

Automatizált járművek körforgalomban való ütközésmentes irányítása tanulási módszerekkel

Farkas Zsófia*, Gáspár Péter**

**Budapesti Műszaki és Gazdaságtudományi Egyetem
Közlekedés- és Járműirányítási Tanszék
1111 Budapest, Műegyetem rkp. 3.
(e-mail: farkas.zsofia@edu.bme.hu).*

***HUN-REN Számítástechnikai és Automatizálási Kutatóintézet
Rendszer- és Irányításelméleti Kutatólaboratórium
1111 Budapest, Kende u. 13-17. (e-mail: gaspar.peter@sztaki.hun-ren.hu)*

Absztrakt: Az automatizált járművek körforgalomban való biztonságos és időhatékony áthaladását biztosító irányítás tervezése számos kihívást jelent. Ilyen irányítástervezési kihívásnak tekinthető a járművek tényleges forgalmi helyzethez való alkalmazkodását és a járművek összehangolt mozgását. Jelen cikkben egy gépi tanulással támogatott hierarchikus mozgásirányítási módszer kerül bemutatásra körforgalmi szituációkra. A tervezett irányítás két szintű: felhő- valamint járműszintű. A felhőszintű irányítás megerősítéses tanulás módszerével került megtervezésre, amely révén energiahatékony járműmozgás valósítható meg. A járműszintű irányítás egy robusztus szabályozót és egy felügyelőt tartalmaz, amellyel biztosítható a járművek közötti ütközés elkerülése. A tervezett irányítási algoritmus implementálása Hardware-in-the-Loop környezetben, kiterjesztett valóságban kisméretarányú beltéri modelljárművek esetében valósult meg. Az automatizált járművek irányításának hatékonysága és a biztonsági előírások garantálása egy többjárműves közlekedési példán kerül bemutatásra.

1. BEVEZETÉS

A magasan automatizált járművek és az intelligens közlekedési rendszerek fejlődése arra ösztönzi a tudományos közösséget, hogy az irányítástervezési kihívásokra megoldásokat dolgozzanak ki. Napjainkban a legfőbb irányítástervezési feladatnak bizonyul olyan közlekedési helyzetek vizsgálata, melyben autonóm járművek és más résztvevők – például az ember által vezérelt járművek – vesznek részt. Az ütközés elkerülése, az utazási idő minimalizálása vagy az utasok kényelmének biztosítása olyan forgalmi helyzetekben, mint például körforgalomban való áthaladás, alapvető követelménynek számít az autonóm járművek irányítási stratégiáinak tervezésében. Jelen cikk a fenti kihívások megoldására javasol módszert többjárműves kereszteződés esetére. Korábban (Morsali *et. al.* (2021)) support vector machine eljárás alapján gépi tanulási módszert fejlesztett ki, amely autonóm járművek trajektóriáit számítja ki körforgalomban való biztonságos áthaladás érdekében. Az irányítási módszer ütközési régiókat határoz meg, hogy hozzájáruljon az utazási kényelem növeléséhez. (Wang *et. al.* (2012)) egy ütközést elkerülő, állapotbecslésen alapuló algoritmust dolgozott ki autonóm járművek számára trajektória-követésre. A konfliktusos területek elkerülésére és a körforgalomban való biztonságos áthaladásra felhívást adó függvény és a potenciálmező alapú megközelítést építették be a kidolgozott módszerbe.

A szakirodalomban számos közlemény foglalkozik a körforgalmak elemzésével a forgalom és az autonóm járművek irányításának különböző aspektusai szerint. Autonóm járművek komplex közlekedési helyzetekben való mozgását és vezetői viselkedést vizsgálja (Németh *et. al.* (2019)) járművek körforgalomban való biztonságos haladásának irányítástervezéséhez. (Perez *et. al.* (2011)) pályatervezést és a járművek oldalirányú irányítását magában foglaló koordinációs sémát dolgozott ki körforgalmas csomópontokra. (Rodrigues *et. al.* (2017)) az emberi járművezetők viselkedési profilját és egy döntéshozatali algoritmust kapcsolt össze autonóm járművek körforgalomban való koordinálására. Egy, a járművezető viselkedésén alapuló döntéshozatali algoritmus garantálja az automatizált járművek biztonságos és hatékony mozgását (Hang *et. al.* (2021)) kutatásában. Ezen kutatásban játékelméleti megközelítések kerültek beépítésre a tervezett módszertanba, miközben modell prediktív irányítást alkalmaztak a járművek mozgásának predikciójára. (Debada *et. al.* (2017)) olyan irányítási stratégiát dolgozott ki, amely a virtuális járművek megközelítését használja a manőverek mérlegelésére és más járművekkel való együttműködésre. A javasolt algoritmus garantálja, hogy a járművek sebességprofilja teljesíti a kényelmi és dinamikai előírásokat a városi körforgalmi helyzetekben.

Az autonóm járművek bonyolult közlekedési helyzetekben való irányítástervezésében széleskörűvé váltak a gépi tanulási módszerek alkalmazása. Számos publikáció fókuszál tanulási megközelítések irányítási algoritmusba való beépítésére a

járművek körforgalomban való hatékony áthaladásának megvalósítása érdekében. Például (Deveaux *et. al.* (2021)) elemezte a vezetési kockázatokat (például az ütközéseket), erre alapozva dolgozott ki irányítási módszereket autonóm járművekre. Figyelembe véve az ütközéshez szükséges időt, egy felügyelővel ellátott, gépi tanuláson alapuló algoritmus előre jelzi a járművek kilépő mozgásának valószínűségét, így garantálva a biztonságos városi közlekedést. Egy Q-learning alapú algoritmust dolgozott ki (Garcia *et. al.* (2019)) autonóm járművek a körforgalomban való biztonságos haladásához. Az algoritmus működése révén a járművek a megfelelő manőverezési viselkedést követik, hogy áthaladjanak a körforgalomban ütközés nélkül.

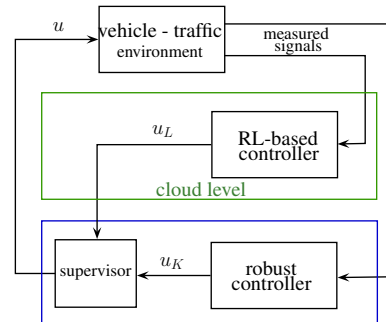
Összefoglalva a szakirodalomban lévő eredményeket, a kutatási tevékenység elsősorban az autonóm járművek irányítási módszereire összpontosul, ezáltal több következtetés is levonható. Először is számos modern megközelítés létezik már, de a komplex forgalmi helyzetek egy kevésbé vizsgált terület, amit az autonóm járművek alkalmazásához szükséges megoldani. Másodsor, gépi tanulási eljárásokon alapuló megoldást dolgoztak ki autonóm járművek komplex körforgalmi szituációkban való irányítására. Ennek ellenére szükséges olyan irányítási algoritmusok tervezése, melyek biztonságos feltételeket garantálnak körforgalomban való áthaladásnál. Továbbá szükséges egyéb kommunikációs és irányítási architektúrák tervezése, mint például a felhő alapú megoldások, a széles körű implementáció és a kapcsolt, automatizált járműtechnológiák alkalmazása érdekében.

Jelen kutatás során egy hierarchikus irányítás került kidolgozásra automatizált járművek számára, amellyel garantálható a biztonságos és hatékony mozgásuk körforgalom esetében többjárműves környezetben. A tervezett hierarchia járműszintű és egy felhőszintű irányítást foglal magában. A felhőszintű szabályozás célja az irányítási performanciák elérése a felhő nagy számításai kapacitásának felhasználásával. Így a felhőszinten megerősítéses tanulás alapú módszer került implementálásra a járművek energiafogyasztásának minimalizálására. Emellett a jármű szinten került biztosításra a biztonsági követelmények, mint az esetleges ütközés elkerülése. A megoldás előnye, hogy a biztonsági követelmények a kommunikáció hálózat romlása ellenére is garantálhatók maradjanak. Újszerű eleme ennek a munkának a módszer implementálása felhő kapcsolattal rendelkező beltéri tesztjárműves környezetre.

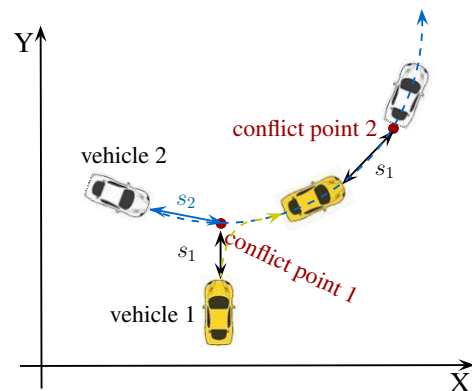
A tanulmány a következőképpen épül fel. A jármű- és felhő szintű szabályozást tartalmazó hierarchikus irányítási struktúrát a 2. fejezet mutatja be. A 3. fejezet középpontjában a módszer hatékonyságának bemutatása áll egy Hardware-in-the-Loop (HiL) implementáción keresztül. Végül a 4. fejezetben kerül összefoglalásra a kutatás.

2. HIERARCHIKUS IRÁNYÍTÁS AUTOMATIZÁLT JÁRMŰVEK SZÁMÁRA

A hierarchikus irányítási struktúrát mutatja be az 1. (a) ábra. A szabályozás egy lépéses $u(k)$ mozgási bemeneti jelet generál az adott jármű számára, például $a_1(k)$ hosszirányú gyorsulási jelet, mellyel a jármű képes az útvonalán haladni. Az $u(k)$ jelet a felügyelő számítja és $u(k) = u_K(k) + \Delta(k)$, ahol $u_K(k)$ a járműszintű robusztus szabályozó kimenetét jelöli. $\Delta(k) \in \hat{\Delta}$ az irányítási bemenet további tagja és $\hat{\Delta}$ a $\Delta(k)$ véges halmaza. Az irányítási struktúrában $u_L(k)$ az megerősítéses tanulás alapú szabályozó által javasolt irányítási bemeneti jel. $\Delta(k)$ értéke a felügyelő általi optimalizációs folyamat eredménye, mely folyamat csökkenti $u(k)$ és $u_L(k)$ közötti különbséget, valamint biztosítja az automatizált és más járművek közötti ütközés elkerülését. (Németh *et. al.*, (2021))



1. (a) ábra: Az irányítási architektúra



1. (b) ábra: Jármű interakciók körforgalomban

A járművek közötti korlátozások definiálása konfliktuspontok meghatározásának módszerével történik. A körforgalom komplex közlekedési szcenáriónak tekinthető, amelyben kereszteződési és járműkövető feladatok végrehajtása történik. Ezt mutatja az 1. (b) ábra, melyen látható, hogy a jármű biztonságos mozgásához a konfliktuspont módosítása szükséges. Körforgalomba való érkezés alkalmával, a konfliktuspont meghatározható a járműútvonalak keresztezéseként. A körforgalomba való belépést követően az automatizált jármű feladata az előző jármű követése.

Ilyen esetben az előző jármű jelenlegi pozíciója jelöli a folyamatosan változó konfliktuspontot. Ezen korlátozás révén biztosítható az automatizált és más járművek közötti s_{safe} biztonságos távolság, például további automatizált vagy hagyományos járművek esetében $s^2_1(k+1) + s^2_2(k+1) \geq s^2_{safe}$, ahol $k+1$ jelöli a következő idő lépést.

A felügyelő általi korlátozott optimalizációs folyamat n számú járműre a következőképpen írható fel:

$$\min(u(k) - u_L(k))^2, \quad (1a)$$

$$\Delta(k) \text{ továbbá} \quad (1b)$$

$$\left(s_{i,i}(k+1, u(k))\right)^2 + (s_i(k+1))^2 \geq s^2_{safe} \forall i \in [1, n],$$

$$\Delta(k) \in \hat{\Delta} \quad (1c)$$

Az (1) optimalizációs probléma eredménye $\Delta(k)$, amelyből $u(k)$ irányítási bemenet, mint $u_k(k)$ és $\Delta(k)$ összege, következik.

Az $u_L(k)$ kiszámítását egy neurális hálózat végzi, amelyet megerősítéses tanulással került betanításra. A tanulási folyamat modellje tartalmazza a felügyelőt, a robusztus szabályozót és a jármű-forgalom környezetet. A felügyelő és a robusztus szabályozó modellbe való beépítésének köszönhetően, az ütközés elkerülése minden epizódban garantált az ágens tanulási folyamata közben. A neurális hálózat alkalmazása javítja az automatizált jármű gazdaságos energiafelhasználását, azaz u minimalizálását. Továbbá a felügyelő döntéseit is ajánlott figyelembe venni a tanítás során, ami azt jelenti, hogy $(u(k) - u_L(k))^2$ minimalizálása javasolt. Így az $r(k)$ jutalom függvény a következőképpen épül fel:

$$r(k) = -Q_1 u^2(k) - Q_2 (u(k) - u_L(k))^2, \quad (2)$$


ahol Q_1 és Q_2 pozitív értékek a tervezési paraméterek, amelyek az $r(k)$ összes tagjának jelentőségét mérik.

A megerősítéses tanulási folyamat célja a (2) jutalom maximalizálása az epizódok során. jelen kutatásban Deep Deterministic Policy Gradient (DDPG) kerül alkalmazásra az ágens betanítási folyamatához. Ez egy model-free megerősítéses tanulási módszer (Lillicrap *et. al.* (2016)) aktor-kritikus struktúrában, amely olyan optimális értéket számol ki, ami maximalizálja a hosszú távú jutalmat. A megfigyelések, azaz a neurális hálózat mért jelei az $s_{1,i}(k)$ érték, $u(k-1)$, $u_L(k-1)$ és $u_k(k)$. Az RL alapú szabályozó kimenete $u_L(k)$, amely a javasolt irányítási bemenet.

3. A MOZGÁS IRÁNYÍTÁSI ALGORITMUS IMPLEMENTÁCIÓJA


Ebben a fejezetben bemutatásra kerül a kidolgozott algoritmus hatékonysága annak kis méretarányú tesztjárművekre való implementálása révén. A demonstrációban egy Hardware-in-the-Loop (HiL) környezetet alkalmazunk, amely magában foglal kiterjesztett valóságot (AR) és több beltéri járművet is.

A demonstrációs példa (automatizált járművek körforgalomban való mozgása) azt a célt szolgálja, hogy bemutassa az irányítási algoritmus által működő automatizált járművek biztonságos mozgását. A 2. ábrán látható a demonstrációban alkalmazott körforgalom rajza. A körforgalomban való haladás az óramutató járásával ellentétes irányú és három bejáratral/kijáratral rendelkezik. A járművekkel szembeni biztonsági performancia követelmény, hogy legalább $s_{safe} = 1\text{m}$ távolságot tartsanak egymástól.



2. ábra: A körforgalom illusztrációja

A példában három automatizált jármű vesz részt, ezek között valósághű kisméretarányú modelljármű, egy pedig virtuális jármű. A HiL architektúra sémáját a 3. ábra szemlélteti. A fizikai járművek pozícióit az OptiTrack kamerarendszeren keresztül mérjük, és az adatok a ROS hálózaton keresztül kerülnek továbbításra. Az architektúrában a virtuális járművek mozgását egy számítógépen, mint a ROS hálózat csomópontján, kerülnek szimulálásra. Ezen mozgások a kiterjesztett valóságban a táblagépen láthatók, amelyen Android-alapú Unity környezetet Vuforia AR-rel alkalmazunk. Ezzel megbecsülhető a táblagép pozíciója a padlón rögzített markerek segítségével. Az irányítás implementálásának szempontjából, az RL-alapú irányítás a felhőben található, és a felügyelő általi robusztus irányítás a fizikai járművekre (vagy virtuális járművek esetén a PC-re) telepítve van. A valós modelljárművek mozgásának irányítása PID szabályozó segítségével történik a középvezetől mért oldalirányú hibájuk alapján.



3. ábra: A HiL architektúra sémája

A szimuláció néhány időpillanatát szemlélteti a 4. ábra. A szcenárió elején az 1. és a 2. jármű kerül konfliktus helyzetbe, lásd 4. (a) ábra. Annak ellenére, hogy az 1-es jármű úgy dönt, hogy az I. bejáratnál behajt a körforgalomba, az 1. és a 2. jármű közötti távolság a biztonságos érték felett marad, lásd az 5. (d) ábrát másfél másodperc körül. Az ütközés elkerülése az u_2 csökkentésével érhető el (lásd 5. (b) ábra), ami a v_2 redukcióját okozza, ami 5. (c) ábrán látható. A 4. (b) ábrán az 1. és a 3. jármű közötti konfliktushelyzet látható, ami az 1. jármű sebességének csökkenését eredményezi, lásd az 5. (c) ábrán 2 másodperc után. Rövid ideig 2 és 4 mp között, amíg a 2-es jármű nem hagyja el a körforgalmat a II. kijáraton (lásd 4. (c) ábra), az összes jármű együtt mozog. A szimuláció ezen fázisában, s_1 és s_2 értéke kicsi, de s_{safe} távolság megmarad, ahogy az 5. ábrán látható. A szcenárió utolsó részében az 1. jármű követi a 3. járművet, és mindkét jármű elhagyja a körforgalmat az I. kijáratnál. A járművek mozgása s_1 jellemzőivel együtt (lásd 5. (d) ábra) azt mutatja, hogy a tervezett mozgás irányítási algoritmus képes garantálni a jármű biztonságos követését és a jármű interakcióinak kezelését.

(a)



(b)



(c)



(d)







Végül érdemes összehasonlítani u_L és u jeleit minden jármű

4. (a) ábra: 1-es jármű behajt a körforgalomba; (b) 3-as jármű behajt a körforgalomba; (c) 2-es jármű elhagyja a körforgalmat; (d) 3-as jármű elhagyja a körforgalmat

esetében, lásd az 5. (a)-(b) ábrán. Az (1) függvény szerint u és u_L közötti különbséget minimalizálni kell, miközben az optimalizálás követelményei betartásra kerülnek. Látható, hogy u és u_L jellemzői minden jármű esetében közelítenek egymáshoz. Ennek ellenére, u és u_L közötti különbség garantálja az automatizált járművek biztonságos mozgását.

4. KONKLÚZIÓ

Jelen cikkben az automatizált járművek mozgásszabályozására egy hierarchikus algoritmus került bemutatásra, mely garantálja azok körforgalomban való biztonságos áthaladását. A bemutatott módszer beltéri tesztjárművekre került implementálásra és többjárműves környezetben került tesztelésre. A megerősítéses tanulási módszerrel kiegészített hierarchikus irányítási stratégia biztosítja a járművek ütközés nélküli áthaladását a körforgalomban. Továbbá az irányítási algoritmus, magában foglalva a felhő szinten lévő megerősítéses tanulási módszert, hozzájárul a járművek általi energiafelhasználás csökkentéséhez.



5. (a) ábra: Javasolt bemenet a felhőből; (b) gyorsulási bemenet; (c) járművek sebessége; (d) távolság az aktuális konfliktus ponttól

KÖSZÖNETNYILVÁNÍTÁS

A publikációban szereplő kutatást a HUN-REN SZTAKI az Európai Unió támogatásával valósította meg, az Autonóm Rendszerek Nemzeti Laboratórium keretében. (RRF-2.3.1-21-2022-00002)

IRODALOMJEGYZÉK

Debada, E., Makarem, L., Gillet, D., 2017. A virtual vehicle based coordination framework for autonomous vehicles in heterogeneous scenarios. In "2017 IEEE International Conference on Vehicular Electronics and Safety (ICVES)", pp. 51–56.

Deveaux, D., Higuchi, T., Ucar, S., Wang, C.H., Harri, J., Altintas, O., 2021. Extraction of Risk Knowledge from Time To Collision Variation in Roundabouts. In "2021 IEEE International Intelligent Transportation Systems Conference (ITSC)", pp. 3665–3672.

Garcia, C.L., Puertas, E., Fernandez Andres, J., Aliane, N., 2019. Autonomous Driving in Roundabout Maneuvers Using Reinforcement Learning with Q-Learning. Electronics, Volume 8, Number 12.

Gáspár, P., Németh, B., 2019. Predictive Cruise Control for Road Vehicles Using Road and Traffic Information. Springer Verlag.

Hang, P., Huang, C., Hu, Z., Xing, Y., Lv, C., 2021. Decision Making of Connected Automated Vehicles at an Unsignalized Roundabout Considering Personalized Driving Behaviours. IEEE Transactions on Vehicular Technology, Volume 70, Number 5, pp. 4051–4064.

Lillicrap, T.P., Hunt, J.J., Pritzel, A., Heess, N., Erez, T., Tassa, Y., Silver, D., Wierstra, D., 2016. Continuous control with deep reinforcement learning. In "International Conference on Learning Representations".

Morsali, M., Frisk, E., Aslund, J., 2021. Geometrical Based Trajectory Calculation for Autonomous Vehicles in Multi-Vehicle Traffic Scenarios. In "2021 IEEE Intelligent Vehicles Symposium (IV)".

Németh, B., Gáspár, P., 2021. The design of performance guaranteed autonomous vehicle control for optimal motion in unsignalized intersections. Applied Sciences, 11(8).

Perez, J., Milanés, V., de Pedro, T. Vlacic, L., 2011. Autonomous driving manoeuvres in urban road traffic environment: a study on roundabouts. In "IFAC Proceedings Volumes", Volume 44, Issue 1, pp. 13795–13800.

Rodrigues, M., Gest, G., McGordon, A., Marco, J., 2017. Adaptive behaviour selection for autonomous vehicle through naturalistic speed planning. In "2017 IEEE 20th International Conference on Intelligent Transportation Systems (ITSC)", pp. 1–7.

Wang, L., Huang, W., Liu, X., Tian, Y., 2012. Vehicle collision avoidance algorithm based on state estimation in the roundabout. In "2012 Third International Conference on Intelligent Control and Information Processing", pp. 407–412.