

Institute for optical systems
annual report 2019

Foreword



Hochschule Konstanz University of Applied Sciences (HTWG) has been one of the first Universities of Applied Sciences that has clearly committed itself to applied research. Today, HTWG has positioned itself in the growing group of research active Universities of Applied Sciences, and is continuously striving for even greater excellence, visibility, and leadership.

The research institutes play an essential role in the overall research activities of HTWG. The Institute for Optical Systems (IOS) has been founded as one of three focus institutes in 2008, and has lived up to its mission and HTWG's expectation ever since.

Measuring the success of research is generally a difficult task. It becomes easy, however, for individuals and institutes alike that contribute to the scientific community in many different ways. The IOS clearly is such an institute. Its members have published their work in numerous high quality publications, they have acquired substantial amounts of external funding, and they have successfully led several doctoral candidates to their advanced degree, to name only the most obvious contributions. The institute's success has only been possible because of the enthusiasm of its members, and its tight integration with HTWG. Students have contributed to the research work on various levels, and the results have been fed into the members' teaching. In this sense, the IOS has demonstrated the importance of excellent applied research also as a means for high quality teaching, in particular on the graduate level.

I am proud to write these few lines of thanks and congratulations for the IOS and cordially wish the institute, but first and foremost its members, ongoing enthusiasm, thirst for knowledge, and success for the future.

A handwritten signature in black ink that reads "Oliver Haase". The signature is written in a cursive, flowing style.

Prof. Dr. Oliver Haase
Vice-President for Research, University of Applied Sciences Konstanz

Preface

The present report gives an overview over the research and development activities of the Institute for Optical Systems (IOS) Konstanz in the year 2016. Our main fields of interest are cognitive systems, geometric modelling, image processing, optical metrology and light engineering, thus representing the fundamental disciplines of current optical technology. The focus on optical systems as a whole allows us to offer competent partnership to the local industry in all relevant aspects. The IOS was founded in April 2008 by four professors from three different faculties of the University of Applied Sciences at Konstanz and is led by Prof. Dr. Umlauf (director) and Prof. Dr. Franz (associate director).


The following project descriptions present ongoing activities mainly on a status report level. Most of the reports are written by students working on their diploma, bachelor, master or Ph.D. theses. They reflect the largely varying levels of content, practice and insight that are characteristic for an institution involved in academic education. Due to its interdisciplinary nature, research at the IOS combines approaches from optics, computer graphics, image and signal processing, metrology, light engineering and sensor technology typically resulting in optical systems on a prototype level, either in pre-phase research or in cooperation with local industry.

On the occasion of our annual report, we would like to thank all of our students and co-workers for their enthusiasm and dedication which makes our institute a great place to be. Special thanks go to our institute officers, Pascal Laube, Martin Schall and Michael Grunwald for smoothly managing our day-to-day activities. We are also indebted to the administration and staff of the HTWG Konstanz for their help, especially president Dr. Carsten Manz and Prof. Dr. Oliver Haase, for their support and for continuing the start-up funding, and the faculties of Mechanical Engineering, Electrical and Information Engineering, and Computer Science with the deans Prof. Dr.-Ing. Klaus Schreiner, Prof. Dr. Thomas Birkhölzer and Prof. Dr. Jürgen Neuschwander for their assistance. Furthermore we appreciate the support of the Institute for Applied Research (IAF) Konstanz, especially Prof. Dr. -Ing Horst Werkle and Dipl.-Ing. FH Andreas Burger.

Contents

Institute Profile	6
IOS Building and Location Plan	7
Institute Members	8
IOS Staff	10
External Fundings and Grants	11
Cooperations with Research Institutions and Industry	11
Theses and Student Projects	13
Publications	14
Research Activities	15
DeepRain	17
Scene Reconstruction with HD-Streams	19
Geodesic Distances based on Heat Method and Fast Marching Method	21
Entwicklung einer Visualisierungspipeline für 3D-Daten	25
Modellierung von digitalem Druck mit Hilfe von neuronalen Netzen	27
Anomaliedetektion an digital gedruckten Dekoren mit Hilfe von künstlichen neuronalen Netzen	30
Feasibility of reinforcement learning for point cloud preprocessing	32
Analysis of point cloud convolutions for edge detection on point clouds	34
Konfidenzintervalle bei der Erkennung unbekannter Fehlerarten mittels Referenzmodellierung	36
Experiment zum Vergleich von Convolutional Neural Networks mit Graph Neural Networks	38

Institute Profile

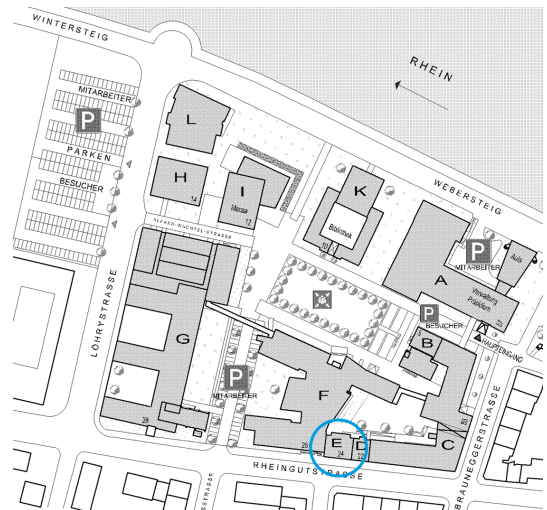


IOS BUILDING AND LOCATION PLAN



Institute for Optical Systems

Brauneggerstrasse 55
Building E
3rd and 4th floor
78462 Konstanz



Location Plan

INSTITUTE MEMBERS

Prof. Dr. Georg Umlauf:



Diploma in computer science from University of Karlsruhe, 1996. Doctoral degree in computer science from University of Karlsruhe, 1999. PostDoc at University of Karlsruhe and University of Florida, Gainesville, USA, 1999-2000. Software development and senior researcher at Tebis AG, Hamburg, 2000-2002. Assistant professor for geometric algorithms at University of Kaiserslautern, 2002-2009. Interim professor for computer graphics at University of Karlsruhe, 2009. Since 2009 professor for computer graphics at University of Applied Sciences Konstanz and head of the computer graphics lab. Since 2010 member of the 'Institute for Optical Systems (IOS)' and 'Institute for Applied Research (IAF)'. Main research interests: Computer graphics, geometric modeling (splines, subdivision), reverse engineering, physical simulations.

Prof. Dr. Matthias Franz:



M.Sc. in Atmospheric Sciences from SUNY at Stony Brook, Diploma in physics from the Eberhard-Karls-Universität, Tübingen and doctoral degree in 1998. Thesis research in visual insect and robot navigation at the MPI for Biological Cybernetics and as a PostDoc at the Australian National University in Canberra. In industry he worked on various aspects of autonomous vision systems. 2002, he returned to the MPI as a group leader in the area of machine learning and computer vision. Since 2007 professor at the University of Applied Sciences in Konstanz and head of cognitive systems lab. Member of 'Institut für Angewandte Forschung (IAF)'. Main research activities in the development of automatically generated vision systems, optimisation and probabilistic modeling, with applications in industrial machine vision, texture analysis and steganalysis.

Prof. Dr. Rebekka Axthelm:



Diploma in mathematics from University of Freiburg, 1998. Doctoral degree in applied mathematics from University of Freiburg, 2007. Software Engineer Video at Micronas GmbH in Freiburg, 2005-2008. Lecturer for mathematics and numerics at Zurich University of Applied Sciences (ZHAW) in Winterthur (Switzerland), 2009-20017. Since 2017 professor for mathematics at University of Applied Sciences Konstanz (HTWG). Since 2018 member of the 'Institute for Optical Systems (IOS)' and 'Institute for Science and Mathematics (INM)'. Main research interests is in numerical mathematics that is in particular: Finite element methods to solve partial differential equations which describe different physical processes. My strong interest is currently focused on the calculation of pedestrian flow, based on a macroscopic modeling and mathematical methods of image processing.

Prof. Dr. Oliver Dürr:



Diploma in physics and doctoral degree at University Konstanz 2003 in the fields of theoretical and computational physics. From 2003 - 2012 senior algorithm developer/scientific consultant at Genedata AG (Basel). From 2012 assistant professor in statistical data analytics at Zurich University of Applied Sciences (ZHAW) in Winterthur (Switzerland). Since 2018 professor for data science at University of Applied Sciences Konstanz (HTWG). Since 2018 member of the 'Institute for Optical Systems (IOS)'. Main research interests in statistical/machine/deep learning, currently focusing on probabilistic aspects.

Prof. Dr. Claus Braxmaier:



Diploma in precision engineering at University of Applied Sciences Furtwangen. Diploma in physics and doctoral degree at the University of Konstanz in the field of fundamental tests of physics. Post-Doc at University of Konstanz. At EADS Astrium GmbH, system responsible for scientific and Earth observation missions for ESA and head of group 'Mission Metrology'. 2005-2013 professor for physics and control theory at the University of Applied Sciences Konstanz. Since 2013 ZARM Deputy Executive Director, Director Space Technology, and department lead "System Enabling Technologies" at the DLR-Institute of Space Systems, Bremen. Main research: high resolution optical metrology for industrial and space applications, tests of fundamental physics.

Prof. Dr. Bernd Jödicke:



Study of physics at the University of Karlsruhe. Doctoral degree at Technical University Hamburg and University Karlsruhe in the field of high frequency technology. After that, industrial work at ABB Baden, Switzerland, as executive director for R&D. Since 1992 professor for applied physics at University of Applied Sciences Konstanz. Member of 'Institute for Applied Research (IAF)', 'Institut für Naturwissenschaften und Mathematik (INM)', 'Institute for Optical Systems (IOS) Konstanz' and 'Deutsche Lichttechnische Gesellschaft'. Head of laboratory for light engineering at HTWG. Main research activities in color and light measurements and color camera systems.

Prof. Dr. Burkhard Lehner:



Diploma in computer science from University of Kaiserslautern, 2004. Doctoral degree in computer science from University of Kaiserslautern, 2008. Software development at Sirona Dental System GmbH, Bensheim, 2008-2013. Since 2013 professor for computer science at University of Applied Sciences Konstanz. Since 2014 member of the 'Institute for Optical Systems (IOS)'. Main interests: software development, computational geometry, optical 3D measurement (especially in dental CAD/CAM).

Prof. Dr. Klaus-Dieter Durst:



Study of physics at the University of Stuttgart, 1986 doctoral degree in the field of magnetism at the Max-Planck-Institute of metal research. Thereafter research center Weissach of the Dr. Ing. h.c. F. Porsche AG, responsible for the central unit 'measurement technologies'. Since 1993 professor for measurement engineering and sensor technology at the University of Applied Sciences Konstanz. Member of 'Institut für Naturwissenschaften und Mathematik' and 'Institute for Optical Systems' Konstanz. Head of laboratories for measurement and sensor technology and production metrology. Currently director of 'Institut für Naturwissenschaften und Mathematik' Konstanz. Activities in the accreditation and surveillance of testing laboratories and inspection bodies.

Prof. Dr. Christian Hettich:



Diploma in physics and doctoral degree (2002) at the University of Konstanz in the fields of quantum-optics and nano-optics. Post-doc at the Eidgenössische Technische Hochschule (ETH) Zürich and at the Niels Bohr Institut in Copenhagen. Systems engineer for illuminators of semiconductor lithography systems at Carl Zeiss SMT GmbH in Oberkochen. Systems engineer for time-of-flight cameras at ifm automotive GmbH in Kressbronn. Project leader for automated microscopes at Sensovation AG in Radolfzell. Since 2014 professor for physics, feedback control systems and metrology at the department of mechanical engineering of the University of Applied Sciences Konstanz. Member of the 'Institut für Naturwissenschaften und Mathematik' (INM) and the 'Institute for Optical Systems' (IOS). Main research interests: optical 3D measurements, spectroscopy, interferometry, holography, microscopy.

IOS STAFF

Professors

Georg Umlauf, director IOS
Matthias Franz, associate director IOS
Bernd Jödicke
Burkhard Lehner
Klaus-Dieter Durst
Christian Hettich

Officer

Pascal Laube

Academic Staff

Matthias Hermann
Pascal Laube
Dennis Grießer
Fabian Freiberg
Tobias Birkle
Felix Schmidt
Martin Schall
Joey Rieg
Patrick Fiur

Postdoc

Thilo Schuldt

PhD Students

Matthias Hermann
Pascal Laube
Dennis Grießer
Fabian Freiberg
Tobias Birkle

EXTERNAL FUNDINGS AND GRANTS

- Baumer Inspection GmbH, Konstanz: "Farbtexturen in der industriellen Oberflächeninspektion", contract research.
- Baumer Inspection GmbH, Konstanz: "Inline - Inspektionstechnologie zum Farbabgleich für den digitalen Dekordruck", contract research.
- Australian Research Council, Pattern recognition in animals and machines: using machine learning to reveal cues central to the identification of individuals, Discovery Projects Grant.
- BMBF-Grant "Forschung für die Produktion von morgen" 2015, Entwicklung einer innovativen Anlagentechnik zur automatisierten und laserbasierten Reparatur strukturierter Formeinsätze - ToolRep.

COOPERATIONS WITH RESEARCH INSTITUTIONS AND INDUSTRY

Academic and Institutional Cooperations

- University of Queensland, Brisbane
- Humboldt-Universität zu Berlin
- ZARM (drop tower), Center of Applied Space Technology and Microgravity, Bremen
- DLR Institut für Raumfahrtssysteme Bremen
- University of Tübingen
- Max-Planck-Institute for Biological Cybernetics, Tübingen
- German Federal Office for Information Security (BSI), Bonn
- Universität Konstanz
- University of California, Davis
- Technische Universität Kaiserslautern
- University of Florida, Gainesville
- Grenoble Institute of Technology
- University of Strasbourg
- Zurich University of Applied Sciences (ZHAW), Winterthur

Industry Cooperations

- Siemens Postal, Parcel & Airport Logistics GmbH, Konstanz
- Sirona GmbH, Bensheim
- EADS Astrium, Immenstaad
- Breuckmann GmbH, Meersburg
- Chromasens GmbH, Konstanz
- Baumer Inspection GmbH, Konstanz
- Procon-System GmbH, Thierstein
- Lightdesign-Solutions GmbH, Dresden
- Knotenpunkt, Wenzel Präzision GmbH, Balingen
- Tebis AG
- Liebherr Aerospace GmbH, Lindenberg
- NTT Data Deutschland GmbH
- Lacuna Solutions GmbH
- ACSYS Lasertechnik GmbH
- ASE AG, Zürich
- PerEx GmbH, Stuttgart

PhD Theses

- Pascal Laube, Machine Learning Methods for Reverse Engineering of Defective Structured Surfaces, 2019.

Master Theses

- Joey Rieg, Analysis of point cloud convolutions for edge detection on point clouds, 2019.
- Jonas Fleischer, Feasibility of reinforcement learning for point cloud preprocessing, 2019.

Bachelor Theses

- Nico Lutz, Untersuchung von Algorithmen zur Verzeichniskorrektur an einer Mikrobolometer-Kamera, 2019.
- Simon Christofzik, Modellierung von digitalem Druck mit Hilfe von neuronalen Netzen, 2019.
- Semih Demir, Anomaliedetektion an digital gedruckten Dekoren mit Hilfe von künstlichen neuronalen Netzen, 2019.

Student Projects

- Henning Krause, Kevin Deggelmann, Hendrik Aufderstroth, Benjamin Bäuml, Patrick Fiur, Scene Reconstruction with HD-Streams, 2019.
- Daniel Kuhn, Geodesic Distances based on Heat Method and Fast Marching Method, 2019.
- Florian Djokaj, Tom Georgi und Anton Hummel, Entwicklung einer Visualisierungspipeline für 3D-Daten, 2019.
- Thomas Gnädig, Etienne Gramlich, Merle Wolff, Tim Hardenacke, DeepRain, 2019.

Small Research Projects

- Prof. Dr. Georg Umlauf, Dennis Grießer, Experiment zum Vergleich von Convolutional Neural Networks mit Graph Neural Networks.
- Prof. Dr. Matthias O. Franz, Matthias Hermann, Tobias Birkle, Konfidenzintervalle bei der Erkennung unbekannter Fehlerarten mittels Referenzmodellierung

PUBLICATIONS

Journal Papers

- Rohrbach, J., T. Rainhard, B. Sick, and O. Dürr, Bone erosion scoring for rheumatoid arthritis with deep convolutional neural networks, , 2019.

Conference Proceedings

- Schall, M., M-P. Schambach, and M. O. Franz, "Dissecting Multi-Line Handwriting for Multi-Dimensional Connectionist Classification", 15th IAPR International Conference on Document Analysis and Recognition: IEEE, 2019.

Chapter Book

- Stadelmann, T., V. Tolkachev, B. Sick, and O. Dürr, "Beyond ImageNet: Deep Learning in Industrial Practice", Applied Data Science: Springer, pp. 205-232, 2019.



Laboratories and Infrastructure

The Institute for Optical Systems laboratories and infrastructure is composed of scientific equipment from the fields of Image Sensing, 2D and 3D Surface Analysis and Reconstruction as well as a powerful computing cluster for machine learning and high performance computing. Our laboratories and infrastructure is located in buildings *E*, *G* and *O* on the university campus.

The laboratory in building *G* includes equipment with focus on illumination engineering and high precision stereoscopic surface scanning. The laboratory in building *E* comprises of camera calibration and spectrometric color measurement equipment, multispectral cameras as well as devices for 3D laserscanning, 3D visualization and 3D printing.

The computing cluster located in building *O* consists of GPU as well as CPU-Servers for high performance computing.

Most of the institutes workspaces are located on floors three and four of building *E*.



Research Activities

DeepRain

Thomas Gnädig, Etienne Gramlich, Merle Wolff, Tim Hardenacke

In this Paper we try to predict precipitation for a range of 35 minutes in an area around Constance. Therefore we are using machine learning techniques and train a UNet on radar data images. Here we present the result of precipitation prediction as well with regression as with classification. Both approaches provide good results. Source code and full length documentation in german can be found at GitHub: <https://github.com/thgnaedi/DeepRain>.

Data

We are using radar data from the Climate Data Center of the DWD¹. There are radar images from the years 2004 until 2017. This data has to be downloaded and converted to png, this is done by our crawler² and converter³. The rainfall images then are tailored and scaled. Unattractive images are then rejected, and only interesting images are used for the training. The resulting images are grayscale PNG files. As network input five temporally consecutive of them are combined to a 3D tensor. The label consists of seven of them.

Architecture

To predict precipitation either with regression or classification we are using a UNet. This Architecture is a convolutional neural network that was at first developed for biomedical image segmentation. A UNet is a set of convolution layers, combined with a downsampling part, such as pooling layers, and later with upsampling parts like deconvolution layers.




Figure 1: The image is taken from the university of Freiburg [1]

The input images have a shape of 64x64 pixels. They are pooled until the shape reaches a minimum of 8x8 features. Then they are upsampled and concatenated with the downsampling part. This yields into an u-shaped architecture with crosslinks and is the reason for its name.

Regression

First approach is to predict the complete radar image. For this regression we use the MSE as loss-function. The input layer takes the five incoming timesteps and transfers it into a 7 timestep prediction wich reaches up to 35 minutes into the future. Our network is trained on the radar data from 2005 till 2017. As validation set we use the images from 2004. further information can be found in our full project description⁴. The result of this task is shown in the following graphics.





Figure 2: The input is a 64x64x5 tensor containing the last 25 minutes



¹https://www.dwd.de/DE/klimaumwelt/cdc/cdc_node.html

²https://github.com/thgnaedi/DeepRain/tree/master/DWD_Crawler

³<https://github.com/thgnaedi/DeepRain/blob/master/Data/DWDtoPngScript.py>

⁴<https://github.com/thgnaedi/DeepRain/blob/master/Docs/Langdokumentation.pdf>

Figure 3: The labels are seven timesteps to predict, from 5 minutes till 35 minutes into the future. The result is shown here. In the upper row we can see the seven timesteps in the Labels. White means a lot rainfall while black is no rainfall. The second row contains the labels for this input. In the last row are the predictions of our model.

The predicted values are very close to the label for a difference of only 5 minutes to the input data. The further the time progresses, the worse the prediction becomes. In the last image it looks like the resolution of the output has been drastically decreased compared to the first output. In fact the resolution is the same we can say that this is an indication of uncertainty in the network. Over time, the movement of the rainfall is well predicted. Even the tiny spot in the top left of images can be predicted. Even if the area of rainfall increases much faster than in the labels, the center is still well predicted and close to the center of the label.

Classification

The second approach is to predict the precipitation by classification. Here we try to classify into either three classes (no rain, rain, heavy rain) or two classes (no rain, rain) for each pixel. Therefore the Unets output is modified to three classes per pixel and an additional softmax layer at the output to provide probabilities. The labels are generated by a threshold for each class.




Figure 4: Classification output. In the left image the prediction of the first class (no rainfall) is plotted. The white spots are 100% no rainfall. The black spots are 0% no rainfall.

The gray spots can be rainfall or not depending on the probability of the other two classes. The right image (difference) shows us the absolute difference between the prediction and the label. Here we can see that the big black spots (no difference between prediction and label) are at the no rainfall labels. The network has a high accuracy by predicting rainfree pixels. This can be shown in the following ROC-image. By evaluating the confusion

matrix for three class classification, you can recognize that the last class (heavy rainfall) is highly undersampled. There are much more rainfall pixels and even more no rainfall pixels in the dataset. To increase the the performance we tried over and undersampling, but both techniques didnt work well for our scenario. Finally we changed the problem to a two clas classification with a threshold of 0, so the classes are 'no rainfall' and 'rainfall'.

The ROC-curve in figure 5 shows how well the two classes rain and no rain can be separated and predicted independent of the number of elements per class.




Figure 5: The ROC shows the performance by classification. The calculated AUC is close to 97%, wich means, that the model has a good class separation.

Conclusion and Future Work

In summary, this paper argued that short term precipitation prediction can be done by only observing radar data and without any other source of information. The accuracy could still be improved as well at the regression, were another lossfunction may could help, as at the classification were the 'rainfall' class is still undersampled and worse accurate than the 'no rain' class.

Bibliography

- [1] ,Ronneberger, Olaf and Fischer, Philipp and Brox, Thomas: U-net: Convolutional networks for biomedical image segmentation, International Conference on Medical image computing and computer-assisted intervention,2015.

Scene Reconstruction with HD-Streams

Henning Krause ,Kevin Deggelmann, Hendrik Aufderstroth, Benjamin Bäuml, Patrick Fiur

Unser Projekt befasst sich mit der automatisierten Rekonstruktion existierender Hausfassaden. Ziel war es, ein 3D-Modell zu erzeugen, das genau genug ist, um darin Vermessungen durchzuführen, wie sie von einem Architekturbüro oder einem Fassadenbauer benötigt werden, z.B. die Fläche der Fassade ohne Fenster oder der Abstand der Fenster untereinander. Im Laufe des Projekts trafen wir auf einige Hindernisse, von denen sich nicht alle im Rahmen des Projekts lösen ließen. Wir präsentieren den Prototyp einer Software, die aus monokularen Videodaten ein darin abgebildetes Objekt dreidimensional als Punktwolke rekonstruiert. Als Sensor setzen wir ausschließlich die Kamera eines handelsüblichen ferngesteuerten Quadropters ein.




Figure 6: Der Arbeitsablauf, den unsere Software durchläuft, nachdem sie für eine spezifische Kamera kalibriert wurde. Der Ablauf lässt sich in drei konkrete Phasen unterteilen, wie abgebildet. Als Input wird lediglich ein Video des zu rekonstruierenden Objekts benötigt. Am Ende gibt die Software eine dichte Punktwolke aus, die das Objekt repräsentiert.


Unser Prototyp normalisiert zunächst die Bilder innerhalb eines Windows⁵ mithilfe einer zuvor berechneten Kameramatrix und intrinsischen Kameraparametern. Anschließend werden Features gesucht die über alle Bilder eines Windows getrackt werden können, diese dienen als Grundlage zur Berechnung der Projektionsmatrizen, welche uns die relative Kamerapositionen in den einzelnen Bildern des Windows gibt. Diese allein ist aber durch numerische Fehler-

fortpflanzungen und auch durch teilweise falsche Feature Matches ungenau und wird deshalb noch einmal mithilfe des Bundle Adjustments optimiert. Im letzten Schritt werden dann die Feature Matches mithilfe der optimierten Projektionsmatrizen trianguliert um eine Punktwolke zu generieren. Diese kann dann mithilfe von CloudCompare oder evtl. auch dem IOS-Viewer betrachtet werden.


⁵Gruppen von hintereinander aufgenommenen Bildern, welche von uns als "Windows" bezeichnet werden.




Figure 7: Keypoints welche trianguliert werden um eine Punktwolke zu erzeugen.



(a) Ansicht von rechts



(b) Ansicht von rechts



(c) Ansicht von open

Figure 8: Drei verschiedene Ansichten der generierten Punktwolke..

Der nächste Schritt wäre es die Punktwolken aus unterschiedlichen Windows zueinander zu registrieren umso eine dichte Punktwolke aus einem ganzen Video zugenerieren und nicht nur einen kleinen Teil des Videos.

Geodesic Distances based on Heat Method and Fast Marching Method

Daniel Kuhn, Matthias Hermann, and Georg Umlauf

This work presents the comparison of the relatively new *Heat Method* and the well-known and frequently applied *Fast Marching Method*. Both methods can be used for many computational problems such as geodesic calculations and path extractions. Furthermore, this article proves the results of the research work carried out by *Keenan Crane, Clarisse Weischedel, and Max Wardetzky* for the *Heat Method* [2]. While being an order of magnitude faster than the *Fast Marching Method*, the *Heat Method* achieves almost the same error rate.

Introduction

Geodesic distance computation is an old and already solved problem. But researches are still being conducted as well as new techniques are introduced to provide e.g. faster or more robust solutions. An example of this approach is the *Heat Method (HM)* which offers faster calculation than the state of the art *Fast Marching Method (FMM)*. The *FMM* is a well-known and frequently applied technique for many computational problems such as geodesic calculations and path calculations. But for some applications this method is not fast enough, and further research has been done in recent years. One of these works is presented as *HM* by *Keenan Crane, Clarisse Weischedel, and Max Wardetzky* [1]. This method is simpler and faster than the *FMM* and achieves almost the same error rate. This work describes the fundamentals of the relatively new *HM* and compares it with the *FMM*. Furthermore, it proves the results of the research work carried out in [2]. The *FMM* is taken as a reference and implemented from an already existing project [3].

The term geodesic describes the shortest path between two points along a curved space. This term derives from geodesy, the science of measuring the size and the shape of the Earth. The term has been generalized to include measurements for different mathematical applications, e.g. in graph theory, where it is used to find the geodesic between the two nodes of a graph. Figure 9 shows the Stanford Bunny [1], where the geodesic path (red) and the Euclidean path (black) between two points on a surface are exemplarily represented.

Methods Presentation

In this work in total four methods are presented. The *HM* and the *FMM*, which provide distance values for any given vertex on a domain as seen in Figure 10 (*domain*, e.g. grid, triangle mesh, point cloud). The *HM* is a linear Partial Differential Equation (PDE) problem where the *FMM* is a non-linear PDE problem.

Geodesic Distance




Figure 9: Path, Geodesic and Euclidean [1]




Figure 10: Distance values of each vertex on a domain

Also two different methods for the extraction of geodesic paths based on the *HM* and the *FMM* results are presented. In this work there are named *Path Edge Method* and *Path Exact Method*. The

Path Edge Method uses only given points on a domain to extract the path, for an example see Figure 11. The *Path Exact Method* introduces new points on a domain to achieve an more accurate result of the geodesic, as seen in Figure 12. Because the *HM* is the main focus of this work it is described in more detail in the following two sections.




Figure 11: Path Edge Method




Figure 12: Path Exact Method

Heat Method

The *HM* allows the computation of the shortest geodesic distance from any point on a given domain to a specified subset (e.g. point or curve). It was first published in *ACM Transactions on Graphics*, 32, 2013 under *Geodesic in Heat: A New Approach to Computing Distance Based on Heat Flow* [2]. Compared to other established methods, like the *FMM*, the *HM* is a relatively new approach to the practical computation of distance. *HM* comes with two major advantages: The first is the lower computational costs with comparable accuracy. The second is the possibility to calculate the distance on a variety of geometric domains such as grids, triangle meshes, point clouds and tetrahedral meshes [2]. As the name of the method indicates, the *HM* was inspired by *Varadhan's formula*, a well-known relationship between heat and distance. It is a classic result in differential geometry, which measures the length along the shortest and straightest curves through the domain instead of straight lines through space [2]. The *HM* uses this approach, in a discrete form, in step I of the algorithm. Here the heat is allowed to diffuse for a short time. In step II, the

temperature gradient is normalized and negated to obtain a unit vector field X pointing along the geodesic. Step III, recovers the final distance function ϕ whose gradient follows X with the help of the *Poisson* equation [4].

The *Heat Method* Algorithm [4]:

- I. Integrate the heat flow $\dot{u} = \Delta u$ for some fixed time t .
- II. Evaluate the vector field $X = -\frac{\nabla u_t}{|\nabla u_t|}$.
- III. Solve the Poisson equation $\Delta \phi = \nabla \cdot X$

Time step, Heat Method

The time step parameter t can be manipulated either to obtain an accurate result of the geodesic distance or to smooth the result for further applications.

Optimal time step

In step I of the *Heat Method* Algorithm the heat flow must be integrated for some fixed time t . This parameter is domain specific and influences the accuracy of the result. The optimal value for t can be determined by analyzing the domain. However, the inclusion of the cut locus (points at which there is no unique shortest path to the source) makes this analysis complex [5]. Instead, numerical experiments show that the simple approach $t = h^2$, provides nearly optimal accuracy for a wide variety of problems [4]. Where h is the average distance between the adjacent vertices. Therefore, if not explicitly stated, this work also uses the simple approach to determine the time step t .

Smoothed distance

An exact solution of the geodesic distance leads to sharp edges in the cut locus regions. The time parameter t can be used to obtain a smoothed distance result by providing large values for t . This property can be used for a smoothed path planning, applications where derivatives of the distance function are desired, or for visual purposes.




Figure 13: Increasing time step values (left to right) smooths the geodesic distance and leads to a differentiable result.

Figure 13 shows the *Stanford Bunny* with a source at the front (source: start point for geodesic distance measurements, distance value is zero) and results for increasing values of t . This causes the sharp edges to disappear at the cut locus regions but has the disadvantage of an increasing error in the geodesic distance values. Figure 14 (left) shows a path planning scenario in which the suggested value for t is chosen (left). This extracted path contains sharp edges but is near the exact distance value. Figure 14 (right) shows the same scenario, but a much larger value for t is chosen. This leads to a smooth path, but also increases the overall length (and error of geodesic distance values) of the path.




Figure 14: Path planning with suggested t (left) and a much larger t (right)

Method Comparison

In this section the two methods, the *HM* and the *FMM* are compared. As criteria the accuracy and the execution time are chosen.

Accuracy

Both methods (*HM* and *FMM*) provide an error. Therefore a simple cube is chosen as the domain (Figure 11, left). This is because the exact geodesic can be calculated manually and the absolute error can be obtained. In comparison, this example showed an error of +1% for *FMM* and an error of -2% for *HM*. In this example, this means that the *HM* has an error twice as large as the *FMM* if the suggested value for t is selected. Since the *HM* error, in most cases, is relatively small, the *HM* will still be suitable for most applications where *FMM* is already in use.

Execution time

One of the advantages of *HM* is the possibility to separate the calculation in two parts, the pre-calculation of the domain and the solver for the distance values [4]. For each further distance calculation on the same domain, only the solver has to be executed to obtain new distance values. The *FMM* cannot reuse already calculated results for

further calculations on the same domain. For applications where the domain does not change often, the *HM* provides an execution time which is an order of magnitude faster [4]. A direct comparison of the execution time in this work was not possible since the *HM* is implemented in *Python* and the *FMM* in *C++* [3]. For a better comparison of the execution time, please refer to Table 1 in [4].

Conclusion

In this project the *HM* and the *FMM* could be implemented in one application and the results were compared with each other. It was possible to achieve a comparable accuracy of the distance computation from *HM* compared to *FMM*. Furthermore, the same behavior for the time step parameter t could be explored. This property can serve in applications where smoothness or appearance is required. Both the *HM* and the *FMM* have considerably further properties that can be compared. Due to the limited time, only a few relevant properties were selected and compared in a visualizer.

Next Steps

In this project the *HM* could be examined and implemented in a visualizer. But many properties of the *HM* could not be investigated, e.g. calculations on different geometric domains, such as point clouds or polygonal faces. Neither the effect of different boundary conditions (*Neumann*, *Dirichlet*) on path planning and the extraction of the medial axis for 2D and 3D domains (e.g. tetrahedral volume mesh). In future examinations the shortest geodesic path not on a surface of a domain, but through a volumetric domain, could be calculated. This could be used e.g. for path planning for robots or for simple digital wiring of electrical cables in CAD systems. As the suggestions for further work shows, the application cases for the *HM* are just as extensive as for already known methods, e.g. *FMM*. But some use cases for the *HM* can still be researched and established.

Bibliography

- [1] The Stanford 3D Scanning Repository: The "Stanford Bunny", [IOS Annual Report 2019](http://graphics.stanford.edu/data/3Dscanrep, 2019-03-01, 1994,
[2] , Crane, Keenan and Weischedel, Clarisse

</div>
<div data-bbox=)

and Wardetzky, M A X, Geodesics in Heat, ACM Transactions on Graphics, 2013.

- [3] Gabriel Peyre, Toolbox Fast Marching - version 1.2.0.0 - File Exchange - MATLAB Central, <https://www.mathworks.com/matlabcentral/fileexchange/61101-strook>, 2019-03-02

- [4] , Crane, Keenan and Weischedel, Clarisse and Wardetzky, Max, The heat method for distance computation, 2017,issn:00010782.

- [5] Nave, P. and Strook, D., Analysis of the cut locus via heat kernel, 2013, issn:10529233,

Entwicklung einer Visualisierungspipeline für 3D-Daten

Florian Djokaj, Tom Georgi und Anton Hummel

Egal ob beim Modellieren einer Maschine in der Industrie, beim Scannen einer Bodenlandschaft in der Geomorphologie oder beim Planen einer Stadtlandschaft in der Architektur. Überall entstehen dreidimensionale Daten in Form einer Punktwolke, eines Meshes oder eines Graphen. Diese Daten sollen letztendlich visualisiert werden, um die komplexe Datenmenge vereinfacht darzustellen. Hierbei entsteht die Herausforderung der Visualisierung dieser Daten. Die Schnittstelle zum Anwender soll möglichst einfach und trotzdem flexibel bleiben.

Einleitung

Um 3D-Daten zu visualisieren wurden im Institut für Optische Systeme in einigen Projekten die Visualisierungssoftware libigl genutzt. Das tool bietet dem Anwender eine schlanke Schnittstelle, bei der mit Hilfe der Programmiersprache Python kleine Skripte genügen um die Visualisierungspipeline von libigl in Gange zu setzen. Trotz schlanker Schnittstelle nach außen, ist die Nutzung der libigl-Bibliothek unhandlicher als erwünscht. Eine Änderung der Datenmenge in der laufenden Anwendung ist nicht möglich. Weder mit Hilfe des Pythonskripts welches die notwendigen libigl-Funktionen aufrufen kann, noch mit Hilfe eines interaktiven Interpreters wie IPython. Das ändern der zu visualisierenden Datenmenge, verlangt immer ein Schließen des "Viewers".




Figure 15: Screenshot aus dem libigl-Viewer mit gerendertem Schatten

Diese Problematik soll nun gelöst werden. Der Anwender soll die Möglichkeit haben, zur Laufzeit von libigl die visualisierte Datenmenge zu ändern. Zusätzlich soll die Datenänderung auch von einem interaktiven Kommandozeileninterpreter möglich

sein. Der geöffnete libigl-" Viewer" soll direkt auf die Pythonbefehle reagieren. Als ergänzendes Feature soll dem " Viewer" ein Screenshot-Feature sowie ein Schatten-Rendering hinzugefügt werden. Damit die Nutzung der Bibliothek auf Python Seite einfacher wird soll libigl mittels dem Python Paket Manager pip installierbar sein.

Um die folgenden Ziele umzusetzen, wurden folgende Technologien genutzt:

- OpenSource C++ Bibliothek libigl
- Die Spezifikation OpenGL [2]
- Programmiersprachen C++ und Python
- Paketverwaltungsprogramm pip

Laufzeitänderung

Ziel der Implementierung einer Datenänderung zur Laufzeit ist es gewesen, diese möglichst schlank in die bereits bestehende Architektur von libigl einzubetten. Dies wurde mithilfe eines Threads gelöst.

Schatten und Screenshot

Für den Schatten der auf Abbildung 16 zu sehen ist wurde ein shadow-mapping Algorithmus implementiert. Dafür wird in einem zusätzlichen render durchlauf eine depthmap erstellt. [1]




Figure 16: Screenshot aus dem libigl-Viewer mit gerendertem Schatten

Ergebnis

Die gesetzten Ziele des Teamprojekts sind erreicht worden. In die Visualisierungspipeline lässt sich während der Laufzeit interaktiv eingreifen. Wie in Abbildung 16 zu sehen ist, ist außerdem ein Schatten erfolgreich in den Renderprozess in-

tegriert worden. Das Screenshot-Feature gibt dem Anwender die Möglichkeit seine Datenmenge im laufenden libigl-Viewer festzuhalten und zu speichern. Die Python Bibliothek "pyigl" lässt sich unkompliziert mit Hilfe von pip, wahlweise auch in einer virtuellen conda-Umgebung, installieren.

Zusammenfassung

Zusammenfassend lässt sich sagen, dass uns dieses Teamprojekt im Institut für Optische Systeme ein grundlegendes Verständnis für die Visualisierung von 3D-Daten geliefert hat.

Bibliography

- [1] Nischwitz, Alfred: Computergrafik, 3., neu bearb. Aufl, 2011, ISBN 978-3-8348-1304-6
- [2] <https://learnopengl.com/Getting-started/OpenGL> 2019

Modellierung von digitalem Druck mit Hilfe von neuronalen Netzen

Simon Christofzik

Diese Arbeit beschreibt die Umsetzung der Modellierung von digitalem Druck. Dazu wird ein neuronales Netzwerk mit Daten trainiert, die den Druck und Digitalisierungsprozess repräsentieren. Die Daten werden mittels Drucker und Scanner in digitale Form gebracht. Die Qualität der Prognose durch das Netzwerk wird anhand seiner Referenz verglichen. Dazu wird eine Rekonstruktionsbasierte Anomalie Erkennung in Kombination mit einer Distanzbasierten Anomalie Erkennung verwendet.

Einleitung

Neuronale Netze haben sich in den letzten Jahren immer mehr in unser alltägliches Leben integriert. Sie übernehmen Aufgaben wie die Autovervollständigung bei Suchanfragen über Google, kommen bei Spracherkennung zum Einsatz und werden auch schon seit mehreren Jahren erfolgreich bei der Deutschen Post zur Erkennung von Absender und Empfänger eingesetzt. Mit zunehmender Rechenleistung werden neuronale Netze immer leistungsfähiger und können in Bereichen eingesetzt werden, die vor einigen Jahren noch unmöglich von Maschinen bewerkstelligt werden konnten. Insbesondere im industriellen Bereich rückt der Einsatz von neuronalen Netzen immer mehr in den Vordergrund. Das Inspizieren von Produkten wie z.B. Parkettböden übernehmen Computer, welche da-

rauf ausgelegt sind Fehler am Produkt zu erkennen und diese aussortieren. Das Trainieren eines neuronalen Netzwerk auf solche Anwendungen benötigt eine grosse Anzahl an Daten, deren Beschaffung oft eine mühsame Aufgabe darstellt. Des weiteren müssen die Daten gewissen Anforderungen entsprechen. Um dies zu erreichen kann es erforderlich sein, ein grossen Satz an Daten von Hand durchzugehen und fehlerhafte Daten aussortieren. Im Falle der Parkettböden müssten zuerst Daten erhoben werden, indem Referenzböden gedruckt werden. Diese müssen auf Fehler überprüft werden und können dann in das Datenset aufgenommen werden. Diesen Prozess zu automatisieren, indem synthetische Parkettböden erzeugt werden ist eine erstrebenswerte Aufgabe, die die Datenerhebung wesentlich vereinfacht.




Figure 17: Die digitale Referenz wird auf Din A4 Papier gedruckt und mittels Scanner in digitale Form gebracht

Methodik

Mit Hilfe eines neuronalen Netzes wird der Druck und digitalisierungsprozess, der in Abbildung 17 illustriert ist, modelliert.

Als digitale Referenz dienen 31 verschiedene Holztexturen, welche die Auflösung von 1100 × 1600 besitzen. Die digitalisierte Textur wird mittels SIFT und Homographie an die digitale Referenz angeglichen. Wie in Abbildung 17 zu erkennen ist besitzt die digitalisierte Textur eine Auflösung von 5103 × 7016. Durch das angleichen mittels SIFT wird die digitale Referenz auf die selbe Auflösung wie die digitalisierte Textur überführt. Um das Rauschen, welches beim Digitalisierungsprozess entsteht zu vermindern werden die Bilder mit einem Gaußfilter der den Radius

drei besitzt geglättet. Die digitale Referenz wird als Input für das neuronale Netz genutzt, die digitalisierte Textur ist hierbei die gewünschte Prognose. Als Kostenfunktion wird der *Structural SIMilarity* (kurz SSIM) verwendet:

$$SSIM(x, y) = \frac{(2\mu_x\mu_y + C_1)(2\sigma_{xy} + C_2)}{(\mu_x^2 + \sigma_x^2 + C_1)(\mu_y^2 + \sigma_y^2 + C_2)} \quad (1)$$

Als Netzwerkarchitektur wird ein Netzwerk verwendet, das ursprünglich zur Rekonstruktion von HDR-Bildern verwendet wird [1]. Dies ist in nachstehender Abbildung 18 zu sehen. Das Netzwerk wird mit drei verschiedenen Patchgrößen trainiert, welche 128×128, 160×160 und 256×256 sind.

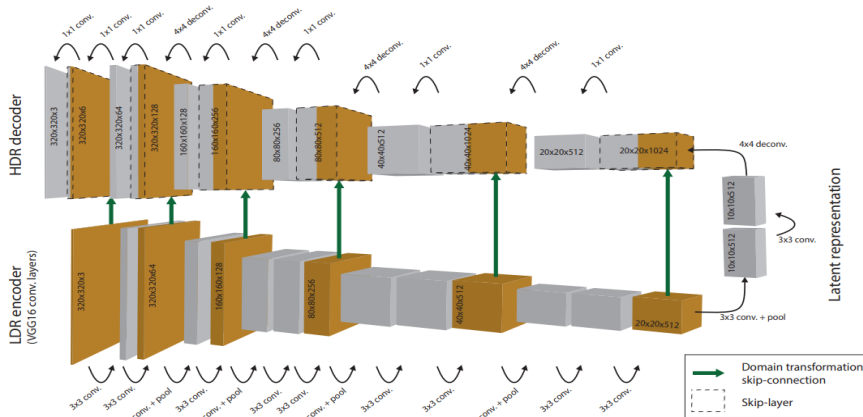


Figure 18: Verwendete Architektur des Netzwerks [1]

Das Training des Netzwerks dauert je nach Patchgröße zwischen 7 und 15 Stunden.

Um die Qualität der Prognose des Netzwerks zu vergleichen, werden mit einem VGG19 Netzwerk Features der Prognose und der zugehörigen digitalisierten Textur extrahiert. Durch die Mahalanobis-Distanz wird eine Menge an Features definiert, welche zur digitalisierten Textur gehören. Die Mahalanobis-Distanz ist definiert durch:

$$D(x, \mu) = (x - \mu)^T \Sigma^{-1} (x - \mu) \quad (2)$$

Für die Prognose werden ebenfalls die Features extrahiert und in ihrer Dimension reduziert. Daraufhin wird die Mahalanobis-Distanz zum Schwerpunkt der digitalisierten Textur berechnet. Alle Features die in der zuvor berechneten Menge liegen, werden als gute Prognose angesehen. Die Extraktion der Features geschieht Patchweise, d.h. jeder Patch des zu untersuchenden Bildes stellt ein Datenpunkt der erzeugten Menge dar. Patches die ausserhalb der definierten Menge liegen werden farblich markiert. Dabei beschreibt die Farbe der Umrandung des Patches wie weit dieser vom Mittelpunkt entfernt ist.




Figure 19: Durch das Netzwerk prognostizierte Gesamtbild

Patchgröße	Metrik	Bild			
		a	b	c	d
256 x 256	Fehler %	63	15	56	27
160 x 160	Fehler %	8	4	5	12
128 x 128	Fehler %	2	3	5	2

Table 0.2: Ergebnis der Prognose

In Abbildung 19 ist zusehen, dass einige Patches markiert sind. Hier liegen ca. zwei Prozent der Patches ausserhalb der Referenzmenge. Lässt man die digitale Textur den Digitalisierungsprozess noch einmal durchlaufen, und vergleicht daraufhin die zwei digitalisierten Texturen, so liegen ca. sieben Prozent der Patches ausserhalb der Referenzmenge. Tabelle 0.2 zeigt die Ergebnisse der Prognose. Zu sehen ist, dass die Patchgröße 256 den größten Fehler besitzt. Die Patchgrößen 128 und 160 liefern mit zwei bis zwölf Prozent Fehler die besten Ergebnisse.

Fazit

Die in dieser Arbeit vorgestellte Methode zur Modellierung von digitalen Druck zeigt, dass neu-

ronale Netze durchaus fähig sind diese Aufgabe zu bewerkstelligen. Insbesondere die Datenprognose für die Patchgröße 128 des KNN liefert akzeptable Ergebnisse. Da das KNN Patches vorher sagt und das vorhergesagte Bild somit durch das zusammensetzen von Patches erzeugt wird, sind diese Stellen kritische Punkte. Die Schnittstellen sind oftmals zu verschieden, als dass sie die Fehlererkennung unbemerkt passieren können.

Bibliography

- [1] Eilertsen and Gabriel and Kronander and Joel and Denes and Gyorgy and Mantiuk and Rafał and Unger, Jonas: HDR image reconstruction from a single exposure using deep CNNs, 2017.

Anomaliedetektion an digital gedruckten Dekoren mit Hilfe von künstlichen neuronalen Netzen

Semih Demir

In dieser Arbeit wird der Einsatz von künstlichen neuronalen Netzen [1] als Inspektionssystem für den Single Pass Digitaldruck in der Industrie geprüft. Hierzu werden zum Testen Drücke mit typischen Defekten künstlich aufbereitet. Zur Detektion der Defekte werden verschiedene Modelle der Anomaliedetektion mit defektfreien Drücken trainiert, um anschließend anhand dieses erlernten Referenzmodells Defekte als Anomalie zu den Referenzdaten zu erkennen.

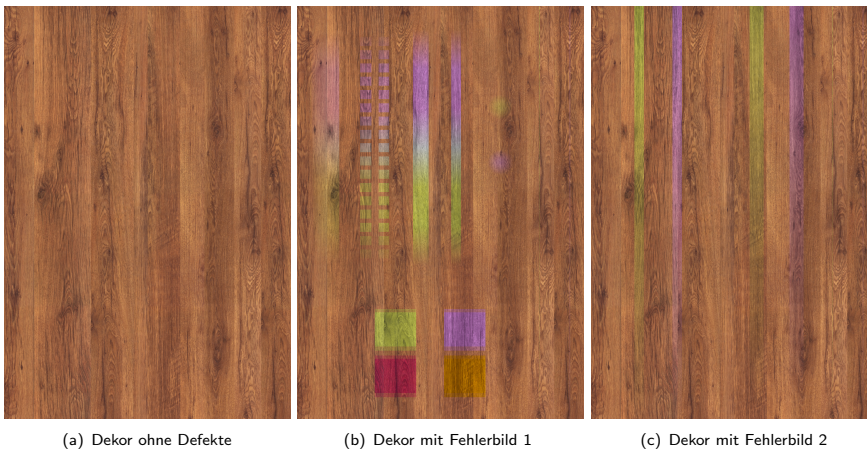


Figure 20: Ein Dekor ohne und mit den erstellten Defekten

Einleitung

Künstliche neuronale Netze werden in der Industrie immer beliebter, da sie Aufgaben wie Spracherkennung, Trendprognosen sowie Bildverarbeitung vor allem bei großen Datenmengen deutlich besser als Menschen bewältigen können. Ein bereits trainiertes Netz, kann im Gegensatz zum Menschen, Millionen Datensätze in wenigen Stunden verarbeiten. Dies kann z. B. die Auswertung von MRT Aufnahmen in der Medizin oder Material- bzw. Oberflächeninspektion in der Produktion sein.

Methodik

Als Evaluierungsmodell dient die One-Class Support Vektor Machine [3] sowie der Local Outlier Factor [4]. Im ersten Schritt werden diese Modelle durch Dimensionsreduktion mit Hilfe eines Autoencoders verbessert. Des Weiteren wird der Rekonstruktionsfehler eines Autoencoders als Modell der Anomaliedetektion getestet. Zuletzt wird noch das 2018 von Forscher der Universität Durham vorgestellte Modell GANomaly [2] zur Anomaliedetektion, für den Einsatz als Inspektionssystem geprüft und optimiert.

Ergebnisse

	AVG AUC	AVG F1-Score
One-Class SVM	0,609	0,238
LOF	0,615	0,195
CAE+One-Class SVM	0,644	0,287
CAE+LOF	0,682	0,319
CAE Reconstruction Loss	0,798	0,547
GANomaly	0,625	0,276
GANomaly+Reconstruction Loss	0,74	0,427

Figure 21: Durchschnittlicher AUC sowie F1-Score über alle Dekore, für alle in den Experimenten getesteten Methoden. Die besten Werte sind jeweils Grün markiert, ebenso sind die schlechtesten Werte Rot markiert.

Fazit

Oberflächeninspektionssysteme in der Industrie erfordern ein hohes Maß an Genauigkeit. Für die zwei klassischen Methoden One-Class SVM und LOF, hat sich gezeigt, dass sie selbst dazu nicht in der Lage sind. Durch die Dimensionsreduktion mit Hilfe eines Autoencoders ließ sich das Ergebnis jedoch verbessern, wobei dann der LOF der One-Class SVM überlegen war. Das beste Ergebnis lieferte jedoch die Methodik den Rekonstruktionsfehlers eines Autoencoders zu nutzen. Obwohl wir das GANomaly Modell für unseren Einsatzzweck verbessern konnten, lieferte es nur das zweitbeste Ergebnis. Alle Methoden haben jedoch gemein, dass sie nur auf einfachen Dekoren mit wenig Farbvielfalt und einfachen Strukturen gut funktionieren. Sobald das Dekor ein komplexeres Bild enthält, können bei allen Methoden die Defekte nicht mehr mit einer zufriedenstellenden Genauigkeit detektiert werden.

Bibliography

- [1] Ian Goodfellow and Yoshua Bengio and Aaron Courville: Deep Learning, MIT Press, 2016.
- [2] Samet Akcay and Amir Atapour-Abarghouei and Toby P. Breckon, GANomaly: Semi-Supervised Anomaly Detection via Adversarial Training, 2018.
- [3] Schölkopf, B. and Williamson, RC. and Smola, AJ. and Shawe-Taylor, J. and Platt, JC, Advances in Neural Information Processing Systems 12, 2000.
- [4] M. Breunig, Markus and Kriegel, Hans-Peter and Ng, Raymond and Sander, Joerg, LOF: Identifying Density-Based Local Outliers, 2000.

Feasibility of reinforcement learning for point cloud preprocessing

Jonas Fleischer

Machine learning techniques have already been successfully applied when working with point clouds. Examples of this include, among other things, robotic grasping, segmentation, classification, and learning knot placement for B-spline curves. However, the point cloud preprocessing is often performed with handcrafted heuristics. This thesis explores the viability of point cloud preprocessing using reinforcement learning. Specifically, sequencing, selection, and segmentation tasks are evaluated. For this purpose, the performance of five common reinforcement learning algorithms is measured. Next, the effect of changing various elements of the reinforcement learning process on the performance of each algorithm is explored through isolated experiments. These changes either affect the problem formulation or the trained agent's capabilities. Through utilizing an attention window mechanism, the task of sequencing a large point cloud was subdivided into smaller problems that could be solved by a reinforcement learning agent.

Introduction

The raw data output of a 3d Scanner is often unsorted and contains noise. Seeing the natural order and segments of a point cloud and therefore guessing at the represented shape can be very intuitive for humans. However, for algorithms extracting the right order and segmentation can pose a considerable challenge. Often before the data is usable, it is necessary to clean and prepare the data in a preprocessing step. Preprocessing is usually done using handcrafted heuristics. In contrast, this thesis explores the viability of using reinforcement learning for point-cloud-preprocessing.

Method

To answer this question, three new reinforcement learning environments based on three point cloud preprocessing tasks were implemented. For the viability evaluation, a broad range of reinforcement learning algorithms were selected. Then five common reinforcement learning algorithms were selected and applied to the environments. By switching various elements of the reinforcement learning process, the effect of each element on the agent's performance was analyzed.




Figure 22: Point cloud size 50 before (left) and after (right) sorting.

Results and Conclusion

For point clouds biased into one particular direction, it is viable to use Q-Learning [6] and Imitation learning [5] to solve small local subproblems of the sequencing task and apply this solution to a larger point cloud by using a sliding window technique (see figure 22). However, as soon as the point clouds are rotated arbitrarily the agent's performance falls so rapidly that even this solution becomes infeasible. On the one hand, switching elements of the reinforcement learning process increased performance by making the problem easier or by increasing the agent's capabilities. On the other hand, using larger environment sizes or more challenging datasets quickly overwhelmed the pre-

viously achieved performance improvements. to center the image

Bibliography

- [1] Ross, Stéphane and Gordon, Geoffrey J and Bagnell, J Andrew (2011): No-regret reductions for imitation learning and structured prediction: In: Aistats 15, pp. 627–635
- [2] Mnih, Volodymyr and Kavukcuoglu et al. (2015): Human-level control through deep reinforcement learning: In: Nature 518.7540, pp. 529-533. issn: 14764687. doi: 10.1038/nature14236

Analysis of point cloud convolutions for edge detection on point clouds

Joey Rieg

Autonomous systems like self driving vehicles, which act upon their environment need an exact representation of their surroundings. 2-dimensional images and point clouds generated by 3D sensors, e.g. *light detection and ranging* (LiDAR), are often used as such representation. The tasks to identify an action for an autonomous system are based on extracting features like edges, objects or semantically cohesive regions. Convolutional neural networks were already utilized to solve object detection and scene segmentation tasks as well as detecting feature-edges on images. To analyse point cloud convolutions on the feature-edge detection topic a PyTorch implementation of the PCNN network was developed and validated on the original PCNN implementation. Further, the accuracy of the PyTorch PCNN was compared to Kd-Net and PointNet++ on benchmark datasets and on a custom edge labeled point cloud datasets based on three different point samplings of intersecting mesh primitives. The validation experiment showed that the forward passes of both PCNN implementations are the same within a numerical tolerance. The lack of performance on the ModelNet40 dataset was due to not leveraging voting and data augmentation techniques in the PyTorch PCNN implementation. The equal validation accuracy of the three networks on the edge labeled point cloud datasets indicated a similar learning scheme. This was proven as all networks only predicted non-feature edge belonging points, which was due to the imbalance of the datasets and the used architectures. In conclusion, point cloud convolution architectures designed for classification tasks yield a large generalization error on point cloud edge detection tasks.

Introduction

Edge detection is essential in a variety of fields, especially in autonomous systems [1], where feature-edges define the shape of the environment. Algorithms to detect edges are also applied in other fields such as medical image processing to find anomalies in the human body [2]. The main data edge detection is applied to are images. With the development of 3-dimensional sensor such as *light detection and ranging* (LiDAR) unstructured data such as point clouds are easier to obtain and are already used in before mentioned autonomous systems with deep learning algorithms to solve tasks on object detection scene segmentation. This thesis approaches the symbiosis of edge detection on point clouds and convolutional neural networks.

Results and conclusion

The PCNN architecture was chosen for the edge detection task because of its invariance to point order, equivariance of the convolution kernel and stability on different sampling densities. The PyTorch PCNN implementation was validated on

Methods

Three convolutional neural networks were theoretically compared on their compatability to the edge detection task. The most suitable network was implemented in PyTorch and validated with the original Implementation. In order to train networks on this tasks, edge labeled point cloud datasets were developed by intersecting mesh primitives, uniformly sampling the surface of these mesh constructs in different sampling densities. The labeling process consisted of comparing the distance of all points to the sharp feature edges on the mesh constructs. An labeled point cloud in different sampling densities is shown in 23. Further, three neural networks were tested on classification benchmark datasets as well as on the edge labeled point cloud dataset.

the original PCNN implementation. The forward passes of both implementations are the same within a numerical tolerance. Still, there is a lack of performance due to not utilizing data augmentation and voting techniques. The PyTorch PCNN validation accuracy on ModelNet40 was slightly




Figure 23: Three different samplings of the same mesh construct. Red points indicate feature-edge points.

lower than its competitors, namely Kd-Net [3] and PointNet++ [4]. The results on the edge labeled point cloud datasets revealed the same validation accuracies of the network across one dataset. This was due to imbalanced classes of the datasets as less than 9% of the point cloud were feature-edge points. The imbalanced dataset and the used classification architectures were responsible that the networks only predicted non-feature-edge points. In conclusion, point cloud convolution architectures, that are designed for classification task yield a large generalization error on point cloud edge detection tasks.

References

Bibliography

- [1] [Lin et al., 2010] Lin, Q., Youngjoon, H., and Hahn, H. (2010). Real-time lane detection based on extended edge-linking algorithm. In *2nd International Conference on Computer Research and Development, ICCRD 2010*.
- [2] [K. Gajre et al., 2016] K. Gajre, R., A. Lothe, S., and G. Vishwakarma, S. (2016). Identification of Brain Tumor using Image Processing Technique: Overviews of Methods. *International Journal of Computer Science and Engineering*, 3(10):89–93.
- [3] [Klokov and Lempitsky, 2017] Klokov, R. and Lempitsky, V. (2017). Escape from Cells: Deep Kd-Networks for the Recognition of 3D Point Cloud Models. In *Proceedings of the IEEE International Conference on Computer Vision*.
- [4] [Qi et al., 2017a] Qi, C. R., Su, H., Mo, K., and Guibas, L. J. (2017a). PointNet: Deep learning on point sets for 3D classification and segmentation. In *Proceedings - 30th IEEE Conference on Computer Vision and Pattern Recognition, CVPR 2017*.
- [5] Ross, Stéphane and Gordon, Geoffrey J and Bagnell, J Andrew (2011): No-regret reductions for imitation learning and structured prediction: In: *Aistats 15*, pp. 627–635
- [6] Mnih, Volodymyr and Kavukcuoglu et al. (2015): Human-level control through deep reinforcement learning. In: *Nature* 518.7540, pp. 529-533. issn: 14764687. doi: 10.1038/nature14236

Konfidenzintervalle bei der Erkennung unbekannter Fehlerarten mittels Referenzmodellierung

Prof. Dr. Matthias O. Franz, Matthias Hermann, Tobias Birkle

Individualisierung und Personifizierung stehen derzeit im Mittelpunkt der digitalen Transformation von klassischer Konsumgüterindustrie hin zu Unikat-Produzenten. Konzepte und Visionen, die häufig mit Industrie 4.0, IoT (Internet of Things), oder ganz allgemein Digitalisierung umschrieben werden, skizzieren technologische Lösungswege für die wachsenden Herausforderungen in Industrie und Gesellschaft. Im Zentrum solcher Konzepte stehen automatisierte Prozesse, additive Fertigungsverfahren und autonome Systeme. Damit einher geht ein immer größerer Bedarf an Informationen, auf deren Basis Maschinen ihr Umfeld und die zu bearbeitende Objekte erkennen und situationsabhängig bewerten können. Optische Systeme, insbesondere aus dem Bereich der Photonik und industriellen Signalverarbeitung, stellen dafür eine entsprechende technologische Grundlage und werden beispielsweise für die maschinelle Objekt- und Fehlererkennung eingesetzt.

Grundsätzlich werden drei klassische Herangehensweisen im Bereich automatisierter Fehlerdetektion unterschieden: (1) Schwellwertverfahren, welche durch Festlegen verschiedener Signalschwellwerte Fehler erkennen. (2) Template-Verfahren, welche auf Basis bekannter Fehlermuster *gut* von *schlecht* unterscheiden. (3) Lernverfahren, welche mittels gelabelten Daten Klassifikatoren trainieren.

In Bereichen vieler diversifizierter Fehlerarten stoßen diese klassische Verfahren an ihre Grenzen. Beispielsweise ist im Bereich additiver Fertigungsverfahren die vollständige Beschreibung von Fehlern oftmals nicht möglich oder wirtschaftlich uninteressant. Grund hierfür ist, dass Fehler von darunter liegenden Schichten abhängen können. Diese Abhängigkeit führt zu einer Vielzahl an möglichen Fehlervariationen, welche nicht handhabbar sind. Im Digitaldruck werden beispielsweise Linienausfälle abhängig vom Druckbild

sichtbar oder bleiben verborgen (siehe Abb. ??).



Figure 24: Unterschiede in der Sichtbarkeit von Linienausfälle.

Neue Verfahren setzen aus diesem Grund auf sogenannte *Novelty*-Detektionsverfahren. Diese Techniken des maschinellen Lernens benötigen keine gelabelten Daten, sondern lediglich fehlerfreie Beispiele aus jener Domäne, in welcher die Fehlererkennung später stattfinden soll. Ziel ist es eine möglichst gute Beschreibung dieser Beispiele, das sogenannte Referenzmodell, zu erlernen. Das Detektionsverfahren fußt im Anschluss auf der Erkennung von Ausreißern.

Im Kern eines solchen Verfahrens stehen passend gewählte Merkmale. Diese zeichnen sich durch Robustheit, Invarianz gegenüber Produktionsvarianz und Erkennungsrate aus. Bestehende Merkmale basieren zumeist auf Graustufenbildern, welche für das Erkennen von Farbfehlern ungeeignet sind (siehe Abb. ??).



Figure 25: Sichtbarkeit von Farbfehlern in (1) Graustufenbild und (2) Farbbild.

Ziel ist es daher, Farbmerkmale mit zugehöriger Struktur, sog. Farbtexturmodelle, systematisch zu evaluieren und auf Tauglichkeit für die Erkennung von Fehlern im Digitaldruck mittels Methoden der Novelty-Detektion zu untersuchen. Insbesondere gilt es Konfidenzmaße zur Klassifikation anzugeben, welche bei den bestehenden Algorithmen fehlen.

Die erfolgreiche Mitwirkung des Instituts für Optische Systeme am oben genannten Forschungsfeld sicherte den wissenschaftlichen Stand und wichtige Industriekooperationen, vorwiegend im Bereich der Photonik. Um die daraus resultierenden technischen und wissenschaftlichen Fragestellungen zur Inspektion additiv gefertigter Industrieprodukten adressieren zu können, war eine intensive Verfolgung des Stands der Technik bzw. relevanter wissenschaftlichen Arbeiten notwendig. Weiter wurden neue Modelle in Form einer Pilotanwendungen zu evaluiert.

Konkret wurden im Rahmen des vorgeschlagenen *Small Research Projekts (SRP)* folgende Themen erarbeitet

- Erweiterung der bestehenden Novelty-Detektionsverfahren um neuartige Algorithmen wie *Linear Discriminant Analysis* und *Dropout*.
- Integration der Konfidenzmaßberechnung in die bestehende Inspektionsumgebung.
- Anwendung von Farbtexturmodellen zur Beschreibung von Fehlern im Digitaldruck (additive Herstellung).

Die Ergebnisse des Projekts wurden einerseits in die bestehende Projekte am Institut für Optische Systeme eingepflegt aber auch in Form eines Konferenzbeitrags auf (1) SPIE Optics & Photonics, (2) Computer Graphics & Visual Computing (CGVC), oder (3) Machine Learning for Signal Processing (MLSP) mit peer-review-Verfahren verwertet. Die zu entwickelnde Anwendung wurde außerdem am Institut für Optische Systeme in die bestehende Laborumgebung integriert und damit der Nutzen des Labors für zukünftige Forschungsprojekte sichergestellt.

Die Umsetzung der Pilotanwendung wurde durch eine wissenschaftliche Hilfskraft durchgeführt. Hierunter fällt sowohl die Erarbeitung des wissenschaftlichen Hintergrunds als auch die Integration in die bestehende Infrastruktur. Aufgrund der hohen Komplexität wurde die wissenschaftliche Hilfskraft von zwei Doktoranden am Institut für Optische Systeme betreut und unterstützt.

Prof. Dr. Matthias O. Franz, Matthias Hermann, Tobias Birkle
Institut für Optische Systeme (IOS)

Experiment zum Vergleich von Convolutional Neural Networks mit Graph Neural Networks

Prof. Dr. Georg Umlauf, Dennis Griebner

Autonome oder teilautonome Assistenz- und Sicherheitssysteme sind brandaktuelle Themengebiete führender Forschungsgruppen und leisten einen wichtigen Beitrag zur Automatisierung in der Binnenschifffahrt. Ziel dieser Systeme soll es sein, die Sicherheit dahingehend zu erhöhen, dass Unfälle, die auf menschliches Versagen zurückzuführen sind, vermieden werden können. Um dies realisieren zu können, werden die Schiffe mit optischen Sensoren ausgestattet, die die Besatzung in Gefahrensituationen unterstützen sollen. Für die Umfelderkennung werden dabei Stereo-Systeme sowie Lidar-Sensoren eingesetzt. Die Stereokameras erlauben es, mittels eines Bildpaares den Abstand zu den in der Szene befindenden Objekten zu berechnen. Diese Tiefeninformationen lassen sich in sogenannten Disparitätskarten abspeichern, wobei die Tiefe in einem zweidimensionalen Bild als Graustufenabstufung kodiert ist, siehe ???. Die Lidar-Sensoren hingegen senden Laserimpulse aus und detektieren das zurückgestreute Licht. Dabei wird aus der Lichtlaufzeit die Distanz zum reflektierenden Objekt bestimmt. Die detektierten Lichtstrahlen werden dabei in einer sogenannten Punktwolke, wie in Abbildung ?? dargestellt, gespeichert. Die Punktwolke entspricht dabei

einer Menge kartesischer Koordinaten im dreidimensionalen Raum. Die Herausforderung besteht nun darin, Muster in den gewonnenen Sensordaten mithilfe von maschinellen Lernalgorithmen zu erkennen.

Um die Umgebung korrekt verstehen zu können, müssen sich die darin befindenden Objekte korrekt detektieren sowie klassifizieren lassen. Klassische Merkmalsdeskriptoren zeigten hierbei schon sehr gute Ergebnisse. Die Merkmalsgewinnung konnte allerdings mit Aufkommen der Convolutional Neural Networks (CNN) nochmals deutlich gesteigert werden. Diese CNN lassen sich zur Objektdetektion und Klassifikation der Stereodaten einsetzen. Um jedoch Punktwolken mit nicht definierten Nachbarschaften verarbeiten zu können, bedarf es einer Anpassung der herkömmlichen CNNs. Um Muster in Punktwolken mithilfe maschineller Lernalgorithmen erkennen zu können, werden deshalb sogenannte Graph Neural Networks (GNN) eingeführt. Diese ermöglichen Operationen wie zum Beispiel Faltung auf 3D-Punktwolken zu berechnen, um dann Objekte vorherzusagen zu können.




Figure 26: In (a) wird aus dem Stereobildpaar eine Disparitätskarte berechnet. In (b) wird die zugehörige Punktwolke des Lidar-Systems dargestellt.

Im Rahmen verschiedener Forschungsprojekte, die zu diesem Zeitpunkt am Institut für Optische Systeme statt fanden, wurden diese CNNs und GNNs entwickelt. Aufgrund der Neuartigkeit der GNNs wurden diese ständig erweitert und mussten deshalb evaluiert werden. Hierfür wurde im Rahmen des hier vorgeschlagenen *Small Research Projekts (SRP)* ein Experiment gestartet, bei dem bestehende CNNs, welche auf RGB-Daten sowie auf Disparitätskarten operieren, mit den neuartigen GNNs, die auf Punktwolken anwendung finden, verglichen wurden. Dabei wurde sowohl die Trefferquote sowie die Inferenzzeiten der Netzwerke berücksichtigt und bewertet.

Die Durchführung des Projekts gliedert sich in folgende Arbeitspakete:

- Konzeption eines geeigneten Testszenarios, um die beiden Netzwerke miteinander zu vergleichen.
- Entwicklung eines Testframeworks.
- Integration des Testframeworks in die institutseigene Deep Learning Bibliothek.

Prof. Dr. Georg Umlauf, Dennis Grießer
Institut für Optische Systeme (IOS)

Institut für Optische Systeme
Hochschule Konstanz
Brauneggerstr. 55
78462 Konstanz
www.ios.htwg-konstanz.de