

Autoritatea contractanta: Unitatea Executivă pentru Finanțarea Învățământului Superior, a Cercetării, Dezvoltării și Inovării (UEFISCDI)

Codul proiectului: PN-III-P2-2.1-PED-2021-1572,

Tip proiect: Proiect experimental demonstrativ (PED)

Titlul proiectului: Restaurarea vizibilității în imagini afectate de ceață neomogenă

Acronimul proiectului: NHID

Data inceperii proiectului: 30.06.2022

Data incheierii proiectului: 29.06.2024

Valoarea totală a contractului: 598.795,00 lei

Durata: 24 luni

Director proiect:

Prof. Dr. habil. Ing. Codruta Ancuti

Universitatea Politehnica Timisoara,

Facultatea de Electronica si Telecomunicatii, B312

Blvd. Vasile Parvan 2, 300223, Timisoara, Romania

Tel: (+40)-0256-403363

Fax: (+40)-0256-403295

Institutia coordonatoare:

Universitatea Politehnica Timisoara, Facultatea de Electronică, Telecomunicații și Tehnologii Informaționale, Departamentul de Masurari si Electronica Optica (MEO)

Rezumatul etapei

Etapa II: In aceasta etapa obiectivul principal a fost introducerea unui „*image prior*” pentru problema de imbunatatire a vizibilitatii in imagini afectate de ceata (*image dehazing*). Astfel, considerand modelul optic si utilizand informatia din bazele de imagini introduse anterior care includ perechi de imagini cu ceață și fără ceață (referință), am introdus un nou „*image prior*” care s-a dovedit mai eficient decat „*prior*”-urile existente pentru problema de *image dehazing* (imbunatatire a vizibilitatii in imagini afectate de ceata). Pe baza acestui *prior* am dezvoltat o noua metoda de *image dehazing* care genereaza rezultate comparative si chiar mai bune decat metodele recent introduse in literatura de specialitate.

1. Descrierea științifică și tehnică

1.1. Investigarea și dezvoltarea unui "prior" general pentru imagini afectate de ceață

În general, metodele existente de *image dehazing* urmează două strategii de dezvoltare fundamentale: tehnici de modelare a imaginilor prin utilizarea unor modele pentru care se estimează parametrii prin diverse optimizări sau informații *prior*, sau modele dezvoltate cu ajutorul rețelelor de învățare profundă (CNN) care pot de asemenea integra informația *prior*. Este important de menționat că eficiența acestor informații *prior* poate varia în funcție de condițiile specifice și caracteristicile imaginilor cețoase.

Majoritatea algoritmilor de *dehazing* se bazează pe *prior*-ul de **dark channel prior (DCP)**, dar acesta nu reflectă dependența exponențială de factorul beta sau distanța geometrică. DCP este modelat de intensitatea luminii, dar nu se bazează pe o intensitate absolută globală a imaginii, ci mai degrabă pe intensitățile locale ale pixelilor.

DCP se bazează pe observația că în majoritatea scenelor naturale, există zone sau pixeli care sunt considerabil mai întunecați decât regiunea adiacentă în imaginea originală, în absența ceții. *Prior*-ul DCP se estimează identificând pentru fiecare pixel valoarea minimă a intensității dintr-o anumită regiune (*patch*). Această strategie face ca *prior*-ul DCP să fie sensibil la intensitățile relative din regiunile locale ale imaginii care pot varia semnificativ în funcție de sursele de lumină, texturile obiectelor și distanțele relative.

Alternativ, se pot utiliza alte informații *prior* precum atenuarea de culoare: disparitatea de culoare, color lines și color clusters care urmăresc să estimeze și corecteze nuanțele de culoare (color-shifting) produse de ceață. Complementar, informația de contrast precum contrastul maxim local sau contrastul maxim de culoare sunt utilizate pentru a optimiza contrastul local afectat de fenomenul ceții.

Un alt aspect este *prior*-ul de luminozitate, care s-a dovedit util pentru îmbunătățirea vizibilității zonelor întunecate din imagini cețoase. Informații statistice despre distribuția intensităților

pixelilor sau a gradientelor în imagini clare sau imaginile cu ceață, pot fi folosite pentru a ghida procesul de *dehazing*. Totuși acestea s-au doedit a fi mai puțin eficiente decât DCP.

Combinarea mai multor *prior* și integrarea lor în algoritmi sofisticăți, cum ar fi cei bazati pe învățare adâncă (*deep learning*), poate duce la rezultate mai robuste și mai precise în imagini neomogene. În general metodele existente se încadrează în două categorii principale: tehnici bazate pe fizică și tehnici bazate pe învățare adâncă.

În aceasta etapa am introdus o metoda non-deep learning ghidată de o aproximare rafinată a luminii atmosferice care reprezintă un nou prior bazat pe lumina atmosferică (*airlight*). În abordarea noastră, am folosit setul de date realist O-HAZE (care conține și imaginea corespunzătoare fără ceață) pentru a rafina o aproximare simplistă a luminii atmosferice. În studiile noastre anterioare¹, am observat că transmisia este în general caracterizată de valori mici în scenele cu ceață, ceea ce permite aproximarea luminii atmosferice prin imaginea cu ceață de intrare. În pasul următor, folosind imaginile cu ceață și cele corespunzătoare fără ceață disponibile din setul de date O-HAZE, o a doua estimare a luminii atmosferice poate fi calculată rezolvând modelul optic folosind o valoare de transmisie derivată din prioritatea canalului întunecat. Comparând aceste două estimări ale luminii atmosferice, am observat că diferența lor conține în principal frecvențele joase ale imaginii cu ceață. Prin urmare, pentru imaginile pentru care imaginea fără ceață nu este disponibilă, propunem să rafinăm aproximarea luminii atmosferice derivată dintr-o transmisie zero, consolidând astfel componenta sa de frecvență joasă și reducând diferența sa față de lumină atmosferică care ar fi calculată din imaginea fără ceață. Acest nou *image prior* a fost integrat în metoda descrisă în secțiunea următoare. Metoda a fost testată pe scară largă atât pe seturi de date existente specializate pentru *image dehazing* (inclusiv cu ceața neomogenă), cât și pe imagini reale cu ceață. Evaluarea calitativă și cantitativă (folosind metrice tradiționale) a demonstrat că abordarea noastră oferă rezultate mai bune decât tehnicile de *dehazing* bazate pe modelul optic și se produce rezultate comparative cu abordările de *image dehazing* bazate pe învățare profundă.

¹ C. O. Ancuti, C. Ancuti, C. De Vleeschouwer, and A. C. Bovick, "Day and night-time dehazing by local airlight estimation," in IEEE Transactions on Image Processing, 2020

1.2 Dezvoltare metoda de imbunatatire a vizibilitatii in imagini afectate de ceata (*dehazing*)

Conform modelului optic al lui Koschmieder², prezența particulelor atmosferice care absorb și dispersează lumina de-a lungul liniei de vedere a observatorului reduce cantitatea de lumină reflectată și afectează calitatea imaginii vizuale percepute. Matematic, intensitatea luminii I a fiecărui pixel x este exprimată astfel:

$$I(x) = J(x) T(x) + A_{\infty}(x) [1 - T(x)] \quad (1)$$

unde J reprezintă radianța scenei sau imaginea fără ceață care trebuie estimată, T este transmisia de-a lungul liniei de vedere, iar A_{∞} reprezintă lumina atmosferică (*airlight*). Modelul optic exprimă o relație liniară între imaginea observată, radianța imaginii și lumina atmosferică. Primul termen modelează modul în care radianța scenei este redusă datorită proprietăților atmosferei, în timp ce lumina atmosferică este cauza principală a degradării imaginii în ceea ce privește schimbările de culoare, zgomot și estompare. În condiții omogene, transmisia $T(x)$ este exprimată matematic:

$$T(x) = e^{(-\beta d(x))} \quad (2)$$

unde β este coeficientul de atenuare a mediului datorat dispersiei și $d(x)$ este distanța între observator și punctul observat.

În general, tehnicile existente *non-deep learning* estimează cei doi parametri necunoscuți: transmisia $T(x)$ și lumina atmosferică $A_{\infty}(x)$. Prin urmare, majoritatea soluțiilor folosesc informații apriori. Cu toate acestea, diverse abordări/presupuneri, cum ar fi considerarea faptului că lumina atmosferică $A_{\infty}(x)$ este constantă în întreaga scenă, s-au dovedit a nu fi general valabile pentru scenele cu ceață mai complexe, cauzând în general schimbări de culoare (vezi **Figura 2**).

Pentru a rezolva aceste limitări, metoda propusă în acest proiect se bazează pe de setul de date O-HAZE pentru a rafina o aproximare non-uniformă și simplistă a luminii atmosferice. Experimentele noastre demonstrează clar beneficiul semnificativ rezultat din acest *prior* nou. În

² H. Koschmieder, "Theorie der horizontalen sichtweite," in Beitrage zur Physik der freien Atmosphere, 1924.

cea ce privește transmisia, metoda propusa extinde varianta DCP-ului. Astfel in aceasta abordare am considerat o aproximare pentru transmisia DCP care se poate exprima matematic:

$$T(x) = (1 - \min_{R,G,B}(I))^k \quad (3)$$

unde k este un parametru întreg pozitiv care comprimă valorile transmisiei aproape de zero (in metoda noastra generăm rezultatele folosind valoare default $k=6$).

Spre deosebire de metodele anterioare, in abordarea noastra lumina atmosferică este calculată în două etape (*prior*-ul nostru). Prima etapă adoptă observația convențională făcută în studiile anterioare că transmisia este în general mică în scenele cu ceață. Luând în considerare cazul extrem, adică $T(x)=0$, rezultă în aproximarea A_{∞} cu I . Această aproximare este denumită $A_{\infty 0}$ în restul descrierii metodei noastre. A doua etapă este contribuția principală a metodei propuse și constă în rafinarea lui $A_{\infty 0}$ pentru a îmbunătăți imaginea fără ceață. Pentru a proiecta acest proces de rafinare, perechile de imagini cu ceață și fără ceață din setul de date O-HAZE au fost luate în considerare pentru a calcula lumina atmosferică A_{∞} calculata asa cum este descris de Ecuția (1) atunci când $T(x)$ este aproximat cu Ecuția (3), unde $I(x)$ și $J(x)$ corespund imaginilor cu ceață și respectiv imaginilor fara ceata (referinta) disponibile din setul de date O-HAZE.

Astfel, devine posibilă compararea dintre A_{∞} si $A_{\infty 0}$ pentru perechile de imagini din setul de date O-HAZE. Așa cum era de așteptat, această diferență este foarte mică și conține frecvențele joase ale imaginii cu ceață (vezi **Figura 1**). Deoarece frecvențele înalte ale unei imagini pot fi reconstruite prin suma tuturor valorilor Laplacian-urilor sale³, putem exprima această diferență matematic ca:

$$Diff_A = A_{\infty 0} - \sum_{i=0}^N \mathcal{L}_i \quad (4)$$

unde L_i reprezintă al i -lea nivel al Laplacian-ului imaginii cu ceață. Pentru a menține eficiența computațională a soluției, setăm valoarea lui N destul de mică ($N=2$), astfel încât practic doar câteva frecvențe înalte ale imaginii sunt filtrate. Astfel, putem exprima estimarea noastră rafinată

³ C. O. Ancuti, C. Ancuti, C. De Vleeschouwer, and A.C. Bovik, "Single-scale fusion: An effective approach to merging images," IEEE Transactions on Image Processing, 2017.

a luminii atmosferice, consolidând componenta sa de frecvență joasă prin adăugarea acestei diferențe. Matematic, estimarea noastră rafinată a luminii atmosferice este exprimată astfel:

$$\bar{A}_{\infty} = A_{\infty 0} + Diff_A \quad (5)$$

În plus, deoarece am observat că contribuția imaginii cu ceață la frecvența joasă crește odată cu valoarea inițială a transmisiei T , am aproximat în final lumina atmosferică folosind o formulă inspirată din metoda tradițională de *alfa matting*:

$$\bar{A}_{\infty} = (1 - T)^{\alpha} A_{\infty 0} + T^{\alpha} Diff_A \quad (6)$$

unde $A_{\infty 0}$ este calculat pentru $T=0$ și este identificat cu imaginea cu ceață, T este transmisia calculată cu expresia descrisă în Ecuatia (3), iar parametrul α controlează cantitatea de amestecare (valoarea implicită este $\alpha=0.5$). Pentru a restabili imaginile cu ceață, în metoda propusă rezolvăm ecuația modelului optic descris de Ecuatia (1), folosind estimarea noastră finală a luminii atmosferice, data de Ecuatia (6), și transmisia estimată exprimată prin Ecuatia (3).



Figura 1: Considerând imaginea cu ceață (stânga sus), estimarea noastră rafinată a luminii atmosferice (dreapta sus) este aproape similară cu imaginea cețoasă originală (deoarece, în principiu, filtrăm din imaginea cu ceață doar câteva frecvențe înalte). Utilizând transmisia noastră apropiată de zero (Ecuatia 3) (stânga jos), putem rezolva modelul optic și genera rezultatele folosind metoda propusă (dreapta jos).

1.3 Evaluare metodei dezvoltate si compararea cu tehnicile existente de imbunatatire a vizibilitatii in imagini afectate de ceata;

In prima etapa am validat metoda noastra printr-o evaluare comprehensivă calitativă și cantitativă considerand **setul de imagini realist O-HAZE**⁴, care conține 45 de scene variate în aer liber cu ceață generată cu ajutorul unei mașini profesionale de ceață, oferind condiții realiste de ceață. O-HAZE are avantajul de a furniza și imagini corespunzătoare fără ceață (*ground-truth*), permițând evaluarea obiectivă a metodelor de îndepărtare a ceții folosind metrici tradiționale.

Tabelul I prezintă evaluarea obiectivă a setului de date O-HAZE pe baza mai multor metrici tradiționale de calitate a imaginii (cum ar fi PSNR, SSIM și CIEDE2000). Am considerat mai multe tehnici de *dehazing* bazate pe modelul optic dar si metode mai recente care utilizeaza deep learning. Prima metodă pe care am examinat-o in studiul nostru este metoda lui **He et al.**⁵, care a introdus cunoscuta *Dark Channel Prior (DCP)* utilizată pentru estimarea hărții de transmisie. În implementarea originală, rafinarea hărții de transmisie se bazează pe o strategie de alpha matting⁶ care reduce artefactele de tranziție locale. Rezultatele lui He et al. prezentate în această lucrare au fost obținute folosind filtrul (*guided filter*) pentru a rafina harta de transmisie.

Metoda lui **Meng et al.**⁷ folosește, de asemenea, DCP pentru a estima harta de transmisie. În plus, transmisia este rafinată pe baza unei etape de regularizare a normei L1 ponderate. Comparativ cu metoda lui He et al., această tehnică reduce în mod semnificativ artefactele de halo prezente în jurul marginilor ascuțite, dar și artefactele care apar adesea în regiunile luminoase ale cerului. Fattal⁸ introduce o abordare care se bazează pe observația că distribuțiile pixelilor în mici porțiuni ale imaginilor naturale prezintă structuri unidimensionale, numite linii de culoare. Ca rezultat, transmisia este estimată în primul rând din liniile de culoare detectate deviate față de origine, în timp ce o transmisie rafinată este generată printr-un model de câmp

⁴ C. O. Ancuti, C. Ancuti, C. De Vleeschouwer, and R. Timofte, "O-haze: a dehazing benchmark with real hazy and haze-free outdoor images," IEEE CVPR, NTIRE Workshop, 2018

⁵ K. He, J. Sun, and X. Tang, "Single image haze removal using dark channel prior," *IEEE Trans. on Pattern Analysis and Machine Intell.*, 2011

⁶ A. Levin, D. Lischinski, and Y. Weiss, "A closed form solution to natural image matting," *In IEEE Transactions on Pattern Analysis and Machine Intelligence (TPAMI)*, 2008.

⁷ G. Meng, Y. Wang, J. Duan, S. Xiang, and C. Pan, "Efficient image dehazing with boundary constraint and contextual regularization," *In IEEE Int. Conf. on Computer Vision*, 2013.

⁸ Raanan Fattal, "Dehazing using color-lines," *ACM Trans. on Graph.*, 2014.

aleatoriu Markovian. Metoda lui **Berman et al.**⁹ extinde conceptul de observație a consistenței culorii¹⁰, și în plus, explorează observația că distribuția culorii în imagini fără ceață este bine aproximată printr-un set discret de grupuri în spațiul de culoare RGB. Acest algoritm presupune în general că pixelii dintr-un grup dat sunt non-locali și sunt răspândiți pe întreaga planimetrie a imaginii, fiind afectați diferit de ceață. Ca urmare, fiecare grup devine o linie în imaginea cu ceață, iar poziția unui pixel în cadrul liniei reflectă nivelul său de transmisie. În final, aceste linii de ceață furnizează informații structurale despre transmisie în diferitele regiuni ale imaginii și sunt combinate pentru a estima harta de transmisie.

Dehaze-Net¹¹ este o metoda *deep learning* care utilizează o arhitectură de rețea duală pentru estimarea hărții de transmisie, unde rețeaua mai mare furnizează o estimare inițială, iar rețeaua mai mică o rafinează pentru o precizie sporită. Antrenarea modelului pe date sintetice îi permite să gestioneze eficient imagini reale afectate de ceață, învățând din scenarii simulate cu ceață.

Multiscale CNN¹² este o metoda *deep learning* care în etapa inițială, transmisia este evaluată utilizând o rețea neuronală cu o scală mare, urmând să fie ulterior rafinată printr-o rețea neuronală cu o scală mică. Acest algoritm a fost instruit pe imagini cu ceață generate sintetic, create prin utilizarea imaginilor fără ceață însoțite de hărți adiacente de adâncime asociate acestora.

PMS-NET¹³ este o metoda bazată pe *deep learning* care înlătură ceața folosind o caracteristică nouă numită harta patch-urilor. Deoarece algoritmii convenționali de înlăturare a ceții bazate pe patch-uri (de exemplu, dark channel prior) efectuează *image dehazing* cu o dimensiune de patch fixă pot duce la mai multe probleme, cum ar fi supra-saturarea și distorsiunea culorilor, PMS-NET folosește un model de selecție adaptivă și automată a dimensiunii patch-ului numit *Patch Map*

⁹ D. Berman, T. Treibitz, and S. Avidan, "Non-local image dehazing," in *IEEE Transactions on Pattern Analysis and Machine Intelligence (TPAMI)*, 2020

¹⁰ I. Omer and M. Andwerman, "Color lines: image specific color representation," In IEEE Conference on Computer Vision and Pattern Recognition, 2004.

¹¹ B. Cai, X. Xu, K. Jia, C. Qing, and D. Tao, "Dehaze-net: An end-to-end system for single image haze removal," *IEEE Transactions on Image Processing*, 2016.

¹² W. Ren, S. Liu, H. Zhang, X. Cao, J. Pan, and M.-H. Yang, "Single image dehazing via multi-scale convolutional neural networks," *IEEE Transactions on Image Processing*, 2020

¹³ Wei-Ting Chen, Jian-Jiun Ding, and Sy-Yen Kuo, "PMS-NET: Robust haze removal based on patch map for single images," in *IEEE CVPR*, 2019.

Selection Network (PMS-Net) pentru a selecta dimensiunea patch-ului corespunzătoare fiecărui pixel. Această rețea a fost proiectată pe baza rețelei neuronale convoluționale (CNN), care poate genera harta patch-urilor din imaginea de intrare.

PPDN¹⁴ este o metoda bazata pe rețelele neuronale convoluționale (CNN) care învâța direct o funcție non-liniară între imaginile cu ceață și imaginile clare corespunzătoare. Metodă folosește o scară multiplă, utilizând o rețea profundă cu piramidă perceptuală bazată pe blocuri dense și blocuri reziduale, care sunt populare în ultimul timp. PPDN implică o structură encoder-decoder cu un modul de piramidă în decoder pentru a încorpora informații contextuale ale scenei în timpul decodificării. Rețeaua este învățată prin minimizarea erorii medii pătratice și a pierderilor perceptive. Patch-uri la scară multiplă sunt folosite în procesul de antrenament și inferență pentru a îmbunătăți în continuare performanța.

Aditional, față de valoarea medie pentru întregul set de imagin O-HAZE, **Tabelul I** prezintă, de asemenea, rezultatele metodelor evaluate pentru cele 5 imagini ale setului de date O-HAZE prezentate în **Figura 2**.

	He et al.			Meng et al.			Fattal			Berman et al.			Dehaze-Net			Multiscale CNN			PMS Net			Ours		
	SSIM	PSNR	CIEDE	SSIM	PSNR	CIEDE	SSIM	PSNR	CIEDE	SSIM	PSNR	CIEDE	SSIM	PSNR	CIEDE	SSIM	PSNR	CIEDE	SSIM	PSNR	CIEDE	SSIM	PSNR	CIEDE
Set 6	0.74	16.68	19.00	0.78	20.71	11.44	0.73	15.16	21.89	0.77	17.11	12.68	0.59	15.32	16.16	0.72	17.54	13.20	0.73	19.36	11.58	0.77	19.26	11.15
Set 10	0.78	16.22	15.22	0.76	15.98	16.63	0.75	16.42	17.49	0.72	14.48	17.77	0.71	15.02	16.17	0.80	16.57	13.70	0.77	16.80	12.29	0.76	18.34	12.78
Set 21	0.69	16.78	27.50	0.78	19.80	21.13	0.63	16.10	28.25	0.72	15.90	20.54	0.71	16.37	19.49	0.73	17.14	20.26	0.80	19.33	15.98	0.78	21.29	12.94
Set 30	0.75	15.71	18.85	0.74	14.68	18.59	0.72	14.68	18.46	0.81	17.48	14.55	0.77	18.57	12.70	0.82	19.72	12.66	0.78	19.94	12.17	0.88	23.02	8.15
Set 33	0.76	18.96	18.54	0.74	18.01	15.84	0.76	17.28	17.86	0.66	16.37	19.39	0.81	17.87	14.61	0.88	22.61	10.87	0.84	20.19	12.03	0.88	20.06	9.29
Average	0.74	16.59	20.75	0.75	17.44	16.97	0.71	15.64	19.85	0.75	16.61	17.09	0.67	16.21	17.35	0.77	19.07	14.67	0.81	19.05	13.47	0.81	20.27	10.56

Tabelul I: Rezultate comparative pe baza SSIM, PSNR si CIEDE2000 a metodelor introduse de He et al., Meng et al., Fattal, Berman, Dehaze-Net, Multiscale-CNN, PMS-NET si metoda propusa in acest proiect.

¹⁴ H. Zhang, V. Sindagi, and V. M. Patel, "Multi-scale single image dehazing using perceptual pyramid deep network," IEEE CVPRW, 2018.




Figura 2: Rezultate comparative a metodelor introduse de He et al., Meng et al., Fattal, Berman et al., Dehaze-Net, Multiscale-CNN, PMS-NET si metoda propusa in acest proiect folosind 5 imagini din setul de imagini O-HAZE. Rezultatele cantitative pe baza SSIM, PSNR si CIEDE sunt prezentate in **Tabelul I**.

Ma mult, pentru a avea o comparație corectă cu tehnicile de învățare profundă, **Figura 3** prezintă rezultatele doar pentru ultimele cinci imagini (celelalte 40 de seturi de imagini au fost folosite pentru antrenarea modelelor CNN) ale setului de date O-HAZE, conform recomandărilor challenge-ului de *image dehazing* NTIRE 2021. **Tabelul II** oferă metrice cantitative pentru trei tehnici de învățare profundă și trei tehnici non-deep-learning (inclusiv metoda propusa in acest proiect) atunci când se iau în considerare cele 5 imagini prezentate în **Figura 3**.

Analizând aceste rezultate, **putem concluziona că abordarea noastră performează mai bine decât tehnicile non-deep learning, dar oferă și rezultate comparabile cu tehnicile de învățare profundă luate în considerare.** Desigur, fiind antrenată pe setul de date O-HAZE, metoda PPDN oferă cele mai bune rezultate în termeni de evaluare cantitativă și calitativă. Cu toate acestea, abordarea noastră se apropie în performanțe și are avantajul unei complexități computaționale mai reduse în comparație cu tehnicile de învățare profundă.

În concluzie, abordarea noastră se bazează pe observația că transmiterea în scenele cu ceață este tipic caracterizată de valori mici. Utilizând setul de date O-HAZE, care conține și imagini corespunzătoare fără ceață, am calculat o aproximare rafinată a luminii atmosferice derivată dintr-o transmisie zero, îmbunătățind componenta sa de frecvență joasă. Așa cum demonstrează atât evaluările calitative, cât și cele cantitative, abordarea noastră depășește metodele de *image dehazing* bazate pe modelul fizic și este comparabilă cu cele bazate pe învățare profundă.

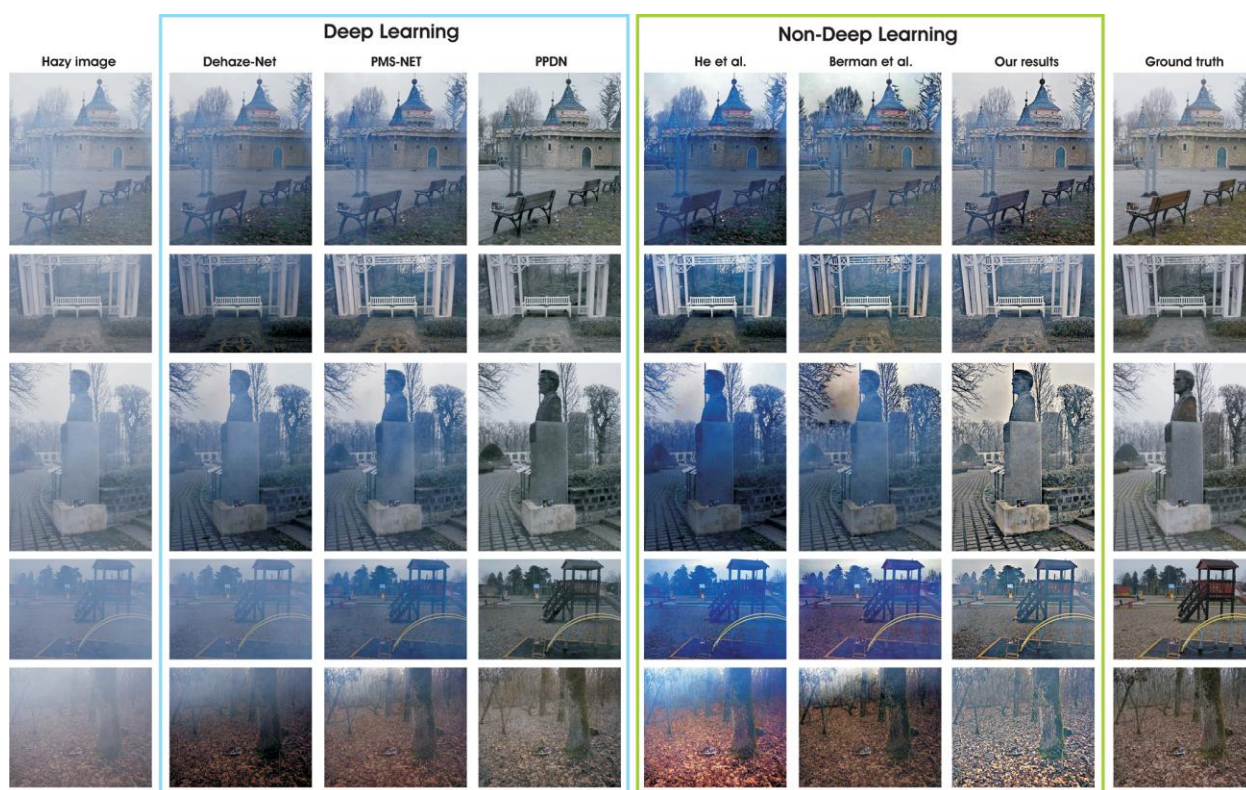


Figura 3: Rezultate comparative a metodelor bazate pe deep learning (metodele Dehaze-Net, PMS-NET și PPDN) și metodele care nu folosesc deep-learning (He et al., Berman et al. și metoda propusă în acest proiect) folosind 5 imagini din setul de imagini O-HAZE. Rezultatele cantitative pe baza SSIM, PSNR și CIEDE sunt prezentate în **Tabelul II**.

	Dehaze-Net	PMS-Net	PPDN	He et al.	Berman et al.	Ours
SSIM	0.704	0.822	0.861	0.77	0.805	0.833
PSNR	17.245	19.322	24.029	16.871	17.655	21.186
CIEDE2000	15.081	13.112	7.124	18.963	14.519	9.797

Tabelul II: Rezultate comparative pe baza SSIM, PSNR si CIEDE2000 a metodelor bazate pe deep learning (metodele Dehaze-Net, PMS-NET si PPDN) si metodele care nu folosesc deep-learning (He et al., Berman et al. si metoda propusa in acest proiect) folosind 5 imagini din setul de imagini O-HAZE (vezi **Figura 3**).

In partea a doua, in cadrul studiului nostru, am analizat mai multe tehnici recente de îndepărtare a ceții din imagini, inclusiv tehnicile care folosesc cele mai eficiente „*image priors*” pentru problema de *image dehazing* folosind baza de date NH-HAZE¹⁵ (imagini cu ceata neomogena). Pe langa unele din metodele prezentate mai sus am analizat alte doua metode. Li et al.¹⁶ au introdus un model de îndepărtare a ceții pentru timpul de noapte care ia în considerare și efectul de strălucire al iluminării variabile. În metoda lor, harta luminii atmosferice este folosită ca indiciu pentru a estima harta de transmisie. Această metodă folosește filtrul ghidat pentru a netezi valoarea luminii atmosferice. Ren et al.¹⁷ rezolvă problema îndepărtării ceții dintr-o singură imagine prin utilizarea unei soluții CNN (Rețele Neurale Convoluționale) la scară multiplă care își propune să estimeze harta de transmisie direct din imagini cețoase. În primul rând, harta de transmisie este estimată printr-o rețea la scară mare, iar apoi este rafinată printr-o rețea la scară mică. Algoritmul a fost antrenat pe imagini cu ceață generate sintetic, obținute din imagini fără ceață folosind hărți adiacente de adâncime asociate acestora.

Tabelul III prezinta rezultate comparative a metodelor lui He et al., Meng et al., Li et al., Fattal, Berman et al., Ren et al. si metoda propusa pe intreg setul de imagini NH-HAZE. Indicele SSIM variaza în intervalul [-1,1], cu valoarea maximă de 1 pentru două imagini identice. Raportul semnal-zgomot maxim (PSNR), măsurat în decibeli (dB), este, de asemenea, calculat între

¹⁵ C. O. Ancuti, C. Ancuti, F. Vasluiuanu, and R. Timofte et al., “NTIRE 2021 nonhomogeneous dehazing challenge report,” IEEE CVPR, NTIRE Workshop, 2021.

¹⁶ Y. Li, R. T. Tan, and M. S. Brown, “Nighttime haze removal with glow and multiple light colors,” In IEEE Int. Conf. on Computer Vision, 2015.

¹⁷ W. Ren, S. Liu, H. Zhang, X. Cao J. Pan, and M.-H. Yang, “Single image dehazing via multi-scale convolutional neural networks,” IEEE Transactions on Image Processing, 2020.

imaginea reală și rezultat. Un scor PSNR ridicat indică o restaurare mai bună în comparație cu imaginea de referință (fără ceață). Pe de altă parte CIEDE2000, care măsoară diferența de culoare față de imaginea reală și generează valori în intervalul [0,100]. Un scor mai mic indică o fidelitate mai mare a culorilor.

Din acest tabel, deși metoda propusă de noi obține cele mai bune rezultate cantitative, putem conchiziiona că pentru imagini cu ceață neomogene există încă loc de îmbunătățiri semnificative. Una dintre principalele limitări este schimbarea puternică a culorilor introdusă de metodele evaluate atunci când sunt aplicate pe imagini cețoase neomogene.

	He et al.	Meng et al.	Li et al.	Fattal	Berman et al.	Ren et al.	Ours
SSIM	0.64	0.68	0.68	0.66	0.66	0.68	0.71
PSNR	14.28	13.06	11.95	12.06	11.77	14.39	14.98
CIEDE2000	28.91	30.86	25.67	33.23	30.96	25.71	21.79

Tabelul III: Rezultate comparative pe baza SSIM, PSNR și CIEDE2000 a metodelor lui He et al., Meng, Li et al., Fattal, Berman, Ren et al. și metoda propusă pe întreg setul de imagini NH-HAZE.

În ultima parte a evaluării noastre, am luat în considerare și imagini reale cu ceață (vezi **Figura 4**). Deoarece nu există imagini referință cu care să ne comparăm cantitativ, asupra acestor rezultate se poate face în general doar o apreciere calitativă subiectivă. Rezultatele obținute pe aceste imagini demonstrează că, în general, abordarea noastră reușește să recupereze corespunzător culorile și detaliile scenei. Mai mult, în comparație cu tehnicile de învățare profundă, metoda noastră oferă bune capacități de generalizare și este capabilă să recupereze mai bine detaliile din regiunile îndepărtate (aproape de orizont).

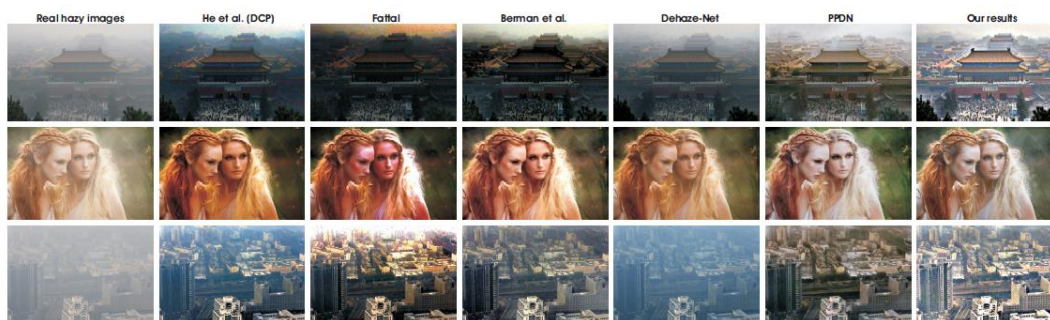


Figura 4: Rezultate comparative folosind imagini cu ceață reală. Ne-am comparat cu metodele lui He et al., Fattal, Berman et al., Dehaze-Net, PPDN (descrise mai sus).

1.4 Diseminare rezultate

In aceasta etapa rezultatele au fost publicate 2 lucrari in volumul unor conferinte de top din domeniul procesarii de imagini/computer vision:

Codruta O. Ancuti, Cosmin Ancuti, C. De Vleeschouwer, „Image Dehazing Guided by Low-Pass Reinforced Airlight”, 2023 **IEEE International Conference on Image Processing (ICIP)**, 2245-2249, Kuala Lumpur, Malaysia, 11-14 Octombrie, 2023

Codruta O. Ancuti, Cosmin Ancuti, Florin A. Vasluianu, Radu Timofte, „NTIRE 2023 HR NonHomogeneous Dehazing Challenge Report ”, 2023 Proceedings of the **IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)**, NTIRE Workshop, Los Angeles, US, 18-22 Iunie, 2023

2. Participare la conferințe în Etapa II a proiectului:

În cea de-a doua etapă s-a participat la 2 conferinte internationale:

1. **IEEE ICIP 2023, 9-13 octombrie, Kuala Lumpur, Malaysia.**
2. **ACM SIGGRAPH, 6-11 august, Los Angeles, US.**

3. Sumar al progresului si rezultate

In aceasta etapa rezultatele au fost publicate 2 lucrari indexate ISI/WoS:

- **Codruta O. Ancuti**, Cosmin Ancuti, C. De Vleeschouwer, „Image Dehazing Guided by Low-Pass Reinforced Airlight”, 2023 IEEE International Conference on Image Processing (ICIP), 2245-2249, Kuala Lumpur, Malaysia, 11-14 Octombrie, 2023
- **Codruta O. Ancuti**, Cosmin Ancuti, Florin A. Vasluianu, Radu Timofte, „NTIRE 2023 HR NonHomogeneous Dehazing Challenge Report ”, 2023 Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), NTIRE Workshop, Los Angeles, US, 18-22 Iunie, 2023

4. Rezumat executiv

Etapa a-II-a a proiectului a fost impartita in 4 activitati principale descrise in sectiunea 1:

A2.1. Investigarea si dezvoltarea unui "prior" general pentru imagini afectate de ceata

A2.2 Dezvoltare metoda de imbunatatire a vizibilitatii in imagini afectate de ceata

A2.3 Evaluare metodei dezvoltate si compararea cu tehnicile existente de imbunatatire a vizibilitatii in imagini afectate de ceata

A2.4 Diseminare rezultate

Gradul de realizare al obiectivelor – 100%

Data: 30.11.2023

Director Proiect:

Prof. Dr. Ing/ Codruta O. Ancuti

