

Streszczenie

Model otoczenia, który obejmuje odległość do najbliższej przeszkody, jest niezbędny dla systemu jazdy autonomicznej. Dlatego też można uznać, że każdy system nawigujący autonomicznie musi być w stanie oszacować głębokość (czyli odległość do najbliższego obiektu). Istnieje jednak konflikt pomiędzy rozmiarem, złożonością i kosztem czujnika głębokości, z jednej strony, a gęstością i dokładnością pomiarów, z drugiej strony.

Celem tej rozprawy jest zbadanie wykonalności zagęszczania map głębi (czyli tworzenia gęstej mapy głębokości na podstawie rzadkich pomiarów głębokości) dla wyjątkowo rzadkich pomiarów głębokości. Większość tej pracy dotyczy uzupełniania głębokości w radarach samochodowych typu *Frequency Modulated Continuous Wave* (FMCW). Dodatkowo przedstawiam nowy sposób zagęszczania map głębi na chmurze punktów lidaru, który opracowałem w celu stworzenia zestawu danych szkoleniowych do zadania uzupełniania głębokości radarowej, algorytm dodający szum do wag sieci neuronowej podczas treningu i prostą symulację pokazującą, że sieć neuronowa jest w stanie estymować kąt do celu w obecności dwóch celów.

Pierwsze dwa rozdziały rozprawy opisują rozwiązywany problem, motywację oraz sensory motoryzacyjne, ze szczególnym uwzględnieniem radarów FMCW. Kolejne rozdziały opisują osiągnięcia doktoratu.

Pierwszym osiągnięciem (opisanym w Rozdziale 3) jest algorytm wykorzystujący centrowane wokół zera, addytywne perturbacje wag w trakcie szkolenia sieci neuronowej. Pokazuję, dlaczego pomaga to zwiększyć ilość informacji, której sieć neuronowa może nauczyć się przy danym rozmiarze sieci. Dodatkowo demonstruję przydatność metody dla niektórych powszechnie stosowanych architektur sieci neuronowych. Perturbacje wag były wykorzystane w szkoleniu sieci WeaveNet oraz przy treningu sieci przeprowadzających *angle finding* na symulowanych danych.

Drugim osiągnięciem (opisanym w Rozdziale 4) tej pracy jest zdefiniowanie Sieci WeaveNet – sieci neuronowej, której architektura została zaprojektowana w celu skutecznego zagęszczania map głębi dla danych lidarowych, o zmiennej gęstości wejściowych pomiarów głębokości. Nazwa sieci

została zainspirowana wzorem jąder konwojacyjnych, który wygląda jak tkanina. Sieć WeaveNet została przeszkolona i przetestowana przy użyciu danych z konkursu KITTI Depth Completion. Sieć WeaveNet odegrała kluczową rolę w tworzeniu gęstego zestawu danych głębokości, który później został wykorzystany w moim rozwiązaniu uzupełniania głębokości radarowej.

Trzecim osiągnięciem (opisany w Rozdziale 5) jest zestaw wyidealizowanych symulacji, które pokazują, że sieci neuronowe są zdolne do znajdowania kątów do dwóch celów, gdy anteny radarowe odbierają superpozycję fal odbitych (niezbędny krok dla sieci zagęszczania map głębi na danych radarowych).

Czwartym osiągnięciem (opisany w Rozdziale 6) jest stworzenie zestawu danych używanego do szkolenia i walidacji algorytmów zagęszczania map głębi na danych radarowych. Zestaw składa się z ponad 1 000 000 *Radar Data Cubes* (RDC) z radaru skierowanego w przód, wraz z odpowiadającymi im obrazami z kamery i gęstymi mapami głębokości (tworzonymi przy użyciu sieci WeaveNet).

Piątym osiągnięciem (opisany w Rozdziale 7) jest zaprojektowanie architektury sieci neuronowej zdolnej do przekształcania niskopoziomowego wejścia RDC w abstrakcyjne kanały na płaszczyźnie azymut-elewacja. W rezultacie możliwe stało się przeszkołnenie tej sieci neuronowej do przewidywania gęstych map głębokości przy użyciu RDC jako wejścia. Sieci te były szkolone i testowane na zestawie danych stworzonym na potrzeby pracy nad tym doktoratem. Wyjście sieci zagęszczania map głębi używającej wyłącznie danych radarowych jest wizualnie sensowne i znacznie lepsze niż interpolacja liniowa chmury punktów uzyskanej przy użyciu standardowych algorytmów przetwarzania radarowego. O ile mi wiadomo, jest to pierwsze rozwiązanie generujące gęstą mapę głębokości na podstawie RDC z motoryzacyjnego radaru FMCW.

Ostatnim osiągnięciem (również opisany w Rozdziale 7) jest projekt architektury sieci neuronowej zdolnej do łączenia danych pochodzących z radaru (RDC) i obrazów kamery RGB w celu zagęszczania map głębi (również przeszkolonej i przetestowanej na tym samym zestawie danych). Pokazałem, że sieci wykorzystujące RDC w połączeniu z danymi wizualnymi uzyskują wyniki od 3% do 21,5% lepsze niż analogiczne sieci szkolone tylko do korzystania z danych wizualnych (na różnych podzbiorach zbioru danych).

Słowa kluczowe: radar, FMCW, zagęszczanie map głębi, perturbacja wag

2023-10-06

Mariusz K. Nowak

Abstract

A model of the environment which includes distance to the nearest obstacle is necessary for a system tasked with autonomous movement. Therefore, it is reasonable to say that every autonomously-navigating system must be able to estimate depth (i.e. the distance to the nearest object). However, there is a trade-off between the size, complexity and cost of a depth sensor on one hand, and the density and accuracy of its measurements on the other hand.

The goal of this dissertation is to examine the feasibility of depth completion (i.e. producing a dense depth-map from a sparse depth input) for extremely sparse depth measurements. The bulk of this work deals with depth completion on automotive Frequency Modulated Continuous Wave (FMCW) radars. Additionally, I present a novel way to perform depth completion on lidar point cloud, which I developed for the purpose of creating the training dataset for the radar depth completion task, an algorithm utilizing zero-centered, additive weight perturbations during neural network training and simple simulations showing the capability of a neural network to perform angle finding in the presence of 2 targets.

The first two chapters of the dissertation describe the problem formulation, motivation and automotive sensors, with emphasis put on FMCW radars. The next chapters describe my original contributions.

The first contribution (described in Chapter 3) is an algorithm utilizing zero-centered, additive weight perturbations during neural network training. I show why it helps to increase the amount of information the neural network can learn for a given size and demonstrate its usefulness for some commonly used neural network architectures. Weight perturbations were utilized in the WeaveNet training and in the training of the radar angle finding model on simulated data.

The second contribution (described in Chapter 4) is the definition of WeaveNet - a neural network whose architecture is designed to perform well in the task of lidar depth completion on variable input sparsity depth measurements (name inspired by the convolutional kernels pattern, which looks like a woven fabric). It was trained and tested utilizing the data from the KITTI Depth Completion challenge.

WeaveNet was instrumental in creating a dense depth dataset, that was later used in my radar depth completion solution.

The third contribution (described in Chapter 5) consists of a set of idealized simulations, showing that neural networks are capable of finding angles to two targets when radar antennae receive a superposition of reflected waves (a necessary step for a radar depth completion network).

The fourth contribution (described in Chapter 6) is the creation of a dataset used to train and validate algorithms for radar depth completion. It consists of over 1,000,000 Radar Data Cubes (RDCs) from a forward-facing radar, together with corresponding camera images and dense depth maps (produced using WeaveNet).

The fifth contribution (described in Chapter 7) is the design of a neural network architecture capable of transforming the low-level RDC input into abstract channels in the azimuth-elevation plane. Consequently, it was possible to train this neural network to predict dense depth maps using RDC as input. They were trained and tested on the dataset that was created for the purpose of the work on this PhD dissertation. The output of the radar-only depth completion networks is visually reasonable and much better than the linear interpolation of the point cloud obtained using standard radar processing algorithms. To the best of my knowledge, this is the first solution producing a dense depth map on the basis of automotive FMCW radar RDC.

The final contribution (also described in Chapter 7) is the design of the neural network architecture capable of fusing the RDC-derived data from the radar and the data derived from RGB camera images for the purpose of radar depth completion (also trained and tested on the same dataset). I have shown that the networks utilizing RDC in addition to visual data obtain results between 3% and 21.5% better than analogous networks trained to use visual data only (during different data collection drives).

Keywords: radar, FMCW, depth completion, weight perturbation

2023-10-06

Mariusz K. Nowak