



(12)

BREVET DE INVENȚIE

(21) Nr. cerere: **a 2021 00559**

(22) Data de depozit: **17/09/2021**

(45) Data publicării mențiunii acordării brevetului: **30/08/2023** BOPI nr. **8/2023**

(41) Data publicării cererii:
30/05/2022 BOPI nr. **5/2022**

(73) Titular:
• **UNIVERSITATEA TEHNICĂ DIN
CLUJ-NAPOCA, STR.MEMORANDUMULUI
NR.28, CLUJ-NAPOCA, CJ, RO**

(72) Inventatori:
• **MOLNAR SZILARD, STR.BERZEI, NR.10,
SFÂNTU-GHEORGHE, CV, RO;**
• **TAMAS LEVENTE, STR.BISERICII
ORTODOXE, NR.18, CLUJ-NAPOCA, CJ,
RO**

(56) Documente din stadiul tehnicii:
**WO 2013067235 (A1); DAVID GALLUP,
"PIECEWISE PLANAR AND NON-PLANAR
STEREO FOR URBAN SCENE
RECONSTRUCTION", CONFERENCE
PAPER IN IEEE COMPUTER SOCIETY
CONFERENCE ON COMPUTER VISION
AND PATTERN RECOGNITION,
<https://www.researchgate.net>;
US 2013321393 (A1)**

(54) **METODĂ PENTRU ESTIMAREA NORMALELOR
PENTRU CAMERE CU INFORMAȚIE DE DISTANȚĂ
EMIȚĂTOARE DE IMPULSURI**



RO 135781 B1

1 Inventția se referă la o metodă de calculare automată a normalelor de pe suprafețele
sitate pe scanări 3D, create de către camere cu senzori de tipul "Time-of-Flight" (ToF).

3 Calcularea normalelor este un aspect important în domeniul viziunii artificiale. Pe
cunoștința normalelor se poate baza segmentarea imaginilor, sau aplicarea efectelor de
5 lumină în modelarea 3D. Astfel, putem trage concluzia, cu cât mai rapidă este estimarea
normalelor, cu atât se poate accelera și celelalte procese, și cu cât mai exactă este o
7 predicție despre o normală, cu atât va îmbunătăți efectele aplicate.

Pentru calcularea normalelor există multe metode, din care o subcategorie aparține
9 metodelor cu învățare automată conform referințelor [5], [6], [7], [8] iar cealaltă categorie fiind
cea a metodelor tradiționale.

11 *Metodele tradiționale*

Abordarea clasică de calculare a normalelor este bazată pe analiza componentei
13 principale (Principal Component Analysis -PCA) [4], care afirmă că se poate considera un
suport pentru fiecare punct într-un nor de puncte, iar analizând covarianța punctelor din
15 interiorul acestui suport, se obține vectorul propriu care corespunde celei mai mici a valorilor
propriei. Acest vector este considerat ca fiind normala punctului respectiv. Câteva metode au
17 analizat efectul mărimii bazei de suport asupra calității normalei estimate [9,10,11], dar asta
înseamnă că și complexitatea programului crește [12] .

19 Alte metode tradiționale folosesc celule de tip Voronoi [13] , [14] , [15] . Aceste
metode apar ca fiind instabile, dar dacă sunt bazate pe PCA, atunci se obțin rezultate îmbu-
21 nătățite [16]. Alții au folosit abordări multiscalare, și au obținut metode robuste, în ceea ce
privește zgomotul [17,18] , aici putem să menționăm și transformările Hough [19]. Presupu-
23 nând că suporturile sunt planare, chiar și pe margini, se obțin rezultate mai robuste [20,21].

25 *Metode bazate pe învățare automată*

Prin folosirea învățării automate se pot obține îmbunătățiri considerabile [22] , [5] ,
[23], [24], [6], [25], [7], [3]. Metodele cu învățare automată sunt populare chiar dacă sunt
27 lente și au nevoie de seturi mari de date.

În primul rând, se poate folosi proiecția seturilor de puncte în 2D, cu care sunt
29 obținute imagini de adâncime, astfel încât se pot folosi și operații de convoluție tradiționale,
făcând estimarea normalelor ușoară și rapidă.

31 În al doilea rând, câteva metode se concentrează pe seturi de puncte discrete
nestructurate [26], începând de aici, s-au obținut metode pentru estimarea normalelor
33 [22],[25], introducând abordări orientate înspre seturile multiscalare . Cu ajutorul acestor
metode și prin adaugarea vectorilor de tip Fischer [3] combinați cu anumiți experți (metode
35 de decizie) în faza de estimare a normalelor au evoluat noile metode.

37 *Abordări multimodale*

Abordările multimodale folosesc date heterogene, de exemplu intrări radiometrice sau
39 spectrale [27]. Metoda noastră se poate considera o abordare multimodală, din cauză că pe
lângă imaginile de adâncime se poate introduce și semnalul infraroșu.

41 *Literatura de brevete*

Majoritatea metodelor sunt bazate pe metoda Random sample consensus
(RANSAC), diferența fiind fie stocarea datelor și abordările propuse.

43 **US 10097813 B2** estimează cromaticitățile pentru fiecare pixel. Metoda acesta are
nevoie de cel puțin trei surse de lumină și două camere, din care cel puțin o cameră trebuie
45 să fie o cameră stereo. În metoda noastră avem nevoie numai de o cameră de tip ToF.

US 20170227942 A1 și **US 10097813 B2** folosesc imagini rotite pentru estimarea
47 poziției, care este robustă cu privire la zgomot, dar calculele sunt foarte complexe. Metodele
caută marginile în fiecare plan, și produsul lor este considerat ca un vector normal. Căutarea
49 marginilor are un timp de procesare foarte mare, iar metoda noastră este mult mai rapidă.

RO 135781 B1

În **US 9767598 B2** este prezentată o aproximare pentru normale, similară cu modul de funcționare al algoritmului RANSAC. Modelul potrivește un plan pentru punctele din vecinătatea unui punct. Dacă planul este mic, atunci calitatea aproximării nu va mai fi atât de robustă, numai cu un plan mai mare. Motivul este că această metodă netezește norul de puncte, care mai are nevoie de calcule robuste, în contrast, metoda noastră moștenește un comportament adaptiv de la mai multe straturi ale FPN-ului.

O altă metodă este **US 9117281 B2**, care lucrează cu imagine RGB și imagini de adâncime, similar cu metoda noastră. Această metodă calculează o funcție de cost ca să aproximeze planurile, dar iarăși, planurile sunt folosite cu RANSAC ca să obțină normalele. Mai trebuie menționat și faptul că în această metodă este integrată și asumarea de spațiu Manhattan, adică planurile sunt aliniată cu coordonatele lumii, simplificând calculele.

US 8665267 B2 se procesează punctele 3D, deci datele au nevoie de preprocesare, în contrast metoda noastră lucrează cu datele pure obținute de la camera ToF. Din aceste cadre, metoda creează niște plasturi, care sunt utilizați în calcularea normalelor. Metoda calculează cu o mai mare precizie normalele, însă acestea sunt des interpolate, ceea ce duce la pierderi mari de informație și rezoluție.

US 9875554 B2 perfecționează normalele suprafețelor, și nu le generează. Metoda constă în faptul că normalele obiectelor fizice reprezintă câmpuri de normale conservative. De aceea, o hartă de înălțime bazată pe componenta conservatoare a suprafeței inițiale se poate să îmbunătățească direcțiile normalelor. Metoda noastră calculează normalele din prima procesare, nu are nevoie de normale preexistente.

US 9626767 B2 folosește imagini secvențiale cu condiții de lumini diferite pentru a reproduce informațiile spațiale de la imaginile RGB. Imaginile sunt împărțite în diferite zone, dintre care se pot folosi informații diferite, mai ales de la diferite imagini. Este de menționat faptul că o cameră cu laser și o tehnică de triangulație este mai inferioară decât metoda aceasta, deoarece este mult mai complexă, și se poate să piardă informații referitoare la suprafețele transparente sau non-reflectorizante. Problema aceasta este prezentă și la camerele RGB-D, deci și metoda noastră suferă de acest fenomen. În orice caz, dacă verificăm numai datele comune în cele două metode, ajungem la concluzia că metoda noastră funcționează mai bine, și nu are nevoie de imagini atât de multe. Faptul că metoda noastră folosește o cameră care înglobează toate informațiile necesare, metoda noastră este mult mai potrivită pentru procese de timp real sau procese dinamice.

US 009043186 B2 tratează punctele din spațiul 3D drept sarcini electrostatice. Dacă se consideră un punct drept centrul unei sfere și se calculează potențiale electrostatice în interiorul sferei, atunci un vector care pornește din centrul sferei până la punctul unde potențialul electrostatic este minim, vectorul respectiv poate fi considerat ca normală pentru centrul sferei. Metoda este bazată pe modelul RANSAC.

US 20180025496 A1 folosește mai multe puncte de vedere pentru a capta o imagine a unei scene sau a unui obiect. Dacă se aliniază scena de la mai multe imagini, din diferențele minore, de exemplu luminescență, se pot calcula normalele. Un dezavantaj este când în anumite zone pozele nu se aliniază corect, iar atunci se setează un prag, care decide care dintre imagini este folosită, în anumite cazuri se poate ca numai o poză să fie folosită pentru zona problematică.

În **US 005283837 A** este calculată variația medie a punctelor pe axele x, y și z din care rezultă matricea de covarianță. Prin descompunerea ei în valori proprii se obțin normalele. Acest fapt se datorează deoarece normalele tind să se alinieze pe direcția cu cea mai mare variație. Această metodă se afirmă prin faptul că este eficientă, nu are nevoie de calcule complexe, și este flexibilă, din cauză că folosește o mărime variabilă a vecinătății de puncte.

RO 135781 B1

1 Problema pe care o rezolvă invenția este procesarea imaginilor mai rapid și mai
precis prin calcularea automată a normalelor de pe suprafețele situate pe scanări 3D, create
3 de camere cu senzori de tip ToF.

Metoda, conform invenției, presupune realizarea următoarelor etape:

5 1. Preluarea imaginii cu ajutorul camerei și crearea setului de date necesare
antrenării rețelei neuronale;

7 2. Realizarea modelului neuronal;

9 3. Exploatarea modelului neuronal pentru estimarea normalelor codificat în spațiul
RGB;

11 4. Convertirea normalelor în spațiul 3D, combinând cu informația de distanță de la
imaginile de intrare.

Metoda cuprinde o componentă care folosește rețele neuronale convoluționale
13 (Convolutional Neural Networks - CNN) pentru calcularea normalelor dintr-un nor de puncte.
Norul de puncte este creat de o cameră ToF și stocat ca o imagine de adâncime. CNN-ul se
15 bazează pe stocarea informației pe 3 canale, informațiile obținute pe cele 3 canale au fost
antrenate folosind seturi mari de date, atât reale cât și sintetice. În faza evaluării, CNN-ul
17 este capabil să estimeze normalele pentru un nor de puncte, astfel încât aceasta să fie mai
rapidă și mai robustă decât metodele existente.

19 Pentru acesta se folosește arhitectura FPN [1] și o codificare a normalelor în spațiul
RGB. Adicional, este folosit și o funcție de pierdere specifica, care transformă informația de
21 la 2D în 3D.

Se dă în continuare un exemplu de realizare a invenției, în legătură cu fig. 1...3, care
23 reprezintă:

- fig. 1, diagrama de flux cu arhitectura FPN;

25 - fig. 2, detaliile modelului FPN;

- fig. 3, codificarea normalelor de la spațiul 3D în spațiul RGB.

27 Metoda se bazează pe abilitatea de a captura caracteristici multi-scalare de la
camerele ToF folosind Feature Pyramid Networks (FPN) **(1)** pentru estimarea normalelor
29 conform Figurii 1. Din cauza tipului specific al camerelor ToF, măsurătorile spațiului 3D sunt
codificate sub forma imaginilor de adâncime **(2)**, care se pot proiecta în 3D ca un nor de
31 puncte organizat. Chiar dacă între straturile piramidei și bazele de suport a normalelor, din
norul de puncte, nu este o legătură strictă definită, modelul imită estimarea normalelor
33 folosind metode multi-scalare în spațiul 3D.

Mărimea imaginii la antrenare trebuie să fie aceeași ca mărimea de imagine la
35 testare. O imagine de adâncime stochează informațiile cu numere întregi pe 16 biți, și fiecare
număr întreg reprezintă un milimetru în spațiul real. Metoda convertește numere în format
37 virgulă mobilă pe 32 biți. Pentru o antrenare adecvată este necesar un set de date care
conține cel puțin 5000 de imagini de adâncime asociate cu imagini în format RGB, care
39 stochează normalele de referințe.

Codificarea informațiilor referitoare la normale înseamnă că în spațiul 3D un vector
41 are trei coordonate: x , y și z . Vectorii sunt considerați ca fiind vectori normalizați, adică
valorile coordonatelor sunt în intervalul $[-1,1] \in \mathbb{R}$, iar lungimea vectorului este de o unitate.
43 După stabilirea limitelor în spațiul 3D, putem să stabilim limitele în spațiul RGB. La o imagine
color, de obicei sunt 3 canale (R-roșu (red), G-verde (green), B-albastru (blue)), fiecare canal
45 fiind pe 8 biți, cu valori posibile în intervalul $[0,255] \in \mathbb{N}$ **(3)**. Folosindu-ne de informațiile
menționate, se poate face o mapare între coordonatele x , y , z și canalele R, G, B cu o
47 pierdere minimală, care este sub un grad.

RO 135781 B1

Modelul neuronal are ca intrare o imagine de adâncime, iar la ieșire o imagine RGB, folosind astfel doar spațiu 2D. Modelul neuronal este compus din trei ramuri, fiecare ramura având 5 nivele interconectate. 1 3

Detaliile modelului FPN prezentate în fig. 2 sunt prezentate după cum urmează: Dimensiunea imaginii de intrare poate fi aleatoare (depinde de camera ToF folosită), pentru că la ieșire rezultatul va avea aceeași dimensiune. Ca bază, putem să folosim orice model, însă noi am folosit ResNet [2] care este un model pre-antrenat pe setul de date ImageNet. 5 7

Construirea piramidelor (1) înseamnă că trebuie să avem o cale de jos în sus (4) și o altă cale de sus în jos (5) unite prin mai multe căi laterale (6). 9

Calea de jos în sus (4):

Această cale constă în calculul feedforward al rețelei convoluționale, combinând hărți caracteristice de la diferite straturi. 11

Pentru faza de upsampling am folosit pixel shuffle cu interpolare biliniară, ca să evităm mărimile inconsistente de la hărțile caracteristice. Ieșirea unui nivel este intrarea pentru următorul nivel. Din cauză că am folosit ResNet la bază, am avut acces la caracteristica de activare pentru ieșirea blocului rezidual de la ultima etapă, notat cu C_i de la stratul i (fig. 2). 13 15

Calea de sus în jos (5): 17

Calea aceasta imită caracteristici cu rezoluții înalte, fiindcă modelul face un upsampling de la hărțile caracteristice rare, dar mai descriptive. Straturile sunt notate cu P_i . Conexiunile laterale impun aceste caracteristici incluzând informația de la calea de jos în sus. 19 21

Operatorul între ultimele două nivele conține două module convoluționale consecutive de 3x3 pentru procesarea ultimei hărți caracteristice, urmat de o funcție de activare de tip Sigmoid. 23

Conexiunile laterale (6): 25

Conexiunile de la straturile P sunt asigurate printr-o convoluție de 1x1 și o sumă de element cu element. Dimensiunile straturilor verticale sunt moștenite și de către straturile laterale. 27

Eroarea este calculată ca diferența de unghi între normalele calculate și normalele de referință. În această fază normalele sunt convertite în spațiul 3D. Funcția de calculare a erorii este: 29 31

$$L_{normal} = \frac{1}{N} \sum_i^N \left(1 - \frac{\|N_i \times N_{GT}\|}{\|N_i\| \cdot \|N_{GT}\|} \right) \quad 33 \quad 35$$

În ecuația de mai sus se descrie funcția de calculare a erorii pentru antrenarea modelului. Funcția calculează diferențele (7) între unghiurile dintre vectorii normalelor din norul de puncte de referință (8) și din norul de puncte estimat (9). În ecuație, N este numărul punctelor din norul de puncte, N_i reprezintă vectorii normalelor estimați, iar N_{GT} reprezintă vectorii normalelor de referință. 37 39

Ideea inovatoare iese în evidență prin faptul că metoda, conform invenției, codifică normalele de la spațiul 3D în spațiul RGB (3), care este un fapt unic. Metoda noastră ca multe dintre metodele prezentate folosește CNN, dar diferit de ele, folosește arhitectura FPN (1). Am mai adăugat și o funcție de pierdere nouă, care înseamnă că în timpul antrenării rețeaua calculează normalele într-o imagine RGB, care este proiectată înapoi în spațiul 3D, iar erorile sunt calculate în spațiul proiectat. 41 43 45

RO 135781 B1

1 Prin invenție, se obține o metodă cu care putem să estimăm normalele pentru o
anumită suprafață extrasă de la o imagine făcută de către o cameră de tip ToF. Metoda se
3 poate folosi ca o fază de preprocesare pentru mai multe teme în domeniul viziune artificială,
de exemplu clasificarea imaginilor, segmentarea obiectelor sau calcularea reflexiei luminii
5 în modelare 3D.

7 Bibliografie

9 [1] Lin, P. Dollár, R. Girshick, K. He, B. Hariharan, and S. Belongie, "Feature pyramid
networks for object detection", în 2017 IEEE Conference on Computer Vision and Pattern
11 Recognition (CVPR), 2017, pp. 936-944.

[2] He, X. Zhang, S. Ren, and J. Sun, "Deep residual learning for image recognition,
13 "2016 IEEE Conference on Computer Vision and Fattern Recognition (CVPR), pp. 770-778,
2016.

[3] Ben-Shabat, M . Lindenbaum, and A. Fischer, "Nestinet: Normalestimation for
15 unstructured 3d point clouds using convolutional neural networks", în The IEEE Conference
on Computer Vision and PatternRecognition (CVPR), 06 2019.

[4] Hoppe, T. DeRose, T. Duchamp, J. McDonald, and W. Stuerzle, "Surface
19 reconstruction from unorganized points", in Proceedings of the 19th Annual Conference on
Computer Graphics and Interactive Techniques , ser. SIGGRAPH '92. New York, NY, USA:
21 Association for Computing Machinery, 1992, p. 71-73. Available:
<https://doi.org/10.1145/133994.134011>

[5] J. E. Lenssen, C. Osendorfer, and J. Masci, "Deep iterative surface normal
23 estimation," 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognitiior
(CVPR) , Jun 2020.

[6] H. Zhou, H . Chen, Y. Feng, Q. Wang, J. Qin, H. Xie, F. L. Wang, M. Wei, and J.
27 Wang, "Geometry and learning cosupported normal estimation for unstructured point cloud,"
2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR) , pp. 13
29 235-13 244, 2020.

[7] D . Lu, X. Lu, Y. Sun, and J. Wang, "Deep feature-preserving normal estimation
31 for point cloud filtering", Comput. Aided Des., vol. 125, p. 102860.

[8] Z. Wang and V. A. Prisacariu, "Neighbourhood-insensitive point cloud normal
33 estimation network", in BMVC, 2020.

[9] Catala and M. Pouget, "Estimating differential quantities using polynomial fitting
35 or osculating jets," Computer Aided Geometric Design , vol. 22, no. 2, pp . 121-146, 2005.

[10] R. Bormann, J. Hampp, M. Hägele, and M. Vincze, "Fast and accurate normal
37 estimation by efficient 3d edge detection", in 2015 IEEE/PSJ International Conference on
Intelligent Robots and Systems (IROS), 2015, pp. 3930-3930

[11] G. Guennebaud and M. Gross, "Algebraic point set surfaces," ACM Trans.
39 Graph., vol. 26, no. 3, p. 23-es, July 2007. Available:
41 <https://doi.org/10.1145/1276377.1276406>

[12] Jordan and P. Mordohai, "A quantitative evaluation of surface normal estimation
43 in point clouds," in 2014 IEEE/RSJ International Conference on Intelligent Robots and
Systems, 2014, pp. 4220-4226.

[13] Q. Mérigot, M. Gvsjanikov, and L. J. Guibas, "Voronoi-based curvature and
45 feature estimation from point clouds," IEEE Transactions on Visualization and Computer
47 Graphics , vol. 17, no. 6, pp . 743-756, 2011.

RO 135781 B1

- [14] T. K. Dey, G. Li, and J. Sun, "Normal estimation for point clouds: a comparison study for a voronoi based method," in Proceedings Eurographics/IEEE VGTC Symposium Point-Based Graphics, 2006, pp. 39-46. 1
3
- [15] T. K. Dey and S. Goswami, "Provable surface reconstruction from noisy samples," Computational Geometry, vol. 35, no. 1, pp. 124-141, 2006, special Issue on the 20th ACM Symposium on Computational Geometry. 5
- [16] Alliez, D. Cohen-Steiner, Y. Tong, and M. Desbrun, "Voronoi-based variational reconstruction of unoriented point sets," in Proceedings of the Fifth Eurographics Symposium on Geometry Processing, ser. SGP '07. Goslar, DEU: Eurographics Association, 2007, p. 39-48. 7
9
- [17] Mura, G. Wyss, and R. Pajarola, "Robust normal estimation in unstructured 3d point clouds by selective normal space exploration," The Visual Computer, vol. 34, pp. 961-971, 2018. 11
13
- [18] J. Zhang, J. Cao, X. Liu, H. Chen, B. Li, and L. Liu, "Multi-normal estimation via pair consistency voting," IEEE Transactions Visualisation and Computer Graphics, vol. 25, pp. 1693-1706, 2019. 15
- [19] Boulch and P. Marlet, "Fast and robust normal estimation for point clouds with sharp features," Computer Graphics Forum, vol. 31, pp. 1765-1774, 08 2012. 17
- [20] H. Avron, A. Sharf, C. Greif, and D. Cohen-Or, "Sparse reconstruction of sharp point set surfaces," ACM Trans. Graph., vol. 29, no. 5, Nov. 2010. 19
- [21] H. Chen, J. Huang, O. Remil, H. Xie, J. Qin, Y. Guo, M. Wei, and J. Wang, "Structure-guided shape-preserving mesh texture smoothing via joint low-rank matrix recovery," Computer-Aided Design, vol. 115, pp. 122-134, 2019. [Online]. Available: <https://www.sciencedirect.com/science/article/pii/S0010448519302063> 21
23
- [22] Hyeon, W. Lee, J. H. Kim, and N. Doh, "Normnet: Point-wise normal estimation network for three-dimensional point cloud data," International Journal of Advanced Robotic Systems, vol. 16, no. 4, p.1729881419357532, 2019. 25
27
- [23] A. Boulch and R. Marlet, "Deep learning for robust normal estimation in unstructured point clouds," Computer Graphics Forum, vol. 35, 2016. 29
- [24] X. Wang, D. F. Fouhey, and A. Gupta, "Designing deep, networks for surface normal estimation," 2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), pp. 539-547, 2015. 31
- [25] P. Guerrero, Y. Kleiman, M. Ovsjanikov, and N. Mitra, "Pop net learning local shape properties from raw point clouds," Computer Graphics Forum, vol. 37, 2018. 33
- [26] C. R. Qi, H. Su, K. Mo, and L. J. Guibas, "Pointnet: Deep learning on point sets for 3d classification and segmentation", 2017. 35
- [27] M. Gao, J. Jiang, G. Zou, V. John, and Z. Liu, "RGB-D-Based Object Recognition Using Multimodal convolutional Neural Networks: A Survey", IEEE Access, vol. 7, pp. 43 110-43 136, 2019. 37
39

RO 135781 B1

1

Revendicare

3

Metoda de estimare a normalelor pentru puncte 3D, implementată cu ajutorul calculatorului, **caracterizată prin aceea că**, se parcurg următoarele etape pentru calculul normalelor:

5

7

a. Crearea setului de date pentru antrenarea modelului de rețele neuronale profunde de tip Feature Pyramid Network, Informația de intrare fiind o imagine de adâncime creată cu o camera de tip ToF sau obținută de la un nor de puncte;

9

b. Realizarea modelului neuronal folosind modelul Feature Pyramid Network (FPN) din care se extrag informații despre normalele punctelor 3D;

11

c. Antrenarea modelului FPN utilizând o funcția de calcul a erorii adaptată pentru suprafețele locale asociate normalelor punctelor 3D, eroarea fiind calculată cu valorile convertite înapoi în spațiul 3D, adică, valorile RGB sunt convertite în coordonate 3D, iar eroarea este diferența între vectorul de normale generat și vectorul de referință;

13

15

d. Codificarea vectorilor de direcție pentru normale pe axele X, Y și Z în spațiul 2D ca și imagine RGB pe 32 biți;

17

e. Extragerea normalelor din imaginea codificată 2D RGB, astfel încât la ieșirea rețelei, se obține o imagine RGB, în care sunt codificate normalele calculate.

(51) Int.Cl.

G06V 10/32^(2022.01);
 G06T 7/50^(2017.01);
 G06T 1/40^(2006.01)




Fig. 1

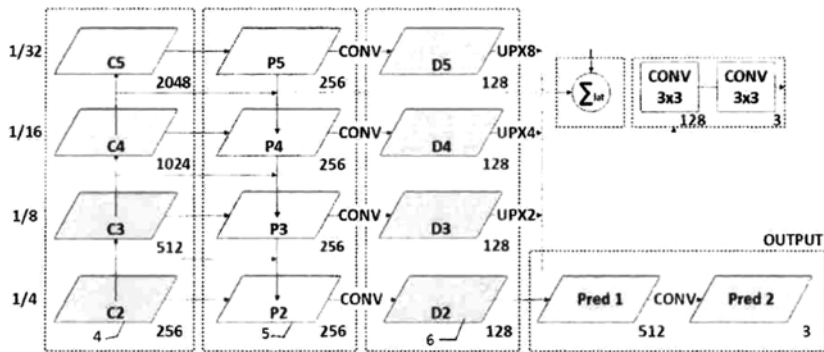


Fig. 2

(51) Int.Cl.

G06V 10/32 (2022.01);

G06T 7/50 (2017.01);

G06T 1/40 (2006.01)




Fig. 3



Editare și tehnoredactare computerizată - OSIM
Tipărit la Oficiul de Stat pentru Invenții și Mărci
sub comanda nr. 345/2023