

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

Codul proiectului: PN-III-P1-1.1-TE-2019-1111

Tip proiect: Proiecte de cercetare pentru stimularea tinerelor echipe independente (TE)

Titlul proiectului: Bază de date și tehnici de eliminare a ceații pentru scene afectate de ceața densă

Acronimul proiectului: Data - Dehaze

Data inceperii proiectului: 01.11.2020

Data incheierii proiectului: 31.10.2022

Valoarea totală a contractului: 431.900 lei

Durata: 24 luni

Director proiect:

Conf. Dr. habil. Ing. Codruta Ancuți

Universitatea Politehnica Timișoara,

Facultatea de Electronica și Telecomunicații, B312

Blvd. Vasile Parvan 2, 300223, Timișoara, România

Tel: (+40)-0256-403363

Fax: (+40)-0256-403295

Instituția coordonatoare:

Universitatea Politehnica Timișoara, Facultatea de Electronică, Telecomunicații și

Tehnologii Informaționale, Departamentul de Măsurări și Electronică Optică (MEO)

Rezumatul etapei III

Interpretarea imaginilor înregistrate cu deep learning. Dezvoltare metodă de dehazing cu deep-learning, utilizând baza construită de imagini afectate de ceața. Diseminarea rezultatelor.

În această etapă ne-am concentrat atenția asupra antrenării modelelor de interpretare a imaginilor potrivite pentru cazul nostru (imaginile capturate în condiții nefavorabile de ceață). Am explorat și posibilitatea dezvoltării unei soluții care să convertească imaginea neclară de intrare, într-o imagine care are ca rezultat o interpretare precisă atunci când este procesată de modele convenționale pentru îmbunătățirea imaginilor. Astfel, în această etapă am introdus o abordare originală care permite utilizarea setului de date existente (referință și ceață) pentru a antrena modele deja dezvoltate pentru îmbunătățirea vizibilității în condiții diferite de cele înregistrate în setul de antrenament (un aspect de dorit care ajută la diminuarea dificultății de a colecta noi imagini specifice).

Etapa a III-a. În această etapă am realizat următoarele acțiuni:

- Interpretarea imaginilor înregistrate cu deep learning. Utilizarea bazei de imagini înregistrată în etapa a doua [2] pentru testarea eficienței unor arhitecturi CNN deja existente.
- Dezvoltare metodă de dehazing cu deep-learning, utilizând baza construită de imagini afectate de ceață. Dezvoltarea unei soluții de adaptare a imaginilor de intrare la condițiile învățate din imaginile de training și test.
- Diseminarea rezultatelor

A1. Interpretarea imaginilor înregistrate cu deep learning. Utilizarea bazei de imagini înregistrată în etapa a doua pentru testarea eficienței unor arhitecturi CNN deja existente.

În această etapă am continuat procesul de analiză și implementare al algoritmilor bazati pe modele de învățare CNN. În etapa de învățare a rețelelor, am utilizat baza de imagini achiziționată în acest proiect (vezi rezumatul pentru prima etapă) care conține imagini cu ceață neomogenă (NH-HAZE).

În această secțiune prezentăm pe scurt o parte din concluziile extrase în urma procesului de analiză a celor mai reprezentative metode de învățare dezvoltate în domeniul image dehazing.

Un prim aspect legat de metodele evaluate, în general soluțiile bazate pe învățare de image dehazing, pot fi clasificate în două clase principale: o primă categorie de tehnici care se bazează pe (rezolvarea) modelului fizicului [1], (acesta descrie modul în care lumina este absorbită și împrăștiată în astfel de condiții) și o a doua categorie de metode care îmbunătătesc vizibilitatea în imagini, dar care ignoră parametrii modelului fizic.

Al doilea aspect important, este că pentru a facilita înțelegerea principiilor de îmbunătățire a imaginilor, diversi algoritmi dedicați de image dehazing, utilizează în dezvoltarea arhitecturii rețelelor doar module de bază. Astfel, modulele utilizate în mod obișnuit sunt următoarele: convoluție standard (standard convolution), convoluție dilatată (dilated convolution), fuziune pe mai multe scări (multi-scale fusion), piramidă caracteristică (feature pyramid), conexiune încrucișată (cross-layer connection and attention) și mecanismul de atenție.

- *Convoluția standard* – se folosește într-un mod de conexiune secvențială pentru a construi rețelele neuronale în mod eficient și este adesea folosită împreună cu alte blocuri în modelele de dehazing [3, 4, 5]
- *Convoluție dilatată* - poate crește câmpul receptiv, păstrând în același timp dimensiunea nucleului convoluției neschimbat. Câteva studii[6, 7, 8] au arătat cum convoluția dilatată poate îmbunătăți performanța extragerii caracteristicilor globale. Un alt avantaj exploatat este că fuzionarea straturilor de convoluție cu rate diferite de dilatare poate extrage caracteristici cu câmpuri receptive diferite.
- *Fuziune pe mai multe scări* - prin utilizarea miezurilor de convoluție de diferite scări și prin fuzionarea informației extrasă s-a demonstrat că strategia de fuziune poate obține detalii la scară multiplă în timpul restaurării imaginii cu ceață[9, 10, 11,31]. Procesul de fuziune a caracteristicilor, concatenează caracteristici de ieșire obținute prin nuclee de convoluție de diferite dimensiuni în mod eficient pentru rezolvarea unor sarcini vizuale variate[9].
- *Piramida caracteristică* - se utilizează pentru a obține informații de diferite rezoluții. Câteva metode de deep learning investigate[12, 13, 14, 15] folosesc această strategie în stratul mijlociu al rețelei pentru a extrage mai multe informații la scale diferite.

- *Conexiune încrucișată* - îmbunătățește schimbul de informații între diferite straturi și crește capacitatea de extragere a caracteristicilor rețelei, conexiunile încrucișate sunt adesea folosite în CNN-uri. În rețelele de dehazing se întâlnesc trei tipuri de conexiuni încrucișate: conexiunile reziduale(residual connection) [16, 17, 18] inspirată de ResNet [19], conexiune densă(dense connection) [20, 21,22] propusă de DenseNet [23] și skip connection [9, 24, 25, 26] din U-Net [7].
- *Mecanism de Atenție la dehazing* - blocurile de atenție utilizate în mod obișnuit în viziunea computerizată sunt atenția canalului și atenția spațială. În extragerea caracteristicilor și în procesul de reconstrucție a imaginilor 2D, mecanismul de atenție canal impune ponderi diferitele pentru hărțile caracteristicilor. Această strategie de procesare ghidată a hărților de caracteristici permite modelului să selecteze eficient informațiile despre caracteristici. Mecanismul atenției spațiale se concentrează pe diferențele dintre regiuni ale hărților caracteristice, precum distribuția și influența ceții pe harta întreaga. Câteva dintre metode precum [27, 28, 29, 5] au atins performanțe excelente de dehazing.

Un alt aspect important în dezvoltarea algoritmilor de învățare este reprezentant de funcția de pierdere (*loss function*) care joacă un rol central în învățarea automată. Metodele de învățare de tip supervised, semi-supervised sau unsupervised utilizează diferite funcții de pierdere (*loss function*) sau combinații de funcții. Cele mai des întâlnite funcții de pierdere în literatură sunt funcția de fidelitate/fidelity loss (L1[32, 33, 34,35] ,L2[36, 37, 38]), pierderea perceptuală/perceptual loss [39,40,41], funcția de gradient/ Gradient loss [5, 14,42], SSIM [30, 43,44], MS-SSIM (Multi Scale SSIM [45,20 ,46] sau funcția TotalVariation Loss [47, 48].

Concluziile din această etapă de studiu, arată că metodele de învățare de tip supervised, semi-supervised sau unsupervised au obținut performanțe calitativ ridicate, deși există încă un număr important de aspecte care pot să fie îmbunătățite (exemplu: un model optic mai precis de formare al ceții ar permite abordări mai eficiente). De asemenea, o problemă principală este numărul redus de perechi de imagini (ceață plus imagine

referință), care nu oferă suficiente informații pentru înțelegerea modelului, precum înțelegerea mecanismului de atenuare al culorii, dar și inversarea acestui proces.

A2. Dezvoltare metodă de dehazing cu deep-learning, utilizând baza construită de imagini afectate de ceață. Adaptarea imaginilor de intrare la condițiile învățate din imaginile de training și test. Această soluție include adaptarea imaginilor de intrare cu ceață la imaginile de antrenament (training) referință;

Evoluția importantă a metodelor bazate pe deep learning, a introdus un nou concept în care algoritmul învață relația directă dintre ceață și imaginea referință (fără ceață), prin utilizarea în mai multe etape a diverselor soluții bazate pe informația de atenție, mecanism multi-patch, etc. Soluțiile de învățare pot, de asemenea să fie clasificate în cele două categorii menționate drept implementări fundamentale timpurii în image-dehazing.

Aceste soluții de învățare profundă (*deep learning*) au generat interes pentru înregistrarea unor seturi de date reale de imagini cu ceață. În primele încercări de abordare a acestei probleme (care au apărut în literatură), au fost generate seturi de imagini cu ceață și referință (fără ceață) prin sintetizarea ceței utilizând mai multe seturi de date cu informație necesară sintetizării precum adâncimea scenei. Cu toate acestea, având în vedere complexitatea scenelor afectate de ceață, majoritatea algoritmilor sunt antrenați să se ocupe de anumite categorii de imagini cu ceață, cum ar fi ceață înregistrată în condiții de iluminare pe timp de zi, ceață densă sau ceață înregistrată în condiții de iluminare pe timp de noapte, etc. De asemenea, unele categorii de imagini nu sunt acoperite în totalitate și seturile de date reale existente conțin doar zeci de imagini. Imaginile neclare generate sintetic sunt mult mai ușor de obținut, dar nu prezintă garanție că algoritmul va fi similar eficient în situații reale, comparativ cu imaginile generate realistic pentru antrenament.

Din cauza constrângerilor fizice și a variabilității scenei, este greu să se obțină seturi care să conțină multe perechi de imagini, iar majoritatea seturilor existente momentan conțin doar zeci de asemenea perechi pentru antrenament și validare.

O soluție posibilă este antrenarea unui algoritm pentru un set de date și investigarea posibilității de a îmbunătăți performanța algoritmului, folosind diferite scene care nu sunt similare cu imaginile de antrenament. Concret, o problemă importantă pe care am abordat-o, este îmbunătățirea imaginilor nocturne cu ceață, care evident prezintă o problemă pentru algoritmi dezvoltați și antrenați pentru imaginile din timpul zilei.

După cum se poate observa în imaginea de mai jos, algoritmul antrenat și testat pe imaginile din timpul zilei, generează imagini realiste de calitate ridicată (pentru imaginea prezentată, PSNR=20.24 and SSIM=0.64).

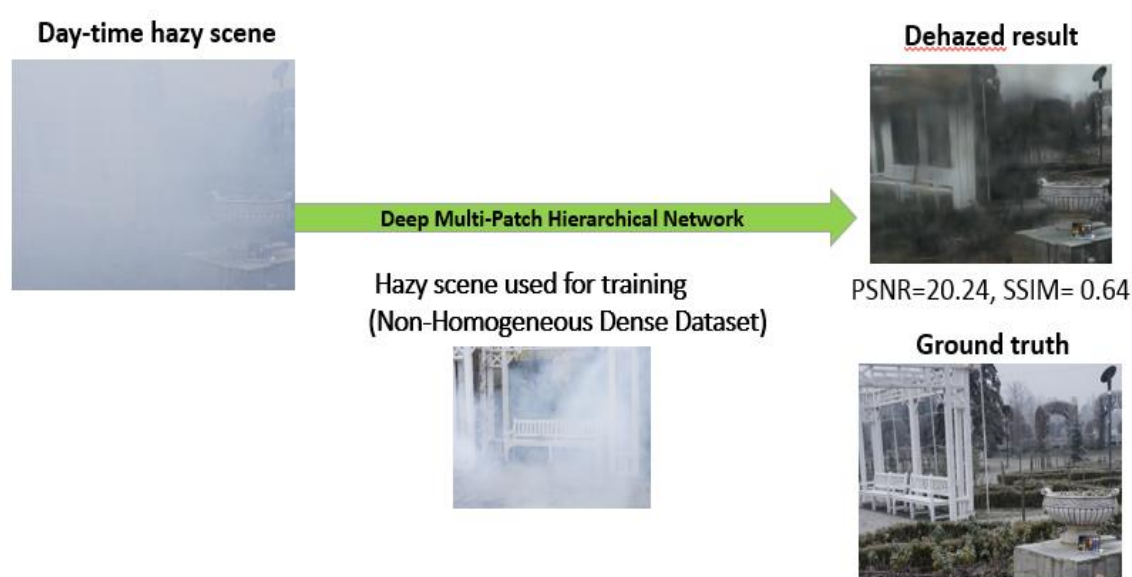


Figura 1. Rezultat generat de algoritmul antrenat/testat cu perechi de imagini (cu vizibilitate și afectate de ceață neomogenă) înregistrate în condiții similare de iluminare.

Același algoritm dacă este aplicat pe imaginile cu ceață nocturne, generează imagini de calitate scăzută, în care vizibilitatea nu este recuperată și culorile nu sunt percepute naturale. Această problemă se poate observa în figura următoare, care demonstrează limitările unui algoritmul antrenat și testat pe imaginile din timpul zilei, atunci când procesează o imagine diferită precum o imagine nocturnă afectată de ceață.



Figura 2. Exemplu de limitare al eficienței algoritmului antrenat (cu perechi de imagini înregistrate în condiții similare de iluminare pe timpul zilei), dacă algoritmul procesează imagini de intrare cu ceață pe timp de noapte.

O alternativă este utilizarea imaginilor corespunzătoare pentru etapa de antrenament, astfel încât algoritmul să genereze imagini de calitate ridicată și pentru acest caz particular. Dezavantajul imediat observabil este faptul că algoritmul devine dedicat, deci este eficient fie pentru imagini cu iluminare pe timp de zi sau pentru imagini nocturne cu iluminare scăzută. Pentru că ne interesează să evităm reantrenarea și/sau readaptarea algoritmului de învățare pentru fiecare categorie nouă de imagini, noi am ales abordarea care este prezentată mai jos. Principalul avantaj este că soluția propusă este capabilă să rezolve ambele tipuri de imagini prezentate, fără să necesite reantrenarea rețelei. Mai mult, este posibil să genereze rezultate calitativ ridicate și pentru tipuri mai complexe de imagini cu ceață din timpul zilei, în care informația de culoare (din motive legate de iluminare) este responsabilă pentru rezultatele slab calitative ale algoritmilor standard pentru image dehazing.

O altă problemă este faptul că nu există încă suficiente baze de imagini care să acopere toate situațiile întâlnite, ceea ce ne-a motivat să abordăm o altă soluție. În aceasta etapă am dezvoltat un algoritm de adaptare pentru imaginile zi-noapte, care transferă caracteristicile importante din imaginile cu iluminare naturală (din timpul zilei), în imaginile cu iluminare scăzută (din timpul nopții).

Soluția utilizată este o soluție inspirată de corecția culorii (CCC) un algoritm pe care l-am introdus în [49]. O alternativă studiată, este conversia imaginilor de intrare cu algoritmi

de tipul conversie noapte-zi (Night-to-Day). Datorită complexității crescute a acestor soluții și deoarece acestea sunt dedicate și antrenate doar pentru imagini de interior sau anumite scene de trafic, am implementat și am validat soluția noastră printr-un algoritm construit pe transferul/adaptarea distribuției între două imagini (cea de intrare și cea de referință). Un alt aspect pe care l-am considerat în această alegere este faptul că am preferat să evităm utilizarea de algoritmi de învățare în această etapă.

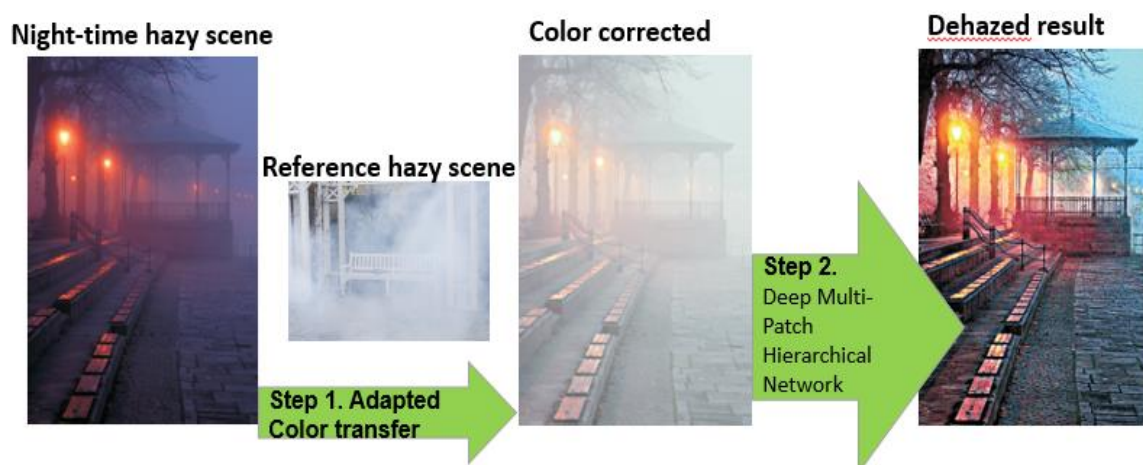


Figura 3. Algoritm de îmbunătățire a imaginilor cu ceață pe timp de noapte, se realizează în două etape: în prima etapă se aplică algoritmul de adaptare a intrării, iar în etapa a doua se execută procesul de imagine dehazing bazat pe învățare.

Algoritmul dezvoltat și testat dedicat îmbunătățirii imaginilor cu ceață pe timp de noapte se realizează în două etape: în prima etapă se aplică algoritmul de adaptare a intrării, iar în etapa a doua se execută procesul de imagine dehazing bazat pe învățare.

Prima etapă de adaptare are beneficiul adițional de a îmbunătății estimarea transmisiei din imaginea cu ceață, de a îmbunătății distribuția culorilor precum și a crește intensitatea luminoasă din imaginea de intrare. Această soluție deschide de asemenea o nouă direcție de cercetare pentru reiluminarea scenei (în comparație cu soluțiile anterioare de transfer de culoare care nu abordau problema reiluminării scenei).

Soluția propusă se realizează în spațiul de culoare oponent introdus de Ruderman et al. și extinde soluția propusă de Reihard et al.[50]. Implementarea noastră realizează 4 pași principali: mai întâi, imaginea este convertită din spațiul de culoare RGB în spațiul de culoare $l\alpha\beta$ (conversia transformă valorile canalului RGB în valori tristimulus XYZ și apoi

în spațiu LMS. Valorile LMS sunt comprimate logaritmic, ceea ce minimizează deformarea și distorsiunea datelor, înainte de a aplica o transformare liniară decorelativă). În acest spațiu de culoare, axa I este canalul acromatic, iar canalele α și β corespund canalelor adverse cromatice galben-albastru și roșu-verde.

În a doua parte a etapei de adaptare, se estimează referința care pornește de la o imagine de referință aleasă din setul antrenament pentru imagine dehazing. Pentru a se potrivi cu valoarea medie a imaginii de referință inițială, dar și pentru a păstra detaliile importante din imaginea de intrare, se însumează la imaginea de referință, valoarea detaliilor precum și valorile din zonele prominente din imaginea de intrare. Dacă această etapă este ignorată, rezultatul transferului ar pierde detaliile din zonele iluminate de sursele artificiale, iar aspectul general ar fi corespunzător unei imagini supra-expuse. Prin normalizarea domeniului de reprezentare și prin reajustarea contrastului, rezultatul ar pierde iluminarea câștigată prin transfer, dar ar menține corecția de culoare.

În ultima etapă de transfer se aplică o formula directă de adaptare care are rolul de a potrivi valoarea medie a imaginii de intrare cu valoarea medie a imaginii de referință și, de asemenea, scalată cu abaterile standard ale ambelor imagini: imaginea de referință și imaginea sursă.

Procesul de adaptare și transfer de intensitate și culoare este prezentat în imaginea următoare:

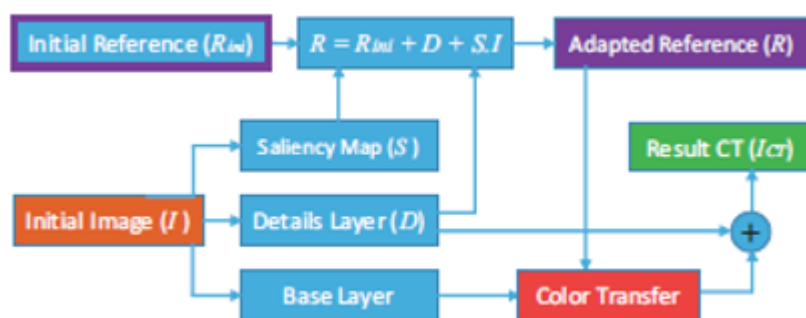


Figura 4. Procesul de adaptare al imaginii de intrare, adaptează procesul de transfer al culorii la obiectivul de image dehazing.

Etapa a doua a implementării execută procesul de image dehazing bazat pe învățare. Această soluție a fost inspirată de metoda recentă [51] care a demonstrat că generează rezultate rapide, menținând în același timp o bună fidelitate a rezultatelor, pentru două baze de testare introduse de noi: O-Haze (light-haze) și NH-Haze (Non-Homogeneous Haze). Tehnica de Deep Multi-Patch Hierarchical Network (DMPHN) a fost dezvoltată inițial pentru sarcina de a elimina efectul de neclaritate (blur) din imagine. Metoda noastră noastră a implicat implementarea unei rețele de tipul DMPHN pentru care am ales 3 niveluri de descompunere și procesare. Astfel numărul de regiuni (patches) definite este definit astfel: o regiune pentru nivelul superior, două regiuni pentru al doilea nivel intermediar și patru regiuni la nivelul inferior.




Figura 5. De sus în jos: nivelul superior utilizează imaginea originală cu ceață, nivelul intermediar procesează două regiuni, iar nivelul inferior împarte imaginea de intrare în patru regiuni.

Fiecare nivel are o pereche de encoder-decodor, iar transmiterea informațiilor între niveluri se face de jos în sus.

Arhitectura codificatorului și decodatorului utilizată pentru toate nivelurile constă din 15 straturi convoluționale, 6 conexiuni reziduale și 6 unități ReLU

Excepția (diferența dintre codificator-decodor) este aceea că cele 2 straturi convoluționale sunt modificate cu straturi deconvoluționale (pentru a produce imagini dezintegrate).

Rețeaua dezvoltată a fost antrenată utilizând setul de date realist de dehazing de imagini înregistrate în timpul zilei NH-Haze

După cum se poate vedea în exemplele generate de mai jos, imaginile îmbunătățite cu algoritmul DMPHN amplifică vizual deplasarea/eroarea de culoare care se datorează în principal din cauza spectrului luminii artificiale. În comparație cu tehnica DMPHN, o operație de transfer a caracteristicilor imaginilor de antrenament înainte de procesarea imaginii are ca efect îmbunătățirea considerabilă a rezultatelor.

Mai mult, se poate observa în figura 7, imaginile procesate fără adaptare, pot să prezinte erori de fuziune ale celor 4 regiuni utilizate de nivelul inferior. După adaptare, acest tip de eroare nu mai este observat. Acest rezultat este important deoarece procesarea separată a regiunilor, este deseori responsabilă de introducerea de artefacte care apar aleatoriu în timpul procesului de dehazing a imaginii.

În figura 10 sunt prezentate rezultate comparative obținute folosind baza de date NH-HAZE. Ne-am comparat cu metodele lui He et al. [52] și Liu et al. [53].

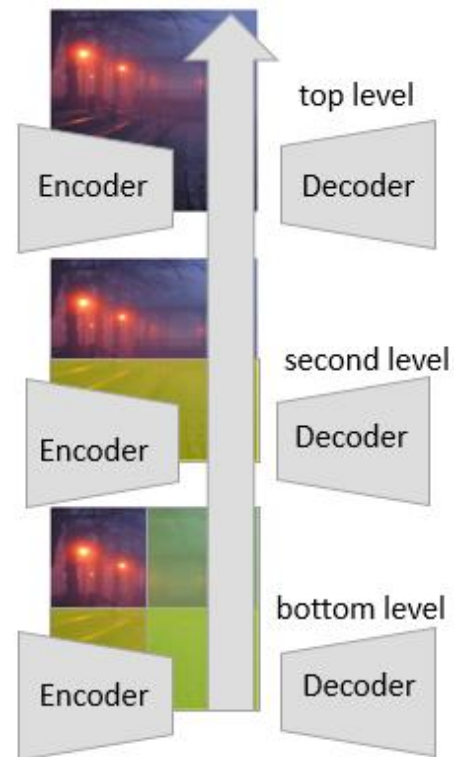


Figura 6. De sus în jos: arhitectura celor trei niveluri este similară și conține o pereche de encoder-decodor, iar transmiterea informațiilor între niveluri se face de jos în sus.



Figura 7. De la stanga la dreapta (prima coloană): imaginea originală cu ceață, imaginea îmbunătățită pe baza DCP fără modificare de culoare. De la stanga la dreapta (a doua coloană): imaginea îmbunătățită cu algoritmul bazat pe DMPHN antrenat cu NH-Haze, imaginea îmbunătățită cu algoritmul bazat pe DMPHN (similar antrenat cu NH-Haze) dar cu adaptare de domeniu.



Figura 8. De la stanga la dreapta (prima coloană): imaginea originală cu ceață, imaginea îmbunătățită pe baza DCP fără modificare de culoare. De la stanga la dreapta (a doua coloană): imaginea îmbunătățită cu algoritmul bazat pe DMPHN antrenat cu NH-Haze, imaginea îmbunătățită cu algoritmul bazat pe DMPHN (similar antrenat cu NH-Haze) dar cu adaptare de domeniu.



Figura 9. De sus în jos: imaginea originală cu ceață, imaginea îmbunătățită cu metoda lui Meng et al., imaginea îmbunătățită cu metoda lui Li et al., imaginea îmbunătățită cu metoda lui Berman et al., imaginea îmbunătățită cu metoda lui He et al. (pe baza DCP), imaginea îmbunătățită cu algoritmul bazat pe DMPHN antrenat cu NH-Haze, imaginea îmbunătățită cu algoritmul bazat pe DMPHN (similar antrenat cu NH-Haze) + adaptare de domeniu.


Original hazy images



He et al.



Liu et al.



Our results



Figura 10. Rezultate comparative obtinute folosind baza de date NH-HAZE. Ne-am comparat cu metodele lui He et al. [52] si Liu et al. [53].

A3. Diseminarea rezultatelor:

In această etapă rezultatele au fost publicate intr-o lucrare cotate ISI/WOS :

1. Arpad Kis, Codruta O. Ancuti, Night-time image dehazing using deep hierarchical network trained on day-time hazy images, IEEE ELMAR, 199-202, Zadar, Croatia, 2022

Gradul de realizare al obiectivelor – 100%

Director de proiect:
Ancuti O. Codruta

Referinte:

- [1] H. Koschmieder. Theorie der horizontalen sichtweite. In Beitrage zur Physik der freien Atmosphere, 1924.
- [2] Codruta O. Ancuti, Cosmin Ancuti, Florin-Alexandru Vasluiianu, Radu Timofte, Minghan Fu, Huan Liu et al., NonHomogeneous Dehazing Challenge Report, NTIRE 2021
- [3] Boyi Li, Xiulian Peng, Zhangyang Wang, Jizheng Xu, and Dan Feng. 2017. AOD-Net: All-in-One Dehazing Network. In International Conference on Computer Vision. 4780–4788.
- [4] Wenqi Ren, Si Liu, Hua Zhang, Jinshan Pan, Xiaochun Cao, and Ming-Hsuan Yang. 2016. Single image dehazing via multi-scale convolutional neural networks. In European Conference on Computer Vision. 154–169
- [5] Xiaoqin Zhang, Tao Wang, Jinxin Wang, Guiying Tang, and Li Zhao. 2020. Pyramid Channel-based Feature Attention Network for image dehazing. Computer Vision and Image Understanding 197-198 (2020), 103003
- [6] Dongdong Chen, Mingming He, Qingnan Fan, Jing Liao, Liheng Zhang, Dongdong Hou, Lu Yuan, and Gang Hua. 2019. Gated Context Aggregation Network for Image Dehazing and Deraining. In Winter Conference on Applications of Computer Vision. 1375–1383.
- [7] Dongdong Chen, Mingming He, Qingnan Fan, Jing Liao, Liheng Zhang, Dongdong Hou, Lu Yuan, and Gang Hua. 2019. Gated Context Aggregation Network for Image Dehazing and Deraining. In Winter Conference on Applications of Computer Vision. 1375–1383.
- [8] Shengdong Zhang, Fazhi He, and Wenqi Ren. 2020. Photo-realistic dehazing via contextual generative adversarial networks. Machine Vision and Applications 31 (2020), 1–12.
- [9] Akshay Dudhane, Harshjeet Singh Aulakh, and Subrahmanyam Murala. 2019. Ri-gan: An end-to-end network for single image haze removal. In Conference on Computer Vision and Pattern Recognition Workshops. 2014–2023
- [10] Anna Wang, Wenhui Wang, Jinglu Liu, and Nanhui Gu. 2018. AIPNet: Image-to-image single image dehazing with atmospheric illumination prior. IEEE Transactions on Image Processing 28, 1 (2018), 381–393
- [11] Cong Wang, Yuexian Zou, and Zehan Chen. 2020. ABC-NET: Avoiding Blocking Effect & Color Shift Network for Single Image Dehazing Via Restraining Transmission Bias. In International Conference on Image Processing. 1053–1057.
- [12] Shuxin Chen, Yizi Chen, Yanyun Qu, Jingying Huang, and Ming Hong. 2019. Multi-scale adaptive dehazing network. In Conference on Computer Vision and Pattern Recognition Workshops. 2051–2059
- [13] Ayush Singh, Ajay Bhave, and Dilip K Prasad. 2020. Single image dehazing for a variety of haze scenarios using back projected pyramid network. In European Conference on Computer Vision. 166–181.
- [14] He Zhang and Vishal M Patel. 2018. Densely connected pyramid dehazing network. In Conference on Computer Vision and Pattern Recognition. 3194–3203
- [15] He Zhang, Vishwanath Sindagi, and Vishal M Patel. 2018. Multi-scale single image dehazing using perceptual pyramid deep network. In Conference on Computer Vision and Pattern Recognition Workshops. 902–911.
- [16] Y. Qu, Y. Chen, J. Huang, and Y. Xie. 2019. Enhanced Pix2pix Dehazing Network. In Conference on Computer Vision and Pattern Recognition. 8152–8160
- [17] Ming Hong, Yuan Xie, Cuihua Li, and Yanyun Qu. 2020. Distilling Image Dehazing With Heterogeneous Task Imitation. In Conference on Computer Vision and Pattern Recognition. 3462–3471

- [18] Zhengxi Zhang, Liang Zhao, Yunan Liu, Shanshan Zhang, and Jian Yang. 2020. Unified Density-Aware Image Dehazing and Object Detection in Real-World Hazy Scenes. In Asian Conference on Computer Vision. 119–135.
- [19] Kaiming He, Xiangyu Zhang, Shaoqing Ren, and Jian Sun. 2016. Deep residual learning for image recognition. In Conference on Computer Vision and Pattern Recognition. 770–778.
- [20] Tiantong Guo, Venkateswararao Cherukuri, and Vishal Monga. 2019. Dense ‘123’ color enhancement dehazing network. In Conference on Computer Vision and Pattern Recognition Workshops. 2131–2139
- [21] Shengdong Zhang, Wenqi Ren, Xin Tan, Zhi-Jie Wang, Yong Liu, Jingang Zhang, Xiaoqin Zhang, and Xiaochun Cao. 2022. Semantic-aware dehazing network with adaptive feature fusion. *IEEE Transactions on Cybernetics* (2022).
- [22] Hongyuan Zhu, Xi Peng, Vijay Chandrasekhar, Liyuan Li, and Joo-Hwee Lim. 2018. DehazeGAN: When Image Dehazing Meets Differential Programming. In International Joint Conference on Artificial Intelligence. 1234–1240.
- [23] Gao Huang, Zhuang Liu, Laurens Van Der Maaten, and Kilian Q Weinberger. 2017. Densely connected convolutional networks. In Conference on Computer Vision and Pattern Recognition. 4700–4708.
- [24] Yean-Wei Lee, Lai-Kuan Wong, and John See. 2020. Image Dehazing With Contextualized Attentive U-NET. In International Conference on Image Processing. 1068–1072.
- [25] Fei Yang and Qian Zhang. 2021. Depth aware image dehazing. *The Visual Computer* (2021), 1–9.
- [26] Dong Zhao, Long Xu, Lin Ma, Jia Li, and Yihua Yan. 2021. Pyramid Global Context Network for Image Dehazing. *IEEE Transactions on Circuits and Systems for Video Technology* 31, 8 (2021), 3037–3050.
- [27] Xuesong Chen, Haihua Lu, Kaili Cheng, Yanbo Ma, Qiuhaio Zhou, and Yong Zhao. 2019. Sequentially refined spatial and channel-wise feature aggregation in encoder-decoder network for single image dehazing. In International Conference on Image Processing. 2776–2780.
- [28] Hang Dong, Xinyi Zhang, Yu Guo, and Fei Wang. 2020. Deep multi-scale gabor wavelet network for image restoration. In International Conference on Acoustics, Speech and Signal Processing. 2028–2032.
- [29] Shibai Yin, Xiaolong Yang, Yibin Wang, and Yee-Hong Yang. 2021. Visual Attention Dehazing Network with Multi-level Features Refinement and Fusion. *Pattern Recognition* 118 (2021),
- [30] Mingzhao Yu, Venkateswararao Cherukuri, Tiantong Guo, and Vishal Monga. 2020. Ensemble dehazing networks for non-homogeneous haze. In Conference on Computer Vision and Pattern Recognition Workshops. 450–451.
- [31] J. Zhang and D. Tao. 2020. FAMED-Net: A Fast and Accurate Multi-Scale End-to-End Dehazing Network. *IEEE Transactions on Image Processing* 29(2020), 72–84.
- [32] W. Chen, J. Ding, and S. Kuo. 2019. PMS-Net: Robust Haze Removal Based on Patch Map for Single Images. In Conference on Computer Vision and Pattern Recognition. 11673–11681
- [33] Wei-Ting Chen, Hao-Yu Fang, Jian-Jiun Ding, and Sy-Yen Kuo. 2020. PMHLD: patch map-based hybrid learning DehazeNet for single image haze removal. *IEEE Transactions on Image Processing* 29 (2020), 6773–6788
- [34] Zijun Deng, Lei Zhu, Xiaowei Hu, Chi-Wing Fu, Xuemiao Xu, Qing Zhang, Jing Qin, and Pheng-Ann Heng. 2019. Deep multi-model fusion for single-image dehazing. In International Conference on Computer Vision. 2453–2462.
- [35] Jiangxin Dong and Jinshan Pan. 2020. Physics-based feature dehazing networks. In European Conference on Computer Vision. 188–204.

- [36] Xiaoqin Zhang, Runhua Jiang, Tao Wang, and Wenhan Luo. 2021. Single Image Dehazing via Dual-Path Recurrent Network. *IEEE Transactions on Image Processing* 30 (2021), 5211–5222.
- [37] Hang Dong, Jinshan Pan, Lei Xiang, Zhe Hu, Xinyi Zhang, Fei Wang, and Ming-Hsuan Yang. 2020. Multi-scale boosted dehazing network with dense feature fusion. In *Conference on Computer Vision and Pattern Recognition*. 2157–2167.
- [38] Peter Morales, Tzofi Klinghoffer, and Seung Jae Lee. 2019. Feature forwarding for efficient single image dehazing. In *Conference on Computer Vision and Pattern Recognition Workshops*. 2078–2085.
- [39] Rongsen Chen and Edmund M-K Lai. 2019. Convolutional Autoencoder For Single Image Dehazing.. In *International Conference on Image Processing*.
- [40] Qili Deng, Ziling Huang, Chung-Chi Tsai, and Chia-Wen Lin. 2020. Hardgan: A haze-aware representation distillation gan for single image dehazing. In *European Conference on Computer Vision*. 722–738.
- [41] Deniz Engin, Anil Genç, and Hazim Kemal Ekenel. 2018. Cycle-dehaze: Enhanced cyclegan for single image dehazing. In *Conference on Computer Vision and Pattern Recognition Workshops*. 825–833.
- [42] Shengdong Zhang, Fazhi He, and Wenqi Ren. 2020. NLDN: Non-local dehazing network for dense haze removal. *Neurocomputing* 410 (2020), 363–373.
- [43] Haoran Wei, Qingbo Wu, Hui Li, King Ngi Ngan, Hongliang Li, and Fanman Meng. 2020. Single Image Dehazing via Artificial Multiple Shots and Multidimensional Context. In *International Conference on Image Processing*. 1023–1027.
- [44] Eunsung Jo and Jae-Young Sim. 2021. Multi-Scale Selective Residual Learning for Non-Homogeneous Dehazing. In *Conference on Computer Vision and Pattern Recognition*. 507–515.
- [45] Minghan Fu, Huan Liu, Yankun Yu, Jun Chen, and Keyan Wang. 2021. DW-GAN: A Discrete Wavelet Transform GAN for NonHomogeneous Dehazing. In *Conference on Computer Vision and Pattern Recognition Workshops*. 203–212.
- [46] Yankun Yu, Huan Liu, Minghan Fu, Jun Chen, Xiyao Wang, and Keyan Wang. 2021. A Two-branch Neural Network for Non-homogeneous Dehazing via Ensemble Learning. In *Conference on Computer Vision and Pattern Recognition Workshops*. 193–202.
- [47] Y. Shao, L. Li, W. Ren, C. Gao, and N. Sang. 2020. Domain Adaptation for Image Dehazing. In *Conference on Computer Vision and Pattern Recognition*. 2805–2814.
- [48] L. Li, Y. Dong, W. Ren, J. Pan, C. Gao, N. Sang, and M. H. Yang. 2020. Semi-Supervised Image Dehazing. *IEEE Transactions on Image Processing* 29 (2020), 2766–2779
- [49] Color channel compensation (3C): A fundamental pre-processing step for image enhancement, CO Ancuti, C Ancuti, C De Vleeschouwer, M Sbert, IEEE TIP 2019
- [50] E. Reinhard, M. Adhikim, B. Gooch, and P. Shirley, “Color transfer between images,” in *IEEE Computer Graphics and Applications*, 2001
- [51] S. D. Das and S. Dutta, “Fast deep multi-patch hierarchical network for nonhomogeneous image dehazing,” *IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops (CVPRW)*, 2020
- [52] K. He, J. Sun, and X. Tang. Single image haze removal using dark channel prior. In *IEEE CVPR*, 2009
- [53] Xiaohong Liu, Yongrui Ma, Zhihao Shi, and Jun Chen. Griddehazenet: Attention-based multi-scale network for image dehazing. In *IEEE ICCV*, 2019.