

УНИВЕРЗИТЕТ У БАЊОЈ ЛУЦИ
ФАКУЛТЕТ:



УНИВЕРЗИТЕТ У БАЊОЈ ЛУЦИ
ЕЛЕКТРОТЕХНИЧКИ ФАКУЛТЕТ
БАЊА ЛУКА

Број 80

Датум 29. 11. 2019.

ИЗВЈЕШТАЈ о оцјени урађене докторске дисертације

І ПОДАЦИ О КОМИСИЈИ

Комисију за писање Извјештаја о оцјени урађене докторске дисертације именовано је Сенат Универзитета у Бањој Луци, 31.10.2019. године. Састав комисије је следећи:

1. Никола Теслић, редовни професор, предсједник
Ужа научна област: Рачунарске комуникације
Факултет техничких наука у Новом Саду
2. Зденка Бабић, редовни професор, ментор, члан
Ужа научна област: Општа електротехника
Електротехнички факултет Универзитета у Бањој Луци
3. Марио Муштра, доцент, члан
Ужа научна област: Електроника
Факултет прометних знаности Свеучилишта у Загребу
4. Владимир Рисојевић, ванредни професор, члан
Ужа научна област: Општа електротехника
Електротехнички факултет Универзитета у Бањој Луци
5. Алексеј Аврамовић, доцент, члан
Ужа научна област: Општа електротехника
Електротехнички факултет Универзитета у Бањој Луци

- 1) Навести датум и орган који је именовано комисију;
- 2) Навести састав комисије са назнаком имена и презимена сваког члана, научно-наставног звања, назива уже научне области за коју је изабран у звање и назива универзитета/факултета/института на којем је члан комисије запослен.

ІІ ПОДАЦИ О КАНДИДАТУ

Владимир (Јован) Лекић
Рођен је 3.12.1978. у Ријеци, Хрватска.
Други циклус студија завршио је на Универзитету у Бањој Луци,
Електротехнички факултет, студијски програм Електроника и
телекомуникације, те стекао звање магистар електротехничких наука.
Академско звање магистра стекао је одбраном завршног рада ІІ циклуса студија
3.3.2012. године под називом „Ниво-скуп методе за сегментацију слика у боји“

из уже области Општа електротехника.

- 1) Име, име једног родитеља, презиме;
- 2) Датум рођења, општина, држава;
- 3) Назив универзитета и факултета и назив студијског програма академских студија II циклуса, односно последиједипломских магистарских студија и стечено стручно/научно звање;
- 4) Факултет, назив магистарске тезе, научна област и датум одбране магистарског рада;
- 5) Научна област из које је стечено научно звање магистра наука/академско звање мастера;
- 6) Година уписа на докторске студије и назив студијског програма.

III УВОДНИ ДИО ОЦЈЕНЕ ДОКТОРСКЕ ДИСЕРТАЦИЈЕ

Наслов дисертације је „Обрада сигнала сензора аутономних возила коришћењем вјештачких неуронских мрежа“.

Тему докторске дисертације је прихватио Сенат Универзитета у Бањој Луци 30.11.2017. године.

Садржај докторске дисертације са страничењем:

1. Увод (странице 1-13)
2. Архитектура система аутоматизоване вожње (странице 14-26)
3. Материјал и методологија (странице 27-45)
4. Генеративне супарничке мреже (странице 46-54)
5. Условне генеративне супарничке мреже (странице 55-58)
6. Информационе генеративне супарничке мреже (странице 59-69)
7. Условне генеративне супарничке мреже са више генератора (странице 70-76)
8. Трансформација обиљежја и семантичка фузија сензорских мјерења (странице 77-94)
9. Закључак (странице 95-96)
10. Библиографија (странице 97-104)

Основни подаци о докторској дисертацији:

Обим: 104 страна (укупно 121 страна са свим додатним странама)

Број табела: 6

Број слика, шема, графикана: 38

Број цитиране литературе: 96

- 1) Наслов докторске дисертације;
- 2) Вријеме и орган који је прихватио тему докторске дисертације
- 3) Садржај докторске дисертације са страничењем;
- 4) Истаћи основне податке о докторској дисертацији: обим, број табела, слика, шема, графикана, број цитиране литературе и навести поглавља.

IV УВОД И ПРЕГЛЕД ЛИТЕРАТУРЕ

Истраживања у области аутономних возила не треба схватити као потрагу за неком формом опште вјештачке интелигенције, која би била у стању да самостално, поштујући уобичајене друштвене норме управља моторним возилом, већ као тражење оптималне комбинације технологија које би, под важећим нормама у аутомобилској индустрији, омогућиле моторном возилу самостално испуњавање возних задатака. У системима аутоматске вожње, када је степен аутоматизације такав да систем преузима контролу над свим

аспектима неких возних задатака, а од возача се, у случају потребе, не очекује примјерене реакција, говори се о високо аутоматизованом возилу.

О томе шта једно возило чини аутоматизованим, потребно је усагласити мишљења свих интересних група укључених у развој истих. Управо ради тога, међународна организација Удружење аутомобилских инжењера - SAE (енг. Society of Automotive Engineers) је у међувремену постала опште прихваћена и де-факто стандард приликом описивања аутоматизованих система вожње. Нормом SAE J3016 [5] дефинисано је 6 степени аутоматизације, од 0 (без аутоматизације) до 5 (потпуна аутоматизација).

Данас је фасцинација високо аутоматизованим системима вожње израженија него икада прије. Подстакнути од стране великих ИТ компанија и произвођача аутомобила, веома мали је број универзитета и истраживачких института који се не баве овом тематиком. Међутим, иако значајан фактор, покретачка снага развоја оваквих система није само новац. Успјешна примјена алгоритама машинског учења у разним индустријским областима створила је критичну масу инжењера и научника која се усудила да повјерује у идеју да се примјеном исте или веома сличне технологије може ријешити и проблем постизања потпуно аутоматизоване вожње.

Циљ исраживања проведеног у токе израде ове докорске дисертације је обрада сигнала сензора високо аутоматизованих возила коришћењем вјештачких неуронских мрежа.

Основна хипотеза је да је коришћењем вјештачких неуронских мрежа, на основу улазних сензорских мјерења једног модалитета, на излазу могуће добити вјештачка сензорска мјерења другог модалитета. На тај начин се обиљежја садржана у улазним сигнаlima трансформишу у простор обиљежја излазног сигнала. Обучене неуронске мреже, са представљеним радарским мјерењима на њиховим улазима, у могућности су да генеришу вјештачке слике, независно од камера које евентуално постоје у сензорској конфигурацији високо аутоматизованог возила.

Посматрајући успјехе алгоритама дубоког учења и дубоких неуронских мрежа у готово свим индустријским областима [16-18], стиче се утисак да се њиховом примјеном може ријешити и велики број сложених проблема интерпретације сензорских мјерења (на примјер семантичка сегментација радарских мјерења или одређивање диспаратетних мапа на основу слика моно камере). Међутим, већ након кратке анализе различитих врста сензора у сензорској конфигурацији возила, јасно је да се тек комбиновањем или фузијом сензорских мјерења може остварити висок ниво поуздане перцепције окружења возила. Класична фузија сензорских мјерења добро је позната област пробабилистичке роботике [19]. Проблем класичне фузије сензорских мјерања представља фузија сензорских мјерења различитих модалитета, јер да би се остварила семантичка фузија информација, поред тога што мјерења морају бити просторно, геометријски и временски усаглашена, мјерења се морају довести у заједнички семантички простор.

Анализом карактеристика сензора и метода фузије и интерпретације сензорских мјерења, јасно је да се за надгледање окружења системског возила слике добијене камерама користе као главни носиоци семантичке информације. Због једноставности анотације слика, на располагању стоји велики број јавно доступних анутираних скупова података [33,34] који омогућавају обучавање алгоритама машинског учења високог капацитета, на примјер дубоких неуронских мрежа, дубоких Бајесових мрежа и сличних. У више тестних окружења показано је да такви алгоритми у многим случајевима постижу резултате класификације и регресије који су изнад просјечних људских могућности [35]. Камере су, са друге стране, осјетљиве на отежане радне услове, као што су лоше или прекомјерно освјетљење или неповољне метеоролошке појаве, па је уз њих, за перцепцију возног окружења потребно користити сензоре који се заснивају на другачијем мјерном принципу. Радари се због високе поузданости рада у готово свим метеоролошким условима намећу као логично ријешење. Међутим, мјерења радара, за разлику од слика добијених камером, до сада се нису показала погодна за препознавање и семантичку класификацију објеката.

Коришћена литература:

- [1] Jens Rasmussen. Skills, rules, and knowledge; signals, signs, and symbols, and other distinctions in human performance models. *IEEE transactions on systems, man, and cybernetics*, (3):257-266, 1983.
- [2] Markus Maurer, J Christian Gerdes, Barbara Lenz, and Hermann Winner. *Autonomes Fahren: technische, rechtliche und gesellschaftliche Aspekte*. Springer, 2015.
- [3] Tom M Gasser, Clemens Arzt, Mihir Ayoubi, Arne Bartels, Lutz Bürkle, Jana Eier, Frank Flemisch, Dirk Häcker, Tobias Hesse, Werner Huber, et al. *Rechtsfolgen zunehmender Fahrzeug Automatisierung*. Berichte der Bundesanstalt für Straßenwesen. Unterreihe Fahrzeugtechnik, (83), 2012.
- [4] National Highway Traffic Safety Administration et al. Preliminary statement of policy concerning automated vehicles. washington, dc. Verfügbar unter www.nhtsa.gov/staticfiles/rulemaking/pdf/Automated_Vehicles_Policy.pdf, 2013.
- [5] SAE International. *Automated driving: levels of driving automation are defined in new sae international standard j3016*. 2014.
- [6] Benjamin Lussier, Raja Chatila, Felix Ingrand, Marc-Olivier Killijian, and David Powell. On fault tolerance and robustness in autonomous systems. In *Proceedings of the 3rd IARP-IEEE/RAS-EURON joint workshop on technical challenges for dependable robots in human environments*, pages 351-358, 2004.
- [7] ISO Vim. *International vocabulary of basic and general terms in metrology (vim)*. International Organization, 2004:09-14, 2004.
- [8] Ljubiša Golubović. *Električna mjerenja*. 1996.
- [9] Ramon Pallas-Areny and John G Webster. *Sensors and signal conditioning*. John Wiley & Sons, 2012.
- [10] Bernd Jähne. *Emva 1288 standard for machine vision: Objective specification of*

- vital camera data. *Optik & Photonik*, 5(1):53-54, 2010.
- [11] Katedra za merenja. *Metrologija električnih veličina - predavanja*. Univerzitet u Nišu, Elektronski fakultet, 2014.
- [12] Peter Pinggera, Sebastian Ramos, Stefan Gehrig, Uwe Franke, Carsten Rother, and Rudolf Mester. Lost and found: detecting small road hazards for selfdriving vehicles. In 2016 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS), pages 1099-1106. IEEE, 2016.
- [13] Hirokatsu Kataoka, Yoshimitsu Aoki, Yutaka Satoh, Shoko Oikawa, and Yasuhiro Matsui. Fine-grained walking activity recognition via driving recorder dataset. In 2015 IEEE 18th International Conference on Intelligent Transportation Systems, pages 620-625. IEEE, 2015.
- [14] Faraz M Mirzaei. *Extrinsic and intrinsic sensor calibration*. 2013.
- [15] Merrill Ivan Skolnik. *Introduction to radar systems*. New York, McGraw Hill Book Co., 1980. 590 p., 1980.
- [16] Hongming Chen, Ola Engkvist, Yinhai Wang, Marcus Olivecrona, and Thomas Blaschke. The rise of deep learning in drug discovery. *Drug discovery today*, 23(6):1241-1250, 2018.
- [17] Dan Guest, Kyle Cranmer, and Daniel Whiteson. Deep learning and its application to lhc physics. *Annual Review of Nuclear and Particle Science*, 68:161-181, 2018.
- [18] Maciej A Mazurowski, Mateusz Buda, Ashirbani Saha, and Mustafa R Bashir. Deep learning in radiology: an overview of the concepts and a survey of the state of the art. arXiv preprint arXiv:1802.08717, 2018.
- [19] Sebastian Thrun, Wolfram Burgard, and Dieter Fox. *Probabilistic robotics*. MIT press, 2005.
- [20] Ivan Klajn and Milan Šipka. *Veliki rečnik stranih reči i izraza*. Prometej, 2006.
- [21] Jae Pil Hwang, Seung Eun Cho, Kyung Jin Ryu, Seungkeun Park, and Euntai Kim. Multi-classifier based lidar and camera fusion. In 2007 IEEE Intelligent Transportation Systems Conference, pages 467-472. IEEE, 2007.
- [22] Feihu Zhang, Daniel Clarke, and Alois Knoll. Vehicle detection based on lidar and camera fusion. In 17th International IEEE Conference on Intelligent Transportation Systems (ITSC), pages 1620-1625. IEEE, 2014.
- [23] Zhexiang Yu, Jie Bai, Sihan Chen, Libo Huang, and Xin Bi. Camera-radar data fusion for target detection via kalman filter and bayesian estimation. Technical report, SAE Technical Paper, 2018.
- [24] Xian Wu, Jing Ren, Yujun Wu, and Jianwang Shao. Study on target tracking based on vision and radar sensor fusion. Technical report, SAE Technical Paper, 2018.
- [25] Alireza Asvadi, Luis Garrote, Cristiano Premebida, Paulo Peixoto, and Urbano J Nunes. Multimodal vehicle detection: fusing 3d-lidar and color camera data. *Pattern Recognition Letters*, 115:20-29, 2018.
- [26] Xiao Wang, Linhai Xu, Hongbin Sun, Jingmin Xin, and Nanning Zheng. Onroad vehicle detection and tracking using mmw radar and monovision fusion. *IEEE Transactions on Intelligent Transportation Systems*, 17(7):2075-2084, 2016.

- [27] Zigu Zhong, Stanley Liu, Manu Mathew, and Aish Dubey. Camera radar fusion for increased reliability in adas applications. *Electronic Imaging*, 2018(17):258-1, 2018.
- [28] Luca Caltagirone, Mauro Bellone, Lennart Svensson, and Mattias Wahde. Lidar-camera fusion for road detection using fully convolutional neural networks. *Robotics and Autonomous Systems*, 111:125-131, 2019.
- [29] Liang Xiao, Ruili Wang, Bin Dai, Yuqiang Fang, Daxue Liu, and Tao Wu. Hybrid conditional random field based camera-lidar fusion for road detection. *Information Sciences*, 432:543-558, 2018.
- [30] Jakob Lombacher, Markus Hahn, Jürgen Dickmann, and Christian Wöhler. Potential of radar for static object classification using deep learning methods. In *Microwaves for Intelligent Mobility (ICMIM)*, 2016 IEEE MTT-S International Conference on, pages 1-4. IEEE, 2016.
- [31] Christian Wöhler, Ole Schumann, Markus Hahn, and Jürgen Dickmann. Comparison of random forest and long short-term memory network performances in classification tasks using radar. In *Sensor Data Fusion: Trends, Solutions, Applications (SDF)*, 2017, pages 1-6. IEEE, 2017.
- [32] Vladimir Lekić and Zdenka Babić. Automotive radar and camera fusion using generative adversarial networks. *Computer vision and image understanding*, 2019.
- [33] Marius Cordts, Mohamed Omran, Sebastian Ramos, Timo Rehfeld, Markus Enzweiler, Rodrigo Benenson, Uwe Franke, Stefan Roth, and Bernt Schiele. The cityscapes dataset for semantic urban scene understanding. In *Proceedings of the IEEE conference on computer vision and pattern recognition*, pages 3213-3223, 2016.
- [34] Gerhard Neuhold, Tobias Ollmann, Samuel Rota Buló, and Peter Kotschieder. The mapillary vistas dataset for semantic understanding of street scenes. In *ICCV*, pages 5000-5009, 2017.
- [35] Jia Deng, Wei Dong, Richard Socher, Li-Jia Li, Kai Li, and Li Fei-Fei. Imagenet: A large-scale hierarchical image database. In *Computer Vision and Pattern Recognition, 2009. CVPR 2009. IEEE Conference on*, pages 248-255. Ieee, 2009.
- [36] Vladimir Lekić and Zdenka Babić. Multiphase tensor level-set method for segmentation of natural images. In *Image Processing and Communications Challenges 3*, pages 77-84. Springer, 2011.
- [37] Vladimir Lekić and Zdenka Babić. Neneta: Heterogeneous computing complex valued neural network framework. In *2017 40th International Convention on Information and Communication Technology, Electronics and Microelectronics (MIPRO)*, pages 192-196. IEEE, 2017.
- [38] Vladimir Lekić and Zdenka Babić. Using gans to enable semantic segmentation of ranging sensor data. In *2018 Zooming Innovation in Consumer Technologies Conference (ZINC)*, pages 96-99. IEEE, 2018.
- [39] Alexandru Constantin Serban, Erik Poll, and Joost Visser. A standard driven software architecture for fully autonomous vehicles. 2018.
- [40] Filip Ejduš. *Međunarodna bezbednost: Teorije, sektori i nivoi*. Beograd: Službeni glasnik, 2012.

- [41] G Fine Kinney and AD Wiruth. Practical risk analysis for safety management. Technical report, Naval Weapons Center China Lake Ca, 1976.
- [42] EN IEC. 61508 1-6: Funktionale sicherheit sicherheitsbezogenelektrischer/elektronischer/programmierbarer elektronischer systeme, 2002.
- [43] ISO26262 ISO. 26262: Road vehicles-functional safety. International Standard ISO/FDIS, 26262, 2011.
- [44] Sebastien Christiaens, Juergen Ogrzewalla, and Stefan Pischinger. Functional safety for hybrid and electric vehicles. Technical report, SAE Technical Paper, 2012.
- [45] Markus Müller, Klaus Hörmann, Lars Dittmann, and Jörg Zimmer. Automotive SPICE in der Praxis: Interpretationshilfe für Anwender und Assessoren. dpunkt.verlag, 2012.
- [46] Rick Salay, Rodrigo Queiroz, and Krzysztof Czarnecki. An analysis of iso 26262: Using machine learning safely in automotive software. arXiv preprint arXiv:1709.02435, 2017.
- [47] Jens Henriksson, Markus Borg, and Cristofer Englund. Automotive safety and machine learning: Initial results from a study on how to adapt the iso 26262 safety standard. In 2018 IEEE/ACM 1st International Workshop on Software Engineering for AI in Autonomous Systems (SEFAIAS), pages 47-49. IEEE, 2018.
- [48] Sina Shafaei, Stefan Kugele, Mohd Hafeez Osman, and Alois Knoll. Uncertainty in machine learning: A safety perspective on autonomous driving. In International Conference on Computer Safety, Reliability, and Security, pages 458-464. Springer, 2018.
- [49] Rick Salay, Rodrigo Queiroz, and Krzysztof Czarnecki. An analysis of iso 26262: Machine learning and safety in automotive software. Technical report, SAE Technical Paper, 2018.
- [50] Bryan C Russell, Antonio Torralba, Kevin P Murphy, and William T Freeman. Labelme: a database and web-based tool for image annotation. International journal of computer vision, 77(1-3):157-173, 2008.
- [51] Alberto Elfes. Using occupancy grids for mobile robot perception and navigation. Computer, 22(6):46-57, 1989.
- [52] Florian Himm, Nico Kaempchen, Jeff Ota, and Darius Burschka. Efficient occupancy grid computation on the gpu with lidar and radar for road boundary detection. In Intelligent Vehicles Symposium (IV), 2010 IEEE, pages 1006-1013. IEEE, 2010.
- [53] WXiao, B Vallet, Y Xiao, J Mills, and N Paparoditis. Occupancy modelling for moving object detection from lidar point clouds: A comparative study. ISPRS Annals of Photogrammetry, Remote Sensing & Spatial Information Sciences, 4, 2017.
- [54] Daniel Pagac, Eduardo Mario Nebot, and Hugh Durrant-Whyte. An evidential approach to probabilistic map-building. In Robotics and Automation, 1996. Proceedings., 1996 IEEE International Conference on, volume 1, pages 745-750. IEEE, 1996.
- [55] Huadong Wu, Mel Siegel, Rainer Stiefelhagen, and Jie Yang. Sensor fusion

- using dempster-shafer theory [for context-aware hci]. In Instrumentation and Measurement Technology Conference, 2002. IMTC/2002. Proceedings of the 19th IEEE, volume 1, pages 7-12. IEEE, 2002.
- [56] Chunlei Yu, Veronique Cherfaoui, and Philippe Bonnifait. An evidential sensor model for velodyne scan grids. In Control Automation Robotics & Vision (ICARCV), 2014 13th International Conference on, pages 583-588. IEEE, 2014.
- [57] Mehdi Mirza and Simon Osindero. Conditional generative adversarial nets. CoRR, abs/1411.1784, 2014.
- [58] Vesna Marinković. Računarska grafika uvod.
- [59] Bernd Pfrommer, Nitin Sanket, Kostas Daniilidis, and Jonas Cleveland. PenncoSyvio: A challenging visual inertial odometry benchmark. In 2017 IEEE International Conference on Robotics and Automation, ICRA 2017, Singapore, Singapore, May 29 - June 3, 2017, pages 3847-3854, 2017.
- [60] Davide Scaramuzza. Omnidirectional Vision: From calibration to root motion estimation. PhD thesis, ETH Zurich, 2007.
- [61] Davide Scaramuzza. Ocamcalib: Omnidirectional camera calibration toolbox for matlab. Retrieved from the World Wide Web: [http://robotics.ethz.ch/scaramuzza/Davide Scaramuzza Files/Research/OcamCalib Tutorial. htm](http://robotics.ethz.ch/scaramuzza/Davide%20Scaramuzza%20Files/Research/OcamCalib%20Tutorial.htm), 2013.
- [62] Bolei Zhou, Hang Zhao, Xavier Puig, Sanja Fidler, Adela Barriuso, and Antonio Torralba. Scene parsing through ade20k dataset. In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2017.
- [63] Yann LeCun, Leon Bottou, Yoshua Bengio, Patrick Haffner, et al. Gradientbased learning applied to document recognition. Proceedings of the IEEE, 86(11):2278-2324, 1998.
- [64] Tsung-Yi Lin, Michael Maire, Serge Belongie, James Hays, Pietro Perona, Deva Ramanan, Piotr Dollar, and C Lawrence Zitnick. Microsoft coco: Common objects in context. In European conference on computer vision, pages 740-755. Springer, 2014.
- [65] Tim Salimans, Ian Goodfellow, Wojciech Zaremba, Vicki Cheung, Alec Radford, and Xi Chen. Improved techniques for training gans. In Advances in Neural Information Processing Systems, pages 2234-2242, 2016.
- [66] Martin Heusel, Hubert Ramsauer, Thomas Unterthiner, Bernhard Nessler, and Sepp Hochreiter. Gans trained by a two time-scale update rule converge to a local nash equilibrium. In Advances in Neural Information Processing Systems, pages 6626-6637, 2017.
- [67] Christian Szegedy, Vincent Vanhoucke, Sergey Ioffe, Jon Shlens, and Zbigniew Wojna. Rethinking the inception architecture for computer vision. In Proceedings of the IEEE conference on computer vision and pattern recognition, pages 2818-2826, 2016.
- [68] Raimundo Real and Juan M Vargas. The probabilistic basis of jaccard's index of similarity. Systematic biology, 45(3):380-385, 1996.
- [69] Mladen Nikolić and Anđelka Zečević. Mašinsko učenje. Skripta, Univerzitet u Beogradu, Matematički fakultet, 2019.
- [70] Ian Goodfellow, Jean Pouget-Abadie, Mehdi Mirza, Bing Xu, David Warde-

- Farley, Sherjil Ozair, Aaron Courville, and Yoshua Bengio. Generative adversarial nets. In Advances in neural information processing systems, pages 2672-2680, 2014.
- [71] Ian J. Goodfellow. NIPS 2016 tutorial: Generative adversarial networks. CoRR, abs/1701.00160, 2017.
- [72] Roger B Myerson. Game theory. Harvard university press, 2013.
- [73] Martin Arjovsky, Soumith Chintala, and Leon Bottou. Wasserstein gan. arXiv preprint arXiv:1701.07875, 2017.
- [74] Alec Radford, Luke Metz, and Soumith Chintala. Unsupervised representation learning with deep convolutional generative adversarial networks. CoRR, abs/1511.06434, 2015.
- [75] Sergey Ioffe and Christian Szegedy. Batch normalization: Accelerating deep network training by reducing internal covariate shift. arXiv preprint arXiv:1502.03167, 2015.
- [76] Bing Xu, Naiyan Wang, Tianqi Chen, and Mu Li. Empirical evaluation of rectified activations in convolutional network. arXiv preprint arXiv:1505.00853, 2015.
- [77] Minhyeok Lee and Junhee Seok. Controllable generative adversarial network. IEEE Access, 7:28158-28169, 2019.
- [78] Grigorios G. Chrysos, Jean Kossaiifi, and Stefanos Zafeiriou. Robust conditional generative adversarial networks. In International Conference on Learning Representations (ICLR), 2019.
- [79] Michael Z Bell. Why expert systems fail. Journal of the Operational Research Society, 36(7):613-619, 1985.
- [80] Christopher M Bishop. Pattern recognition and machine learning. springer, 2006.
- [81] Ian Goodfellow, Yoshua Bengio, and Aaron Courville. Deep learning. MIT press, 2016.
- [82] Claude E Shannon and Warren Weaver. The mathematical theory of communication. Urbana, il, 1949.
- [83] Liam Paninski. Estimation of entropy and mutual information. Neural computation, 15(6):1191-1253, 2003.
- [84] Xi Chen, Yan Duan, Rein Houthoofd, John Schulman, Ilya Sutskever, and Pieter Abbeel. Infogan: Interpretable representation learning by information maximizing generative adversarial nets. In Advances in Neural Information Processing Systems, pages 2172-2180, 2016.
- [85] Quan Hoang, Tu Dinh Nguyen, Trung Le, and Dinh Q. Phung. Multi-generator generative adversarial nets. CoRR, abs/1708.02556, 2017.
- [86] Vinod Nair and Geoffrey E Hinton. Rectified linear units improve restricted Boltzmann machines. In Proceedings of the 27th international conference on machine learning (ICML-10), pages 807-814, 2010.
- [87] Andrew L Maas, Awni Y Hannun, and Andrew Y Ng. Rectifier nonlinearities improve neural network acoustic models. In Proc. icml, volume 30, page 3, 2013.
- [88] Christian Szegedy, Wei Liu, Yangqing Jia, Pierre Sermanet, Scott Reed, Dragomir Anguelov, Dumitru Erhan, Vincent Vanhoucke, and Andrew

Rabinovich. Going deeper with convolutions. In Proceedings of the IEEE conference on computer vision and pattern recognition, pages 1-9, 2015.

- [89] Jonathan Long, Evan Shelhamer, and Trevor Darrell. Fully convolutional networks for semantic segmentation. In Proceedings of the IEEE conference on computer vision and pattern recognition, pages 3431-3440, 2015.
- [90] Hengshuang Zhao, Jianping Shi, Xiaojuan Qi, Xiaogang Wang, and Jiaya Jia. Pyramid scene parsing network. In IEEE Conf. on Computer Vision and Pattern Recognition (CVPR), pages 2881-2890, 2017.
- [91] David J Trigg. The chemist as astronaut: searching for biologically useful space in the chemical universe. *Biochemical pharmacology*, 78(3):217-223, 2009.
- [92] Avrim Blum and Ronald L Rivest. Training a 3-node neural network is np-complete. In *Advances in neural information processing systems*, pages 494-501, 1989.
- [93] Vladimir Vapnik. *The nature of statistical learning theory*. Springer science & business media, 2013.
- [94] Ian Osband. Risk versus uncertainty in deep learning: Bayes, bootstrap and the dangers of dropout. In *NIPS Workshop on Bayesian Deep Learning*, 2016.
- [95] Ian Osband, Charles Blundell, Alexander Pritzel, and Benjamin Van Roy. Deep exploration via bootstrapped dqn. In *Advances in neural information processing systems*, pages 4026-4034, 2016.
- [96] Sabine Kubesch and Laura Walk. Körperliches und kognitives Training exekutiver Funktionen in Kindergarten und Schule. *Sportwissenschaft*, 39(4):309, 2009.

Основни допринос ove дисертације је нови, ненадгледани модел машинског учења, такозвана условна генеративна супарничка мрежа са више генератора - CMGGAN (енг. Conditional Multi-Generator Generative Adversarial Network) [32], којим се врши трансформација обиљежја садржаних у сензорским мјерењима једног модалитета у сензорска мјерења другог модалитета. Важна карактеристика CMGGAN модела је да се његово обучавање регуларизује условом максималне заједничке информације улазних и излазних сигнала, осигуравајући тиме да се обиљежја присутна на улазу налазе и на излазу модела. На тај начин превазилазе се описани проблем губитка информација који настају услед фузије сензорских мјерења различитих модалитета и проблем недостатка обиљежја који носе семантичку информацију у трансформисаним обиљежјима.

Коришћењем погодних сензорских мјерења једног модалитета, који се посматрају као латентне промјенљиве, CMGGAN-овима могуће је генерисати вјештачка мјерења другог модалитета. Валидација предложеног метода трансформације обиљежја извршена је на конкретном примјеру фузије радарских мјерења и слика добијених камером. Објективном и субјективном анализом генерисаних слика показано је да се предложени метод трансформације обиљежја може користити за генерисање вјештачких слика, које квалитативно и квантитативно садрже обиљежја садржана у радарским

мјерењима. Поред тога, за семантичку фузију обиљежја садржаних у сликама добијених камером и мјерењима радара није потребно дефинисати вектор обиљежја. Такав начин фузије мјерења, како је показано, води губитку обиљежја садржаних у мјерним подацима. Ово представља велику предност предложене методе трансформације обиљежја у односу на познате методе фузије. Такође, веома важна карактеристика предложених SMGGAN мрежа је да се обучавају потпуно ненадгледано. То значи да је граница квалитета сигнала генерисаних SMGGAN мрежом одређена само капацитетом коришћених неуронских мрежа.

Показано је да генерисане вјештачке слике квалитативно и квантитативно садрже обиљежја окружења детектована радаром, те да их је могуће користити за семантичку сегментацију или регресију коришћењем неких од надгледаних алгоритама машинског учења који су обучени јавно доступним скуповима аотираних слика.

У пракси, генерисање вјештачких слика на основу радарских мјерења отвара разне могућности њихове семантичке фузије са сликама стварне камере. У дисертацији је приказан принцип аутоматске аотације радарских података. Коришћењем неког од обучених алгоритама за семантичку сегментацију или регресију граничних оквира, врши се процјена семантичке класе пиксела или граничних оквира објеката садржаних у генерисаној слици. Ако се претпостави да су камера и коришћени радар исправно калибрисани, у односу на исти координатни почетак (уобичајено је то средина предње осовине возила), могуће је пројектовати семантичке елементе слике у раван решетке доказа. На тај начин добијају се аутоматски аотирани ћелије решетке којима се може обучавати неки од надгледаних алгоритама машинског учења за сегментацију решетке доказа. Након успјешно обученог алгорита за сегментацију радарских података отвара се могућност оптимизације сензорске конфигурације возила (на примјер елиминацијом једне или више камера). Могућност аутоматске аотације радарских решетке доказа коришћењем релативно јефтиних аотација слика такође представља веома велики допринос ове дисертације.

У дисертацији је приказан још један принцип семантичке фузије генерисаних и стварних слика чији је циљ повећање вјеродостојности мјерења стварног сензора. Камере су веома осјетљиве на промјене вањског освјетљења и лоше временске и радне услове. На примјер, нечистоће на површини сочива често узрокују замућене области на добијеним сликама. Радари са друге стране нису осјетљиви на поменуте феномене, па је у циљу постизања одређеног степена функционалне безбједности система, хипотезу о неком обиљежју простора израчунату обрадом слике добијене стварном камером провјерити користећи генерисану слику.

- 1) Укратко истаћи разлог због којих су истраживања предузета и представити проблем, предмет, циљеве и хипотезе;
- 2) На основу прегледа литературе сажето приказати резултате претходних истраживања у вези проблема који је истраживан (водити рачуна да обухвата најновија и најзначајнија сазнања из те области код нас и у свијету);
- 3) Навести допринос тезе у рјешавању изучаваног предмета истраживања;

V МАТЕРИЈАЛ И МЕТОД РАДА

За имплементацију рјешења кориштен је програмски језик Python и програмска библиотека Tensorflow за рад са неуронским мрежама. Статистичка анализа тачности, као и обучавање подешене архитектуре, рађено је кориштењем ових алата.

Основне научне методе истраживања примјенљиване у раду су:

- Прикупљање, анализа и систематизација доступне литературе.
- Извођење закључака о методолошким приступима развоју специјализованих неуронских мрежа на основу постојеће литературе, и истраживања.
- Аквизиција, анализа, трансформација и анотација мјерних података радара и камере.
- Анализа јавно доступних анотираних скупова података за обучавање коришћених неуронских мрежа.
- Адаптација обучене неуронске мреже за детекцију и сегментацију слика.
- Обучавање предложеног ненадгледаног модела машинског учења за трансформацију обиљежја, користећи прикупљене мјерне податке радара и камере.
- Статистичка анализа резултата добијених кориштењем предложеног модела за трансформацију обиљежја и поређење са постојећим рјешењима.

Потврда резултата истраживања извршена је поређењем са постојећим резултатима у литератури као и примјеном развијеног рјешења на бази прикуљених мјерних података радара и камере. Поред ориштене су јавно доступне базе анотираних слика: Imagenet, ADE20K, MNIST и PennCOSYVIO.

Истраживање је изведено на основу предвиђеног плана и остварило резултате упоредиве са најбољим из области, уз широк преглед постојећег стања у области.

Верификација резултата извршена је и објављивањем резултата истраживања у научним часописима и конференцијама:

Vladimir Lekic and Zdenka Babic, "Automotive radar and camera fusion using Generative Adversarial Networks," *Computer Vision and Image Understanding* 184: 1-8, 2019

Vladimir Lekić and Zdenka Babić, "Using GANs to Enable Semantic Segmentation of Ranging Sensor Data," *2018 Zooming Innovation in Consumer Technologies Conference (ZINC)*. IEEE, pp. 96-99, 2018

Vladimir Lekić and Zdenka Babić. "Neneta: Heterogeneous computing complex-valued neural network framework." *2017 40th International Convention on Information and Communication Technology, Electronics and Microelectronics (MIPRO)*. IEEE, pp. 192-196, 2017

материјала;

- 2) Дати кратак увид у примијењени метод истраживања при чему је важно оцијенити сљедеће:
1. Да ли су примијењене методе истраживања адекватне, довољно тачне и савремене, имајући у виду достигнућа на том пољу у свјетским нивоима;
 2. Да ли је дошло до промјене у односу на план истраживања који је дат приликом пријаве докторске тезе, ако јесте зашто;
 3. Да ли испитивани параметри дају довољно елемената или је требало испитивати још неке, за поуздано истраживање;
 4. Да ли је статистичка обрада података адекватна.

VI РЕЗУЛТАТИ И НАУЧНИ ДОПРИНОС ИСТРАЖИВАЊА

Најважнији резултати ове докторске дисертације су:

1. Преглед области и сродних истраживања везаних за тему докторске дисертације;
2. Нови ненадгледаног модел машинског учења, такозвана условна генеративна супарничка мрежа са више генератора – CMGGAN, за трансформацију обиљежја и семантичку фузију сензорских мјерења различитих модалитета;
3. Семантичка фузија обиљежја садржаних у сликама добијених камером и мјерењима радара;
4. Примјене семантичке фузије обиљежја за аутоматску анотацију радарских решетки доказа коришћењем релативно јефтине анотација слика и повећање вјеродостојности мјерења стварног сензора.

Кандидат је јасно приказао добијене резултате, правилно, логично и јасно их је тумачио и поредио са резултатима других аутора, при чему је испољавао довољно критичности.

У овом истраживању показана је ефикасност коришћења вјештачких неуронских мрежа у обради сигнала сензора високо аутоматизованих возила. Примјеном предложених рјешења трансформације обиљежја и семантичке фузије сензорских мјерења различитих модалитета, отворени су многи даљи правци истраживања. Предложена рјешења дата су уз образложење имплементационих детаља и уз анализу перформанси и скалабилности, са циљем повећања употребне вриједности.

- 1) Укратко навести резултате до којих је кандидат дошао;
- 2) Оцијенити да ли су добијени резултати јасно приказани, правилно, логично и јасно тумачени, упоређујући са резултатима других аутора и да ли је кандидат при томе испољавао довољно критичности;
- 3) Посебно је важно истаћи до којих нових знања се дошло у истраживању, који је њихов теоријски и практични допринос, као и који нови истраживачки задаци се на основу њих могу утврдити или назирати.

VII ЗАКЉУЧАК И ПРИЈЕДЛОГ

На основу прегледа докторске дисертације Владимира Лекића, магистра електротехничких наука, закључујемо да је ова докторска дисертација самостални рад кандидата и да садржи све елементе научног приступа и оригиналне резултате у рјешавању проблема обраде сигнала сензора високо аутоматизованих возила примјеном вјештачких неуронских мрежа.

Кандидат је постигао постављене циљеве и доказао хипотезу да је коришћењем вјештачких неуронских мрежа могуће извршити трансформацију обиљежја садржаних у сензорским мјерењима једног модалитета у обиљежја сензорских мјерења другог модалитета. Такав начин трансформације обиљежја сензорских мјерења јединствен је у доступној литератури и отвара потпуно нове правце истраживања у области обраде сигнала сензора коришћењем вјештачких неуронских мрежа.

Комисија предлаже да се докторска дисертација кандидата Владимира Лекића под насловом „Обрада сигнала сензора аутономних возила коришћењем вјештачких неуронских мрежа” прихвати, а кандидату одобри одбрана докторске дисертације.

- 1) Навести најзначајније чињенице што тези даје научну вриједност, ако исте постоје дати позитивну вриједност самој тези;
- 2) На основу укупне оцјене дисертације комисија предлаже:
 - да се докторска дисертација прихвати, а кандидату одобри одбрана,
 - да се докторска дисертација враћа кандидату на дораду (да се допуни или измијени) или
 - да се докторска дисертација одбија.


ПОТПИС ЧЛАНОВА КОМИСИЈЕ

Датум: 29.01.2020.

1.


Проф. др Никола Теслић

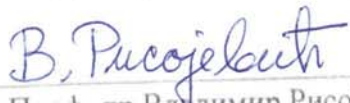
2.


Проф. др Зденка Бабић

3.


Доц. др Марио Муштра

4.


Проф. др Владимир Рисојевић

5.


Доц. др Алексеј Аврамовић