

MINISTERUL EDUCAȚIEI ȘI CERCETĂRII AL REPUBLICII MOLDOVA

Universitatea Tehnică a Moldovei

Facultatea Calculatoare, Informatică și Microelectronică

Departamentul Ingineria Software și Automatică

Admis la susținere

Şef departament:

Ion Fiodorov, conf. univ. dr.

“ ” 2022

MACHINE LEARNING PENTRU VEHICULE AUTONOME

MACHINE LEARNING FOR AUTONOMOUS VEHICLES

Teză de master

Student: Postica Ana-Maria, gr. TI-201M

Coordonator: Rostislav Călin, lect. univ.

Consultant: Cojocaru Svetlana, lect. univ.

Chișinău, 2022

ADNOTARE

Teza de master are următoarea structură de redactare:

- introducere;
- importanța temei;
- analiza domeniului de studiu;
- descrierea sistemului de detectare a liniilor de bandă și a obiectelor;
- implementare și rezultate;
- concluzii;
- bibliografie;
- anexe.

Cuvinte cheie: conducere autonomă, percepție, *machine learning*, rețele neuronale, yolov4.

Scopul lucrării constă în cercetarea și implementarea metodelor de procesare a imaginii bazate pe *machine learning* în sistemul care va extrage informația despre liniile de bandă a carosabilului și prezența altor obiecte în timp real pe direcția de deplasare a vehiculului autonom.

Domeniul de cercetare îl constituie aspectele teoretice și științifice de implementare a algoritmilor bazați pe rețele neuronale cu scopul de percepție a mediului înconjurător din perspectiva conducerii autonome.

Teza cuprinde în sine introducere, trei capituloare, concluzii și bibliografie, anexe.

Capitolul 1 descrie aspecte teoretice despre analiza literaturii în domeniul conducerii autonome, etapa actuală și analiza provocărilor în domeniu. Cercetarea mai amplă a componentei de percepere bazată pe metode de *machine learning*.

Capitolul 2 prezintă descrierea modelelor bazate pe rețele neuronale ce pot fi utilizate cu scop de detectarea de obiecte și a liniilor de bandă, descrierea sistemului și a pașilor pentru a obține recunoașterea adecvată a obiectelor în timp real pentru conducerea autonomă.

Capitolul 3 conține descrierea rezultatelor cantitative și calitative obținute în urma implementării și antrenării sistemului pe seturi de date utile pentru vehicul autonom, cu scopul de a determina posibilitatea de utilizare în timp real pentru conducerea autonomă.

În concluzie se remarcă că s-a reușit implementarea unui sistem cu scop de percepere a mediului înconjurător în timp real pentru vehicul autonom, implementând modele bazate pe rețele neuronale cu scop de recunoaștere a obiectelor legate de circulația rutieră și a liniilor de bandă.

ANNOTATION

The master's thesis is based on the following rendering stricture:

- introduction;
- importance of the topic
- field of study analysis;
- description of system for object and lane line detecting;
- implementation and results;
- conclusions;
- bibliography;
- annexes.

Key words: autonomous driving, perception, machine learning, neuronal networks, yolov4.

The purpose of the thesis is researching and implementing image processing and object detection methods based on machine learning, in the system that will extract information in real time about the road lane line and presence of other objects on the direction of movement of the autonomous vehicle.

Thesis contains introduction, three chapters, conclusions, a bibliography list and annexes.

Chapter one describes theoretical aspects of literature analysis in the field of autonomous driving, actual situation and analysis of actual challenges in field. Extensive research on the perception component based on methods of machine learning.

Chapter two discloses a description of the methods based on neuronal networks which could be used for object and lane line detection, system description and paths for obtaining suitable recognition of objects in real time for autonomous driving.

Chapter three describes the quantitative and qualitative results obtained after implementing and training the system on suitable datasets for autonomous vehicle with purpose of using the system in real time for autonomous driving.

In conclusion it is noted that was implemented a system for real time perception of environment for autonomous vehicle, using models based on neuronal networks with purpose of recognition of information related to objects from autonomous driving perspective and lane line detection.

CUPRINS

INTRODUCERE.....	8
ANALIZA DOMENIULUI DE STUDIU	9
1.1 Sistemele senzoriale întâlnite la un automobil autonom	9
1.2 Clasificarea Nivelelor de Automatizare	12
1.3 Nivelul actual de dezvoltare al automobilelor autonome	13
1.4 Cele mai importante provocări cu care se confruntă mașinile autonome în prezent	14
1.5 Percepția	19
1.5.1 Detectarea liniilor de bandă	19
1.5.2 Detectarea obiectelor	21
1.5.3 Metode de detectare a obiectelor moderne: rețele neuronale convoluționale(RNC)	24
DESCRIEREA SISTEMULUI DE DETECTARE A LINIILOR DE BANDĂ ȘI A OBIECTELOR PENTRU CONDUCEREA AUTONOMĂ.....	35
2.1. Arhitectura rețelei nuronale pentru detectarea obiectelor.....	36
2.1.2 Prepararea setului de date	40
2.1.3 Antrenarea modelului	41
2.1.4 Testarea modelului antrenat.....	43
2.2 Componenta de detectare a liniilor de bandă pentru conducerea autonomă	44
2.2.1 Arhitectura modelului	44
2.2.2 Descrierea și testarea componentei de detectare a liniilor de bandă.....	48
REZULTATE.....	52
CONCLUZII	58
BIBLIOGRAFIE	59
ANEXA I	62
ANEXA II	65

INTRODUCERE

Automobilele autonome au devenit un subiect foarte important în ultimul deceniu, în cercetările inginerești și știința calculatoarelor. Majoritatea companiilor mari producătoare de automobile au lansat vehicule cu caracteristici semi-autonome. Companii precum Google, Uber, Ford, BMW și-au testat deja autovehiculele pe șosea. Viziunea optică este o componentă esențială a mașinii autonome. Detectarea precisă a obiectelor în timp real, cum ar fi vehiculele, pietonii, animalele și indicatorile rutiere, ar putea accelera ritmul construirii unei mașini cu conducere automată la fel de sigură ca șoferii umani. Înțelegerea imaginii a fost o sarcină provocatoare de zeci de ani. Spre deosebire de figurile geometrice, obiectele din lumea reală sunt întotdeauna figuri neregulate. Același obiect poate să apăre sub diferite forme atunci când este capturat din diferite unghiuri sau obiectul în sine își schimbă formă. Mai mult, imaginile obiectelor din mediul real sunt variate de iluminare, rotație, scară și ocluzie, ceea ce face sarcina de detectare a obiectelor mai dificilă. În ultimii ani, o serie de soluții bazate pe rețele neuronale convoluționale au făcut o îmbunătățire semnificativă în recunoașterea imaginilor. În competiția de recunoaștere vizuală pe scară largă ImageNet (ILSVRC, 2015), computerele se descurcau mai bine decât oamenii în sarcina de clasificare a imaginilor. În 2016, a fost propus un detector rapid de obiecte Yolo [35], pentru a extinde detectarea obiectelor în situații reale în timp. Astfel, apare motivația de aplicare a modelului de detectare a obiectelor Yolo, în domeniul conducerii autonome. Totodată, a avut loc dezvoltarea acestui model și au apărut diverse versiuni cu performanțe îmbunătățite, una din cele mai recente și performante este versiunea a patra YoloV4. Experimental YOLOv4 a obținut o valoare de acuratețe de 43,5 la sută (65,7 la sută AP50) pe setul de date MS COCO și a atins o viteză în timp real de ~ 65 imagini pe secundă pe Tesla V100, depășind cele mai rapide și mai precise detectoare din punct de vedere al vitezei și acuratețe. YOLOv4 este de două ori mai rapid decât EfficientDet, cu performanțe comparabile. În plus, comparativ cu YOLOv3, acuratețea și viteza au crescut cu 10% și respectiv 12% [53]. Totodată sarcina de detectare a liniilor de bandă rămâne una importantă în conducerea autonomă. În special, sarcina de detectare a benzii este cea care este responsabilă să recunoască zona care poate fi condusă prin detectarea marajelor de bandă și elaborarea informațiilor obținute pentru a descrie geometria drumului înaintea vehiculului. Lipsa caracteristicilor distinctive face ca algoritmii de detectare a benzii să confundă liniile cu obiecte cu aspect local similar. În plus, numărul inconsecvent de benzi de pe un drum, precum și modelele diverse ale liniilor de benzi, de ex. liniile solide, întrerupte, simple, duble, de îmbinare și de împărțire împiedică și mai mult performanța. LaneNet este o metodă dezvoltată pentru detectarea liniilor de bandă bazată pe două rețele neuronale profunde. Utilizarea rețelei neuronale profunde conferă metodei o mare robustețe și conductă de detectare în două etape reduce costul de calcul. Viteza mare de rulare și costul de calcul scăzut oferă LaneNet-ului capacitatea de a fi implementat pe vehicule autonome. Experimentele validează faptul că LaneNet oferă în mod constant performanțe remarcabile în scenariile de trafic din lumea reală[51].

BIBLIOGRAFIE

- [1] <https://karpathy.medium.com/software-2-0-a64152b37c35>
- [2] <https://techcrunch.com/2019/04/22/anyone-relying-on-lidar-is-doomed-elon-musk-says/>
- [3] Impaired Driving: Get the Facts. Retrieved from:
https://www.cdc.gov/transportationsafety/impaired_driving/impaired-drv_factsheet.html
- [4] <https://www.tesla.com/support/transitioning-tesla-vision>
- [5] CVPR WAD 2021 https://youtu.be/eOL_rCK59ZI
- [6] Robust Physical-World Attacks on Deep Learning Models, CVPR 2018
<https://arxiv.org/pdf/1707.08945.pdf>
- [7] <https://towardsdatascience.com/self-driving-cars-past-present-and-future-71532430346>
- [8] https://keenlab.tencent.com/en/whitepapers/Experimental_Security_Research_of_Tesla_Autopilot.pdf
- [9] <https://venturebeat.com/2020/02/24/googles-ai-detects-adversarial-attacks-against-image-classifiers/>
- [10] <https://secure-ai.github.io/>
- [11] Geometric Unsupervised Domain Adaptation for Semantic Segmentation, Vitor Guizilini, et al.
<https://arxiv.org/abs/2103.16694>
- [12] Waymo, "Waymo Safety Report," 2018. [Online]. Available:
<https://storage.googleapis.com/sdc-prod/v1/safety-report/Safety%20Report%202018.pdf>
- [13] Korosec K, "Waymo's self-driving Jaguar I-Pace vehicles are now testing on public roads," Techcrunch, 2019. [Online]. Available: <https://techcrunch.com/2019/06/17/waymos-selfdriving-jaguar-i-pace-vehicles-are-now-testing-on-public-roads/>
- [14] U. Ozgunalp and N. Dahnoun, Robust lane detection & tracking based on novel feature extraction and lane categorization, in IEEE Int. Conf. Acoustics, Speech and Signal Processing, 2014, pp. 8129–8133.
- [15] Y. Su, Y. Zhang, T. Lu, J. Yang and H. Kong, Vanishing point constrained lane detection with a stereo camera, IEEE Trans. Intell. Transp. Syst. 19(8) (2017) 2739–2744
- [16] Q. Chen and H. Wang, A real-time lane detection algorithm based on a hyperbola-pair model, in IEEE Intelligent Vehicles Symp. 2006, pp. 510–515
- [17] J. Ruyi, K. Reinhard, V. Tobi and W. Shigang, Lane detection and tracking using a newlane model and distance transform, Mach. Vis. Appl. 22(4) (2011) 721–737
- [18] Dongfang Liu, Yaqin Wang, Tian Chen and Eric T. Matson, Accurate Lane Detection for Self Driving Cars: An Approach Based on Color Filter Adjustment and K-Means Clustering Filter, International Journal of Semantic Computing Vol. 14, No. 1 (2020) 153–168
- [19] P. Purohit and R. Joshi, An efficient approach towards k-means clustering algorithm, Int. J. Comput. Sci. Commun. Netw. 4(3) (2013) 125–129

- [20] A brief introduction to gradient descent. <https://alykhantejani.github.io/a-brief-introduction-to-gradient-descent/>
- [21] LeCun, Y., Bottou, L., Bengio, Y., and Haffner, P. Gradient-based learning applied to document recognition. Proceedings of the IEEE 86, 11 (1998), 2278–2324
- [22] L. Torrey and J. Shavlik, "Transfer Learning," Handbook of Research on Machine Learning Applications, IGI Global, University of Wisconsin, Madison WI, USA, 2009
- [27] <https://hackernoon.com/memorizing-is-not-learning-6-tricks-to-prevent-overfitting-in-machine-learning-820b091dc42>
- [28] 'A friendly introduction to Convolutional Neural Networks and Image Recognition', YouTube, Luis Serrano, <https://www.youtube.com/watch?v=2-OI7ZB0MmU>
- [29] "Supervised Learning: Pooling," Stanford University, [Online]. Available: <http://ufldl.stanford.edu/tutorial/supervised/Pooling/>
- [30] "CS231n: Convolutional Neural Networks for Visual Recognition," Stanford, [Online]. Available: <http://cs231n.stanford.edu/>.
- [31] <https://www.quora.com/What-is-max-pooling-in-convolutional-neural-networks>
- [32] S. Grigorescu, T. Cocias, B. Trasnea, T. Cocias and G. Macesanu, "A Survey of Deep Learning Techniques for Autonomous Driving," arXiv:1910.07738v2, Transilvania University of Brasov. Brasov, Romania , 2020
- [33] K. He, .: X. Zhang, S. Ren and J. Sun, "Spatial Pyramid Pooling in Deep Convolutional Networks for Visual Recognition," arXiv:1406.4729v4 [cs.CV] , Microsoft Research, Beijing, China, 2015
- [34] R. Girshick, J. Donahue, T. Darrell and J. Malik, "Rich feature hierarchies for accurate object detection and semantic segmentation," arXiv:1311.2524v5 [cs.CV] , UC Berkeley, CA, U.S.A., 2014
- [35] J. Redmon and A. Farhadi, "YOLO: Real-Time Object Detection," [Online]. Available: <https://pjreddie.com/darknet/yolo/>
- [36] W. Liu, D. Anguelov, D. Erhan, C. Szegedy, S. Reed, C.-Y. Fu and A. C. Berg, "SSD:Single Shot Multi Box Detector," arXiv:1512.02325v5 [cs.CV], University of Michigan, Ann-Arbor, MI, U.S.A., 2016.
- [37] P. Sermanet, D. Eigen, X. Zhang, M. Mathieu, R. Fergus and Y. LeCun, "OverFeat: Integrated Recognition, Localization and Detection using Convolutional Networks," arXiv:1312.6229 [cs.CV], New York University , New York, U.S.A., 2014
- [38] H. Law and J. Deng, "CornerNet: Detecting Objects as Paired Keypoints," arXiv:1808.01244v2 [cs.CV] , Princeton University, Princeton, NJ, U.S.A., 2019
- [39] F. N. Iandola, SongHan, M. W. Moskewicz, K. Ashraf, W. J. Dally and K. Keutzer, "SqueezeNet: Alexnet-level Accuracy with 50x Fewer Parameters and <0.5MB Model Size," arXiv:1602.07360v4 [cs.CV] , UC Berkeley & Stanford University, U.S.A., 2016

- [40] C. R. Qi, H. Su, K. Mo and L. J. Guibas, "PointNet: Deep Learning on Point Sets for 3D Classification and Segmentation," arXiv:1612.00593v2 [cs.CV] , Stanford University, Pittsburgh, U.S.A., 2017
- [41] K. Shin, Y. P. Kwon and M. Tomizuka, "RoarNet: A Robust 3D Object Detection based on RegiOn Approximation Refinement," arXiv:1811.03818v1 [cs.CV] , UC Berkeley, CA 94720, U.S.A., 2018
- [42] Szegedy, C., Reed, S., Erhan, D., and Anguelov, D. Scalable, high-quality object detection. arXiv preprint arXiv:1412.1441 (2014)
- [43] Redmon, J., Divvala, S., Girshick, R., and Farhadi, A. You only look once: Unified, real-time object detection. in Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (2016), pp. 779–788
- [44] (<https://corporatefinanceinstitute.com/resources/knowledge/other/vehicle-to-everything-v2x/>)
- [45] <https://www.safercar.gov/technology-innovation/automated-vehicles-safety>
- [46] FIERY: Future Instance Prediction in Bird’s-Eye View from Surround Monocular Cameras, Anthony Hu et al. <https://arxiv.org/abs/2104.10490>
- [47] NVIDIA CVPR 2020 paper “Lift, Splat, Shoot: Encoding Images from Arbitrary Camera Rigs by Implicitly Unprojecting to 3D”
- [48] Sadat, A., S. Casas, Mengye Ren, X. Wu, Pranaab Dhawan and R. Urtasun, “Perceive, Predict, and Plan: Safe Motion Planning Through Interpretable Semantic Representations.” ECCV 2020. <https://arxiv.org/abs/2008.05930>
- [50] Self-driving vehicles could struggle to eliminate most crashes. Retrieved from: <https://www.safercar.gov/technology-innovation/automated-vehicles-safety>
- [51] Ze Wang, Weiqiang Ren, Qiang Qiu “LaneNet: Real-Time Lane Detection Networks for Autonomous Driving”, arXiv:1807.01726v1 [cs.CV] 4 Jul 2018
- [52] Davy Naven, Bert De Brabandere, Stamatios Georgoulis “Towards End-to-End Lane Detection: an Instance Segmentation Approach”
- [53] Alexey Bochkovskiy, Chien-Yao Wang, H. Liao, ” YOLOv4: Optimal Speed and Accuracy of Object Detection”