

Rezumat

În ultimii ani, domeniul Autonomous Driving a căpătat importanță în cercetare, multe companii producătoare de mașini investind tot mai multe resurse atât financiare, cât și umane pentru a crea soluții tehnice astfel încât mașinile să aibă un comportament independent în trafic, cât mai apropiat de cel al oamenilor. De asemenea, în viitor se urmărește ca mașinile să comunice între ele pe drum cu scopul de a îmbunătăți calitatea traficului și a reduce consumul de carburant, din motive ecologice.

Tema acestei lucrări urmărește conducerea autonomă unei mașini electrice în cadrul participării la concursul național studentesc Electromobility, organizat de compania Continental Automotive România. Circuitul pe care mașina trebuie să îl parcurgă este unul simplist, dar care se apropie de unul real prin existența unor indicatoare rutiere și prin impunerea menținerii benzii proprii de circulație, totodată existând riscul de coliziune cu mașina adversă, care circulă din sens opus. Traseul are forma cifrei opt, astfel că cele două mașini se pot întâlni în intersecție.

Lucrarea constă în două componente principale, componenta de detecție și clasificare a indicatoarelor rutiere și componenta decizională pentru benzile de circulație, pe care colegii de echipă le-au integrat în arhitectura software a mașinii. Aceasta are două plăci de dezvoltare Raspberry Pi 3, fiecare placă rulând câte o componentă careia îi furnizează imagini preluate cu ajutorul unei camere pentru Raspberry Pi. Componentele sunt dezvoltate cu ajutorul unor tehnici de Computer Vision și Machine Learning pentru a identifica și clasifica indicatoarele, respectiv pentru a obține o decizie de viraj pentru mașină. Deoarece resursa hardware este Raspberry Pi, am ales limbajul Python și librăriile open-source TensorFlow de la Google și OpenCV pentru dezvoltarea și testarea componentelor, întrucât există documentație bine pusă la punct pe paginile oficiale, precum și o comunitate dezvoltată în aceste două direcții.

Componenta de detecție și clasificare a indicatoarelor rutiere folosește pentru detecție un detector Haar-Cascade din librăria open-source OpenCV pentru identificarea zonelor de interes din imaginea furnizată de cameră. Au fost antrenați trei astfel de detectori, câte unul pentru fiecare indicator. Acest detector nu are o acuratețe de 100%, astfel că pentru a îmbunătăți calitatea detecției am introdus un clasificator bazat pe o rețea neuronală convoluțională datorită capabilității acestei clase de algoritmi de a surprinde relații puternic neliniare între intrări și ieșiri. Rețeaua are o arhitectură aleasă empiric și a fost antrenată cu imagini extrase din seturi de date publicate de cercetători care au studiat problema detecției de indicatoare pentru mașini reale.

Componenta decizională pentru benzile de circulație utilizează imagini de la cameră, iar acestea sunt supuse unui șir de transformări pentru ca, în final, informațiile din imagine să capete un șablon clasificabil. Imaginea rezultată în urma șirului de transformări este furnizată unei rețele neuronale de convoluție pentru clasificare și, în final, se generează decizia de viraj.

Pentru a ușura testarea diverselor arhitecturi pentru cele două rețele neuronale de convoluție, am construit o micro-infrastructură bazată pe TensorFlow pentru antrenarea unor astfel de rețele, folosind un set de date cu structură proprie. Partea care ușurează efectiv procesul de testare constă în definirea rețelei neuronale folosind două dicționare nativ definite în limbajul Python, fără a face modificări în codul Python responsabil cu definirea arhitecturii rețelei. Pe baza acestor două dicționare se construiește efectiv rețeaua, în vederea antrenării. Această micro-infrastructură este capabilă să genereze grafice cu rapoarte în urma procesului de antrenare.

Rezultatele obținute sunt important de specificat la nivelul fiecărei componente implementate. În ceea ce privește componenta de detecție și clasificare a indicatoarelor rutiere, rezultatele care merită menționate sunt cei trei detectori antrenați de la zero. În ceea ce privește

componenta decizională pentru benzile de circulație, a fost impresionant de aflat modul în care scena din simulator surprinde în proporție covârșitoare detaliile din realitate, însă într-o manieră ideală, nefiind necesare foarte multe ajustări în setul de date furnizat la antrenarea rețelei. Mai mult decât atât, este un succes și faptul că rețeaua cu arhitectura modificată față de cea originală a reușit să clasifice imaginile astfel încât să poată generaliza pe traseul din realitate, mai ales că setul de date de antrenare a conținut imagini atât din realitate, cât și din simulator, putând, în final, să învețe modelul din date.