjerena digitalna vrijednost $D(\lambda)$ može se aproksimirati relacijom:

$$D(\lambda) = E(\lambda) \cdot R(\lambda) \cdot S(\lambda) \quad (1)$$

gdje su:

$D(\lambda)$ – izmjereni digitalni signal,

$E(\lambda)$ – spektralna raspodjela izvora svjetla,

$R(\lambda)$ – reflektancija objekta,

$S(\lambda)$ – spektralna osjetljivost sustava.


Bez kalibracije (tamni signal, bijeli referentni standard, korekcija osvjetljenja) nemoguće je dobiti fizikalno interpretabilne podatke. U kontekstu kulturne baštine istaknuto je da je standardizirana radiometrijska kalibracija preduvjet pouzdane klasifikacije materijala [5].

2.3.1 Laboratorijski sustav za multispektralno snimanje pisane baštine

U ovom istraživanju korišten je laboratorijski sustav (shematski prikaz je dat na Slici 2) za multispektralno snimanje razvijen za potrebe dokumentacije i analize pisane povijesne građe. Sustav je koncipiran kao modularna konfiguracija optimizirana za visoku radiometrijsku stabilnost, spektralnu selektivnost i reproduktivnost mjerenja.

Središnja komponenta sustava je industrijska monokromatska kamera s CMOS senzorom rezolucije 5472×3648 piksela (≈ 20 MP). Senzor je formata 1", s veličinom piksela $2,4 \mu\text{m}$. Dinamički raspon iznosi 12 stopa (≈ 72 dB), dok A/D konverzija radi u 12-bitnom režimu. Spektralna osjetljivost detektora obuhvaća područje približno od 300 do 1000 nm.

Visoka prostorna rezolucija i relativno mala veličina piksela omogućuju preciznu dokumentaciju detalja iluminacija, dok 12-bitna kvantizacija osigurava 4096 diskretnih razina signala, što je važno za očuvanje finih tonalnih prijelaza u spektralnim analizama.



Slika 2: Laboratorijski postav za hiperspektralno skeniranje iluminacija rukopisa

Uz kameru se koristi objektiv visoke razlučivosti žarišne duljine 25 mm, maksimalnog otvora blende $f/2,8$ i minimalne udaljenosti fokusa 0,3 m. Horizontalni i vertikalni vidni kut iznose $28,7^\circ$ i $21,7^\circ$. Manualna kontrola fokusa i otvora blende omogućuje optimizaciju dubinske oštine i ekspozicije u skladu s karakteristikama analiziranog artefakta.

3. Spektralna selekcija – uskopojasni filtri

Ključnu ulogu u formiranju spektralne kocke podataka imaju uskopojasni interferencijski filtri. Sustav koristi 21 uskopojasni filtar u vidljivom području, te 12 filtara u blisko infracrvenom području, sa širinom pojasa približno 10 nm oko vršne valne duljine. Tako se dobivaju ukupno 33 diskretna spektralna kanala. U odnosu na klasične hiperspektralne *push-broom* sustave, ovakav pristup predstavlja sekvencijalnu multispektralnu akviziciju visoke selektivnosti.

Širina pojasa od 10 nm omogućuje detekciju uskih apsorpcijskih minimuma, diferencijaciju spektralno sličnih pigmenta i smanjenje integracije neželjenih spektralnih komponenti. Međutim, treba naglasiti da diskretna akvizicija uvodi vremensku komponentu snimanja, što zahtijeva stabilne uvjete osvjetljenja i nepomičnost artefakta.

3.1. Prednosti i ograničenja konfiguracije

3.1.1 Prednosti sustava

Konfiguraciju našeg sustava odlikuje visoka prostorna rezolucija (20 MP), diskretna spektralna selektivnost (razlučivost do 10 nm), širok spektralni raspon (bliski UV + VIS + NIR), kontrolirani laboratorijski uvjeti te visoki dinamički raspon (72 dB). Takva konfiguracija omogućuje precizno mapiranje spektralnih karakteristika iluminacija i pisane građe.

3.1.2 Ograničenja

Ipak, potrebno je imati na umu da sustav ima i određena ograničenja: diskretni (ne kontinuirani) spektralni uzorak, potencijalna varijabilnost između sekvencijalnih snimanja, ovisnost o stabilnosti osvjetljenja i potrebe za strogo definiranom kalibracijom.

Ova ograničenja posebno su relevantna pri primjeni algoritama spektralnog *unmixing*-a i modela strojnog učenja, jer varijacije koje nisu materijalnog podrijetla mogu utjecati na generalizacijsku sposobnost modela [10, 14].

3.2 Implikacije za daljnju obradu podataka

Konfiguracija sustava izravno utječe na kvalitetu PCA separacije, stabilnost NMF/ICA dekompozicije i uspješnost nelinearnih AI modela. Pri čemu diskretni 10 nm kanali čine sustav pogodnim za klasifikacijske modele, regresijske modele procjene sastava, te hibridne spektralno-prostorne CNN arhitekture.

U kontekstu ovog rada, naš sustav predstavlja temelj za razvoj naprednih modela spektralnog *unmixinga* i identifikacije materijala u iluminiranim rukopisima.

3.3 Prostorno-spektralna analiza

Jedna od ključnih prednosti HSI-a u odnosu na točkaste metode (npr. FORS) jest mogućnost istodobne prostorne i spektralne analize. Time se omogućuje mapiranje distribucije pigmentata, segmentacija tekstualnih i slikovnih zona i analiza heterogenosti unutar iste boje.

Primjena metoda poput NMF i ICA pokazala je da se miješani pikseli mogu razložiti na dominantne komponente koje odgovaraju pojedinim pigmentnim doprinosima [7]. Međutim, preciznost takve dekompozicije ovisi o modelu miješanja i kvaliteti podataka.

Integracija prostornih značajki u klasifikacijske modele (npr. konvolucijske neuronske mreže) dodatno povećava robusnost identifikacije pigmentata jer se uzima u obzir i morfologija površine [8].

4. Kalibracija i instrumentalna funkcija odziva (IRF)

4.1 Radiometrijska osnova kalibracije

Hiperspektralno snimanje u području kulturne baštine ima smisla samo ako je izmjereni signal moguće povezati s fizikalnom veličinom – reflektancijom površine. Izmjerena digitalna vrijednost ovisi ne samo o objektu, nego i o izvoru osvjetljenja i osjetljivosti sustava, što je opisano relacijom (1). Kako bi se izolirala reflektancija $R(\lambda)$, potrebno je ukloniti utjecaj spektralne raspodjele izvora $E(\lambda)$ i spektralne osjetljivosti sustava $S(\lambda)$. U tu svrhu primjenjuje se radiometrijska kalibracija koja se temelji na referentnim mjerenjima poznate reflektancije. Postupak kalibracije omogućuje kompenzaciju instrumentalnih i iluminacijskih varijacija te osigurava usporedivost podataka između različitih sesija snimanja. U kontekstu analize umjetničkih djela naglašeno je da bez dosljedne kalibracije spektralna usporedba s referentnim bibliotekama nije pouzdana [10].

4.2 Instrumentalna funkcija odziva (IRF)

Instrumentalna funkcija odziva (IRF) opisuje ukupnu spektralnu osjetljivost sustava, uključujući optičke elemente (leće, filtre), disperzijski sustav, detektor i elektroniku pojačanja signala.

IRF je valno ovisna funkcija i može značajno varirati u UV, vidljivom i NIR području. Ako se IRF ne uzme u obzir, dolazi do sistematskih pogrešaka u obliku spektra, osobito na rubovima spektralnog raspona.

U radovima koji se bave primjenom hiperspektralnog snimanja u arheologiji i konzervaciji naglašeno je da varijacije instrumentalnog odziva mogu dovesti do pogrešne klasifikacije pigmentata ako nisu pravilno kompenzirane [10]. Dodatno, u klasifikacijskim modelima temeljenim na strojnome učenju pokazano je da neujednačena kalibracija smanjuje generalizacijsku sposobnost modela [11].

IRF se može procijeniti eksperimentalno snimanjem poznatih referentnih materijala ili matematičkom aproksimacijom odziva detektora i optičkog sustava.

4.3 Spektralna rezolucija i omjer signal-šum

Spektralna rezolucija definira širinu spektralnog kanala ($\Delta\lambda$) i izravno utječe na sposobnost razlučivanja uskih apsorpcijskih značajki. U identifikaciji pigmentata, osobito mineralnih, točna identifikacija uskih apsorpcijskih vrpca može biti presudna za diferencijaciju kemijski srodnih spojeva [9].

Omjer signal – šum (engl. *signal-to-noise ratio*) (SNR) definira se kao:

$$\text{SNR} = \mu / \sigma$$

gdje su:

μ – srednja vrijednost signala,

σ – standardna devijacija šuma.

Nizak SNR može maskirati suptilne spektralne razlike između sličnih pigmentata. U hiperspektralnoj analizi kulturne baštine preporučuje se optimizacija ekspozicije i višestruko usrednjavanje kako bi se smanjio utjecaj šuma [10].

4.4 Standardizacija i reproduktivnost

Jedan od ključnih izazova u primjeni hiperspektralnog snimanja u kulturnoj baštini jest reproduktivnost rezultata. Različiti sustavi, različiti izvori osvjetljenja i različiti

geometrijski uvjeti snimanja mogu generirati spektralne razlike koje nisu povezane s materijalnim sastavom objekta.

Recentna istraživanja pokazuju da standardizirani protokoli snimanja i kalibracije značajno poboljšavaju točnost klasifikacijskih modela i spektralnog *unmixinga* [7, 11]. Posebno je važno da modeli strojnog učenja budu trenirani na podacima dobivenima pod kontroliranim i dokumentiranim uvjetima, jer u suprotnom dolazi do tzv. *domain shift* problema [12].

U kontekstu pisane kulturne baštine, gdje je svaki artefakt jedinstven, dosljedna kalibracija i dokumentiranje instrumentalnih parametara predstavljaju preduvjet znanstvene vjerodostojnosti rezultata.

5. Multivarijantne metode u spektralnoj analizi

Hiperspektralni podaci mogu se promatrati kao matrica X dimenzija $m \times n$, gdje je m broj piksela (ili uzoraka), a n broj spektralnih kanala. Svaki red matrice predstavlja jedan spektar, a svaki stupac intenzitet pri određenoj valnoj duljini. Zbog visoke dimenzionalnosti i koreliranosti kanala, izravna interpretacija podataka nije praktična. Multivarijantne metode omogućuju redukciju dimenzionalnosti, izdvajanje dominantnih varijacijskih obrazaca, segmentaciju materijalnih zona i pripremu podataka za napredne modele (uključujući UI). U našoj analizi koristimo metode koje su ukratko prikazane u poglavljima koja slijede.

5.1 Analiza glavnih komponenti (PCA)

PCA transformira izvorne varijable u novi skup ortogonalnih komponenti maksimalne varijance. Matematički, postupak se temelji na dekompoziciji kovarijacijske matrice:

$$C = (1 / (m - 1)) \cdot X^T X$$

Rješenje se dobiva eigendekompozicijom:

$$C v_i = \lambda_i v_i$$

gdje su:

v_i – eigenvektori (glavne komponente),

λ_i – eigenvrijednosti (varijanca komponente).

Prva komponenta sadrži najveći udio varijance, druga sljedeći itd.

U hiperspektralnoj analizi umjetničkih djela PCA se široko koristi za uklanjanje šuma, vizualizaciju skrivenih struktura i pojačavanje kontrasta između tekstualnih i slikovnih elemenata [14].

U radu koji uspoređuje NMF i ICA u pigmentnim analizama pokazano je da PCA učinkovito razdvaja glavne varijacijske obrasce, ali ne garantira fizikalnu interpretabilnost komponenti [8].

5.2 Analiza nezavisnih komponenti (ICA)

Za razliku od PCA, koja maksimizira varijancu, ICA traži statistički nezavisne izvore signala. Model se može zapisati kao:

$$X = AS$$

gdje su:

X – matrica opaženih spektara,

A – matrica miješanja,

S – matrica nezavisnih komponenti.

Cilj je pronaći S takvu da su njezini redovi statistički nezavisni.

U kontekstu iluminiranih rukopisa ICA može omogućiti razdvajanje pigmentne komponente, podloge, mrlja ili degradacijskih produkata [15], preslikanog (engl. *bleed-through*) teksta. Usporedba ICA i NMF pristupa pokazala je da ICA često daje jasnije razdvajanje zona gdje su pigmenti pomiješani, ali je osjetljivija na šum i inicijalne uvjete [9]. U iluminacijama s plavim i crvenim zonama ICA bi mogla izdvojiti komponentu vezanu uz bakrene pigmente i zasebnu komponentu podloge, što omogućuje prostornu mapu raspodjele materijala.

5.3 Ne-negativna matrična faktorizacija (NMF)

Za razliku od PCA i ICA, NMF nameće uvjet ne-negativnosti:

$$X \approx WH \quad \text{gdje su } W \geq 0 \text{ i } H \geq 0.$$

Ovo je posebno važno u spektralnoj analizi jer reflektancija i udjeli pigmenta ne mogu biti negativni. Prednosti NMF-a su bolja fizikalna interpretabilnost, prirodna dekompozicija na “dijelove” i kompatibilnost s linearnim *unmixing* modelom. U analizi miješanih pigmenta pokazano je da NMF može bolje rekonstruirati komponente u usporedbi s PCA, ali uz veću računalnu složenost [8].

5.4 Ograničenja klasičnih multivarijantnih metoda

Iako su PCA, ICA i NMF iznimno korisne, njihova ograničenja leže u pretpostavci linearnog miješanja, osjetljivosti na šum i kalibracijske pogreške te ovisnosti o inicijalizaciji (ICA, NMF). Recentna istraživanja spektralnog *unmixinga* u umjetničkim djelima pokazuju da linearnost nije uvijek zadovoljena, osobito kod tankih ili polutransparentnih slojeva [7].

Ovo izravno motivira prijelaz prema nelinearnim modelima i metodama strojnog učenja.

5.5 Prijelaz prema umjetnoj inteligenciji

Klasične multivarijantne metode poput PCA, ICA i NMF pokazale su se učinkovitim u preliminarnoj analizi hiperspektralnih podataka iluminiranih rukopisa, no sve se više koriste konvolucijske mreže (CNN), autoenkoderi i hibridni prostorno-spektralni modeli [15, 16], a pregled metoda dubokog učenja za hiperspektralne podatke pokazuje da nelinearni modeli nadmašuju linearne metode u klasifikaciji miješanih spektara, osobito pri velikoj varijabilnosti podataka [15]. One omogućuju redukciju dimenzionalnosti, vizualnu separaciju spektralno različitih zona te djelomičnu dekompoziciju miješanih signala. U kontekstu kulturne baštine to znači bolju diferencijaciju sličnih pigmentata, robusnije razdvajanje slojeva i potencijalno precizniji spektralni *unmixing* u složenim iluminacijama [8]. Međutim, rezultati dobiveni u ovom istraživanju ukazuju na određena ograničenja takvih pristupa.

Prvo, linearne metode pretpostavljaju da se izmjereni spektar može opisati linearnom kombinacijom nekoliko baznih komponenti koje u stvarnim iluminacijama često prepoznamo kao višeslojne nanose pigmenta, interakcije pigment-vezivo-podloga, degradacijske procese i polutransparentne slojeve i djelomičnu transmisiju svjetlosti. Takve situacije mogu dovesti do nelinearnog spektralnog ponašanja koje linearne metode ne modeliraju u potpunosti.

Drugo, PCA komponente nemaju izravno fizikalno značenje. Iako jasno diferenciraju zone varijance, njihova interpretacija u smislu stvarnih materijalnih sastojaka ostaje ograničena. ICA i NMF nude veću interpretabilnost, ali su osjetljive na šum, inicijalizaciju i varijabilnost spektralnih potpisa.

U tom kontekstu umjetna inteligencija, odnosno metode strojnog i dubokog učenja, predstavljaju potencijalni razvojni smjer. Za potrebe ovog rada umjetna inteligencija definira se kao skup algoritama koji iz podataka uče obrasce i odnose bez eksplicitnog definiranja matematičkog modela fizikalnog procesa.

U hiperspektralnoj analizi to može uključivati klasifikaciju pigmentata na temelju spektralnih potpisa, procjenu udjela komponenti u miješanim pikselima, segmentaciju iluminacija i tekstualnih zona, te detekciju degradacijskih obrazaca.

Pregled suvremenih metoda pokazuje da modeli temeljeni na dubokom učenju postižu visoku točnost u klasifikaciji hiperspektralnih podataka [15, 16]. Važno je naglasiti da implementacija takvih modela zahtijeva dovoljno velik i reprezentativan skup podataka, pažljivu radiometrijsku kalibraciju, validacijske protokole i, nadalje, interdisciplinarnu suradnju između stručnjaka za obradu slike, računalne znanosti i konzervatorske struke.

Laboratorijski sustav korišten u ovom istraživanju, s kontroliranim uvjetima snimanja i diskretnim spektralnim kanalima, predstavlja dobru osnovu za razvoj takvih modela u budućnosti.

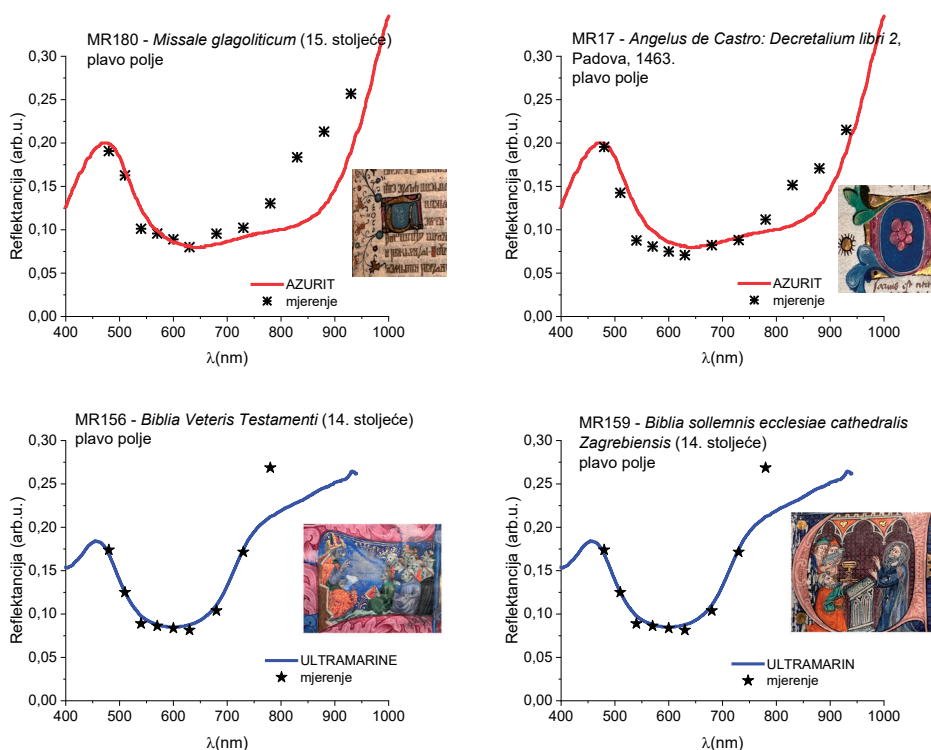
Stoga se umjetna inteligencija u ovom radu ne uvodi kao zamjena za klasične metode, već kao njihova nadogradnja i potencijalni alat za rješavanje problema spektralnog *unmixinga* i preciznije identifikacije materijala. Detaljna implementacija i evaluacija takvih modela zahtijevat će suradnju sa specijalistima iz područja umjetne inteligencije i računalne obrade podataka.

6. Metodološki izazovi spektralne analize pisane baštine

Jedan od temeljnih izazova u hiperspektralnoj analizi iluminiranih rukopisa jest činjenica da spektralni potpis pigmenta u stvarnom artefaktu često odstupa od laboratorijski izmjenjenog referentnog spektra. Razlozi za to uključuju promjene granulacije pigmenta, različite omjere pigment-vezivo, heterogenost podloge (pergament, papir), proces starenja i degradacije, te lokalna oštećenja i retuše.

spektralni potpis mora promatrati kao funkcija materijalnog sustava, a ne izoliranog kemijskog spoja. Ova varijabilnost otežava izravnu klasifikaciju i zahtijeva pažljivo definirane interpretacijske kriterije.

Kako bi ovo ilustrirali prikazat ćemo rezultate (Slika 3) u analizi pigmentata 15. stoljeća što smo proveli na knjigama iz fundusa Metropolitane (Bibliotheca Metropolitana, Metropolitana knjižnica), knjižnice Zagrebačke nadbiskupije i Prvostolnoga kaptola zagrebačkoga. Metropolitana je najveća crkvena knjižnica i jedna od najstarijih sačuvanih knjižnica u Hrvatskoj.



Slika 3: Usporedba reflektancijskih spektara poznatih povijesnih pigmenata (azurit, ultramarin, indigo, crveni olovni prah, cinober) s izmjeranim spektrima iz četiri iluminirana rukopisa (14. i 15. stoljeće). Iako podudarnost nije savršena, eksperimentalni podaci potvrđuju identifikaciju pigmenata. Odstupanja se pripisuju starenju i kasnijim intervencijama

U iluminacijama s plavim i crvenim zonama ICA bi mogla izdvojiti komponentu vezanu uz bakrene pigmente i zasebnu komponentu podloge, što omogućuje prostornu mapu raspodjele materijala. U našim dosadašnjim analizama iluminacija (14.-15. st.) PCA je pokazala da prve dvije ili tri komponente često sadrže dominantnu informaciju o pigmentnim zonama, dok više komponente otkrivaju suptilne razlike unutar iste boje (npr. varijacije plavog područja) [8, 9].

Identifikacija pigmenata u pravilu se temelji na usporedbi izmjenenog spektra s referentnim spektrom. Međutim, dostupne baze podataka često ne uključuju varijacije u vezivu, ne obuhvaćaju degradirane uzorke, te skoro nikad nisu snimljene pod istim instrumentalnim uvjetima. Stoga je razumno pretpostaviti da, bez standardiziranih baza spektralnih potpisa prilagođenih povijesnim materijalima, postoji rizik pogrešne atribucije.

U kontekstu našeg rada, laboratorijski sustav s kontroliranim uvjetima snimanja pruža mogućnost postupne izgradnje vlastite referentne baze, što predstavlja važan razvojni smjer.

Slijedeće ključno pitanje u znanstvenoj analizi kulturne baštine je reproducibilnost. Različiti sustavi, različiti filtri i različite geometrije snimanja mogu, na istim uzorcima, generirati spektralne razlike koje nisu posljedica materijalnih promjena. U suprotnom, usporedba rezultata između različitih institucija postaje metodološki problematična.

Hiperspektralnom analizom iluminacija utvrđeno je da je dominantni plavi pigment azurit, što potvrđuju karakteristične apsorpcijske značajke u području oko 460 nm i 620 nm, tipične za bakrov karbonat-hidroksid [4, 9]. Uočena odstupanja u odnosu na laboratorijske referentne spektre mogu se objasniti utjecajem podloge, starenjem veziva, djelomičnim miješanjem s bijelim pigmentima te mogućim naknadnim restauratorskim intervencijama.

Primjena multivarijantnih metoda, posebice PCA i ICA, omogućila je razdvajanje tekstualnih i slikovnih elemenata te poboljšanje čitljivosti degradiranih dijelova rukopisa korištenjem tehnike lažnog prikaza boje [8, 12]. Dobiveni rezultati ukazuju da varijabilnost spektralnog odziva nije primarno posljedica promjene debljine sloja pigmenta, već složenih nelinearnih interakcija između materijala, što potvrđuje potrebu za primjenom naprednijih modela obrade spektralnih podataka.

7. Diskusija

Rezultati prikazani u ovom radu potvrđuju da hiperspektralna analiza pruža pouzdan uvid u materijalni sastav iluminiranih rukopisa, no istodobno razotkrivaju i temeljna metodološka ograničenja klasičnih multivarijantnih pristupa. PCA i ICA pokazale su se učinkovitima u redukciji dimenzionalnosti i izdvajanja dominantnih spektralnih obrazaca [12, 15], osobito u poboljšanju čitljivosti degradiranog teksta. Međutim, njihova interpretabilnost ovisi o pretpostavci linearne kombinacije izvora, što u slojevitim strukturama povijesnih tekstova nije uvijek fizikalno opravdano. Analiza iluminacija 14. i 15. stoljeća pokazala je da izmjereni spektri odstupaju od referentnih laboratorijskih vrijednosti azurita. Takva odstupanja mogu se objasniti interakcijom pigmenta i veziva, optičkim doprinosom podloge, mikroskopskim miješanjem s drugim pigmentima, te degradacijskim procesima tijekom stoljeća. Stoga, linearni spektralni *unmixing* u tim uvjetima može generirati matematički stabilna, ali fizikalno teško interpretabilna rješenja. To potvrđuje da problem nije isključivo statističke prirode, nego proizlazi iz kompleksne optike višeslojnih sustava. Upravo u tom kontekstu umjetna inteligencija predstavlja metodološki pomak [15, 16]. Duboke neuronske mreže mogu modelirati nelinearne odnose bez eksplicitne definicije funkcionalnog oblika miješanja čime se omogućuje aproksimacija složenih refleksijskih funkcija, robusnija klasifikacija pigmentata, integracija prostornih i spektralnih značajki, adaptivno učenje na heterogenim skupovima podataka, itd.

Međutim, da bi kvalitetno primijenili UI u analizi i zaštiti kulturne baštine potrebno je riješiti niz izazova kao što su nedostatak opsežnih, standardiziranih referentnih baza spektralnih potpisa povijesnih materijala, ograničena količina označenih (labeliranih) podataka za treniranje modela, potreba za objašnjivim modelima (engl. *Explainable AI*), osobito u konzervatorskoj praksi gdje je transparentnost odluka ključna, te reproduktivnost rezultata pri različitim sustavima snimanja i uvjetima osvjetljenja.

Posebno je važno naglasiti da UI ne može zamijeniti fizikalno razumijevanje optičkih procesa. Umjesto toga, optimalni pristup podrazumijeva hibridne modele koji kombiniraju fizikalno utemeljene modele refleksije, multivarijantnu statistiku i nelinearne neuronske arhitekture.

8. Zaključak

U radu je prikazana integracija hiperspektralne analize, multivarijantnih metoda i pristupa umjetne inteligencije u istraživanju pisane kulturne baštine. Teorijska razrada spektralne reflektancije i postupaka radiometrijske kalibracije potvrđuje da je precizna instrumentalna korekcija temelj pouzdane interpretacije spektralnih podataka. Primjena metoda poput PCA i ICA pokazala je njihovu učinkovitost u redukciji dimenzionalnosti i vizualizaciji skrivenih struktura, ali i ograničenja linearnih modela u analizi složenih, višeslojnih materijalnih sustava [2].

Na primjerima iluminiranih rukopisa iz 14. i 15. stoljeća potvrđena je prisutnost azurita kao dominantnog plavog pigmenta, uz izraženu varijabilnost spektralnog odziva koja ukazuje na nelinearne interakcije između pigmenta, veziva i podloge. Takvi rezultati potvrđuju da linearni modeli ne mogu u potpunosti opisati fizikalnu realnost povijesnih slojeva boje te upućuju na potrebu za naprednijim pristupima analizi.

Umjetna inteligencija, osobito metode temeljene na dubokom učenju, predstavlja perspektivan smjer razvoja jer omogućuje modeliranje nelinearnog spektralnog mijenjanja, automatiziranu klasifikaciju materijala i integraciju različitih izvora podataka. Međutim, njezina primjena zahtijeva sustavan razvoj referentnih baza spektralnih potpisa, standardizaciju postupaka snimanja, implementaciju objašnjivih modela te interdisciplinarnu validaciju rezultata.

Zaključno, umjetna inteligencija ne zamjenjuje postojeće analitičke metode, već ih nadopunjuje i proširuje. Sinergija fizikalno utemeljenih pristupa, multivarijantne analize i nelinearnih modela omogućuje dublje razumijevanje materijalne strukture povijesnih dokumenata te otvara nove mogućnosti u nerazornoj dijagnostici, interpretaciji i očuvanju pisane kulturne baštine.

9. Literatura

- [1] Fatma, Z. S. N.; Hardeberg, J. Y., Papachristos, E.: Pigment Identification of Ortelius' Historical Maps using Hyperspectral Imaging, *Journal of Imaging Science (IS&T)*, **22** (2025) 18-23, <https://doi.org/10.2352/issn.2168-3204.2025.22.1.4>
- [2] Liang, H.: Advances in multispectral and hyperspectral imaging for archaeology and art conservation, *Applied Physics A*, **106** (2012) 2, 309-323, <https://doi.org/10.1007/s00339-011-6689-1>
- [3] Zhang, J.; Su, R., Fu, Q., Ren, W., Heide, F., Nie, Y.: A survey on computational spectral reconstruction methods from RGB to hyperspectral imaging. *Scientific Reports*, **12** (2022) 11905, <https://doi.org/10.1038/s41598-022-16223-1>
- [4] Bioucas-Dias, J. M.; Plaza, A., Camps-Valls, G., Scheunders, P., Nasrabadi, N., Chanussot, J.: Hyperspectral unmixing overview: geometrical, statistical, and sparse regression-based approaches, *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, **5** (2012) 2, 354-379, <https://doi.org/10.1038/4456510.1109/JSTARS.2012.2194696>
- [5] Wang, Y.; Lyu, S., Ning, B., Yan, J., Hou, M., Sun, P., Li, L.: Spectral Unmixing of Pigments on Surface of Painted Artefacts Considering Spectral Variability, *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, **X-4** (2024) 403-409
- [6] Liu, J.; Li, T., Yu, Z., Lyu, S., Fu, Q., Yu, X.: Hyperspectral identification of mineral pigments in Thangka paintings for cultural heritage conservation. *npj Heritage Science* **13** (2025) 649, <https://doi.org/10.1038/s40494-025-02241-5>
- [7] Liu, Y.; Lyu, S., Hou, M., Yin, Q.: The Comparison between NMF and ICA in Pigment Mixture Identification of Ancient Chinese Paintings, *ISPRS Archives*, **XLII-3** (2018) 1169-1176
- [8] Modrić, D.: Hyperspectral camera as a spectrometer in the preservation of written and printed historical materials; International scientific conference, Colour in written heritage - multidisciplinary research, Book of abstracts, Zagreb, 25 – 27, September 2024, p 32, ISBN: 978-953-8461-27-9
- [9] Cviljušac, V.: Analysis of the spectrum of illuminations in books from the 14th and 15th centuries obtained with a hyperspectral camera; International scientific conference, Colour in written heritage - multidisciplinary research, Book of abstracts, Zagreb, 25 – 27, September 2024, p 33, ISBN: 978-953-8461-27-9
- [10] Pan, S. J.; Yang, Q.: A Survey on Transfer Learning, *IEEE Transactions on Knowledge and Data Engineering*, **22** (2010) 10, 1345-1359, <https://doi.org/10.1109/TKDE.2009.191>
- [11] Manolakis, D.; Shaw, G.: Detection Algorithms for Hyperspectral Imaging Applications, *IEEE Signal Processing Magazine*, **19** (2002) 1, 29-43, <https://doi.org/10.1109/79.974724>
- [12] Jolliffe, I. T.; Cadima, J.: Principal component analysis: a review and recent developments, *Philosophical Transactions of the Royal Society A*, **374** (2016) 20150202, <https://doi.org/10.1098/rsta.2015.0202>
- [13] Li, S.; Kang, X., Fang, L., Hu, J., Yin, H.: Deep learning for hyperspectral image classification: An overview, *IEEE Transactions on Geoscience and Remote Sensing*, **57** (2019) 9, 6690-6709, <https://doi.org/10.1109/TGRS.2019.2907932>

-
- [14] Chen, Y.; Lin, Z., Zhao, X., Wang, G., Gu, Y.: Deep Learning-Based Classification of Hyperspectral Data, *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, **7** (2014) 6, 2094-2107, <https://doi.org/10.1109/JSTARS.2014.2329330>
- [15] Hyvärinen, A.; Oja, E.: Independent component analysis: algorithms and applications, *Neural Networks*, **13** (2000) 4-5, 411-430, [https://doi.org/10.1016/S0893-6080\(00\)00026-5](https://doi.org/10.1016/S0893-6080(00)00026-5)
- [16] Lee, D. D.; Seung, H. S.: Learning the parts of objects by non-negative matrix factorization, *Nature*, **401** (1999) 788-791, <https://doi.org/10.1038/44565>