



Theia

Automated Perception Driving

Perceção para a condução autónoma

Imagine como será a sua vida no dia em que puder entrar no seu carro e não tiver de preocupar-se com o caminho que terá de fazer até a sua casa. Será suficiente partilhar onde pretende ir e, enquanto o carro o conduz de forma autónoma pela cidade, a decisão mais difícil que terá de tomar é se vai aproveitar o tempo livre para ler um livro, ver um filme ou responder a alguns e-mails. Neste dia, já não terá de preocupar-se com a sua segurança, porque os veículos autónomos irão reduzir drasticamente os acidentes nas estradas. Juntos, estamos a trabalhar para que este dia esteja cada vez mais próximo.

Focado no desenvolvimento de soluções de mobilidade avançada que vão permitir melhorias da perceção e capacidade de decisão dos veículos autónomos através de inteligência artificial, ao mesmo tempo que integra a cibersegurança para proteção da integridade do sistema e da privacidade do utilizador, o projeto THEIA é uma parceria de inovação entre a Bosch e a Universidade do Porto.

Visite a nossa exibição e fique a conhecer tecnologias que poderão vir a fazer parte dos veículos autónomos no futuro.

Subprojecto 1

O papel principal do conjunto de sensores de um veículo autónomo é ser um substituto da visão do condutor humano, fornecendo informações robustas sobre o ambiente externo do veículo em movimento, para permitir uma reação imediata ao ambiente dinâmico em constante mudança e às ameaças ao veículo em condução.

Atualmente, os veículos autónomos são tipicamente equipados com sensores e dispositivos de aquisição de dados 3D, por exemplo o sensor LiDAR, que fornecem uma point cloud 3D capaz de descrever a envolvente externa ao veículo. Estes dados 3D são comumente usados para evitar obstáculos e mapeamento. No entanto, o uso destes dados para uma perceção semântica da cena é ainda muito embrionário. Ao mesmo tempo, a análise da point cloud 3D é complexa, pois estas são não estruturadas, desordenadas e contêm um número variável de pontos.

As Redes Neurais Convolucionais (CNN, Convolutional Neural Networks) são projetadas para analisar dados de input organizados em estruturas de grelha, nas quais podem ser aplicados filtros lineares e invariantes (convoluções). Embora as CNN tenham um desempenho elevado na análise de imagens, elas não podem ser aplicadas naturalmente à point cloud. Propuseram-se variados métodos para permitir aplicar CNNs à análise de point clouds 3D. Uma abordagem comum é pré-processar os dados numa grelha de voxels 3D, na qual as CNNs podem ser aplicadas diretamente.

No entanto, é difícil conciliar um baixo custo computacional e uma boa exatidão. As point clouds também sofrem com ruído, outliers, dependência do referencial, oclusões e desafios de visibilidade.

Um dos principais desafios de percepção é prever comportamentos e ações em cenas dinâmicas. A compreensão semântica de ambientes dinâmicos permitirá que veículos autônomos operem em ambientes abertos, incertos e complexos.

Assim, o objetivo principal do SP1 é melhorar a exatidão da percepção de veículos autônomos, investigando e desenvolvendo soluções de Deep Learning para a compreensão automática da cena, detetando e rastreando múltiplos objetos em movimento (MOT, multi-object tracking) em ambientes de condução, bem como modelando o movimento (devido ao movimento da câmara/sensor) de partes estáticas da cena.

Para enfrentar esse desafio, este subprojecto é composto pelos seguintes tópicos:

- Segmentação pré-semântica (baseada apenas em LiDAR), que fornecerá informações sobre as condições atmosféricas, incerteza de bloqueio/qualidade do sinal do sensor e estimativa da distância.
- Detecção de objetos (comparação entre o sensor LiDAR e a fusão do LiDAR e RGB), dividido detecção de objetos estáticos e detecção de objetos dinâmicos.
- Estimação de Ego-Motion (comparação entre o sensor LiDAR e a fusão do LiDAR e RGB), que irá fornecer estimativas incrementais de poses (posição e orientação) para melhorar a localização do veículo autônomo.

Subprojecto 2

Os algoritmos baseados em redes neuronais artificiais para Perceção, estimação de egomotion e de object tracking que serão desenvolvidos no âmbito do subprojeto SP1 irão necessitar de plataformas de hardware eficientes que melhor satisfaçam os requisitos para os sistemas ADAS (Sistemas Avançados de Ajuda à Condução).

Este subprojecto irá responder a duas questões principais: primeiro, quais métodos ou algoritmos que são capazes de melhorar a eficiência da inferência e, ao mesmo tempo, diminuir o tempo de computação do hardware; e, em segundo, qual é a melhor arquitetura de hardware para as redes adaptadas. Neste sentido, este trabalho visa tornar a inferência menos complexa e mais eficiente através de (co-)design de hardware.

De modo a conseguir ultrapassar estes desafios, o SP2 é composto por três grandes tópicos:

Arquitetura de algoritmos altamente eficientes baseados em redes neuronais para Perceção com LiDAR

Aceleração por hardware em dispositivos embebidos reconfiguráveis

Desenvolvimento de coprocessador neuro-mórfico altamente eficiente



Subprojecto 3

Os recentes desenvolvimentos na área de **Computer Vision e Perceção** têm aumentado as expectativas em relação aos veículos autónomos. Por exemplo, as CNN são, hoje em dia, capazes de superar o ser humano na deteção e identificação de objetos, quer em imagens quer em vídeos. Contudo, os veículos autónomos, além de reconhecerem a envolvente externa, têm de tomar decisões, o que tem implicações em relação à segurança, desempenho, ética e responsabilização. A passagem do reconhecimento de baixo nível da cena para a tomada de decisão/raciocínio, em ambientes complexos e dinâmicos, está longe de ser trivial.

O SP3 centra-se em fornecer uma camada de lógica por cima da camada Perceção que irá permitir aos veículos autónomos raciocinarem sobre o ambiente envolvente e, assim, tomarem decisões adequadas. Essas decisões são altamente complexas, uma vez que envolvem inúmeras variáveis e muitos resultados/consequências possíveis. Por exemplo, um veículo autónomo está a conduzir numa autoestrada e tem a possibilidade de ultrapassar um veículo à sua frente, existindo, contudo, outro veículo 50 metros atrás de si a uma velocidade de 80 km/h. Deverá o veículo autónomo ultrapassar ou não? Quando um veículo autónomo identifica uma bicicleta a 70 km/h, é possível que esteja um ciclista a conduzir a bicicleta, ou será que a bicicleta está presa/ligada a um carro? Uma pessoa com 3 metros de altura deverá ser corretamente identificada como estátua? Os algoritmos de Perceção, por si só, são insuficientes para uma compreensão total da cena, sobretudo em contextos de ambientes complexos, imprevisíveis e incertos.

Outro desafio está relacionado com a autoconsciência do sistema/veículo enquanto está em operação. Por exemplo, sabendo que está a entrar num túnel, e que isso mudará as condições de iluminação, o veículo deverá alterar/reponderar as prioridades entre os sensores (atendendo que as câmaras têm uma degradação significativa sem iluminação).

Tecnologias semânticas, em particular no ramo de Computer Vision, têm um papel chave na resolução deste desafio, uma vez que estas são capazes de formalizar, usar representações de conhecimento e aplicar mecanismos de inferência em problemas complexos. Modelação formal do domínio, interligação de conhecimento, interoperabilidade semântica e reasoning (OWL DL, SHAC, etc.) são exemplos de benefícios das tecnologias semânticas. Aplicando estas tecnologias aos algoritmos de Perceção, irá aumentar a flexibilidade, a robustez e o desempenho desta camada, permitindo também uma representação do conhecimento consistente em todas as camadas necessárias à condução autónoma.

Por outro lado, o processo de tomada de decisão dos veículos autónomos necessita de ser interpretável, auditável e confiável. Por exemplo, em caso de acidente, o processo de tomada de decisão que levou àquele resultado específico necessita de ser analisado, quer para responsabilização quer para implementação de melhorias futuras. A capacidade de explicar o raciocínio por detrás das decisões irá acrescentar transparência aos sistemas autónomos, tornando-os mais confiáveis.

De forma a endereçar os desafios anteriormente mencionados, o SP3 é composto por três grandes tópicos:

- Representação de Conhecimento que irá recorrer aos resultados produzidos pelo SP4 (deteção de objetos) e SP1 (modelos de Deep Learning) para criar uma representação simbólica da envolvente, na forma de Base de Conhecimento.
- Mecanismos de Inferência e Aprendizagem, que irá utilizar o raciocínio lógico sobre a Base de Conhecimento para suportar/tomar as decisões.
- Algoritmos de Perceção Explicáveis, que irá abordar a problemática, considerada como nuclear na área da condução autónoma, de como produzir explicações que sejam interpretáveis pelo ser humano no processo de tomada de decisão. Cenários de ultrapassagem serão utilizados como caso de uso para prova de conceito no âmbito deste subprojeto, uma vez que estes são uma das manobras mais perigosas no contexto da condução – autónoma ou não autónoma.

Subprojecto 4

Os avanços mais recentes na camada de Percepção são motivados por técnicas de Deep Learning. De modo a obter algoritmos de Percepção robustos e exatos, é necessário um elevado volume de dados rotulados/etiquetados (dataset) de treino (centenas de milhões de bytes de dados). Um desafio adicional complexo é o de ter uma enorme quantidade de dados com a heterogeneidade/variedade e relevância suficientes para que as redes neuronais aprendam padrões a partir destes no contexto de uma tarefa específica da Percepção, que, no limite, deverá abranger todas as situações de condução, em particular as mais críticas.

Todavia, o ambiente de condução é tipicamente caracterizado como sendo incontrollável/imprevisível e complexo. A verdade é que as empresas com os melhores dados, especialmente rotulados/etiquetados, são as que estão um passo (ou muitos) à frente na corrida para a condução autónoma. Todas as empresas de referência nesta área têm uma enorme quantidade de datasets e múltiplos veículos para a recolha de dados, de modo a melhorar o desempenho dos modelos/algoritmos de Percepção, e a cada dia/hora estas empresas estão a aumentar o tamanho dos seus datasets.

Tendo em consideração os desafios acima referidos, o SP4 é obrigatório para potenciar a realização dos subprojetos SP1, SP2 e SP3, cujo foco é resolver problemas de Percepção, tendo como ponto de partida, pelo menos, os dados do sensor LiDAR e explorando abordagens de reasoning.

Isto significa que o objetivo principal deste subprojecto é fornecer datasets de treino (rotulados/etiquetados) e de validação com qualidade e quantidade suficientes para permitir o desenvolvimento de algoritmos de Perceção baseados em Deep Learning com exatidão e eficiência melhoradas.

De modo a assegurar resposta aos desafios apresentados, o SP4 é composto pelos seguintes tópicos:



Definição e construção de um veículo de ensaio capaz de recolher os dados necessários



Recolha de Dados em Laboratório



Recolha de Dados e validação em diferentes condições atmosféricas



Testes Laboratoriais reproduzíveis



Desenvolvimento de indicadores e scripts de avaliação de desempenho

Subprojecto 5

A nova geração de veículos é composta por múltiplos sensores (câmaras, GPS, LiDAR, RADAR, etc), ecrãs/displays, computadores e outros componentes tecnológicos (switches/routers, unidades de controlo eletrónico (ECU, atuadores, etc), que lhes permitirá atingir os níveis mais elevados da condução autónoma, de acordo com a classificação SAE. Além disso, os veículos autónomos devem gerar grandes volumes de dados a taxas consideráveis, na ordem de dezenas a centenas de gigabytes por minuto.

O envio de todos estes dados para a Cloud, utilizando a rede de comunicação celular, é irrealista, mesmo considerando as especificações da próxima geração de redes 5G, devido tanto ao volume de dados como ao número e à própria mobilidade dos veículos. No entanto, a nossa visão é de que alguns dados serão processados localmente (além de serem utilizados pelos respetivos componentes para a finalidade a que se destinam) e serão transferidos para a Cloud, permitindo que a informação seja utilizada para melhorar as decisões e segurança dos veículos autónomos. Além disso, prevemos ainda que situações em que as capacidades sensoriais dos veículos autónomos serão insuficientes para obter autonomia pretendida, obrigando os veículos a recorrer a sistemas externos para a assistência necessária.

Estas parecem suposições realistas por vários motivos, conforme ilustrado nos seguintes cenários.

Cenário 1

Para os veículos autônomos serem um meio de transporte viável, as suas decisões têm obrigatoriamente de ser auditáveis e endereçáveis/responsabilizáveis. Por isso, uma espécie de “caixa preta” deve ser usada para preservar os dados de condução, que estes sejam acedidos em caso de acidentes de trânsito ou outras situações. Contudo, é de esperar que estes dados sejam transferidos regularmente para a Cloud, por questões de disponibilidade e escalabilidade de armazenamento, mas também para valor acrescentado (por exemplo: agendar manutenção periódica do veículo; detetar componentes defeituosos que precisam de substituição; etc.).

Cenário 2

Embora seja de esperar que os veículos autônomos atuem como componentes isolados, isto é: tenham todos os sensores e atuadores necessários para atingir os níveis mais elevados de autonomia, os seus dados sensoriais poderão ser utilizados para gerar conhecimento, como é o exemplo da deteção de problemas nas estradas (exemplo: anomalias na superfície, como lombas ou buracos), podendo, assim, contribuir para o aumento da segurança, do conforto e da eficiência.

Cenário 3

Obstruções temporários (como: estradas inundadas, devido a chuva intensa ou rutura de um tubo de água, árvores caídas devido a mau tempo, etc.) ou outros perigos esporádicos (como a existência de gelo) nas estradas, que podem ser detetados pelos veículos sem necessidades de cálculos adicionais, podem ser reportados pelo veículo para a Cloud, de forma a que os outros veículos possam usar essa informação e possam, assim, reagir antecipadamente – quer evitando os perigos ou alterando a sua trajetória -, o que irá permitir reduzir o congestionamento e a probabilidade de acidentes de trânsito.

Cenário 4

Os veículos autónomos poderão também receber informação ou assistência externas para melhorar a sua autonomia. Por exemplo: num parque de estacionamento, um veículo autónomo poderá receber a sua rota para um espaço disponível diretamente da infraestrutura que gere o parque, em vez de procurar um espaço disponível – ao invés de procurar ele próprio por um espaço. Isto irá permitir aumentar a sua eficiência, pois o veículo pode seguir diretamente para o espaço designado, reduzindo a quantidade de tempo e energia usada para estacionar, mas também elimina a possibilidade de dois ou mais veículos disputarem pelo mesmo espaço. Esses quatro cenários destacam a necessidade dos veículos autónomos transferirem dados para uma infraestrutura de Cloud de suporte; bem como a necessidade de veículos autónomos em usarem dados/informações de fontes externas (incluindo sistemas Cloud e Edge) para enriquecer as suas decisões e, a necessidade de receberem assistência de sistemas externos (incluindo infraestruturas Edge).



UNIÃO EUROPEIA

Fundo Europeu
de Desenvolvimento Regional