

Metrikák meghatározása autonóm járműmodellek szenárió-alapú értékeléséhez

Tompa Tamás*, Németh Norbert*, Szőke László*, Aradi Szilárd*

*Budapesti Műszaki és Gazdaságtudományi Egyetem, Budapest
e-mail: [ttompa, nemeth.norbert]@edu.bme.hu, [szoke.laszlo, aradi.szilard]@kjk.bme.hu.

Kivonat: Jelen munka az autonóm járművek értékelésével, viselkedésük, manővereik számszerűsítésével foglalkozik. Célja, hogy olyan módszereket határozzon meg, melyek objektív mérőszámokat biztosítanak a közúti közlekedés és a forgalomban való haladás összetett feladatainak megvalósítására alkalmas algoritmusok összehasonlításához. Ehhez különböző metrikákat vizsgálunk meg, majd az így kapott eredményekből értékelési módszert alkotunk, amely alkalmazható lehet az új modellek létrehozásának folyamatában és azok minőségi összehasonlításában. A cikk nagy vonalakban bemutatja az autonóm járművek történetét és fejlődésük főbb mérföldköveit, majd az önállóság lehetséges pozitívumairól, negatívumairól is teszünk említést. Felsorolunk több mellettük szóló érvet, és foglalkozunk alkalmazásuk, elterjedésük legfontosabb akadályaival, és a hozzájuk kapcsolódó nehézségekkel. Ilyen például a megfelelő értékelő szimulációk készítése és a közúti tesztelés kivitelezhetőségének kérdése. A támogató érvek között pedig szerepelnek kényelmi és hatékonysági megfontolások is. A cikkben vizsgált algoritmusok között vannak szabályalapúak, illetve felügyelt vagy megerősítéssel tanuló alkalmazások is. Megjelenik az Imitation Learning módszere, Deep Q-Network alkalmazása, az Intelligent Driver Model, a Minimizing Overall Braking Induced by Lane Change modell és az Asynchronous Advantage Actor-Critic megközelítés is. Az algoritmusok mellett az irodalomban található tesztkörnyezetek, gyorsított tesztelési módszerek is említésre kerülnek. A munka eredményeként javaslatot teszünk olyan metrikák meghatározására, melyek monitorozásával és felhasználásával az autonóm vezetést támogató algoritmusok minőségi értékelése, összehasonlítása lehetségessé válik.

1. BEVEZETÉS

1.1 Az autonóm járművekről

Az autonóm járművet (Naukove et al., 2020) a környezetét érzékelő, emberi bemenet nélkül navigálni képes eszközként írja le. Az érzékeléshez felhasznált technológiák között van a GPS, odometria, radartechnológia, lézerek és a gépi látás is. A koncepció leírására nem csak az „autonóm” jelzőt használják, az eszközöket nevezik ezen felül „önvezető”, „vezető nélküli” és „intelligens” járműveknek is. Az első feljegyzett próbálkozások valamilyen szempontból önálló jármű létrehozására az 1920-as évekre tehetőek: ekkor született a Houdina Radio Control járműve, melyet egy közeli autóból, rádióhullám segítségével irányítottak. Több évtized elteltével, az 1960-as évekre már kísérleteztek speciális úttest segítségével megvalósított önálló vezetéssel. Az 1980-as években pedig megjelentek a látás-alapú módszerek is, melyek máig jelentős szerepet kapnak az önvezető járművek funkcionalitásában (Bimbraw, 2015). Nagyobb autógyártóktól azonban csak a 2000-es években kezdtek megjelenni az önvezetéssel kapcsolatos tesztelési célokra kialakított járművek (Naukove et al., 2020).

A járművek önállóvá tételének számos oka lehet. Ezek a gépek az emberek által irányított autókkal szemben több előnnyel is rendelkeznek. Ilyen előny a mobilitás és az utak biztonságának növelése, illetve a környezetszennyezés mértékének és a torlódások számának csökkentése. Felépítésük, működésük változatos, de jellemzően három részből áll: ezek az érzékelési, döntéshozatali és aktuációs rendszerek. Az érzékelésért felelős rendszert szintén több összetevőre bontják. Egyik része többek között a helymeghatározásért felelős alrendszer, aminek feladata a jármű pozíciójának követése. Ide tartozik továbbá a statikus és mozgó akadály-felismerő alrendszer, amely az akadályok felismeréséért és megkülönböztetéséért felel. A döntéshozatali rendszert hasonlóképp feloszthatjuk. Ennek részei lehetnek például az útvonal-, út- és viselkedéstervező alrendszerek (Badue et al., 2021).

Az autonóm járművek forgalomba engedése a mai napig számos problémát vet fel, ezért a bárki által megvásárolható, teljesen önvezető autók megjelenését a legtöbb gyártó a 2030-50-es évekre jöendőli. Azért ilyen távoli a cél, mert a járművek forgalomba helyezéséhez rengeteg tesztelésre van szükség, aminek során kiderül, hogy megfelelnek-e a számos rájuk vonatkozó biztonsági és jogi előírásnak, elvárásnak. A tesztelés egyik formája a fejleszteni kívánt járművek közutakra engedése, de ennek a módszernek több hátránya is

van. A gépi tanulást alkalmazó algoritmusok fejlesztésének fontos szempontja, hogy a jármű a lehető legtöbb, különböző helyzettel szembesüljön a tesztelés során. Ezek esetében tehát a közúti tesztelés nem ideális, hiszen az elvárások kielégítéséhez rengeteg, ebben a környezetben vezetett kilométerre lenne szükség. Emellett a biztonsági szempontból kritikus szituációk előfordulásának gyakorisága a valóságban alacsony, a vezetés nagyobb része monoton jellegű, így az ilyen algoritmusoknak kedvezőtlen. Az USA-ban például „csak” minden ötszázazredik vezetett mérföldre jut egy bejelentett ütközés, ez a szám a halálos áldozatot követelő karamboloknál pedig százmillió mérföld (Z. Huang et al., 2018). Ezen felül a gépi látás járműfelismerése és az olyan különleges körülmények, mint a rendőri közbeavatkozás, a szokatlan időjárás jelenségek vagy a napsütés kedvezőtlen visszaverődése is akadályt jelenthet az autonóm járművek biztonságos közúti haladására nézve (Bartuska & Labudzki, 2020), ezért tovább nehezíti a tesztjárművek tanulását. A gépi tanulás elvén működő járművek tesztelése pedig kiemelkedően fontos lehet, mivel a feketedoboz-effektus miatt a pontos kimenetet megismerni még nehezebb. Ezen nehézségek ellenére 2013-ban négy amerikai államban lehetővé tették az tesztüzemű autonóm járművek számára a közúti közlekedést. Ezt kihasználja járműveik fejlesztésére és tesztelésére többek között a Bosch, a Delphi, a Google Auto, a Nissan, a Mercedes-Benz, a Tesla Motors és a Volkswagen is (Naukove et al., 2020). Azonban a valós tesztek mellett, a fenti megfontolások fényében egyértelművé válik, hogy más módszerekre is szükség van a teszteléshez.

A problémára megoldást kínálhatnak a számítógépes szimulációk. A mesterségesen létrehozott szimulációs szituációk modellezhetnek összetett utakat, többszereplős forgalmat, vagy akár akadályokat is az algoritmusok többszempontú teszteléséhez. A szimulációk alkalmazását viszont szintén számos tényező akadályozza. Ezek közé tartozik például a valósághű környezetek létrehozásának nehézsége.

Az autók minőségbeli értékeléséhez figyelembe kell venni, hogy a jármű milyen önvezetési kategóriába tartozik. Az évek során a járművek automatizáltsági szintjének kategorizálására több modell is készült, melyek 3, 5 vagy 6 különböző szintre helyezik őket. Közös jellemző, hogy a legmagasabb fokozat a „teljesen autonóm” jármű, amely emberi irányítás nélkül képes a haladás megvalósítására, a körülményektől függetlenül. Az „American classification” a National Highway Traffic Safety Administration (NHTSA) által készített, ötszintes beosztás, amit 2016-ban a SAE 6 szintes definíciójához igazítottak. Ezek a szintek pedig a következők:

- A nulladik, ahol a jármű rendszereinek irányítása teljeskörűen a vezető feladata. Ilyenek a klasszikus járművek.
- Az első, ahol a jármű rendszerei közül már vannak, melyek automatizáltak longitudinális vagy laterális kontrolban, de sosem egyszerre mindkettőben. Ezen rendszerek működésbe lépése lehet önálló vagy a

vezető közreműködését igénylő, itt a vezető feladata a rendszerek ellenőrzése.

- A második, amelynél a jármű fel van szerelve a vezetést támogató rendszerekkel, amelyek megadott körülmények között a longitudinális és laterális kontrollt egyidejűleg ellátni képesek. Továbbra is a sofőr felelős mindenért.
- A harmadik, ahol a jármű már képes önálló haladásra a megfelelő körülmények között, a rendszerek működését még mindig a vezető koordinálja, illetve készen kell állnia az esetleges nehéz helyzetek átvételére a gépi irányítástól.
- A negyedik szinten már megvalósul a teljes önállóság bizonyos esetekben, viszont itt a vészhelyzeteket is képes kezelni a jármű. Ilyenkor egy biztonságos állapotba juttatja az autót és ott átadja a vezetést. A vezető beavatkozása már nem szükséges a megfelelő működéshez
- Az ötödik szint nem tartalmaz semmilyen megkötést a rendszer operációképességére. A vezetőnek nincs szerepe a járműben, pusztán utasként viselkedik. (Naukove et al., 2020).

Emellett a SAE International (korábban Society of Automotive Engineers) által leírt, hatszintes modell (Zanchin et al., 2017) és a Verband Der Automobilindustrie (VDA) modellje is széles körben használt.

1.2 Az önállóság pozitívumai

Az önvezető járművek megjelenése számos pozitívummal járhat majd. Ilyen lehet a rendszerek biztonságossága, aminek egyik oka, hogy a gép tulajdonságai több szempontból is kedvezőbbek az emberi sofőr tulajdonságainál. Az algoritmus nem fárad el, nem csökken a reakcióideje egy hosszabb út során, a hangulata sem befolyásolja a vezetési stílusát és sosem áll alkohol vagy más befolyásoló tényezők hatása alatt. A járművek logisztikai szempontból is hasznosabbnak bizonyulhatnak az ember által vezetettekénél, mivel képesek lehetnek részt vállalni a közösségi közlekedésben (Bartuska & Labudzki, 2020). Ennek egyik ága, a „carsharing” mára Budapesten is elterjedt. A város területén több szolgáltató kínálja eszközeit közösségi használatra. Ezek a járművek egyelőre adott határok között, emberi vezetéssel üzemelnek, de az autonóm járművek megjelenésével az ágazat megreformálódhat, hiszen az új járművek képesek lehetnek még hatékonyabbá tenni a használati készletét. Az önvezető autók például nem csak parkolóhelyeiken lennének elérhetőek, hanem akár a felhasználó hívására, az általa meghatározott helyen állhatnának rendelkezésére (Kang et al., 2017).

Az önállóság a kamionos fuvarozás, szállítmányozás területét is megváltoztathatná: a sofőrök fáradtságának tényezője és a munkával eltölthető idő jogi korlátai kieshetnek a szervezési szempontok közül. Az önállósított járműpark az esetleges munkaerőhiányokra is megoldást nyújtana, hiszen vezetőkre nem lenne szükség. További jelentős előny, hogy a

„vezetéssel” töltött idő valójában nem igényli az irányítást, és a folyamatos figyelmet. Ehelyett a sofőr utassá válik, és foglalkozhat munkával vagy akár szabadidős tevékenységgel is. Ez a kényelem szempontjából fontos különbség lehet, továbbá kiemelkedően kedvező torlódások, álló forgalom esetén, ahol a vezetéssel eltöltött idő „káriba veszne” (Bartuska & Labudzki, 2020). Ezen felül a „platooning”, vagyis az együttműködő, közös közlekedés megvalósítását is segítheti az önállósítás. Ennek előnyei közé tartozik az üzemanyaghatékonyság, ami a csoport elöl haladó tagjai által biztosított szélárnyéknak köszönhető, és a – kiszámítható környezetnek betudható – biztonságosabb haladás (Bergenheim et al., 2012).

2. FELHASZNÁLT IRODALOM

2.1 Gépi tanulásra épülő algoritmusok

A gépi tanulási algoritmusokat tanítási elvük alapján több kategóriába is sorolhatjuk. Az egyik ilyen a megerősítéses tanulást alkalmazók kategóriája; ez a módszer jelentősen elterjedt az autonóm járművek fejlesztésében. Alapelve, hogy egy rendszer irányítása megvalósítható jutalomfüggvények alkalmazásával. Itt a „jutalom” általában egy szám, melynek hosszútávú maximalizálása a rendszer feladata. Kedvezőnek ítélt döntések esetén a jutalom nagyobb lesz, míg a kedvezőtlen döntések kisebb jutalmat hoznak. Ez a mechanizmus segít az ágenseknek a megfelelő döntéseket meghatározni és alkalmazni.

Megerősítéses tanulást használ (Pek & Althoff, 2018) egy Deep Q-Network (DQN) alapú ágens fejlesztésekor. Az ágens minden t időlépésben információt kap a környezetéről pillanatnyi állapotáról („state”), majd ezt felhasználva dönt a következő cselekményéről. Ez itt lehet sávváltás balra, sávtartás, vagy sávváltás jobbra. Az ágens egy időlépéssel ezután, a cselekmény következményeként kapja jutalmát, mely adott irányelv („policy”) alapján kerül meghatározásra. Itt a feladata tehát sávváltási és sávtartási döntések meghozatala. A tanítási folyamat után az ágens értékelése 10 darab, autópályán előforduló szituáció szimulációjával zajlik. A pályán haladó további 50 darab jármű sebessége 10 és 24 m/s közé esik. Az ágens eredményességét a szerzők a szituációk teljesítése során elért átlagsebességgel határozzák meg, ahol viszonyítási alapként egy szabályalapú („rule-based”) módszerrel irányított jármű átlagát használják (Pek & Althoff, 2018).

Egy másik példa megerősítéses módszer alkalmazására (Mirchevska et al., 2017) műve. A szerzők célja egy megerősítéses tanulással tanított vezető autópályán előforduló helyzetekre való felkészítése. A feladatok része a kitűzött célsebesség lehető legpontosabb tartása, illetve az előzés végrehajtásának kivitelezése, és az ütközéshez vezető szituációk elkerülése. Ehhez egy költségfüggvényt („cost-function”) használtak (1). A vezetés fejlődését a tanítás minden tíz epizódja után 100 különböző helyzet segítségével

értékelték. A cikkben az értékelés szempontjai az ütközésmentes helyzetek százalékos aránya, az elért átlagos sebesség és az átlagos kumulált költség (K) voltak.

$$K(t) = \begin{cases} (v_{ego} - v_{elvárt})^2 * 0,0764, & \text{ha nem történt ütközés,} \\ 20000, & \text{ha ütközés történt,} \\ 1, & \text{ha jobb vagy bal irányú gyorsulás a döntés,} \\ 1, & \text{ha a jelenlegi döntés sávtartás, de az előző jobb vagy bal irányú gyorsulás volt,} \\ 1, & \text{ha a jelenlegi döntés jobb vagy bal irányú gyorsulás, de az előző sávtartás volt,} \\ 2, & \text{ha a jelenlegi döntés bal irányú gyorsulás, de az előző jobb irányú volt,} \\ 2, & \text{ha a jelenlegi döntés jobb irányú gyorsulás, de az előző bal irányú volt.} \end{cases} \quad (1)$$

(Mirchevska et al., 2017) költségfüggvénye

A (Feng et al., 2021) által készített kutatás nemcsak egy Deep Reinforcement Learning (DRL) módszerrel tanított ágens mutat be, hanem két, hasonló algoritmus számára készített tesztkörnyezetet is. Ezeket a környezeteket szimulációkban, 2000 km-es távon kétféle járművel tesztelik. Az egyik az IDM („intelligent driving model”) és MOBIL („minimizing overall braking induced by lane change”) modellek alapján készült „AV-I”, a másik a DRL-lel tanított „AV-II”. A két vezető értékelésekor vizsgált szempontok között voltak a TTC („time to collision”, az úgynevezett ütközésig fennálló idő), és a lökhárítótól lökhárítóig mért távolságok is. Az összehasonlításhoz ezeken felül mérték a következő helyzetek előfordulásának mennyiségét:

- ütközések,
- háttérművek bevágási („cut-in”) manőverei,
- háttérművek erős fékezésre kényszerítése,
- sávkonfliktus,
- és az AV sávváltása.

Szintén megerősítéses tanulással foglalkozik (Gu et al., 2020). A szerzők a „Waymo Open Dataset” elnevezésű adatbázis felhasználásával készítettek autonóm járműmodellt. A Datasetben szereplő adatokat a Waymo gyűjtötte autonóm járműveivel (AV-k), különböző forgalmi környezetekben. A járművek által eltárolt adatok között szerepelnek radar-, lidar- és képadatok is. Mivel ezen járművek vezetési irányelvei nem hozzáférhetők, a szerzők célja az eredetit imitáló algoritmus létrehozása volt. Az ehhez szükséges számításokhoz a Dataset 12-féle adatát használták fel, melyek a következők:

- v_x , v_y , és v_z az AV sebessége x , y és z irányokban,
- dx és dy az AV és az előtte haladó jármű távolsága x és y irányokban,
- v_{fx} , v_{fy} és v_{fz} az AV előtt haladó jármű sebessége x , y és z irányokban,

- a_{fx}, a_{fy}, a_{fz} az AV előtt haladó jármű gyorsulása x, y és z irányokban,
- $num_v_labels \in \{0, 1\}$ az AV előtt haladó járművek száma.
- ütközés statikus objektummal,
- ütközés járókelővel,
- valamint ütközés másik járművel.

Ezek mellett a Waymo autóin elhelyezett kamerák felvételeit is felhasználták, ez járművenként 5 különböző nézetet jelentett. Az így összegyűjtött adatokkal, a „long short-term memory” (LSTM) módszert alkalmazva x és y irányokba mutató gyorsulásértékek predikcióját valósították meg. Az így kinyert gyorsulásadatokat egy három szituációból álló vezetési folyamaton hasonlították össze a Waymo-s ground truth adatokkal.

Szintén predikcióval foglalkozott (Zhang et al., 2020). A munka adott, autópályán haladó ágens környezeti járműveinek mozgását vizsgálja. A szerzők a monitorozott adatokat önálló haladás megvalósításához és kockázatelemzéshez alkalmazták. Ennek részeként határozták meg az ütközés bekövetkeztének valószínűségét, és az ütközés súlyosságát. A felhasznált módszer a „Constant Turn Rate and Acceleration” (CTRA) és a „simplified maneuver recognition” modelleket integrálja. A kockázatot („Risk”) a következő módon definiálták:

$$Risk(\mathbf{x}_e^F, \mathbf{x}_{oi}^F, t) \triangleq P(\mathbf{x}_e^F, \mathbf{x}_{oi}^F, t) \cdot S(\mathbf{x}_e^F, t) \quad (2)$$

$$P(\mathbf{x}_e^F, \mathbf{x}_{oi}^F, t) = e^{-\frac{(x_e^F - x_{oi}^F)^2}{\sigma_1^2}} \cdot e^{-\frac{(y_e^F - y_{oi}^F)^2}{\sigma_2^2}} \cdot e^{-\frac{1}{\sigma_3^2} \left(\frac{x_e^F - x_{oi}^F}{v_{e,x}^F} \right)^2} \quad (3)$$

$$S(\mathbf{x}_e^F, t) = e^{-\frac{2}{a_4^2 m_e (v_e^F)^2}} \quad (4)$$

Ahol $Risk(\mathbf{x}_e^F, \mathbf{x}_{oi}^F, t)$ az ütközés kockázata az ágens (ACV) és az i környezeti jármű (SV_{*i*}) között, $P(\mathbf{x}_e^F, \mathbf{x}_{oi}^F, t)$ pedig a valószínűsége. $S(\mathbf{x}_e^F, t)$ az ütközés súlyossága, \mathbf{x}_e^F ACV, \mathbf{x}_{oi}^F pedig SV_{*i*} állapotvektora. m_e ACV tömege.

A szimulációs szoftverek között szereplő, korszerű forgalom megjelenítő és -irányító CARLA („CAR Learning to Act”) készítő a program bemutatásához három önvezető járműmodellet alkalmaztak (Dosovitskiy et al., 2017). Ezek közül az első megerősítéses tanulással, az „asynchronous advantage actor-critic” (A3C) algoritmus segítségével készült, a második imitációs módszerrel tanított, a harmadik pedig modulárisan fejlesztett volt. Az ágenseket négy navigációs helyzetbe helyezve, háttérfajművek között közlekedve értékelték. Feladatuk két pont közötti út keresése és követése volt. Az értékelés szempontjai között szerepelt a következő események előfordulásának gyakorisága:

- a jármű „lábnyomának” több, mint 30%-a átlóg a szembejövő forgalom sávjába,
- a jármű „lábnyomának” több, mint 30%-a rálóg a járdára,

2.2 Algoritmusok tesztelése és értékelése

A különböző algoritmusok tesztelésének fontossága számos tesztkörnyezet létrehozását eredményezte. Ezek közül több ma is a fejlesztők rendelkezésére áll. Két ilyen környezet szerepel például (Feng et al., 2021) fent említett kutatásában is. A „természetes” és „természetes és ellenséges” környezetek a háttérfajművek különböző vezetési stílusait hivatottak megjeleníteni. A szerzők szerint azért lehet szükség ellenséges környezetre, mert az önvezető járművek hétköznapi körülmények közötti tesztelésekor akár többmilliárd mérföldet is igénybe vehet egy eszköz biztonságosságának megállapítása. A kutatás tapasztalatai szerint a „természetes” környezethez viszonyítva a „természetes és ellenséges” környezetben jelentősen több ütközés, háttérfajmű általi bevágás és sávkonfliktus keletkezett. A „természetes és ellenséges” környezetben emellett a sávváltási manőverek relatív távolságai és sebességkülönbségei is alacsonyak voltak (Feng et al., 2021). Ez a példa is mutatja, hogy a természetes, hétköznapi környezetek nem felelnek meg maradéktalanul a tesztelés kapcsán felmerülő elvárásoknak.

Erre a problémára hivatkozik (Xu et al., 2018): a szerzők leírása szerint egy önvezető jármű 100 példányából álló flotta 25 mérföld per órával átlagsebességgel, az év 365 napján át tartó, egézszenapos vezetés mellett is 225 évet igényelne ahhoz, hogy a modell biztonságosságát hitelesen demonstrálja. A szerzők ezért olyan tesztkörnyezetet hoztak létre, amelyben megvalósítható különböző önvezető algoritmusok biztonságosságának gyorsított értékelése. Az értékelési folyamat részeként az autópályán előforduló bevágás („cut-in”) helyzetének részekre bontására és számszerűsítésére kiemelt figyelmet fordítottak. A szerzők indoklása szerint azért került a kutatás középpontjába ez a szcenárió, mert előfordulása gyakori, és veszélyessége nagy. Egy ilyen manőver során a következő értékeket monitorozzák:

- v , az önvezető jármű (AV) sebessége
- v_l , a sávváltó jármű (LCV) sebessége
- R , az LCV leghátsó és az AV legelső pontjai közötti távolság
- TTC , a „time to collision”, vagyis a következő képlet alapján az ütközésig számított idő:
$$TTC = -\frac{R}{v}$$

Hasonló céllal, a manőverek kockázatosságának felmérésével foglalkozik (Jiang et al., 2021) kutatása. A kockázatosság széleskörben elterjedt mérőszámaiként, a gyorsulással kapcsolatos adatok mellett kiemeli a „ TTC ” (idő az ütközésig), „ TTR ” (reakcióidő) és „ TTB ” (idő a fékezésig) metrikákat. A szerzők a balra és jobbra való sávváltáshoz, illetve a

sávtartáshoz határoznak meg biztonságos távolságokat. A biztonságos sávtartást a következő képlettel határozták meg:

$$D_{safe, kp} = v_r t_\delta + \frac{1}{2} a_{accel} t_\delta^2 + \frac{(v_r + a_{accel} t_\delta)^2}{2a_{r, brake}} - \frac{v_f^2}{2a_{f, brake}} \quad (5)$$

Itt a vizsgált jármű („B”) előtt haladó jármű („A”) sebessége v_f , „B” hosszirányú sebessége v_r (2. ábra). A biztonságos távolság meghatározásához feltételezik, hogy „A” $a_{f, brake}$ -kel lassul, míg meg nem áll. „B” pedig a_{accel} gyorsulással halad t_δ reakcióidőn át, majd $a_{r, brake}$ -kel lassul, míg szintén meg nem áll. A táv biztonságosnak ítéhető, ha a leírt folyamat alatt a két jármű nem érintkezik.



1. ábra: biztonságos sávtartás (Jiang et al., 2021)

Szintén manőverek értékelésével foglalkozik (H. Huang et al., 2020). A munkában indexeket határoztak meg egy jármű teszt pályán való haladásának értékelésére. Ezek a biztonsági, hatékonysági, racionalitási és kényelmi indexek. A hatékonysági indexet a következő képlet segítségével számolták:

$$U_{eff} = \frac{1}{2} m_i v_i^2 + \int_{t_0}^{t_f} G_i v_{i,x} dt \quad (6)$$

Itt a G_i virtuális gravitáció az eszközzel szemben támasztott mobilitási elvárásokat reprezentálja, és a (6) képlettel határozható meg, ahol m_i az i jármű tömege, g pedig a gravitációs gyorsulás.

$$G_i = m_i g \sin \theta_i \quad (7)$$

Innen θ_i -t a következő módszerrel határozták meg:

$$\sin \theta_i = k \frac{v_{der}}{v_{limit}} \quad (8)$$

Itt k állandó, a cikkben $k = 0,2$. v_{der} a vezető elvárt sebessége, v_{limit} a sáv sebességhatárátja, t_0 és t_f pedig a vezetési folyamat kezdő- és végideje. (H. Huang et al., 2020).

Ahogy az előbbi cikk szerzői, úgy több független kutatás is foglalkozik az autonóm járművek kényelmi szempontú értékelésével. (Müller et al., 2019) olyan kísérletet mutat be, melyben különböző, autópályán előforduló sávváltási és előzési helyzeteket az utas kényelmének szempontjából vizsgáltak, szimuláció segítségével. A szerzők három vezetési stílust különböztettek meg: ezek a kényelmes, a hétköznapi és a dinamikus vezetés, melyek paramétereit a 3. ábra

1. táblázat - Manőverek összehasonlítása vezetői stílusok alapján

| Manőver | Vezetési stílus | | |
|--|-----------------|------------------|-----------------|
| | Dinamikus | Hétköznapi | Kényelmes |
| Előzőtt járműtől mért távolság az előzés megkezdésekor (m) | 65 | 97,5 | 130 |
| Balra sávváltás időtartama (s) | 4 | 6,5 | 9 |
| Jobbra sávváltás időtartama (s) | 3,5 | 6 | 8,5 |
| Hosszirányú gyorsulás (m/s ²) | 0 és 2,8 között | 0 és 2,25 között | 0 és 1,5 között |
| Hosszirányú lassulás (m/s ²) | 0 és -6 között | 0 és -4 között | 0 és -2 között |
| Követési távolság az előzés után (s) | 0,9 | 1,8 | 2,9 |

tartalmazza. A kísérletben részt vevők kényelmének szintjét a szimuláció közben egy kézi visszajelző eszközzel és vizuális jelek segítségével értékelték, szimuláció után pedig kérdőívvel, melyen többszem pontú értékelést kértek.

Szintén kényelmi szempontból vizsgálja a járművek haladását (Yusof et al., 2016). A szerzők célja azon „kényelmi értékek” meghatározása, melyek mellett egy jármű utasa kellemesen érzi magát utazás közben. Három vezetési stílust vizsgáltak, melyek itt „asszertív”, „defenzív” és „LRT” elnevezést kaptak. Ezeket valódi vezetővel, Automatic Acceleration and Data controller (AUTOAccD) rendszer segítségével szimulálták. A szimuláció része volt egy bukkanó, ez a vertikális gyorsulást képviselte, egy kereszteződést megközelítő és elhagyó útszakasz, amik a hosszirányú gyorsulásokat, és egy kanyar, ami az oldalirányú gyorsulást.

A vezetők autonóm járművekhez fűződő viszonyát kevesebben vizsgálták, de egy példa (Brown & Laurier, 2017), akik ezzel a kérdéskörrel foglalkoznak. A cikkben videók alapján elemzik a Google és Tesla cégek autonóm járműveinek interakcióit más, emberek által vezetett járművekkel. Céljuk megállapítani, hogyan viszonyulnak a hétköznapi vezetők a vezető nélküli járművekhez. Ezen rövid áttekintés után áttérünk az általunk javasolt metrikák részletezésére, mellyel minőségben meg lehet állapítani egy autonóm járműirányítási funkció színvonalát/teljesítményét.

3. JAVASOLT METRIKÁK

Ebben a fejezetben a fentiek alapján javaslatokat teszünk a járművek értékelésére. A javasolt mérőszámokat négy csoportra bontottuk, az első csoportba az alapvető mérőszámok kerültek, a másodikba a biztonsághoz kapcsolódó minőségi jelzőket soroltuk. A harmadik a kényelemmel, míg a negyedik a fenntarthatósággal, környezetkíméllettel kapcsolatos adatokat tartalmazta.

3.1 Alapvető mérőszámok

Az általunk mérni javasolt, értékeléshez szükséges információkhoz olyan egyszerű, könnyen kinyerhető adatok

tartoznak, melyek minden, pályán haladó járműre megállapíthatóak, belső vagy külső szenzorai által megkaphatóak. Ezek a

- sebességértékek mindhárom irányban,
- gyorsulások longitudinális és laterális irányban és azok deriváltjai (jerk)
- illetve az autók elfordulása, dőlése mindhárom tengelyen, a deriváltjaikkal együtt.

Ezek az alapértékek a következőkben bemutatott metrikák számolásánál is fontos adatok. Viszont egy teljes kiértékeléshez az értékek időbeli alakulása, a fent meghatározott **időfüggvények minimuma, maximuma és átlaga** statisztikai alapon képes összehasonlítani a járművek mozgását. Az értékek mérésére alkalmazhatók extra IMU szenzorok, de a legtöbb autóban a fenti értékek meghatározása mindennapi gyakorlat.

3.2 Biztonsági metrikák

A biztonságos sávtartás, vagyis a **megfelelő követési távolság** tartásának fontossága megkérdőjelezhetetlen. Ennek a távolságnak meghatározására jó példa a (Jiang et al., 2021) munkájában definiált és használt képlet. A két jármű közötti biztonságos táv számításához a pontos képletet (4) tartalmazza. A számoláshoz a legtöbb érték mérhető alapmetrika, a hiányzó adatok pedig a környező járművekről valamilyen szenzor segítségével megkaphatóak. Például távolság-, sebesség- és gyorsulásmérésre alkalmas a már forgalmazott járművekben is elterjedt radar.

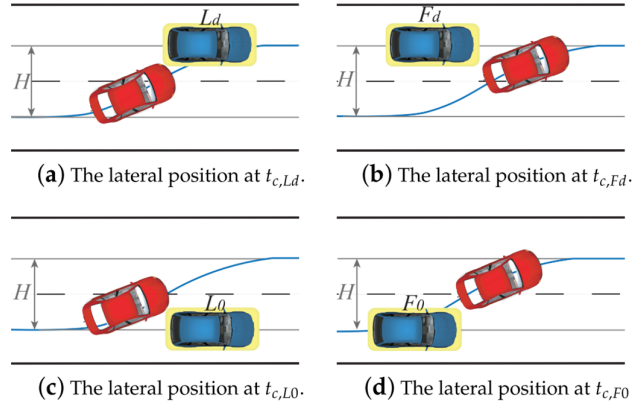
A **TTC**, vagyis „**time to collision**” két, egymás mögött haladó jármű ütközéséig számított idő. Ezt (Xu et al., 2018) a

$$TTC = \frac{R}{\dot{R}} \quad (9)$$

képlettel határozza meg, ahol R a hátul és az elől haladó jármű között mért legkisebb távolság, \dot{R} pedig ennek időbeli deriváltja. Emellett számíthatóak még a **TiV**, **TTR** és **TTB** értékek, melyek rendre „**time in between vehicles**”, „**time to react**” és „**time to brake**”. A mi esetünkben a TTR a legnehezebb paraméter, melyet hozzáadott mérés nélkül tudnánk használni, ezért ennek alkalmazását javaslatunkból mellőzzük. A TiV számolási képlete:

$$TiV = \frac{R}{v_b} \quad (10)$$

Ahol a v_b a hátul haladó jármű sebessége. A TTB pedig az elől haladó jármű lassulása és a hátsó jármű fékezésének megkezdése közötti idő. A bevágás, vagy „cut-in” értékelésével is többen foglalkoztak pl.: (Xu et al., 2018). Mi hasonlóképp a követési távolsághoz, a figyelt autó mögött haladó jármű szemszögéből is kiszámoljuk az értékeket. Ezek



3. ábra (Jiang et al., 2021)

átlaga, minimuma és maximuma szintén jó mérőszámokat adhat a vezetői minőségre.

A (Dosovitskiy et al., 2017)-ben leírt módszer olyan **kiemelt események** bekövetkezési gyakoriságát mutatja, melyekkel a szerzők értékelték a járművet (a kiemelt események: lásd 2.1 alfejezet). Az általunk javasolt számolható metrikák a következők:

- **Ütközések száma / megtett kilométer**
- **Ütközések nagysága / megtett kilométer**
- **Vészfékezések száma / megtett kilométer**
- **Hirtelen irányváltoztatás / megtett kilométer**
- **Autó sávon kívül tartózkodása legalább 30%-kal:**
 - alkalom / megtett kilométer
 - időtartam / megtett kilométer

Ütközés esetén felhasználható a két résztvevő relatív sebessége, mely az ütközés súlyosságát befolyásolja. Többszereplős ütközést ebben a munkában nem vizsgálunk, ez további kutatásoknak ad teret. Vészfékezésnek detektálunk minden olyan negatív gyorsulást, ami egy adott határnál (pl. 6 m/s^2) nagyobb. A vészfékezés lassulási értékei kiterjedhetnek 7 m/s^2 -től akár 9 m/s^2 -ig (Kudarauskas, 2007). Hirtelen irányváltoztatás főleg a laterális hirtelen mozgásokra utal, itt is egy thresholdhoz viszonyítunk. Az autó sávelhagyásának megállapításához viszont valamilyen kamera-alapú megfigyelés szükséges, de ez esetleg a térkép ismeretében, pozícióból is számolható. Ezen események detektálása mind szimulációban, mind pedig a valóságban lehetséges.

Ugyancsak Jiang fent említett kutatásában az előzés helyzetét analizálták, és ehhez határoztak meg biztonságosnak ítélt távolságokat. Ezek számolásához, az oldalirányú mozgás leírására a (11)-(13) egyenletekből álló modellt alkalmazták. Ahol H a rendelkezésre álló szélesség, t_{lat} az oldalirányú mozgáshoz igénybe vett idő, y_{start} a manőver előtti, y_{target} pedig a manőver utáni laterális pozíció. A szerzők 4 kritikus pozíciót határoztak meg (4. ábra), melyekre a biztonságos távolságokat számították. Mivel a hossz- és oldalirányú mozgások ideje megegyezik, T időtávra meghatározhatóak a biztonságos

távolságok. D_{Ld} , D_{L0} , D_{Fd} , and D_{F0} a biztonságos hosszirányú távolságok.

$$a_{lat} = \frac{2\pi H}{t_{lat}^2} \sin\left(\frac{2\pi}{t_{lat}}\right) \quad (11)$$

$$y(t) = -\frac{H}{2\pi} \sin\left(\frac{2\pi}{t_{lat}} t\right) + \frac{H}{t_{lat}} t + y_{start} \quad (12)$$

$$H = |y_{target} - y_0| \quad (13)$$

A (14abcd) képletekben bemutatott számolások a sáv szélességén túl többletinformációt nem igényelnek, így egy-egy manőver esetén megfelelő mérőszámok lehetnek modellek összehasonlítására. Nevezzük őket **előzési biztonságos távolságoknak**.

$$D_{Fd} = \max_t \left(\int_0^t \int_0^\lambda (a_{Fd}(\tau) - a_m(\tau)) d\tau d\lambda + (v_{Fd} - v_m)t \right), \forall t \in [t_{c,Fd}, T] \quad (14a)$$

$$D_{Ld} = \max_t \left(\int_0^t \int_0^\lambda (a_m(\tau) - a_{Ld}(\tau)) d\tau d\lambda + (v_m - v_{Ld})t \right), \forall t \in [t_{c,Ld}, T] \quad (14b)$$

$$D_{F0} = \max_t \left(\int_0^t \int_0^\lambda (a_{F0}(\tau) - a_m(\tau)) d\tau d\lambda + (v_{F0} - v_m)t \right), \forall t \in [0, t_{c,F0}] \quad (14c)$$

$$D_{L0} = \max_t \left(\int_0^t \int_0^\lambda (a_m(\tau) - a_{L0}(\tau)) d\tau d\lambda + (v_m - v_{L0})t \right), \forall t \in [0, t_{c,L0}] \quad (14d)$$

3.3 Kényelmi metrikák


A kényelemmel kapcsolatos adatok szubjektívek, ám vannak közöttük olyanok, melyek hatékonyan monitorozhatóak és alkalmazhatóak. Fontosak lehetnek például az oldalirányú gyorsulások. (Müller et al., 2019) fent említett kutatása szerint a később kezdeményezett, rövidebb ideig tartó sávváltásokat a kutatás résztvevői kényelmetlenebbnek ítélték a hamarabb kezdeményezett és több ideig tartóknál. Ezt (Yusof et al., 2016) kutatása is alátámasztja. A résztvevők által legkényelmesebbnek ítélt időtartam balra irányuló sávváltás esetén 6,5 és 9 másodperc közötti, jobbra irányuló esetén pedig 8,5 másodperc volt. Ennek megfelelően a következő metrikákat érdemes meghatározni:

- **Sávváltás időigénye**
- **Longitudinális és laterális gyorsulások nagysága és folytonossága**
- **Ezek deriváltjának (jerk) átlag- és szélsőértékei**


Ezen értékek számolásához az eddigiekben meghatározott információknál több nem kell, csupán a manőver kezdetének és végének megfelelő detektálása szükséges.

3.4 Fenntarthatósági metrikák

A fenntarthatóság napjainkban egyre nagyobb hangsúlyt kap a járműfejlesztés területén is, így egy kitekintéssel megnézzük, milyen metrikákat lehet figyelembe venni az autonóm algoritmusok fejlesztésénél. A (Mirchevska et al., 2017) által összeállított költségfüggvény jó példa a környezetvédelmi szempontok figyelembevételére, hiszen itt az ágens „büntetést” kap a felesleges irányváltoztatásért. Továbbá mérhető a fogyasztás, illetve a gáz- és fékkezéssel okozta elpazarolt energia. Mértéke lehet hozzáadott szenzorokkal a különböző károsanyag-kibocsátásokat, mint például CO_2 , CO , NO_x . Ezen képletek és konkrét értékelések meghatározása



4. ábra: Sebességek alakulása



5. ábra: Gyorsulások alakulása

azonban túlmutat a jelenlegi munkán, viszont mélyebb vizsgálatuk hosszútávú céljaink között mindenképpen szerepel.


4. KIÉRTÉKELT SZITUÁCIÓK

Ebben a fejezetben példát mutatunk azokra a metrikákra, melyeket az előző fejezetek során taglaltunk. A CARLA szimulátor segítségével készítettünk egy szimulációt, melyet két beépített ágens és egy emberi irányítással is megfigyelünk. Ezt követően a metrikákat felhasználva vizsgáljuk a viselkedésüket és értékeljük az ágensket. A szimuláció fixálva volt, így az irányítók ugyanazokkal a helyzetekkel szembesültek. A szimuláció és ezzel együtt a beavatkozási lehetőség 30 FPS, azaz egy másodperc alatt 30 beavatkozás adható. Az egyik CARLA autopilot (továbbiakban normál) alapértelmezett, átlagos vezetési stílussal rendelkezik, míg a második agresszívabb megközelítést alkalmaz a közlekedés során (továbbiakban: agresszív). Harmadik példánk egy általunk vezetett jármű adatai (továbbiakban: élő), melyet kormány, gáz és fékpedál segítségével, a szimulátor élő irányításával értünk el. A tesztjármű egy Tesla model3s, a szimulált környezet egy 3 sávú autótút moderált forgalommal, jó látási és tapadási viszonyokkal.

2. táblázat – Metrikák összehasonlítása különböző vezetési profilokkal

| | Maximum | | | | | | | Átlag | | | | | | | |
|-----------|---------------------------------|---------------------------------|--------------------------------|--------------------------------|----------------|------------------------------|------------------------------------|-----------------------------------|---------------------------------|--------------------------------|---------------------------------|----------------|------------------------------|------------------------------------|-----------------------------------|
| | x gyorsulás [m/s ²] | y gyorsulás [m/s ²] | x lassulás [m/s ²] | y lassulás [m/s ²] | sebesség [m/s] | legyezési szögsebesség [1/s] | jerk gyorsulás [m/s ³] | jerk lassulás [m/s ³] | x gyorsulás [m/s ²] | x lassulás [m/s ²] | y gyorsulás [m/s ²] | sebesség [m/s] | legyezési szögsebesség [1/s] | jerk gyorsulás [m/s ³] | jerk lassulás [m/s ³] |
| Normál | 13,76 | 9,54 | -5,98 | -8,41 | 13,82 | 1,01 | 328,00 | -93,51 | 0,43 | -0,78 | 0,74 | 7,83 | 0,07 | 2,77 | -2,59 |
| Agresszív | 13,76 | 10,11 | -27,10 | -8,93 | 13,31 | 1,00 | 511,00 | -456,35 | 0,81 | -3,40 | 0,94 | 8,04 | 0,08 | 2,90 | -2,59 |
| Élő | 13,60 | 24,72 | -25,54 | -15,37 | 30,91 | 1,80 | 574,20 | -334,61 | 3,11 | -2,04 | 1,18 | 8,60 | 0,17 | 8,96 | -7,68 |

| | Minimum | | | | Átlag | | | | Események | | | | | | |
|-----------|-----------------------|-------------------------|--------------|----------------|--------------|----------------|-----------------------|-------------------------|--------------|----------------|--------------|----------------|----------------|--------------------|------------------|
| | követési táv elől [m] | követési táv hátral [m] | TIV elől [s] | TIV hátral [s] | TTC elől [s] | TTC hátral [s] | követési táv elől [m] | követési táv hátral [m] | TIV elől [s] | TIV hátral [s] | TTC elől [s] | TTC hátral [s] | Ütközések [db] | Vészfékezések [db] | Sávváltások [db] |
| Normál | 9,66 | 6,63 | 0,77 | 2,01 | 3,08 | 2,49 | 26,31 | 26,68 | 2,34 | 22437 | 6,2 | 25612,6 | 0 | 0 | 2 |
| Agresszív | 9,27 | 14,5 | 1,09 | 3,31 | 1,73 | 11,03 | 22,75 | 14,66 | 2,14 | 4,4 | 43,4 | 31,06 | 0 | 3 | 2 |
| Élő | 5,15 | 5,34 | 0,44 | 0,42 | 0,85 | 0,52 | 15,45 | 23,23 | 534,13 | 65807 | 9,61 | 48,95 | 0 | 6 | 6 |



6. ábra: Követési távolságok alakulása

A 4. ábra a vezetők sebességét hasonlítja össze. Itt megfigyelhető, hogy a teljesen megegyező környezeti szituációban hogyan alakul a sofőrök sebessége. A normál sofőr nem alkalmaz akkor fékezéseket, hanem kisebb sebességekkel, kevesebb gyorsítási és lassítási manővert végez. Az agresszív sofőr ugyanakkor állóra is fékezi az autót olykor, illetve nagyobb sebességeket választ. Legtöbbet azonban az élő sofőr sebessége ingadozik. Ez fakadhat a szimulációhoz való adaptáció nehézségeiből, illetve a valós stílusból. Az is látható, ahogy a szimulációk hossza nem egyforma hosszúságú, hiszen a nagyobb sebességgel közlekedő ágensek hamarabb elérik a célt.

Az 5. ábrán mutatjuk meg az autók hosszirányú tengely menti gyorsulásértékeit. Megfigyelhető a CARLA sofőrök sebességkövetését megvalósító PID kontrol, ami a sebességet a gyorsulás irányának váltakozásával követi. Az agresszív sofőrnél láthatóak a nagyobb gyorsulás- és lassulásértékek is. A szimuláció során megfigyelhető nagy lassulási tuskét a tapadási súrlódás (a fékek betapadása) okozza. Az 5. és 6. ábrán is 800 lépésnél kezdjük el mutatni a szimuláció adatait. Ez azért történt, mert a szimuláció elején egy piros lámpánál állnak a sofőrök. A különböző stílusok nem csak a sebességprofilot változtatják meg, de a 6. ábrán látható követési távolságokat is. A szituáció folyamán nyomon követhető, melyik sofőr mekkora követési távolságot tart. Az 50 méternél

messzebb lévő tárgyak kiesnek a szenzor hatótávolságából, ezért a maximális távolságot 50 méterben definiáltuk és a hatótávolságon kívüli értéket (∞) nem ábrázoljuk. Az ábrán a sávváltások ugrásszerű távolságváltozást okoznak, ezeket piros karikával jelöltük. Az agresszív sofőr gyorsan csökkenti a követési távolságokat, illetve 10 méter körüli távolságot tart minimálisan. Az is megfigyelhető, hogy az általunk vezetett autó vált a legtöbbet sávot, és nála a legkisebb a követési távolság.

A 2. táblázatban kiragadtunk pár metrikát, melyek jól jellemzik a különböző sofőröket. A gyorsulási minimum és maximum értékek egyértelműen tükrözik a feltételezéseinket az adott stílusokkal kapcsolatban. Az élő sofőr láthatóan jóval nagyobb oldalirányú gyorsulást engedett meg magának, hiszen az ebből fakadó utazási kényelmetlenséget nem éreztük. Ezzel egybevág a legyezési szögsebesség maximális értéke is, ami szintén a sofőr intenzív kormánykezelésén, és a jármű sebességén múlik. Az x irányú gyorsulás maximuma nagyjából egyforma mindhárom sofőrre, ezt a szimulációs jármű (Tesla S) karakterisztikája limitálja. Ugyanakkor, ha az átlaggyorsulást nézzük, megfigyelhető a különbség az agresszív és normál sofőr között, míg ez az általunk vezetett járműnél a legmagasabb. Ezt a fenti ábrák alá is támasztották. Érdekesekek lehetnek még a maximális lassulások, melyek ugyancsak a stílusnak megfelelően alakulnak, csakúgy, mint a TIV és TTC paraméterek. A különböző eseményeket is logoltuk, melyet szintén a 2. táblázat tartalmaz. A vészfékezések illetve sávváltások szintén segítik az ágensek kategorizálását. Ezek alapján megállapíthatjuk, hogy a mért értékek összefüggenek a stílusok kategóriáival, ezek alapján pedig be lehet sorolni a sofőröket kategóriákba. Fontos azonban, hogy nincs abszolút jó érték, így mindenki saját maga kell definiálja, mi az a tartomány, amin belül szeretné az ajánlott metrikákat tartani.

5. KONKLÚZIÓ

Ebben a munkában áttekintettük az autonóm járművek fogalmát és önállóságuk szintjeit. Irodalomkutatásunk az önvezető autók gépi tanulással megvalósított irányításának megoldásait célozta. Kísérletet tettünk olyan metrikák meghatározására, melyek képesek minőségben különbséget

teni gépi tanulással készített irányító algoritmusok között. Ezeket csoportosítottuk, és részleteztük, melyeknél milyen metrikákat érdemes használni, valamint megadtuk a használatukhoz szükséges mérendő adatokat, illetve azt, hogy hogyan lehet számolni őket. Az általunk javasolt metrikákból néhányat kiválasztva alkalmazási példát is mutattunk a CARLA szimulátor segítségével, és megállapítottuk a CARLA beépített autopilot különböző paraméterezésének hatását a metrikák alakulására. Összességében pedig hangsúlyoztuk az általunk megadott biztonsági és általános metrikák használatának fontosságát a gépi tanulási alkalmazások értékelésénél. A projektek célorientált minőségbiztosítása mellett az összehasonlíthatóságot segítően elő egy sztenderd metrikarendszerrel. Ugyanakkor a metrikák elfogadható tartományának meghatározása további kutatást igényel, illetve projekt- és feladatspecifikus. Munkánk folytatása pedig egy olyan evaluációs keretrendszer kialakítása lesz, ami lehetővé teszi az elkészült algoritmusok általános összehasonlítását, tehát egy úgynevezett „benchmark”-ot biztosít az önvezető autók irányításának szoftverfejlesztésével foglalkozó kutatásoknak.

6. KÖSZÖNETNYILVÁNÍTÁS

EFOP-3.6.3-VEKOP-16-2017-00001: Tehetséggondozás és kutatói utánpótlás fejlesztése autonóm járműirányítási technológiák területén - A projekt a Magyar Állam és az Európai Unió támogatásával, az Európai Szociális Alap társfinanszírozásával valósult meg.

7. HIVATKOZÁSOK

- Badue, C., Guidolini, R., Carneiro, R. V., Azevedo, P., Cardoso, V. B., Forechi, A., Jesus, L., Berriel, R., Paixão, T. M., Mutz, F., de Paula Veronese, L., Oliveira-Santos, T., & De Souza, A. F. (2021). Self-driving cars: A survey. In *Expert Systems with Applications* (Vol. 165, p. 113816). <https://doi.org/10.1016/j.eswa.2020.113816>
- Bartuska, L., & Labudzki, R. (2020). Research of basic issues of autonomous mobility. *Transportation Research Procedia*, 44, 356–360. <https://doi.org/10.1016/j.trpro.2020.02.031>
- Bergenheim, C., Pettersson, H., Coelingh, E., Englund, C., Shladover, S., & Tsugawa, S. (2012). Overview of platooning systems. *19th Intelligent Transport Systems World Congress, ITS 2012*.
- Bimbrow, K. (2015). Autonomous cars: Past, present and future: A review of the developments in the last century, the present scenario and the expected future of autonomous vehicle technology. *ICINCO 2015 - 12th International Conference on Informatics in Control, Automation and Robotics, Proceedings, 1*, 191–198. <https://doi.org/10.5220/0005540501910198>
- Brown, B., & Laurier, E. (2017). The trouble with autopilots: Assisted and autonomous driving on the social road. *Conference on Human Factors in Computing Systems - Proceedings, 2017-May*, 416–429. <https://doi.org/10.1145/3025453.3025462>
- Dosovitskiy, A., Ros, G., Codevilla, F., Lopez, A., & Koltun, V. (2017). *CARLA: An Open Urban Driving Simulator. CoRL*, 1–16. <http://arxiv.org/abs/1711.03938>
- Feng, S., Yan, X., Sun, H., Feng, Y., & Liu, H. X. (2021). Intelligent driving intelligence test for autonomous vehicles with naturalistic and adversarial environment. *Nature Communications*, 12(1). <https://doi.org/10.1038/s41467-021-21007-8>
- Gu, Z., Li, Z., Di, X., & Shi, R. (2020). An LSTM-based autonomous driving model using a waymo open dataset. *Applied Sciences (Switzerland)*, 10(6), 1–14. <https://doi.org/10.3390/app10062046>
- Huang, H., Zheng, X., Yang, Y., Liu, J., Liu, W., & Wang, J. (2020). An integrated architecture for intelligence evaluation of automated vehicles. *Accident Analysis and Prevention*, 145, 105681. <https://doi.org/10.1016/j.aap.2020.105681>
- Huang, Z., Lam, H., Leblanc, D. J., & Zhao, D. (2018). Accelerated Evaluation of Automated Vehicles Using Piecewise Mixture Models. *IEEE Transactions on Intelligent Transportation Systems*, 19(9), 2845–2855. <https://doi.org/10.1109/TITS.2017.2766172>
- Jiang, B., Li, X., Zeng, Y., & Liu, D. (2021). A maneuver evaluation algorithm for lane-change assistance system. *Electronics (Switzerland)*, 10(7). <https://doi.org/10.3390/electronics10070774>
- Kang, N., Feinberg, F. M., & Papalambros, P. Y. (2017). Autonomous electric vehicle sharing system design. *Journal of Mechanical Design, Transactions of the ASME*, 139(1). <https://doi.org/10.1115/1.4034471>
- Kudarauskas, N. (2007). Analysis of emergency braking of a vehicle. *Transport*, 22(3), 154–159. <https://doi.org/10.1080/16484142.2007.9638118>
- Mirchevska, B., Blum, M., Louis, L., Boedecker, J., & Werling, M. (2017). *Reinforcement Learning for Autonomous Maneuvering in Highway Scenarios Fitted Q-iteration with Extremely Randomized Trees*. 32–41.
- Müller, alexander, Beyer, S., Kopp, G., & Deißer, O. (2019). *User-Centered Development of a Public Transportation Vehicle Operated in a Demand Responsive Environment* (Vol. 964). Springer International Publishing. <https://doi.org/10.1007/978-3-030-20503-4>
- Naukowe, Z., Ślaskiej, P., & Transport, S. (2020). *Scientific Journal of Silesian University of Technology. Series Transport – PROBLEMS AND ISSUES*. 108(27), 133–140.
- Pek, C., & Althoff, M. (2018). *High-level Decision Making for Safe and Reasonable Autonomous Lane Changing using Reinforcement Learning Safe Human-Robot Co-Existence View project Formal Controller Synthesis using Optimization and Reachability Analysis View project*. <https://www.researchgate.net/publication/327690711>
- Xu, Y., Zou, Y., & Sun, J. (2018). Accelerated testing for automated vehicles safety evaluation in cut-in scenarios based on importance sampling, genetic algorithm and simulation applications. *Journal of Intelligent and Connected Vehicles*, 1(1), 28–38. <https://doi.org/10.1108/jicv-01-2018-0002>
- Yusof, N. M., Karjanto, J., Terken, J., Delbressine, F., Hassan, M. Z., & Rauterberg, M. (2016). *The Exploration of Autonomous Vehicle Driving Styles*. 245–252. <https://doi.org/10.1145/3003715.3005455>
- Zanchin, B. C., Adamshuk, R., Santos, M. M., & Collazos, K. S. (2017). On the instrumentation and classification of autonomous cars. *2017 IEEE International Conference on Systems, Man, and Cybernetics, SMC 2017, 2017-Janua*, 2631–2636. <https://doi.org/10.1109/SMC.2017.8123022>
- Zhang, L., Xiao, W., Zhang, Z., & Meng, D. (2020). Surrounding Vehicles Motion Prediction for Risk Assessment and Motion Planning of Autonomous Vehicle in Highway Scenarios. *IEEE Access*, 8. <https://doi.org/10.1109/ACCESS.2020.3039789>