

A gépi tanulás szerepe és hatásai a közlekedésben

Napjainkban a közlekedés folyamatos változáson megy keresztül, amely szinte minden részterületét érinti és hatással lesz a jövőre is. Közlekedésszervezési oldalon az új adatgyűjtési technikák soha nem látott lehetőségeket nyitottak meg a forgalombecslés és -irányítás területén.

DOI 10.24228/KTSZ.2020.1.1

Bécsi Tamás – Aradi Szilárd – Fehér Árpád

BME Közlekedés- és Járműirányítási Tanszék

email: becsi.tamas@mail.bme.hu • aradi.szilard@mail.bme.hu • feher.arpad@mail.bme.hu

1. BEVEZETÉS


Az emberek nagy részénél meglévő okoseszközök lehetővé teszik az új innovatív navigációs és útvonaltervező szolgáltatások (1. ábra) kifejlesztését. Ez utóbbiakat már nem is igazán írja le jól a nevük, hiszen ennél jóval összetettebb megoldások jelennek meg, amelyeket az ún. „Mobility as a Service” kifejezés alá sorolhatunk. Ennek során már a felhasználó teljes mobilitási igényeire keressük a válaszokat, beleértve a közlekedési módozatokat, figyelembe véve a különböző optimalizálási kritériumokat (eljutási idő, költség, károsanyag-kibocsátás). Ennek részeként egyre nagyobb teret kapnak a járműmegosztó szolgáltatások, ahol a legkülönbözőbb típusú és kategóriájú járműveket vehetik igénybe a felhasználók a nagyvárosokban, kihasználva az okoseszközök által nyújtott kényelmi szolgáltatásokat.

Járműipari oldalon két fő területen láthatunk komoly fejlődést. A hajtásláncoknál jelenleg még lassan, de folyamatosan gyorsuló ütemben terjednek az olyan alternatív megoldások, mint a hibrid és elektromos hajtások. Ezt

a folyamatot tovább gyorsította a 2015-ben kirobbant „dízelbotrány”, valamint a német szövetségi bíróság 2018. februári ítélete, amely lehetővé teszi az Euro 6-os környezetvédelmi besorolásnál rosszabb dízelüzemű gépjárművek városokból történő kitiltását.

A másik jelentős tempóban fejlődő terület a vezetéstámogató rendszereké ([1] és [2]), ahol a fejlesztők célja, hogy végül teljesen automatizált járművek közlekedjenek az utakon. Ennek elérése érdekében két technológiai terület bevonására van szükség. Az egyik a modern vezetékek nélküli infokommunikációs megoldások, a másik pedig a mesterséges intelligencia, azon belül is a gépi tanulás. A hagyományos autógyártók és beszállítók ezzel a tudással korábban nem rendelkeztek, így mozgástérhez jutottak a nagy nemzetközi IT cégek. Ezek komoly hatással voltak az elmúlt évek fejlesztéseire, amelyek között találunk pozitív és negatív példákat is. Az egyik legjelentősebb fejlesztés a Google önvezető autója, amely Waymo néven jelenleg egy publikus pilot projektet futtat egy teljesen önvezető flottával Arizona állam bizonyos városaiban.

1. ábra: Waymo önvezető autó tesztelés közben és a Google útvonalajavaslatai (forrás: Waymo, Google)



A fejlesztők rendkívül komolyan veszik a biztonságot [3] és kellő figyelmet fordítanak mind a virtuális, mind pedig a valós tesztekre. Sajnos negatív tapasztalatokat is találunk az elmúlt évekből. Az egyik a Tesla Autopilot nevű rendszerével kapcsolatos, amely több halálos kimenetelű balesethez (például [4]) vezetett. Mivel a rendszer 2-es szintű vezetéstámogató rendszer, ezért jogilag a járművezető a felelős. A másik szomorú példa az Uber tesztelés alatt álló önvezető járműve – emberi felügyelet mellett – elgázolt egy kerékpárost, aki nem élte túl az ütközést. A téma felkapottsága miatt a fejlesztők minél gyorsabban próbálnak eredményeket felmutatni, és az új szereplők nem mindig követik azokat a biztonsági és teszte-

lési eljárásokat, amelyek a hagyományos gyártóknál már beváltak. Mindezek komoly etikai kérdéseket vetnek fel, amelyek veszélyeztethetik az önvezető járművek társadalmi elfogadottságát.

Cikkünkben először bevezetjük a mesterséges intelligencia és a gépi tanulás fogalmát. Ezt követően rámutatunk a jogi, etikai és infrastrukturális kérdésekre, és egy rövid kitekintést adunk arról, hogy milyen hatással lehet ez az innovációs szektorra. Végül egy konkrét esettanulmányon keresztül bemutatjuk a gépi tanulás járműirányítási célú felhasználását, amit a ZalaZone tesztpálya segítségével teszteltünk.


2. MESTERSÉGES INTELLIGENCIA ÉS GÉPI TANULÁS

Ahogy az előzőekben már említésre került, abban szinte egyhangúak a vélemények, hogy a mesterséges intelligencia alkalmazása a közlekedés területén már ma is megjelent és egyre intenzívebb szerepet fog betölteni, különös tekintettel az önvezető járművekre. A következőkben áttekintjük, hogy ezen belül mely területek adhatnak hatékony megoldásokat a legfontosabb járműirányítási problémákra.

A mesterséges intelligencia első alapvető fogalma az ágens. Ezen egy olyan algoritmust értünk, amely érzékeli környezetét és autonóm módon cselekszik. A racionális ágens pedig a legjobb (várható) kimenetel érdekében cselekszik [5].

A mesterséges intelligencia rendkívül széles tudományterület, ezen belül napjaink egyik legdinamikusabban fejlődő területe a gépi tanulás. Ennek két fő oka van, amelyek közül az első a számítógépek számítási teljesítményének évtizedek óta tartó exponenciális növekedése, a második pedig az internetnek köszönhető hatalmas mennyiségű adat rendelkezésre állása. Definíció szerint egy számítógépes programról akkor mondjuk, hogy tanul egy E tapasztalatból a T feladat tekintetében, ha a teljesítménynek T-re vonatkozó P mérőszáma növekszik az E tapasztalattal [6].

2. ábra: Példa a többrétegű mesterséges neurális hálózatokra [18]



A gépi tanuláson belül három fontos csoportot különböztetünk meg:

- felügyelt tanulás: címkézett adatok segítségével (azaz ismert bemenetekre ismerjük a rendszer választ) határozzuk meg a változók közötti függvénykapcsolatot;
- felügyelet nélküli tanulás: következtető függvény előállítás, amely rejtett struktúrákat ír le címkézetlen adatokból;
- megerősítéses tanulás: az ágens megtanulja, hogy hogyan kell viselkednie egy adott környezetben, hogy a jutalmát maximalizálja.

A gépi tanuláson belül két fontos terület övez intenzív érdeklődés a járműipar részéről. Az első a mélytanulás vagy a mély mesterséges neurális hálózatok alkalmazása. A mesterséges neuron megalkotása már 1943-ban megtörtént, majd a '60-as években Rosenblatt úttörő munkássága újabb lökést adott a témának [7]. Azonban ezt követően a '80-as évek végéig tetszhalott állapotban maradt. Az új elméleti eredmények mellett az egyre gyorsabb számítógépek is sokat segítettek a téma feldolgozásában. Ekkor alakult ki a mélytanulás kifejezés is, amely a 2010-es évektől kezdve már a köztudatba is beszivárgott. A mélytanulás során olyan előrecsatolt neurális hálózatokat alkalmaznak, amelyek a be- és kimeneti rétegek között több rejtett réteget is tartalmaznak. Habár egy előrecsatolt neurális hálózat egy rejtett réteggel (véges számú neuronnal)

is képes közelíteni folytonos függvényeket az n -dimenziós tér (R_n) egy kompakt részhalmozán, azonban több rejtett réteggel (2. ábra) ugyanaz a feladat kevesebb neuronnal is megvalósítható [8].

Az ilyen többrétegű hálózatok kiválóan alkalmasak például klaszifikációs feladatokra, amikor a címkézett nyers szenzoradatokból betanítható egy objektumfelismerő hálózat.


Ilyenkor nincs szükség

klasszikus képfeldolgozási lépésekre, ezek maguktól alakulnak ki a hálózat rétegein belül. A járművekben elsősorban képfeldolgozásra használják ezeket a módszereket, amelyek a hálózat bemenete után általában konvolúciós rétegeket helyeznek el. Emellett objektumklasszifikációra alkalmazzák radarjelek feldolgozásánál. Továbbá vannak olyan törekvések is, ahol a nyers szenzoradatokból közvetlenül próbálják előállítani a beavatkozó jeleket, ami az ún. „end-to-end-learning” feladatokhoz vezet. Például a kamera képből és a kormányzóegység történetéből történik a hálózat betanítása sávkövetésre.

A másik fontos terület a megerősítéses tanulás, amely a klasszikus valószínűségi megközelítéseket próbálja meg ötvözni a mély neurális hálózatokkal. A megerősítéses tanulás alapelve, hogy az ágens megadott akciókat hajthat végre (cselekszik) a környezetben, amelyek hatására a környezet állapota megváltozik, és egy új állapotvektort ad vissza az ágensnek (3. ábra).

Emellett egy nagyon fontos tulajdonsága, hogy minden egyes lépésben egy skalár értéket, az ún. jutalmat is visszaadja az ágens részére. Az ágens célja, hogy a kumulált jutalomjelet hosszútávon maximalizálja. Emiatt a megerősítéses tanulásnál az állapotváltozók meghatározásán túl a jutalom definiálása is elsőd-

3. ábra: Az ágens-környezet interakció egy Markov döntési folyamatban [19]



leges fontosságú, hiszen ez határozza meg az optimalizációs célt. A környezetmodellezés jellemzően Markov döntési folyamattal történik, míg az ágens viselkedését egy ún. „policy” függvény írja le, amely az állapotok és akciók közötti összerendelést adja meg, így a cél az optimális „policy” meghatározása. Léteznek olyan módszerek is, amelyek nem közvetlenül próbálják meghatározni a „policy”-t, hanem az egyes állapotokhoz értékeket rendelnek hozzá („value” függvény) attól függően, hogy mekkora várható jutalmat lehet elérni az adott állapotból. Itt használják fel a kutatók a mélytanulás eredményeit, és a mély neurális hálózatokat függvényapproximátorként alkalmazzák az optimális „policy” és „value” függvények meghatározásához.

A legtöbb megerősítéses algoritmus nem ismeri a környezet modelljét („model-free”), csak a választható akciókat, az állapotvektort és a jutalmat. Ennek megfelelően véletlenszerű akciókkal kezdi működését és iteratív módon keresi az optimális megoldást. A keresés során fontos megtalálni a felfedezés (exploration) és kihasználás (exploitation) egyensúlyát, azaz mennyit használjon fel még a meglévő tudásból és mennyit próbálkozzon még véletlenszerűen? Itt a mérleg a tanulás hossza és a lokális optimumokban való beragadás között billeg. Ezek a módszerek alkalmasak lehetnek trajektória tervezésére [9], döntéshozásra, energia és egyéb optimumok megtalálására. Előnyük a felügyelt tanulással szemben, hogy nem kell megadni az optimális tanítómintákat, azok maguktól alakulnak ki. Így például egy trajektória

tervezésénél nem az ember által végrehajtott trajektóriát fog az ágens megtanulni, hanem egy közel optimálisat.

Érdekes példákat mutatnak erre a téma egyik vezető kutatóhelyének, a Deepmindnak az eredményei. A cég kutatói számítógépes és táblajátékokkal demonstrálják eredményeiket.

A legutóbbi Alpha Go Zero algoritmusuk sakkban és Go-ban is az emberi játékosok, valamint a jelenlegi legjobb sakkgépek fölé emelkedett [10]. Ezt pedig úgy érte el, hogy előzetes ismeretek nélkül, pusztán magával játszva tanulta meg az optimális stratégiákat.

3. HATÁSOK AZ INNOVÁCIÓ SZÉKTORRA

Az önvezető járművek, az elektromobilitás és a gyártásautomatizálás (Ipar 4.0) nagyon erős hatással van a járműiparra. Az iparág komoly átalakuláson megy keresztül, amelynek köszönhetően megváltozik a mérnökök felé támasztott tudásigény. Erre természetesen a felsőoktatásnak is válaszolnia kell új képzések indításával és a hagyományos képzések modernizálásával. A BME Közlekedésmérnöki és Járműmérnöki Kara 2012-ben indította el a Járműmechanika specializációt a BSc járműmérnök képzésen, amely folyamatosan pozitív visszajelzéseket kap a Magyarországon jelenlévő járműipari cégektől. Emellett 2018-ban a Villamosmérnöki és Informatikai Karral közösen elindult az angol nyelvű Autonomous Vehicle Control Engineering MSc program, amely a legmodernebb tudás átadását tűzte ki célul a járműautomatizálás területén.

Nagyon erős katalizátor hatása lehet a Magyarországon épült ZalaZone autonóm járműipari teszt pályának ([11] és [12]). A létesítmény Zalaegerszeg közelében épül 250 hektáron. Területén a következő tesztek elvégzésére van lehetőség:

- klasszikus járműdinamikai tesztek és validáció,
- teljesen integrált autonóm járműves tesztek és validáció,
- környezet felépítésével (akadályok, jelzőlámpák, forgalomirányítás, további járművek, gyalogosok, biciklisek),
- komplex vezetési és forgalmi szituációk,
- okos város elemek,
- tesztek és validáció a prototípus tesztelésétől a tömeggyártásig.

3.1. Jog és etika

A jogi és etikai háttér szorosan összefügg. Sok országban (többek között Magyarországon) bizonyos feltételekkel engedik az önvezető járművek tesztelését. Várhatóan szériában is pár éven belül az utakra kerülhetnek részleges önvezető funkciókkal rendelkező járművek, ezért szükséges a jogi szabályozást minél hamarabb kialakítani. Az egyik legfontosabb kérdés, hogy egy teljesen önvezető járműnek mi legyen az elsődleges biztonsági célja. Azaz egy elkerülhetetlen balesetnél a teljes kockázatot (a többi résztvevőt is beleértve) vagy csak a járműben ülők kockázatát csökkentse. Társadalmi elvárás lehetne, hogy a teljes kockázatot mérlegelje, de az értékesítést ez jelentősen megnehezítené. A másik kérdés, hogy a jelenlegi közlekedési szabályokat figyelembe véve, mely szabályokat és milyen módon szeghetné meg az önvezető jármű. Például a záróvonal átlépés nem lehet teljesen szigorú, hiszen egy szabálytalan kikerülő manőver akár életet is menthet. Egy kisebb sebességtűllépés a forgalomtól függően akár csökkentheti is a baleseti kockázatot. Ezek szabályozása alapvető fontosságú, hiszen a gyártóknak óriási felelősségük lesz, ezért tisztában kell lenniük a lehetőségeikkel. Végül a közvélemény előtt is ismertek a morális döntési kérdések. Például egy elkerülhetetlen baleset esetén kinek az élete ér többet. Szerencsére az önvezető járművek a várható szituációkat előre kiértékelik, és nagyon kis valószínűséggel állnak elő olyan speciális helyzetek, amelyekben minden választási lehetőség ugyanolyan kockázatotok rejt, így az a kérdés talán az adott helyzet kockázatelemzésével is megoldható.

Mindez rendkívül sok és összetett szoftverjogi, büntetőjogi, felelősségi és adatvédelmi kérdést vet fel a jogi oldalon. Emellett új alapokra kell helyezni a járműbiztosítások rendszerét is, hiszen a járművezetők már csak utasként, esetleg üzemmentartóként fognak funkcionálni.

Ezek után szót kell ejteni az infrastruktúra helyzetéről. Ennek minősége és a karbantartási szintje kulcsfontosságú az autonóm járművek megfelelő működéséhez. A jelenlegi jelzések és azok ellenőrzései az emberi látásra alapoznak, nem pedig a gépi látásra. Ennek megfelelően sok olyan hiba és következtelenség előfordulhat, amely az embernek nem, azonban a gépnek problémát okoz. Az útburkolati jelek és közlekedési táblák szigorúbb szabványosítása fontos lenne. Fontos megemlíteni az ideiglenes eltereléseket és jelzéseiket. Itt gyakran találkozhatunk nem egyértelmű szituációkkal (4. ábra), amit a korábban már leírt módon intuitíven és kooperálva képesek az emberi járművezetők megoldani.

4. ábra: Példa a nehezen értelmezhető jelzésekre (forrás: Richmond District blog)




4. ESETTANULMÁNY

A következőkben egy olyan folyamatban lévő kutatásunkat mutatjuk be, amelynek során a megerősítéses tanulás segítségével próbálunk egy ágenst betanítani egy járműtrajektória optimális megtervezéséhez.

A feladat alapvető fontosságú a járműirányítás és -automatizálás területén. Célja, hogy a járművet egy kezdeti dinamikai állapotból (pozíció, állásszög, sebesség, gyorsulás

5. ábra: Az ágens és a környezet kapcsolata



stb.) egy végállapotba vezessük. A feladat egy multikritériumos nemlineáris optimalizálási feladatként írható fel, ahol a szempontjaink az alábbiak:

- Pontosság
- Biztonság
 - Megvalósíthatóság és robusztusság
- Kényelem
 - Testreszabhatóság
- Egyértelmű stratégia
- Algoritmus sebessége

Az elmúlt évek kutatásaiban a megerősítéses tanulás módszereivel folytattunk kísérleteket a feladat megoldására. Az általunk kifejlesztett algoritmus némileg különbözik a korábbiakban bemutatott általános megerősítő tanulási ciklustól, a módszer az 5. ábrán látható.

Minden epizódban az ágens megkapja a kezdeti és a kívánt jármű végállapotot és - spline illesztéssel - generál egy trajektóriát a köztes pontok megadásával. A tervezett pályán a klasszikus hossz- és keresztirányú szabályozók végigvezetik a járműmodellt és a dinamikai paraméterek alapján értékelésre kerül a trajektória jósága. A jutalom értéket a kiértékelés után megkapja a tanuló ágens. Ezután a folyamat kezdődik elölről egy új epizóddal. A bemutatott folyamat egy-egy lépéses megerősítéses tanulás, aminél egy epizód csak egy lépésből áll és nem veszi figyelembe a következő állapotot. Ez az egyszerűsítés egyben redukálja a tanítási feladat komplexitását. Az állapot és az akciótér folytonos értékekből áll. Az alkalmazott DDPG (Deep Deterministic Policy Gradient) tanuló algoritmus [13] a kísérleteink alapján jól teljesít ezen feltételek mellett.

4.1. Tanító környezet

A trajektóriatervező megoldás valós járművön való futtatása előtt, a DDPG ágenst egy mesterséges tanuló környezetben kell elhelyezni, ahol az próbálkozások sorozatával, tapasztalatot gyűjtve törekedni tud a jutalom

maximalizálására. A szimulációs környezet a következő összetevőkből épül fel:

- teljesíthető trajektóriát generáló algoritmus,
- nemlineáris biciklimodell, dinamikus kerékmodellel,
- hossz- és keresztirányú szabályzó,
- jutalom függvény.

4.2. Trajektóriatervezés

A trajektóriatervező módszer bemenete a jármű állapota a kezdeti és a végpontban. Ezen információkat alapul véve a tanuló ágens meghatározza a trajektória köztes pontjait.

Az alábbiakban egy konkrét esetre mutatjuk be a tanítást, aminél a jármű sebessége konstans, 90 km/h. A kezdeti állapotvektor (1) tartalmazza a jármű pozícióját és állásszögét, amik a jármű koordináta-rendszerében értelmezett értékek. A (2) végállapot egyenletes eloszlású, véletlenszerű értékekből tevődik össze, amelyek maximumai kissé szélesebbek lehetnek mint a fizikailag megvalósítható tartomány (2). Túl sok minta a megvalósíthatatlan célvégállapotból meghosszabbíthatja a tanulási folyamatot, ezért ezt el kell kerülni, bár néhány hasznos lehet a határok megtanulásához.

$$[x_s \ y_s \ \psi_s \ v_s]^T = [0 \ 0 \ 0 \ 25m/s]^T \quad (1)$$

$$\begin{bmatrix} x_e \\ y_e \\ \psi_e \\ v_e \end{bmatrix} = \begin{bmatrix} 3 * v_{start} \\ rand(-y_{max}, y_{max}) \\ 0.1 * \psi_{max} + rand(0,1) * 1.3 * \psi_{max} \\ v_{start} \end{bmatrix} \quad (2)$$

$$R_{min} = 0.1207 * v_{start}^{2.4736} \quad (3)$$

$$y_{max} = R_{min} - \sqrt{R_{min}^2 - x_e^2} \quad (4)$$

$$\psi_{max} = -2 * \arctan (y_e / x_e) \quad (5)$$

A tervezett trajektória egy dinamikai járműmodellel kerül validálásra. A megvalósítható végállapot tapasztalati képlettel határozható meg (3), amely megadja azt a legkisebb ívsugarat, amelyet egy átlagos jármű képes fix sebességgel teljesíteni normál körülmények között.

A kiindulási és a végállapot meghatározásakor az ágens meghatározza a két közbenső pont y koordinátáját, egyenlően elhelyezve a kezdeti és a végpont között az x koordináta mentén. A négy tartópont alapján egy spline kerül illesztésre, figyelembe véve a kezdő- és a véggradienst, amely megadja a kívánt állás-zöget.

4.3. Járműmodell

A jármű viselkedésének pontos meghatározása érdekében egy dinamikus kerékmodellel rendelkező nemlineáris biciklmodell kerül felhasználásra. Ez a saját fejlesztésű modell jó eredményeket hozhat még dinamikus vezetési manőverek esetén is, de elég egyszerű ahhoz, hogy futási idejét és számításigényét elfogadható szinten tartsa [14].

A több testből álló modell (6. ábra) magába foglalja a jármű alvázat és két rugalmasan kapcsolódó kerék reprezentálja az első és a hátsó

tengelyt. A fő paraméterek a tömeg m , az alváz tehetetlenségi nyomatéka Θ , a hosszirányú távolságok a jármű tömegközéppontja és az első és a hátsó kerék középpontjai között l_f és l_r , a jármű tömegközéppontjának magassága h , az első és a hátsó kerék tehetetlenségi nyomatékai Θ_f és Θ_r , valamint sugarai r_f és r_r . A kerékmodellek paraméterei szintén nagy befolyással bírnak, amelyek közül a legfontosabbak a súrlódási együtthatók μ_f és μ_r , továbbá a Magic Formula csúszási görbék paraméterei $C_{[f/r],[x/y]}$, $B_{[f/r],[x/y]}$, $E_{[f/r],[x/y]}$, amelyek befolyásolják az átvihető erő nagyságát az út és a gumiabroncsok között [15].


A modell bemenetei az első kerék kormányzási szöge δ (a hátsó kerék nem kormányzott) és a kerekre ható hajtó M_d és fékező M_b nyomaték. A hajtónyomaték az első és a hátsó tengelyre oszlik meg $M_{[f/r],d}$ idő szerint változó eloszlási tényezővel ξ_M . A fékezési nyomaték esetén az ideális eloszlás $M_{[f/r],b}$, amely fenntartja az azonos csúszásokat. Az alváz képes mozogni hosszirányban x , keresztirányban y és forogni ψ a függőleges tengelye körül. A kerek csak a saját vízszintes tengelyük körül forognak ϕ_f és ϕ_r , a hossz- és oldalcsúszásokat $S_{[f/r],[x/y]}$ dinamikusan modellezzük.

A kerékmodell lehetővé teszi explicit ODE-megoldók használatát, közepes időlépéssel, ami 1 ms körül alakul.

4.4. Hossz- és oldalirányú szabályzók

A jármű pálya mentén történő végigvezetéséhez hossz- és oldalirányú szabályzókat implementáltunk. Az epizód elején a jármű a kez-

6. ábra: Járműmodell



deti állapot szerinti fix sebességre gyorsít fel egy inicializálási szakasz során. A trajektórián való végighaladás csak ezután kezdődik meg. A sebességtartást egy egyszerű PID szabályzó hatékonyan valósítja meg. Az oldalirányú szabályozásért a Stanley módszer [16] felelős.

$$\delta = - \left(\psi + \arctan \left(k * \frac{y}{v} \right) \right) \quad (6)$$

ahol ψ a szöghiba az első tengelynél, y az oldalirányú hiba az első tengelynél, v a jármű sebessége (az első tengelyen számolva, aminek iránya párhuzamos az első kerékkel) és k az erősítési tényező.

4.5. Jutalomszámítás

Az ágens minden tanítási lépésben kap egy állapotvektort a trajektória kezdeti feltételeivel és meghatározott akciókat, amik ebben az esetben a köztes pontok. A jutalom érték meghatározásához a járművet a hossz- és keresztirányú szabályzó vezeti végig a tervezett pályán. A tanítási folyamat minden egyes epizódjá adig tart, amíg a jármű el nem éri a pálya végét, vagy egy kritikus feltétel meg nem állítja.

A jutalom függvény meghatározásakor a következő kritikus feltételeket állapítottuk meg:

- Az oldalirányú távolság hiba nagyobb, mint 10 méter.
- A hossz- vagy az oldalirányú slip nagyobb, mint 0,1.
- A maximum lépésszám nagyobb, mint 2500.
- A legyezési szöghiba nagyobb, mint 0,2 radian.

A kritikus feltételek mellett a lépésenként összegzett slip és az ellenőrző pontokban nézett, pozíció szerint súlyozott oldalirányú és szöghiba alapján kerül kiértékelésre az ágens teljesítménye. Az epizód jutalom ezen három komponens súlyozott összegéből adódik:

$$R_{episode} = s_w * R_{slip} + d_w * R_{dist} + a_w * R_{angle} \quad (7)$$

A környezet 10 darab, a trajektória mentén egyenlően elosztott ellenőrző pontot (cp) definiál.

A távolság (R_{dist}) és a szög (R_{angle}) jutalmak az ellenőrzőpontoknál, a slip jutalom (R_{slip}) minden időlépésben kiszámításra kerül. A részjutalmak a $[0,3]$ tartományba esnek és a következőképpen történik a meghatározásuk.

$$R_{slip} = 3 - \sum_{step=1}^{\max step} -abs(\max(s_{f/r}, |x/y|)) / 10 \quad (8)$$

$$R_{angle} = 3 - \sum_{cp=1}^{10} -abs(\psi) * 2 * pos \quad (9)$$

$$R_{dist} = 3 - \sum_{cp=1}^{10} -abs(y/3) * 2 * pos \quad (10)$$

Ahol ψ az első tengelynél vett szöghiba, y az oldalirányú hiba és pos a jármű pozíciója a trajektória mentén. Az értéke 0 a kezdeti pozícióban és 1 a végén. A kezdeti érték és a képletek tapasztalati úton kerültek meghatározásra. Amennyiben egy kritikus feltétel bekövetkezik, az epizódnak vége és az ágens negatív jutalmat ($R=-10$) kap. Ha az ágens sikeresen végigért a pályán, akkor a (7) szerinti jutalomban részesül.

4.6. Valós teszt

A szimulációs környezetben végzett tanítások eredményének validálása után, a kifejlesztett rendszer tesztelésre került valós járművel tesztpályás környezetben a zalaegerszegi tesztpályán. A következő fejezet a tesztkörnyezetet részletesen bemutatja.

4.6.1. Jármű

A tesztekhez használt jármű egy Smart Fortwo (7. ábra), amely autonóm járműfunkciók tesz-

7. ábra: Tesztjármű



telése és demonstrálása céljából nagyrészt átalakításra került, ezért a jármű nem közlekedhet közutakon.

A Smart egy kézi működtetésű elektromechanikus sebességváltóval van felszerelve. A váltókart egyedi tervezésű vezérlőegység váltja ki, amely lehetővé teszi a sebességváltást CAN buszon keresztül. A nyomatékparancs egy analóg feszültségérték, amit a gázpedál megkerülésével a dSPACE Autobox vezérlőegység analóg kimenetével állít elő. A fékpedál egy lineáris aktuátorral aktiválható. A kormánymű forgatásáért egy DC szervómotor felelős. A jármű gyárilag CAN busszal szerelt, amit további hárommal bővítettek ki a teszrendszer számára.

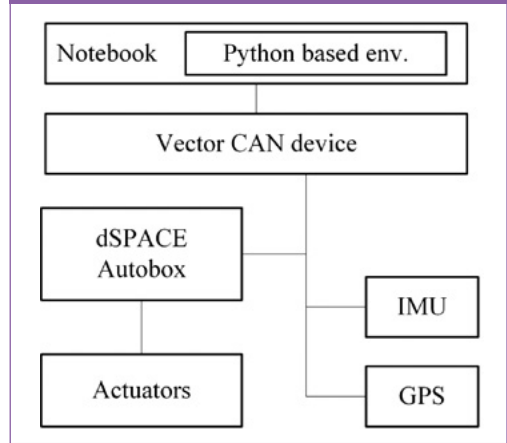
A tesztjárművünket több érzékelővel is felszerelték. A szélvédő alatt van egy autóiipari kamera-modul, amely többek közt képes magas szintű sáv- és objektuminformációt szolgáltatni. Két különböző típusú precíziós GPS modul végzi a helymeghatározást. Előre és hátra autóiipari radarok kerültek beépítésre. Az első fényszórók magasságában két, nagy pontosságú, 2D lidar kapott helyet [17].

4.6.2. Tesztelés menete

A megerősítéses tanuló algoritmus validálására egy Python alapú teszt környezetet fejlesztettek ki. A cél, hogy a jármű képes legyen a betanított neurális hálózat által generált pályán végighaladni, miközben az érzékelők adatait eltárolja. A teszt rendszer hierarchikus felépítésű (8. ábra). A dSPACE Autobox eszköz felelős az alacsony szintű szabályozásért kormányzó és sebesség parancsok végrehajtásával. A Python alapú algoritmus egy Vector CAN eszköz segítségével kapcsolódik a jármű buszrendszerére. Az Autoboxot, a GPS-t és az inerciális szenzort erre a CAN hálózatra kötötték.

A teszt elején a teljes tervezési tartomány lefedése érdekében teszteseteket definiáltunk, amelynek során kanyarodási és kikerülési manővereket teljesített a jármű különböző sebességekkel. A teszt elejétől kezdve a tervezett trajektória, a szabályzó paraméterek és a CAN forgalom mentésre kerül. A szimulációban kifejlesztett hossz- és oldalirányú szabályzók irányítják a járművet a valós tesztknél.

8. ábra: Tesztarchitektúra



A teszteseteket a dinamikai platformon (9. ábra) hajtottuk végre. Ez egy 300 m átmérőjű ultra sík aszfalt felület egy 760 és egy 400 m hosszú gyorsító sávval és 20 m széles FIA (International Automobile Federation) bukótérrel.


4.6.3. Teszteredmények

A tesztkörnyezet megvalósításán túl meg kellett tervezni a teszteseteket a valós járművön való futtatáshoz. Biztonsági okokból a teszteseteket maximum 40 km/h sebességgel hajtottuk végre, miközben egy sofőr ült a járműben. Teszteseteket végeztünk 20, 30 és 40 km/h sebességgel. A kifejlesztett tanító környezetben a jármű konstans sebességgel haladt, ezért különböző tanításokat kellett indítani az eltérő sebességek esetében. A DDPG alapú tanuló ágens az 1. táblázat szerinti eredményeket érte el a tanítás során. Minden tanítás sikeresen konvergált egy magas jutalom értékre. Minden esetben az egyenlően elosztott jutalom súlyok vezettek a legjobb eredményre.

A neurális hálózat struktúrája és a zajparaméterek minden tanítási esetben azonosak voltak (2. táblázat).

A kifejlesztett módszer teljesítményét a legnehezebb manővernél, a legnagyobb sebességgel mutatjuk be. A 10. ábra egy 40 km/h sebességgel végrehajtott kikerülési manővert mutat be. A piros vonal jelöli a tervezett trajektóriát és a kék a bejárt utat. A szaggatott vonal a cél ol-

9. ábra: Dinamikai felület



1. táblázat: Tanítási teljesítmény


Sebesség	Max. Q érték átlaga	Epizódszám	Tanítási idő
20 km/h	2.707	26 840	8h 31m
30 km/h	2.718	50 000	20h 11m
40 km/h	2.732	50 000	21h 27m

2. táblázat: Hiperparaméterek

Actor hálózat	
Tanulási ráta (α)	0.0001
Minta memória méret	64
Rejtett teljesen összekapcsolt rétegek	[128,100,64]
Aktivációs függvény	relu
Kimeneti szorzó	[2,4]
Critc hálózat	
Tanulási ráta (α)	0.001
Discount factor (γ)	0.99
Rejtett teljesen összekapcsolt rétegek	[128,64]
Aktivációs függvény	relu
Ornstein-Uhlenbeck paraméterek	
(μ)	[0,0]
(σ)	0.3
(θ)	0.15


daltávolságot ábrázolja. Látható, hogy a jármű elfogadható hibával képes végrehajtani a manővert. A pálya végrehajtása során az átlagos távolsághiba 0,3051 m, az átlagos szöghiba 0,0415 fok. A járműben ülve komfortos volt a pálya végrehajtása.

10. ábra: Trajektória



Ahogy korábban láthattuk a rendszer jutalmazza a slip alacsony értéken tartását és a kis szög és távolsághibát a tanítás közben. A slip arányos az oldalgyorsulással, ami a 11. ábrán látható. A maximum gyorsulás érték 0,5 m/s² körül alakult, ami teljesíti az elvárásokat.

11. ábra: Oldalgyorsulás



5. ÖSSZEFOGLALÁS

Az előzőekben röviden bemutatuk a közlekedés és a gépi tanulás kapcsolatát, valamint a járműipar átalakulását. Vázoltuk a várható hatásait az innovációs szektorra, valamint felvetettük a megoldandó jogi, etikai és infrastrukturális kérdéseket. Ezt követően részletesen bemutatunk egy esettanulmányt a gépi tanulás járműirányítási célú alkalmazásáról, valamint a ZalaZone tesztpálya kutatási célú felhasználásáról.

Megállapítható, hogy a gépi tanulás alkalmazása gyökeresen át fogja alakítani a közlekedésszervezést és irányítást, valamint a járművek tervezését és gyártását. Különösen kiemelt téma napjainkban az önvezetés. Leszögezhetjük azonban, hogy egy európai szintű teljes körű önvezetésre képes járműre még évtizedeket várunk kell. Azonban folyamatosan jelennek meg az egyre fejlettebb, magasan automatizált járművek az utakon, amelyek már részleges önvezető funkciókkal rendelkeznek. Az egyre jobban automatizált járművek, a járműmegosztó szolgáltatások és a kapcsolódó innovatív informatikai szolgáltatások mindenképpen nagyobb biztonságot és energiahatékonyabb közlekedést eredményeznek a közutakon. Azonban még nagyon sok feladat vár megoldásra mind a járműirányítás, mind a kapcsolódó tudományágakon belül, továbbá a döntéshozóknak is fel kell készülniük az új kihívásokra.

FELHASZNÁLT IRODALOM

- [1] P. Gáspár, Z. Szabó, J. Bokor és B. Németh, Robust Control Design for Active Driver Assistance Systems: A Linear-Parameter-Varying Approach, Springer International Publishing, 2017. DOI: <http://doi.org/djzk>
- [2] O. Sename, P. Gáspár és J. Bokor, Robust Control and Linear Parameter Varying Approaches, Berlin Heidelberg: Springer-Verlag, 2013. DOI: <http://doi.org/djzm>
- [3] Waymo, „Waymo Safety Report: On The Road to Fully Self-Driving,” 2017.. [Online]. Available: <https://waymo.com/safetyreport/>.
- [4] Crash Research & Analysis, Inc., „Special crash investigations: On-site automated driver assistance system crash investigation of the 2015 Tesla model S 70D (Report No. DOT HS 812 481),” National Highway Traffic Safety Administration, Washington, DC, 2018..
- [5] S. Russel és P. Norvig, Mesterséges Intelligencia: Modern megközelítésben, Budapest: Panem kft., 2005.
- [6] T. Mitchell, Machine Learning, McGraw Hill, 1997.
- [7] F. Rosenblatt, „The Perceptron--a perceiving and recognizing automaton,” Report 85-460-1, Cornell Aeronautical Laboratory, 1957.
- [8] C. B. Csáji, *Approximation with Artificial Neural Networks*, Eindhoven, 2001.
- [9] F. Hegedűs, T. Bécsi, S. Aradi és P. Gáspár, „Model Based Trajectory Planning for Highly Automated Road Vehicles,” in *IFAC World Congress: IFAC-PapersOnLine*, Toulouse, Franciaország, 2017. DOI: <http://doi.org/djzn>
- [10] D. Silver, J. Schrittwieser, K. Simonyan, I. Antonoglou, A. Huang, A. Guez, T. Hubert, L. Baker, M. Lai, A. Bolton, Y. Chen, T. Lillicrap, F. Hui, L. Sifre, G. v. d. Driessche, T. Graepel és Demis, „Mastering the game of Go without human knowledge,” *Nature*, %1. kötet550, pp. 354-359, 2017. DOI: <http://doi.org/gcsmk9>
- [11] Z. Szalay, Z. Hamar és P. Simon, „A multi-layer autonomous vehicle and simulation validation ecosystem axis: Zalazone,” *Advances in Intelligent Systems and Computing*, %1. kötet867, pp. 954-963, 2019. DOI: <http://doi.org/djzp>
- [12] Z. Szalay, T. Tettamanti, D. Esztergár-Kiss, I. Varga és C. Bartolini, „Development of a test track for driverless cars: Vehicle design, track configuration, and liability considerations,” *Periodica Polytechnica Transportation Engineering*, %1. kötet 46, pp. 29-35, 2018. DOI: <http://doi.org/dktg>
- [13] T. P. Lillicrap, J. J. Hunt, A. Pritzel, N. Heess, T. Erez, Y. Tassa, D. Silver és D. Wierstra, „Continuous control with deep reinforcement learning,” *arXiv preprint arXiv:1509.02971*, 2015.
- [14] F. Hegedűs, T. Bécsi, S. Aradi és P. Gáspár, „Model Based Trajectory Planning for Highly Automated Road Vehicles,” *IFAC-PapersOnLine*, %1. kötet50, %1. száml, pp.

- 6958-6964, 2017. DOI: <http://doi.org/djzn>
- [15] H. B. Pacejka, *Tire and Vehicle Dynamics (Third Edition)*, Oxford: Butterworth-Heinemann, 2012.
- [16] S. Thrun, M. Montemerlo, H. Dahlkamp, D. Stavens, A. Aron, J. Diebel, P. Fong, J. Gale, M. Halpenny, G. Hoffmann, K. Lau, C. a. P. M. Oakley és e. al., Stanley: The robot that won the DARPA Grand Challenge, Wiley, 2006. DOI: <http://doi.org/c52vnf>
- [17] T. Bécsi, S. Aradi, Z. Szalay és V. Tihanyi, „2D lidar-based localization for highly automated parking in previously mapped environment,” in *34th International Colloquium on Advanced Manufacturing and Repairing Technologies in Vehicle Industry*, Budapest, 2017.
- [18] A. Gibson és J. Patterson, *Deep Learning*, O'Reilly Media, Inc., 2017.
- [19] R. S. Sutton és A. G. Barto, *Reinforcement Learning: An Introduction*, The MIT Press, 2017.



The role and effects of machine learning in transport

This article addresses the present and the predictable future role of artificial intelligence, and in particular machine learning, in transport. It briefly describes trends and changes in transport and vehicle development. It introduces the basics and types of machine learning, an important area of artificial intelligence. The article gives a brief overview of the impact of changes in the automotive industry in the area of the innovation sector, including higher education, and developments in Hungary such as the ZalaZone Automotive Test Track. It then summarizes the relevant legal and ethical issues, focusing on autonomous vehicles. A longer chapter discusses an ongoing domestic research which conducts experiments in the area of trajectory design using reinforcement learning methods. This gives insight into the details of the requirements and problems that arise, as well as a possible solution through machine learning. Finally, several results of the tests carried out at the ZalaZone test track are presented.



Die Rolle und die Auswirkungen des maschinellen Lernens im Verkehr

Dieser Artikel befasst sich mit der gegenwärtigen und zukünftigen Rolle der künstlichen Intelligenz und insbesondere des maschinellen Lernens im Verkehr und behandelt kurz die Trends und die Veränderungen im Verkehr und in der Fahrzeugentwicklung. Es werden die Grundlagen und Arten des maschinellen Lernens – eines wichtigen Bereichs der künstlichen Intelligenz – vorgestellt. Danach folgt ein kurzer Überblick über die Auswirkungen der Veränderungen in der Automobilindustrie auf den Innovationssektor, einschließlich des Hochschulwesens, und über die Entwicklungen in Ungarn wie das ZalaZone Versuchsgelände für die Autoindustrie. Anschließend werden die relevanten rechtlichen und ethischen Fragen zusammengefasst, wobei der Schwerpunkt auf die autonomen Fahrzeuge gesetzt wird. Ein längeres Kapitel befasst sich mit der laufenden ungarischen Forschung im Bereich der Trajektoriengestaltung, wobei die Methoden des verstärkten Lernens verwendet werden. Auf diese Weise erhält der Leser einen Einblick in die Details der auftretenden Anforderungen und Probleme sowie in ihre mögliche Lösung mit der Hilfe des maschinellen Lernens. Es werden schließlich einige Ergebnisse der auf der ZalaZone-Teststrecke durchgeführten Versuche beschrieben.