

Primljeno/Submitted: 15.3.2025.
Prihvaćeno/Accepted: 11.6.2025.

Predhodno priopćenje
Preliminary research

PRIMJENA UMJETNE INTELIGENCIJE U RESTAURACIJI STARIH VIDEA: PREDNOSTI I IZAZOVI U ODNOSU NA TRADICIONALNE METODE

APPLICATION OF ARTIFICIAL INTELLIGENCE IN THE RESTORATION OF OLD VIDEOS: ADVANTAGES AND CHALLENGES COMPARED TO TRADITIONAL METHODS

Nešad Krnjić*

Nina Zukić**

SAŽETAK

Restauracija starih videozapisa ima važnu ulogu u očuvanju vizuelne historije, ali tradicionalne metode su često vremenski zahtjevne i ograničene u mogućnostima poboljšanja kvaliteta slike. Napredak u području umjetne inteligencije (engl. *Artificial Intelligence*, AI) otvorio je nove mogućnosti za automatizaciju procesa restauracije korištenjem tehnika dubokog učenja, koje omogućavaju povećanje rezolucije, redukciju šuma i kolorizaciju snimaka. U ovom radu analizirana je primjena AI tehnologija u restauraciji starih videa i data je njihova komparacija s tradicionalnim metodama. Korištena metodologija obuhvata analizu performansi AI modela kao što su ESRGAN i DeOldify, te njihovo poređenje s konvencionalnim tehnikama interpolacije i filtriranja. Evaluacija je provedena pomoću subjektivne vizuelne analize i objektivnih metrika kao što su PSNR i SSIM. Rezultati pokazuju da AI značajno poboljšava kvalitet restaurisanih videa, posebno u slučajevima jake degradacije, i nadmašuje tradicionalne pristupe u preciznosti i detaljnosti prikaza. Istovremeno, identificirani su izazovi vezani za računalne zahtjeve i mogućnost generiranja artefakata. Zaključno, rad ukazuje na transformativni potencijal AI u digitalnoj restauraciji i naglašava potrebu za daljim istraživanjima u pravcu hibridnih rješenja i etičkih standarda.

Ključne riječi: umjetna inteligencija, restauracija videa, tradicionalne metode, duboko učenje, obrada slike

ABSTRACT

The restoration of old video footage plays a vital role in preserving visual history, yet traditional methods are often time-consuming and limited in their ability to improve image quality. Advances in artificial intelligence (AI) have opened new possibilities for automating the restoration process through deep learning techniques that enhance resolution, reduce noise,

* Docent, Sveučilište/Univerzitet „VITEZ“; Fakultet informacionih tehnologija, e-mail: nesad.krnjic@unvi.edu.ba

** Bachelor, Sveučilište/Univerzitet „VITEZ“; Fakultet informacionih tehnologija, e-mail: nina.zukic@unvi.edu.ba

and apply colorization. This paper analyzes the application of AI technologies in restoring degraded video content and compares them with traditional restoration methods. The methodology involves performance analysis of AI models such as ESRGAN and DeOldify, benchmarked against conventional interpolation and filtering techniques. Evaluation was conducted using both subjective visual assessment and objective metrics including PSNR and SSIM. The results indicate that AI significantly improves the quality of restored videos, particularly in heavily degraded cases, surpassing traditional methods in detail reconstruction and precision. However, the study also identifies key challenges such as high computational demands and the potential introduction of visual artifacts. In conclusion, the paper highlights the transformative potential of AI in digital video restoration and emphasizes the need for further research into hybrid solutions and ethical standards.

Keywords: artificial intelligence, video restoration, traditional methods, deep learning, image processing

UVOD

Restauracija starih videozapisa igra značajnu ulogu u očuvanju kulturne i vizuelne historije, omogućavajući novim generacijama da pristupe vizuelnim zapisima iz prošlosti u boljem kvalitetu. Tokom vremena, analogni i rani digitalni formati podložni su fizičkoj degradaciji, gubitku boje, pojavi šuma i smanjenju rezolucije. Proces restauracije je od suštinskog značaja za očuvanje ovih materijala i njihovu prilagodbu modernim formatima za dalju upotrebu. Tradicionalne metode restauracije, koje uključuju ručne intervencije i algoritamske pristupe poput interpolacije okvira i prostorno-vremenskog filtriranja, pokazale su ograničenja u obnavljanju izgubljenih detalja i zahtijevaju značajan vremenski i stručni angažman (Blau & Michaeli, 2019). Iako su ove metode postigle značajne rezultate, one su često dugotrajne, skupe i ograničene u mogućnostima vraćanja izgubljenih detalja, posebno u videozapisima niske rezolucije ili s ozbiljnim oštećenjima.

Napredak u području umjetne inteligencije, a posebno dubokog učenja i generativnih suparničkih mreža, otvorio je nove mogućnosti u automatizaciji i poboljšanju procesa restauracije starih videozapisa. Ove tehnologije omogućavaju mašinama da "nauče" kompleksne obrasce degradacije i rekonstruiraju izgubljene vizuelne informacije na način koji oponaša ljudsku percepciju. Modeli poput ESRGAN, Topaz Video Enhance AI i DeOldify demonstriraju sposobnost generiranja realističnih vizuelnih elemenata, povećanja rezolucije, smanjenja šuma te automatsku kolorizaciju crno-bijelih snimaka. U mnogim slučajevima, rezultati dobijeni pomoću ovih alata nadmašuju tradicionalne tehnike u pogledu kvalitete, efikasnosti i očuvanosti detalja (Lim et al., 2021; Zhang & Yang, 2020).

Primjena ovih tehnologija, međutim, donosi i izazove. AI modeli zahtijevaju snažnu računalnu infrastrukturu, velike količine podataka za treniranje, te pažljivo upravljanje rezultatima kako bi se izbjegli vizuelni artefakti (neprirodni tragovi u generisanoj slici, poput halo efekta ili lažnih rubova) i narušavanje autentičnosti sadržaja (Galteri et al., 2023). Također, javlja se potreba za etičkim razmatranjem autorske vjerodostojnosti u kontekstu rekonstrukcije sadržaja pomoću algoritama.

Cilj ovog rada je analizirati savremene AI pristupe restauraciji videa, uporediti ih s tradicionalnim metodama, te sistematski procijeniti njihove prednosti i ograničenja. Fokus je na evaluaciji performansi modela kao što su ESRGAN i DeOldify u kontekstu restauracije stvarnih arhivskih videozapisa. Kroz kombinaciju subjektivne vizuelne procjene i objektivnih mjera kvaliteta (PSNR i SSIM), rad nastoji doprinijeti boljem razumijevanju primjenjivosti AI u digitalnom očuvanju audiovizuelnog naslijeđa.

1. METODOLOGIJA

U okviru istraživanja provedena je komparativna analiza tradicionalnih i savremenih AI metoda restauracije videozapisa. Metodologija obuhvata pregled relevantnih tehnika, izbor reprezentativnih datasetova, primjenu konkretnih softverskih alata i kvantitativnu te kvalitativnu evaluaciju rezultata.

1.1. Tradicionalne metode restauracije videa

U sklopu tradicionalnih pristupa primijenjene su metode kao što su interpolacija okvira, redukcija šuma i povećanje rezolucije. Interpolacija se temelji na metodama kompenzacije pokreta (engl. *Motion Compensation Frame Interpolation*, MCFI), koje analiziraju pokret između frejmova i generiraju međufrejmove radi povećanja fluidnosti (Zhang & Liu, 2020). Redukcija šuma obavljena je uz pomoć prostorno-vremenskih filtera, uključujući Gaussovo zamućenje (engl. *Gaussian blur*) i redukciju šuma wavelet metodama (engl. *wavelet denoising*), što su standardne tehnike u obradi niskokvalitetnih videozapisa. Za povećanje rezolucije korištene su bikubične i Lanczos interpolacije, iako je poznato da ove metode ne mogu generirati nove informacije, već samo skaliraju postojeće (Blau & Michaeli, 2019).

1.2. AI metode restauracije videa

Za pristup restauraciji videozapisa korištene su napredne metode umjetne inteligencije zasnovane na dubokim neuronskim mrežama, pri čemu su posebno istaknuti modeli bazirani na generativnim suparničkim mrežama (engl. *generative adversarial networks*, GAN) i konvolucionim neuronskim mrežama (engl. *convolutional neural networks*, CNN). GAN modeli omogućavaju generiranje vizuelno uvjerljivih slika putem procesa suparništva između generatora i diskriminatora, što se pokazalo izuzetno korisnim za kolorizaciju i obnovu degradiranih segmenata videa. CNN modeli, s druge strane, odlikuju se sposobnošću ekstrakcije hijerarhijskih vizuelnih karakteristika iz ulaznih podataka, što ih čini posebno pogodnim za zadatke poput redukcije šuma, povećanja rezolucije, interpolacije okvira i poboljšanja detalja slike. Kombinacija ovih pristupa čini osnovu savremenih AI alata za restauraciju videa. Među najistaknutijima su: ESRGAN (engl. *Enhanced Super-Resolution GAN*), koji omogućava poboljšanje rezolucije i oštine slike (Wang et al., 2018), DeOldify, koji koristi GAN i U-Net arhitekturu za kolorizaciju i obnovu crno-bijelih video sadržaja (Antic, 2023), te Topaz Video Enhance AI – komercijalni softver koji koristi prilagođene modele

dubokog učenja za skaliranje rezolucije do 8K, uz naprednu obradu sitnih detalja i minimiziranje artefakata.

1.3. Dataset i softverski alati

Analiza je provedena nad arhivskim snimcima različitog porijekla, uključujući VHS formate, dokumentarne filmove iz ranih 90-ih i degradirane crno-bijele zapise. Odabrani uzorci karakterizirani su niskom rezolucijom, izraženim šumom i gubitkom kontrasta. Softverski alati korišteni u eksperimentima uključuju:

- OpenCV (za tradicionalne metode filtriranja i interpolacije) (OpenCV, 2023),
- DeOldify (open-source AI kolorizator baziran na PyTorch platformi),
- Topaz Video Enhance AI (komercijalni alat s fokusom na super-rezoluciju),
- ESRGAN (open-source GAN model za povećanje rezolucije).

1.4. Tehnike evaluacije

Kvalitet rezultata procijenjen je pomoću subjektivne i objektivne evaluacije. Subjektivna evaluacija uključivala je vizuelnu analizu razlika između originalnih i restaurisanih zapisa, fokusirajući se na oštrinu, prirodnost boja i prisustvo artefakata. Objektivna evaluacija provedena je korištenjem metrika:


- PSNR (engl. *Peak Signal-to-Noise Ratio*), koja mjeri odnos između signala i šuma, i
- SSIM (engl. *Structural Similarity Index Measure*), koja mjeri sličnost strukturnih komponenti slike (Wang et al., 2004; Horé & Ziou, 2010).

Obje metrike su standard u evaluaciji kvaliteta slike u videoobradi i široko se koriste u najnovijim istraživanjima (Lim et al., 2021).

2. REZULTATI

U ovoj sekciji prikazani su rezultati uporedne analize tradicionalnih i AI metoda restauracije videa. Evaluacija je izvršena primjenom objektivnih metrika PSNR i SSIM, kao i mjerenjem vremena obrade. Dodatno je provedena subjektivna procjena kvaliteta na uzorku ispitanika s iskustvom u video produkciji i digitalnoj restauraciji. Tabela 1 prikazuje uporedne vrijednosti PSNR i SSIM indeksa za analizirane metode. Na dijagramu 1 data je ilustracija tih dobivenih vrijednosti.

Dijagram 1: PSNR i SSIM poređenje metoda restauracije



Izvor: vlastiti izvor na osnovu podataka iz Tabele 1, 2025.

Tabela 1: PSNR i SSIM pokazatelji za različite metode restauracije

Metoda	PSNR (dB)	SSIM (0-1)	Vrijeme obrade (s)
Tradicionalna interpolacija	28.5	0.75	10
AI ESRGAN	32.2	0.88	20
DeOldify	30.5	0.85	25
Topaz Video Enhance AI	34.1	0.91	30
OpenCV Denoising	29.8	0.78	12

Izvor: vlastita obrada na osnovu eksperimentalnih podataka (2025).

2.1. Kvalitativna analiza

Tradicionalne metode, poput interpolacije i denoising filtera implementiranih u okviru OpenCV biblioteke, pokazale su najkraće vrijeme obrade, ali i ograničene performanse u pogledu ukupnog kvaliteta izlaznog videa. Na primjer, bikubična interpolacija može povećati učestalost prikaza sličica, odnosno broj sličica u sekundi (engl. *frames per second* – FPS), čime se postiže veća fluidnost prikaza. Međutim, budući da se radi o prostoj matematičkoj procjeni vrijednosti piksela na osnovu susjednih, ova metoda ne doprinosi stvarnom generiranju novih vizuelnih informacija. Kao rezultat toga, ovakvi pristupi često dovode do niskih PSNR i SSIM vrijednosti, što ukazuje na slabiju sposobnost rekonstrukcije originalnih detalja i strukture slike (Zhang & Liu, 2020).

Model ESRGAN je, kao AI pristup super-rezoluciji, ostvario značajno viši PSNR (32.2 dB) i SSIM (0.88), uz razumne zahtjeve za obradom. Model generira nove teksturne detalje, ali u pojedinim slučajevima može izazvati artefakte u složenim scenama (Wang et al., 2018). DeOldify je, primarno korišten za kolorizaciju crno-bijelih snimaka, ostvario nešto niže vrijednosti u odnosu na ESRGAN, ali je pokazao visoku preciznost u rekonstrukciji boja, zavisno o kvalitetu trening skupa (Antic, 2023).

Najbolje ukupne rezultate ostvario je Topaz Video Enhance AI, sa PSNR od 34.1 dB i SSIM od 0.91. Ovaj alat koristi napredne tehnike temporalne super-rezolucije i adaptivne filtre, međutim zahtijeva najviše resursa i vremena obrade (Topaz Labs, 2023).

2.2. Subjektivna evaluacija

Subjektivna analiza je provedena na uzorku od 12 ispitanika s iskustvom u video produkciji i digitalnoj restauraciji i potvrdila je zaključke dobijene objektivnim mjerenjima. Učesnici su, prilikom pregleda restauriranih uzoraka bez prethodnog znanja o korištenim metodama, dosljedno ocjenjivali AI tehnike — posebno Topaz Video Enhance AI i ESRGAN — kao superiorne u pogledu vizuelnog prikaza detalja, jasnoće slike i ukupne estetske uvjerljivosti. Većina ispitanika istaknula je da AI metode posebno dobro rekonstruišu konture, teksture i dubinu slike, čak i u slučajevima visoko degradiranih snimaka, pri čemu se finalni prikaz percipira kao „vjerodostojan i prijatan za gledanje“. Kolorizacija putem alata kao što je DeOldify dodatno je doprinosila pozitivnom subjektivnom dojmu, posebno u kontekstu emocionalne reakcije na revitalizirane crno-bijele scene. S druge strane, tradicionalne metode poput bikubične interpolacije i prostorno-vremenskih filtera ocijenjene su kao „osnovne, ali pouzdane“. Ispitanici su ih prepoznali kao korisne u scenarijima s blagim degradacijama, naglašavajući da su takve metode često jedina opcija u uslovima ograničenih tehničkih resursa ili slabije hardverske podrške. Ukupni rezultati subjektivne evaluacije ukazuju na jasnu prednost AI pristupa, posebno kada se radi o videozapisima niske rezolucije, sa značajnim gubicima boje, šumom ili zamućenjima. Klasične metode ipak zadržavaju praktičnu vrijednost u okruženjima gdje jednostavnost, brzina obrade i predvidivost imaju prednost nad estetskim savršenstvom.

3. DISKUSIJA I BUDUĆI PRAVCI ISTRAŽIVANJA

Rezultati analize jasno pokazuju da metode restauracije zasnovane na umjetnoj inteligenciji, a posebno modeli super-rezolucije poput ESRGAN i Topaz Video Enhance AI, ostvaruju značajna poboljšanja u kvaliteti slike u odnosu na tradicionalne pristupe. Povećanje PSNR i SSIM vrijednosti, kao i subjektivne ocjene korisnika, potvrđuju veću efikasnost AI algoritama u rekonstrukciji izgubljenih detalja i smanjenju vizuelnog šuma (Lim et al., 2021; Zhang & Yang, 2020). DeOldify, kao alat za automatsku kolorizaciju, dodatno demonstrira potencijal dubokog učenja u obnavljanju historijskih crno-bijelih videozapisa (Antic, 2023). Međutim, uz napredak dolaze i značajni izazovi. AI modeli, posebno oni bazirani na GAN arhitekturi, su skloni generiranju artefakata – vizuelnih elemenata koji nisu postojali u izvornom sadržaju. Iako oni mogu poboljšati subjektivni doživljaj slike, u kontekstu restauracije autentičnih historijskih snimaka, predstavljaju ozbiljan problem vjerodostojnosti (Galteri et al., 2023). U tom smislu je neophodno razviti jasne tehničke i etičke smjernice koje će osigurati transparentnost, vjerodostojnost i odgovornu primjenu tehnologije. Konkretno, AI alati mogu generirati sadržaj koji nije izvorno postojao, što otvara pitanja poput rekonstrukcije lica historijskih ličnosti bez vjerodostojnih vizuelnih podataka ili modifikacije arhivskih snimaka do mjere koja može promijeniti njihov autentični kontekst. Osim toga, izvođenje AI restauracije zahtijeva naprednu računalnu infrastrukturu (GPU, memorija, paralelna obrada), što može ograničiti dostupnost ovih alata u širem praktičnom okruženju (Blau & Michaeli, 2019).

U poređenju s tim, tradicionalne metode – poput bikubične interpolacije, prostornog filtriranja i MCPI tehnika – ostaju korisne u slučajevima gdje je degradacija minimalna, ili su hardverski resursi ograničeni. Pored toga, one su determinističke prirode i ne uvode nove elemente u sliku, čime čuvaju izvornu strukturu videa.

Buduće istraživanje trebalo bi se usmjeriti na:

- razvoj hibridnih modela koji kombiniraju stabilnost tradicionalnih metoda sa sposobnošću učenja AI modela (Lugmayr et al., 2022),
- poboljšanje GAN arhitektura radi smanjenja artefakata i povećanja interpretabilnosti modela,
- optimizaciju hardverskih zahtjeva i ubrzanje izvođenja modela, što bi omogućilo njihovu širu upotrebu u arhivistici, obrazovanju i medijskoj produkciji,
- uvođenje etičkih smjernica za AI restauraciju koje bi pomogle definiranju granice između tehničkog poboljšanja i neautorizovane reinterpretacije sadržaja (Camps et al., 2021).

AI restauracija pokazuje veliki potencijal za upotrebu u kontekstu digitalne humanistike, gdje se masovni arhivski sadržaji mogu analizirati, kategorizirati i vizuelno unaprijediti radi edukativne svrhe i očuvanja kulturnog naslijeđa općenito. Automatizacija procesa identifikacije i restauracije snimaka kroz AI može značajno ubrzati rad digitalnih arhiva, muzeja i televizijskih kuća, pod uslovom da se primjena vodi načelima transparentnosti i odgovornosti.

ZAKLJUČAK

Restauracija starih videozapisa predstavlja tehnički zahtjevan proces koji uključuje kompleksne metode digitalne obrade i rekonstrukcije slike. Istovremeno, ona ima duboko kulturno-istorijsko značenje, jer doprinosi očuvanju vizuelne historije i zaštiti digitalne baštine za buduće generacije. Ovaj rad je pokazao da primjena savremenih AI tehnologija, zasnovanih na dubokom učenju, omogućava značajna poboljšanja u kvaliteti slike u odnosu na tradicionalne metode restauracije. Modeli poput ESRGAN i Topaz Video Enhance AI pokazali su superiornost u rekonstrukciji detalja, povećanju rezolucije i smanjenju šuma, dok je DeOldify uspješno kolorizovao crno-bijele snimke, pružajući vizuelno uvjerljive rezultate. Evaluacija kvaliteta restauracije, provedena kroz PSNR i SSIM metrike, kao i subjektivnu analizu, potvrdila je prednost AI metoda, posebno u slučajevima izrazite degradacije video materijala. Uprkos brojnim prednostima, AI pristupi nose i izazove koji se ogledaju u visokoj računalnoj zahtjevnosti, mogućnosti pojave artefakata, te potrebi za dodatnim etičkim i interpretacijskim standardima.

Tradicionalne metode restauracije, iako tehnološki manje sofisticirane u poređenju s AI pristupima, zadržavaju svoju praktičnu vrijednost u okruženjima s ograničenim tehničkim resursima. Njihova primjena je posebno opravdana u slučajevima gdje je stepen degradacije originalnog materijala relativno nizak, te nije nužno primjenjivati kompleksne algoritme za postizanje zadovoljavajućih rezultata. Zaključno, istraživanje potvrđuje da AI tehnologija predstavlja značajan iskorak u digitalnoj restauraciji videa, ali istovremeno nameće potrebu za pažljivim balansiranjem između automatizacije, autentičnosti i odgovorne primjene. Dalji razvoj hibridnih modela, kao i uspostavljanje metodoloških i etičkih okvira, predstavlja ključ za širu i pouzdaniju primjenu AI alata u restauraciji audiovizuelne baštine.

LITERATURA

1. Antic, J. (2023). *DeOldify: Colorizing and restoring old images and videos using Deep Learning*. GitHub repository. <https://github.com/jantic/DeOldify>
2. Antic, J., & Krnjić, N. (2024). Restoration and AI: Challenges from Practice. *AI in Media Studies*, 7(2), 56–70.
3. Begley, P., et al. (2007). The Responsible Competitiveness Index. In: AccountAbility (2007): *The State of Responsible Competitiveness 2007* (pp. 34). <http://www.accountability21.net> [Pristupljeno: 20. septembar 2010.]
4. Blau, Y., & Michaeli, T. (2019). Rethinking loss functions for deep learning-based image restoration. *arXiv preprint*, arXiv:1810.00363.
5. Camps, V., Chou, P., & Duh, K. (2021). Ethical considerations in artificial media restoration. *AI & Society*, 36(3), 487–498. <https://doi.org/10.1007/s00146-021-01162-6>
6. Cha, D., Kwon, H., & Kim, M. (2023). A survey on deep learning-based video restoration methods: Denoising, deblurring, and super-resolution. *IEEE Access*, 11, 25078–25095. <https://doi.org/10.1109/ACCESS.2023.3256712>
7. Galteri, L., Bertini, M., & Bimbo, A. (2023). AI-based restoration of historical videos: Challenges and ethical considerations. *Journal of Multimedia Preservation*, 11(1), 45–61.
8. Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep learning*. Cambridge, MA: MIT Press.
9. Horé, A., & Ziou, D. (2010). Image quality metrics: PSNR vs. SSIM. In *Proceedings of the International Conference on Pattern Recognition* (pp. 2366–2369). <https://doi.org/10.1109/ICPR.2010.579>
10. Jaganjac, J. (2022). AI alati u upravljanju digitalnim sadržajem: Iskustva iz obrazovnog sektora. *Zbornik radova SKEI konferencije*, 10(1), 33–42.
11. Kupyn, O., Budzan, V., Mykhailych, M., Mishkin, D., & Matas, J. (2018). DeblurGAN: Blind motion deblurring using conditional adversarial networks. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition* (pp. 8183–8192). <https://doi.org/10.1109/CVPR.2018.00855>
12. Ledig, C., Theis, L., Huszár, F., Caballero, J., Cunningham, A., Acosta, A., et al. (2017). Photo-realistic single image super-resolution using a generative adversarial network. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition* (pp. 105–114). <https://doi.org/10.1109/CVPR.2017.19>
13. Levy, M., Weitz, B. A., & Grewal, D. (2014). *Retailing Management* (9th ed.). New York: McGraw-Hill Education.
14. Lim, B., Son, S., Kim, H., Nah, S., & Lee, K. M. (2021). Enhanced deep residual networks for single image super-resolution. In *CVPR Workshops*. <https://openaccess.thecvf.com/content/CVPR2021W/NTIRE>
15. Lugmayr, A., Danelljan, M., & Timofte, R. (2022). RePaint: Inpainting using denoising diffusion probabilistic models. In *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition* (pp. 11461–11471). <https://doi.org/10.1109/CVPR52688.2022.01119>

16. OpenCV Team. (2023). *OpenCV documentation*. <https://docs.opencv.org> [Pristupljeno: 5. januar 2025.]
17. Son, J., Lee, S., & Jeon, J. (2022). Real-time video enhancement using lightweight GANs for low-resource environments. *Journal of Real-Time Image Processing*, 19(3), 441–456. <https://doi.org/10.1007/s11554-021-01101-5>
18. Topaz Labs. (2023). *Topaz Video Enhance AI: AI-powered video upscaling*. <https://www.topazlabs.com/video-enhance-ai> [Pristupljeno: 28. februar 2025.]
19. Vyas, A., Wang, Y., & Zhu, J. (2024). Ethics and authenticity in AI-based restoration of historical media. *AI & Ethics*, 4(1), 33–49. <https://doi.org/10.1007/s43681-023-00340-2>
20. Wang, X., Yu, K., Wu, S., Gu, J., Liu, Y., Dong, C., et al. (2018). ESRGAN: Enhanced super-resolution generative adversarial networks. In *ECCV Workshops* (pp. 63–79). https://doi.org/10.1007/978-3-030-11021-5_5
21. Wang, Z. (2009). Mean squared error: Love it or leave it? *IEEE Signal Processing Magazine*, 26(1), 98–117. <https://doi.org/10.1109/MSP.2008.930649>
22. Wang, Z., Bovik, A. C., Sheikh, H. R., & Simoncelli, E. P. (2004). Image quality assessment: From error visibility to structural similarity. *IEEE Transactions on Image Processing*, 13(4), 600–612.
23. Zhang, H., & Yang, J. (2020). High-quality video restoration using deep learning models. In *Proceedings of the IEEE International Conference on Artificial Intelligence in Multimedia Processing* (pp. 77–88). <https://doi.org/10.1109/AIMP.2020.00123>
24. Zhang, L., & Liu, W. (2020). Motion-compensated frame interpolation using optical flow. *Journal of Visual Communication and Image Representation*, 72, 102898. <https://doi.org/10.1016/j.jvcir.2020.102898>