

Autonóm járművek döntési és irányítási módszereinek kidolgozása előzési helyzetek kezelésére

című értekezés tézisei

Szerző:

HEGEDŰS TAMÁS

Témavezető:

Dr. Németh Balázs



Budapesti Műszaki és Gazdaságtudományi Egyetem
Közlekedésmérnöki és Járműmérnöki Kar
Közlekedés- és Járműirányítási Tanszék



Eötvös Loránd Kutatási Hálózat
Számítástechnikai és Automatizálási Kutatóintézet
Rendszer és Irányításelméleti Kutatólaboratórium

Budapest

2022.

1. Motiváció

NA PJAINKBAN, az autóipar egyik fő kihívását az autonóm járművek fejlesztésével kapcsolatos nehézségek adják, amelyek magukba foglalják a mozgástervezést, a döntéshozatalt, a pályatervezés és az autó irányításáért felelős szabályzó tervezését. A környező járművek pontos mozgás-előrejelzése az autonóm járművek hatékony működésének egyik támpillére. A szakirodalomban számos módszer található, amelyekkel az adott forgalmi helyzetben résztvevő járművek mozgása prediktálható a döntéshozatali folyamat során. A prediktálási folyamat kivitelezésére széles körben használatra kerül a fizikai modellen [1], illetve a gépi tanuláson alapú [2] megközelítések. A kapott eredményeket a döntéshozataltól felelős réteg használja fel. Szabályalapú, valószínűségi vagy optimalizálás eljárásokon alapuló módszerek széles körben elterjedtek [3, 4], mindazonáltal, manapság a megerősítéssel tanuláson alapuló megoldások egyre nagyobb teret hódítanak maguknak [5]. A döntéshozatali réteg eredményeit felhasználva referencia útvonal kerül megtervezésre, amelynek számos előírásnak kell megfelelnie például folytonos görbület biztosítása [6]. Az útvonal tervezésére elterjedt a görbeillesztéssel alapuló megoldás [7], azonban optimalizáción és gépi tanulási módszereken nyugvó algoritmusok is megtalálhatóak a szakirodalomban [8].

A megtervezett útvonal mentén történő járműirányítás is számos kihívást rejt magában. Az utóbbi évtizedek során számos megközelítés került kidolgozásra a dinamikus rendszerek szabályozási problémáira, mint például a robosztus (\mathcal{H}_∞) [9], Lineáris Kvadratikus Regulátor (LQR) [10], Modell Prediktív Irányítás (MPC, NMPC) [11], illetve a politopikus rendszereken alapuló algoritmusok, mint például a Lineáris Változó Paraméterű keretrendszer (LPV) [12]. A CPU-k és GPU-k számítási kapacitásának növekedésével új terület kezdett teret hódítani, mint például az adatvezérelt és gépi tanuláson alapuló megközelítések. Ezzel egy új irány is létrejött, amelyben a klasszikus irányítástechnikai és a gépi tanulás alapú megközelítések kombinációjával kerül az adott rendszer irányításra [13]. Az autonóm járművek fejlesztésével kapcsolatos problémáinak áttekintése során megállapítható, hogy számos megoldás publikálásra került. Mindazonáltal a változó forgalmi helyzetekben is döntésre képes algoritmus tervezési folyamata még mindig sok kihívást és megoldandó feladatot rejt magában. Továbbá, az irányítástervezési folyamat fő nehézsége abból adódik, hogy a jármű paraméterei széles tartományban változhatnak, illetve számos környezeti hatás figyelembevétele is szükséges.

A disszertáció célja olyan előzési manőverekhez kapcsolódó saját döntéshozatali és pályatervezési algoritmusok bemutatása az autonóm járművek irányítására, amelyekkel mind a biztonsági, mind a kényelmi előírások garantálhatóak. Mindemellett oldalirányú irányítástervezési módszerek kerülnek bemutatásra, amelyek alkalmazásával az irányítás minőségi jellemzői növelhetőek, így biztosítva az autonóm járművek biztonságos és hatékony üzemeltetését.

2. A jármű oldalirányú mozgásának modellezése

Jelen disszertációban a jármű oldalirányú modellezése az egynyomú járműmodell segítségével történik [14]. A modell alap gondolata, hogy a jármű egy tengelyén elhelyezkedő kerék párt egy-egy kerék helyettesít, amelyek a jármű hossz tengelyén helyezkednek el. A modellt alkotó egyenletek két fő mozgást írnak le úgy mint a legyezési szöggyorsulást, oldalirányú gyorsulást:

$$\ddot{\psi} I_z = C_f \left(\delta - \beta - \frac{\dot{\psi} l_f}{v_x} \right) l_f - C_r \left(-\beta + \frac{\dot{\psi} l_r}{v_x} \right) l_r, \quad (1a)$$

$$(\ddot{y} + v_x \dot{\psi}) m = C_f \left(\delta - \beta - \frac{\dot{\psi} l_f}{v_x} \right) + C_r \left(-\beta + \frac{\dot{\psi} l_r}{v_x} \right), \quad (1b)$$

ahol $\dot{\psi}$ a legyezési szögsebességet, illetve C_i a gumik kanyarodási merevségét adják meg. A jármű hosszirányú (v_x), és az oldalirányú sebességének (v_y) felhasználásával a kúszási szög közelíthető: $\beta = tg(\frac{v_y}{v_x})$. A tengelyek és a súlypont távolságát l_f, l_r , a jármű oldalirányú helyzetét pedig y adja meg. Továbbá, m jelöli a jármű tömegét, amíg I_z a tehetetlenségi nyomaték értéke. Végezetül δ reprezentálja az elkormányzási szög értékét. Következő lépésben a lokális koordináta-rendszerből átkonvertálásra kerül a jármű mozgása egy, az úthoz kötött, globális koordináta-rendszerbe:

$$\dot{x}_g = v_x \cos(\psi) - v_y \sin(\psi), \quad \dot{y}_g = v_x \sin(\psi) + v_y \cos(\psi), \quad (2)$$

ahol x_g, y_g a globális koordináta-rendszerben lévő pozíciók. A járműmodell felírása során a következő feltételezésekkel élünk:

A./ A laterális gumierők a zérus oldalkúszási szög körül kerülnek linearizálásra: α_f, α_r , emiatt $F_{y,f} = C_f \alpha_f, F_{y,r} = C_r \alpha_r$, ahol $\alpha_f = \delta - \frac{v_y + l_f \dot{\psi}}{v_x}$ és $\alpha_r = \frac{-v_y + l_r \dot{\psi}}{v_x}$ az első és a hátsó tengelyen lévő kúszások.

B./ Amennyiben az elkormányzási szög alacsony értéket vesz fel, a következő közelítés alkalmazható: $\cos \delta \approx 1$ and $\sin \delta \approx \delta$.

C./ Feltételezésre kerül, hogy a jármű orientációja közel azonos az adott útszakasz irányával, emiatt: $\cos \psi \approx 1, \sin \psi \approx \psi$.

A fent leírt feltételezések alkalmazásával (2) összefüggések egyszerűsíthetők:

$$\dot{x}_g = v_x - v_y \psi, \quad \dot{y}_g = v_x \psi + v_y. \quad (3)$$

Az irányítás során használt modell felírható a dinamikai összefüggések (1), illetve az egyszerűsítések segítségével, amelyek felhasználásával a rendszer állapotter reprezentációja a következőképp adódik:

$$\dot{x}_{lat,c} = A_{lat,c} x_{lat,c} + B_{lat,c} \delta, \quad (4a)$$

$$y_{lat,c} = C_{lat,c} x_{lat,c}, \quad (4b)$$

ahol az állapotvektor: $x_{lat,c}^T = [v_y \quad \psi \quad \dot{\psi}]$, és a mért jel: $y_{lat,c} = y$.

3. A disszertáció tézisei

3.1. Optimális pályatervezés önvezető járművek előzési helyzeteinek kezelésére

Az egyik legkockázatosabb manőver a mindennapi közlekedésben az előzés végrehajtása az előforduló számos bizonytalanság és váratlan esemény miatt. A döntéshozatali és pályatervezési folyamat során a fő kihívás egy olyan útvonal meghatározása, amely megfelel a biztonsági előírásoknak. Egy adott forgalmi szituáció kiértékelése során több ütközésmentes útvonal is meghatározható, amelyekből alacsony számítási kapacitás mellett az optimális trajektória kiválasztása jelenti a fő kihívást. További nehézségként fogalmazható meg a forgalomban résztvevők mozgásának előrejelzése, ami a performancia szint növelésében játszik fontos szerepet. Ráadásul, a döntéshozatali folyamat eredménye erősen befolyásolja a pályatervezéssel elérhető maximális performancia szintet. Ez azt jelenti, hogy a megvalósítható trajektóriák paramétereit érdemes figyelembe venni a döntéshozatali folyamat során, azonban a legtöbb létező módszerben a két réteg hierarchikusan helyezkedik el. A tézis a következő két fő részből áll:

- Először egy döntéshozatali algoritmust kerül bemutatásra, amely segítségével az útvonal számítása történik.
- Másodszor, egy olyan módszer kerül kidolgozásra, amelyben a döntéshozó rétegben figyelembevételre kerül a lehetséges, megvalósítható pályákat leíró jellemzők.

Döntéshozatal optimális trajektória tervezéssel A döntéshozatali folyamat első lépése a környező járművek lehetséges mozgásának előrejelzése. Ezen feladat a korábban rögzített adatok segítségével kivitelezhető. Adatokat felhasználva sűrűségfüggvények határozhatók meg, amely során a cél a járművezetők jellemző viselkedési mintájának felismerése az adott forgalmi szituációkban. A sűrűségfüggvény alapján a környező járművek hosszirányú mozgása közelíthető. Ezt követi az optimális pályatervezés, amely során a jármű geometriai információi és egyéb korlátok együttesen kerülnek figyelembevételre. A jármű oldalirányú mozgása a jármű kinematikai modellje alapján kerül modellezésre, mint:

$$\frac{dy(t)}{dt} = v_x \sin \psi(t), \quad \frac{d\psi(t)}{dt} = \frac{v_x}{D} \tan \delta(t), \quad (5)$$

ahol D az első és a hátsó tengely közötti távolság. A mozgásegyenletek a $v_x = ds(t)/dt$ összefüggés segítségével kerülnek diszkretizálásra. Az eredmények felhasználásával megvalósítható pályák tervezhetők, amelyek klotoid

szegmensekből épülnek fel. A korlátozások melletti optimalizálási feladat a következőképpen írható fel:

$$\min_{u_i \dots u_{i+n-1}} \frac{1}{2} \mathbf{C}^T \phi \mathbf{C} + \beta^T \mathbf{C} + \mathbf{C}^T \gamma, \quad (6)$$

ahol a következő korlátozásokat szükséges figyelembe venni:

$$\mathbf{A} - \mathbf{Y}^{min} \geq -\mathbf{B}\mathbf{C}, \quad (7a)$$

$$\mathbf{Y}^{max} - \mathbf{A} \geq \mathbf{B}\mathbf{C}, \quad (7b)$$

$$\mathbf{C} \in \mathbf{C}, \quad (7c)$$

ahol \mathbf{B} , \mathbf{A} az állapotmátrixokból, \mathbf{C} pedig a klotoid szegmensek görbület értékeiből épül fel, és \mathbf{C} ezen kivitelezhető értékeket tartalmazza. A minimális (\mathbf{Y}^{min}) és maximális (\mathbf{Y}^{max}) laterális pozíció értékeket a sávok szélei és a környező járművek határozzák meg. Az optimalizálási feladat megoldható kvadratikus programozási módszer alkalmazásával [15]. A (6) megoldása az L_n predikciós horizonton a klotoid szegmensek görbület sorozata.

A döntéshozatali réteg és a pályatervezés összevonása Az előző megoldás során, az előzési probléma egy hierarchikus algoritmus segítségével került megoldásra. Jelen tézis célja a döntéshozatali és pályatervezésért felelős rétegek összevonása, amellyel több minőségi jellemzőt is figyelembe lehet venni a döntéshozatali folyamat során. Ez azt jelenti, hogy az adott forgalmi helyzet kiértékelése során a lehetséges, megvalósítható trajektóriák jellemző paraméterei figyelembevételre kerülnek, és az a trajektória került kiválasztásra, amely garantálja a biztonsági és kényelmi követelményeket. Kezdeti lépésként a lehetséges pályákat egy mátrixba rendezzük, amelyben az előzési manőver kezdőpontját x_s , a végpontot x_f , az oldalirányú elmozdulást pedig y_i adja meg. A mátrix a következőképpen írható fel:

$$\chi = \begin{bmatrix} x_{s,1}, x_{f,1}, y_0 & x_{s,1}, x_{f,2}, y_0 & \dots & x_{s,1}, x_{f,n}, y_0 \\ x_{s,1}, x_{f,1}, y_1 & x_{s,2}, x_{f,2}, y_0 & \dots & x_{s,2}, x_{f,n}, y_0 \\ \vdots & \vdots & \ddots & \vdots \\ x_{s,1}, x_{f,1}, y_{m-1} & x_{s,3}, x_{f,2}, y_{m-2} & \dots & x_{s,m}, x_{f,n}, y_0 \end{bmatrix}, \quad (8)$$

ahol y_0 a sáv közepe. Abban az esetben, amikor a járműnek nem feltétlenül kell előzési manővert kezdenie, y_{m-1} kerül kiválasztásra. A mátrixban található kezdeti és végpontokat felhasználva kiszámításra kerülnek a kivitelezhető trajektóriák. A megvalósítható trajektóriákat az egyes performancia szintekhez kapcsolódó potenciálmezők segítségével hasonlítjuk össze. A trajektória kiválasztása egy optimalizálási problémára vezet, amelynek költségfüggvénye a potenciálmezők függvényének súlyozott összegét tartalmazza. A potenciálmezőn alapuló megközelítés alkalmazásával több hatás is figyelembevételre kerül, mint például a sáv közepe (P_{sv}), a hosszirányú sebessége (P_v), a

gyorsulás (P_a) és a többi forgalmi résztvevő hatása ($P_{k,j}$). Az optimalizálás költségfüggvénye a következőképpen írható fel:

$$P(x_s, x_f, y, a_{long}) = q_1 P_a(j(x_s, x_f, y)) + q_2 \sum_{k=1}^N P_{k,j}(x_s, x_f, y, a_{long}) + q_3 P_{sv}(y) + q_4 P_v(a_{long}), \quad (9)$$

ahol q_1, q_2, q_3 és q_4 tervezési paraméterek, amelyek segítségével az egyes hatások közötti prioritásokat lehet kezelni. Így a (9) alapú optimalizálás a következőképp írható fel:

$$\min_{x_s, x_f, y, a_{long}} P(x_s, x_f, y, a_{long}), \quad \text{a következő feltételekkel} \quad (x_s, x_f, y) \in \chi. \quad (10)$$

Az optimalizálás eredménye a pálya kezdő- és végpontjának, valamint az oldalirányú eltérésnek a hármasa.

1. tézis *Két döntéshozatali algoritmust dolgoztam ki autonóm járművek előzési helyzeteinek kezelésére. Az első módszerben a mozgáspredikciós réteg a környező járművek jövőbeli lehetséges pozícióijai valószínűségi sűrűségfüggvények segítségével kerülnek meghatározásra. A kidolgozott módszer döntéshozatali és pályagenerálási feladatokat együttesen lát el. A pályagenerálási feladat korlátozások melletti optimalizálási feladatként kerül felírása. A második módszer alapját a döntéshozatali és a pályagenerálási rétegek egy rétegbe való integrálása jelentette. Az összevonás eredménye a járműirányítással szemben támasztott minőségi követelmények magasabb szintű kielégítése. A döntéshozatali módszerek hatékonyságát nagy pontosságú járműdinamikai szimulációs szoftverben bemutattam.*

Kapcsolódó publikációk: [NGH18, NHG19, HNG19, HNG21a, HNG21b]

További részletek a disszertáció 2. fejezetében találhatóak.

3.2. Több kritériumos trajektória tervezés minőségi jellemzők garantálásával

Az adott forgalmi szituációban eszközölt döntéshozatali folyamat során számos hatást kell figyelembe venni, például az adott útszakasz szélességét és a környező forgalmi résztvevőket. Továbbá, több nehézséget kell leküzdeni, mint például a különböző helyzetekben való hatékony működés, illetve azokhoz történő rugalmas adaptálhatóság. A különböző, komplex forgalmi szituációk miatt több esetben is összetett optimalizálási probléma adódik, amelynek megoldása időigényes. Az algoritmus számítási kapacitásának csökkentése érdekében gépi tanuláson alapuló megoldások alkalmazhatóak. Egyes

gépi tanulási módszerek hátránya azonban, hogy a biztonsági követelmények nehezen biztosíthatóak, hiszen ezen megoldások esetén elméleti garanciák nem adhatóak. Az említett hátrányok miatt, egy kombinált megoldás kerül kidolgozásra, amely egy robusztus szabályozási módszert, illetve egy neurális hálózatot, mint gépi tanulási megoldást, egyesít. Jelen tézis két fő részből áll:

- Első lépésben, egy gráf-alapú döntéshozatali algoritmus került kidolgozásra autonóm járművek számára.
- Második lépésben, a gráf alapú algoritmus eredményeit felhasználva egy neurális hálózat alapú megoldás kerül létrehozásra. Ezen túlmenően a rendszer elvárt minimum minőségi jellemzőinek garantálására, egy LPV-alapú irányítási algoritmus került kidolgozásra.

Gráf alapú döntéshozatali algoritmus A gráf alapú útvonalválasztó algoritmus első lépése a környező járművek mozgásának prediktálása az adott időhorizonton. Ezt követi a teljes horizont egyenlő távolságra való felosztása hossz és oldalirányban. Ennek segítségével az adott útszakaszon egy súlyozott, irányított gráf $G = (V; \bar{E})$ kerül felépítésre, amelynek csúcsai (V) a jármű lehetséges útvonalpontjait és sebességprofilját tükrözik. Az ütközési valószínűségek (P_c) diszkrét szegmensekre kerülnek számításra egy adott $t \in [t_i, t_j]$ időintervallumban:

$$P_c(t_i, t_j) = \sum_{l=1}^N \frac{P(\lambda, s_i(t_i), s_j(t_j), y_{min}, y_{max})}{N}, \quad (11)$$

ahol N az adott szituációban lévő járművek száma, λ két jármű előzési valószínűsége, illetve P megadja a valószínűségi függvényt. Az adott útszakaszra vetített G gráf $V_i, V_j \in E(V_i, V_j)$, $j > i$ csúcsok közötti élek súlyai a következőképpen számíthatók:

$$S(i, j) = P_c(t_i, t_j) + S_c(i, j) + S_v(i, j), \quad (12)$$

ahol S_c a sáv közepétől való eltérést súlyozza, míg S_v a referencia sebességtől való eltérést. A cél azon gráf élek sorozatának felderítése, amelyek mentén a legalacsonyabb a súlyok összege. Az említett probléma egy "greedy" algoritmus segítségével megoldható. Az algoritmus eredménye a legrövidebb út a kiindulási és a célcúscok között, ahol a D távolságot a következőképpen határozzuk meg:

$$D = \sum_{d=1}^{M-1} S(d, d+1), \quad (13)$$

ahol M csúcspontok száma. Az algoritmus eredménye a jármű referencia útvonala és referencia sebessége a vizsgált horizonton.

Minőségi kritériumok garantálása előzési esetek kezelésére A gráf alapú döntéshozatali algoritmust felhasználva, egy gépi tanuláson alapuló megoldás kerül bemutatásra. A biztonságos trajektória $(y_{i,s}, v_{x,i,s})$ egy prediktív optimalizációs eljárás segítségével kerül meghatározásra. A végső cél a két algoritmus eredményeinek kombinálása a két trajektória közötti maximális eltérés figyelembevételével:

$$y_{ref} = y_{i+1,s} + \Delta_{l,1}^*, \text{ if } \Delta_{l,1}^* \in \Lambda_{l,1}, \quad (14a)$$

$$v_{ref} = v_{x,i+1,s} + \Delta_{l,2}^*, \text{ if } \Delta_{l,2}^* \in \Lambda_{l,2}, \quad (14b)$$

ahol $\Delta_{l,1}^*, \Delta_{l,2}^*$ megadják a maximális eltérést és $\Lambda_{l,1}, \Lambda_{l,2}$ tartományok.

A szabályzó célja az előzési manőver ütközésmentes végrehajtása. Ez azt jelenti, hogy dönteni kell a gépi tanuláson alapuló referenciajel elfogadhatóságáról, illetve garantálni szükséges a referenciajel pontos követését, egy előre meghatározott s biztonságos távolság betartásával. A robusztus szabályozó képes a tanuláson alapuló megoldás és a biztonságos pálya közötti eltérést a rendszert érő zavarásként kezelni. A rendszer állapotér-reprezentációja a következőképpen írható fel:

$$\dot{x} = A(\rho)x + B_1w + B_2u, \quad (15a)$$

$$z = C_1x + D_{11}w + D_{12}u, \quad (15b)$$

$$y_m = C_2x + D_{21}w \quad (15c)$$

ahol $A(\rho), B_1, B_2$ és $C_1, C_2, D_{11}, D_{12}, D_{21}$ rendszermatrixok, a zavar $w = [F_{dist}, y_{i+1,s}, v_{x,i+1,s}, \Delta_{l,1}, \Delta_{l,2}]^T$ és a bemeneti vektor $u = [\delta, F_{long}]^T$. Az LPV rendszer ütemező változójaként $\rho = v_x$ kerül kiválasztásra.

2. tézis *Kidolgoztam egy gráf alapú döntéshozatali algoritmust, amellyel az adott forgalmi szituáció kiértékelése során többféle hatást (pl. középvezetési helyzete, a közlekedésben résztvevők eltérő mérete) hatékonyan figyelembe lehet venni. A módszer a környező járművek mozgásának prediktálását követően egy gráfot generál az útszakaszra, amellyel a referencia trajektória számolható. Kidolgoztam egy gépi tanulás alapú döntéshozatali módszert, amellyel a gráf alapú megoldás számítási kapacitása csökkenthető. Bemutattam egy olyan tervezési architektúrát, amellyel a gépi tanulás alapú megoldás minimális performancia szintje garantálható a robusztus irányítástervezés és a tanulás alapú eredmények kombinációjával. A módszer hatékonyságát nagy pontosságú járműdinamikai szimulációs szoftverek segítségével mutattam be.*

Kapcsolódó publikációk: [HNG20b, HNG20c, NHG20, HNG20a]


További részletek a disszertáció 3. fejezetében találhatóak.

3.3. Irányítástervezés modell-illesztési eljárással

A legtöbb modern szabályozási megközelítés egy fizikai modellen alapul, amely leírja a vizsgált rendszer dinamikus viselkedését. Jellemzően ezek a modellek kevésbé pontosan képesek leírni a rendszer működését, különösen nagymértékű nemlineáris hatások esetén. Mindazonáltal, a modellek nagy hatással vannak a megtervezett szabályzó minőségi kritériumaira. Ebből következik, hogy a magas performanciaszint eléréséhez pontos modellre van szükség, amelynek megalkotása sokszor számos kihívást rejt magában. A modellezési módszer egyszerűsítése érdekében egy neurális hálózat alapú modell-illesztési algoritmus kerül kidolgozásra. Az eredményül kapott rendszerre a lineáris szabályzótervezés eszköztára hatékonyan használható, mivel a nemlinearitások a modellezési folyamat során eliminálásra kerülnek. A tézis a következő három fő részből áll:

- Első lépésben, egy neurális hálózaton alapuló modell-illesztési algoritmus kerül bemutatásra.
- Második lépésként az eredményül kapott neurális háló kiértékelésre kerül, ahol a cél a zárt hurkú rendszer megbízhatóságának meghatározása.
- Végezetül, a zárt hurkú rendszer elemzése következik és az esetlegesen feltárt bizonytalanságok kezelésére egy robusztus szabályzási eljárás kerül alkalmazásra.

Neurális hálózat alapú modell-illesztés A cél egy addicionális Δu bemeneti jel meghatározása, amellyel a kimeneti jelek (y_{nom} , y_{mat}) azonosak lesznek a nominális u bemeneti jelre. A modell-illesztés felépítését az 1. ábra szemlélteti.



1. ábra. A modell-illesztés struktúrája

Az addicionális bemenőjel meghatározása nem triviális feladat, mivel a nemlineáris rendszer leírása nem pontosan ismert. Ezen probléma megoldá-

sára egy iteratív algoritmus került kidolgozásra, amelyben a rendszer előzetes ismereteit használjuk fel. Az iteratív módszer nem alkalmas valós idejű implementálásra, ezért az iterációs algoritmus eredménye a neurális hálózat tanítására szolgál.

Megbízhatóság számítása A neurális hálózat által kiszámolt addicionális irányítójel segítségével az irányítás minőségi jellemzőinek szintje növelhető. Mindazonáltal, a hálózat esetlegesen előforduló hibái destabilizálhatják a rendszert, így ezen hatásokat figyelembe kell venni az implementáció során. A nem megfelelő eredmény két fő okra vezethető vissza: a nemlineáris rendszer instabil régióiban való működésre, illetve az illesztési hibákra. Emiatt, a rendszer és a hálózat kiértékelésre kerül performancia, illetve stabil mozgás szempontjából. Az értékelés során az egyes munkapontok két halmazba kerülnek csoportosításra, úgy mint "*elfogadható*" és "*nem elfogadható*". A nemlineáris rendszer aktuális állapotára vonatkozó megbízhatósági elemzés során az elfogadható eredmény valószínűségét a Bayes-szabály [16] segítségével kerül meghatározásra:

$$P(\mathcal{R}|\mathcal{X}) = P(\mathcal{R}) \frac{P(\mathcal{X}|\mathcal{R})}{P(\mathcal{X})}, \quad (16)$$


ahol $P(\mathcal{R}|\mathcal{X})$ az elfogadható eredmény valószínűségét adja meg, amennyiben a \mathcal{X} állapotok az $[x_{act} - x_l, x_{act} + x_u]$ intervallumba esnek. A neurális hálózat jóságát $P(\mathcal{R})$ definiálja, amely a felhasznált adathalmaz segítségével az elfogadható adatok aránya alapján számítható. Végül, $P(\mathcal{X})$ egy valószínűségi értéket ad meg, amely kifejezi, hogy a rendszer milyen gyakran van az adott működési tartományon belül. A valószínűségek valós idejű számítása a nagy adatmennyiség miatt nem kivitelezhető. A hatékony használhatóság érdekében (16) eredményei alapján egy lineáris szakaszokból felépülő függvény kerül meghatározásra:

$$f_P(x) = \begin{cases} \frac{P(\mathcal{X}_i|\mathcal{R}_i)}{P(\mathcal{X}_i)}, & x \in \mathcal{X}_i \\ 0, & \text{különb,} \end{cases} \quad (17)$$


ahol \mathcal{X}_i az adathalmaz i^{th} részhalmazát adja meg.

A rendszer bizonytalanságának modellezése A modell-illesztési folyamat a jármű oldalirányú dinamikájának modellezését mutatja be a legyezési szögsebesség ($\dot{\psi}$), mint mért jellemző, függvényében. A $\dot{\psi}_n - \dot{\psi}$ számszerűsítése érdekében számos szimuláció került futtatásra a CarMaker szimulációs szoftverben található nemlineáris járműmodell segítségével. A szimulációk során a linearizált rendszert különböző kormányzási szögekkel lett gerjesztve, illetve a jármű hosszirányú sebessége is változtatásra került. A szimulációk eredményeit felhasználva a legyezési szögsebesség ($\dot{\psi}$) és a legyezési szögsebesség

hibája ($\Delta\dot{\psi} = \dot{\psi}_n - \dot{\psi}$) közötti átviteli függvény meghatározható. A numerikus számításokból származó átviteli függvényeket a 2. ábra szemlélteti.



(a) Különböző sebességek mellett



(b) Különböző kormányzási szögeknél

2. ábra. A neurális hálózat illesztési hibájának átviteli függvényei

Amint az ábrák mutatják, az legyezési szögsebesség hiba ($\Delta\dot{\psi}$) amplitúdója a sebesség növekedésével és a kormányzó amplitúdójával együtt csökken. A neurális hálózat hibáját az irányítástervezés során bizonytalanságként kerül figyelembevételre, így biztosítva a megfelelő minőségi előírásokat.

3. tézis *Kidolgoztam egy új, neurális hálózat alapú modell-illesztési módszert, amelynek célja a nemlinearitások hatásainak figyelembe vétele. Az irányítási struktúrában a neurális hálózat egy belső hurokban található. A nemlineáris rendszer mérhető jeleit felhasználva a neurális hálózat egy további bemenő jelet határoz meg, amellyel a belső hurok kimenetét egy nominális, lineáris modell kimenetéhez igyekszik illeszteni. Ezenkívül, egy robusztus \mathcal{H}_∞ alapú referenciakövető szabályzást terveztem, amely kezeli a neurális hálózat illesztésének hibáját és garantálja a rendszer robusztus viselkedését. A módszer hatékonyságát egy autonóm járművekhez köthető problémán keresztül mutattam be.*

Kapcsolódó publikációk: [HFNG21, FHNG21b, HNG21a]

További részletek a disszertáció 4. fejezetében találhatóak.

3.4. Irányítástervezés hiba alapú ultra-lokális modell segítségével

A neurális hálózaton alapuló modell-illesztési módszer mellett a szakirodalomban találhatóak más megközelítések is, amelyek alkalmazásával javíthatók a szabályozó minőségi jellemzői, mint például a Model Free Control (MFC). Ennek a szabályozási struktúrának az alap gondolata, egy ultra-lokális modell meghatározása, amellyel a nemlineáris rendszer dinamikája közelíthető

egy adott időhorizonton, így elkerülve a rendszer komplex modellezési folyamatát. Emiatt a módszer alkalmas nemlineáris dinamikájú és bizonytalan rendszerek irányításához. Az említett algoritmusnak az alkalmazása azonban kihívást jelentő feladat, a becslési hibák, és az időkésések miatt. Az MFC struktúra további kihívása a klasszikus szabályzó hangolása, amelyhez szükség van egy modellre. Továbbá, az MFC struktúra rendelkezik egy szabad hangolási paraméterrel (α), amellyel a klasszikus szabályzó, illetve ultra-lokális modell hatása skálázható. Ezen érték megfelelő megválasztása mellett, az irányítás performanciái növelhetők, azonban nem megfelelő megválasztás esetén destabilizálhatja is az irányított rendszert. Tekintve, hogy nincs kidolgozott, hatékony módszer az említett paraméternek a meghatározására, a pontos értékének hangolása még nyitott kérdés. Jelen tézis három fő részt ölel föl:

- A módosított MFC struktúra kerül bemutatásra első lépésben.
- Ezt követi az α tervezési paraméter hangolási módszerének ismertetése.
- Végül, az állapotér-reprezentáció kiterjesztése kerül bemutatásra, amely az LPV-szabályozás tervezésének alapjául szolgál.

Módosított struktúra A szabályozási struktúra alapötletét felhasználva, kiszámításra kerül az ultra-lokális modell a nominális és a szabályozott rendszerre is. További cél az előre meghatározott referenciajel és a kimenet közti zérus hiba elérése. A módosított hiba-alapú ultra-lokális modell a következőképp számítható:

$$y^{(\nu)} = F + \alpha u, \quad (18a)$$

$$y_{ref}^{(\nu)} = F_{nom} + \alpha u_{nom,ref}, \quad (18b)$$

$$\underbrace{y^{(\nu)} - y_{ref}^{(\nu)}}_{e^{(\nu)}} = \underbrace{F - F_{nom}}_{\Delta} + \underbrace{\alpha u - \alpha u_{nom,ref}}_{\alpha \tilde{u}}, \quad (18c)$$

ahol, F a valós míg F_{nom} a nominális rendszerre vonatkozó ultra-lokális modell. A hiba-alapú ultra-lokális modell számítható a két modell különbségeként. A rendszer kimenete y és α pedig a hangolási paraméter. y_{ref} a referenciajel, $u_{nom,ref}$ a számított referencia bemenőjel, amely a névleges modell segítségével meghatározható. Végezetül, ν a kimenet ν . deriváltját jelöli.

Az α paraméter hangolása Mindazonáltal a nominális modell alkalmazásával megtervezhető a nominális szabályzó, azonban az α paraméter hangolásához továbbra is szükség van egy algoritmus kidolgozására. Általánosságban az α hatása: ha $\alpha \rightarrow \infty$ az ultra-lokális modellalapú rész befolyása csökken, azonban, ha $\alpha \rightarrow 0$, a szabályozó bemenete főként az ultra-lokális modellből származik. A cél egy olyan módszer kidolgozása, amellyel ez a paraméter a rendszer aktuális működési tartományához igazítható. Gyakorlatban ez azt

jelenti, hogy az α értékét a rendszer állapotai alapján érdemes meghatározni, amelyeknek mérhetőnek kell lenniük. Figyelembe véve, hogy a jármű oldalgyorsulása korrelál a nominális és a valós rendszer közötti különbség mértékével, az α számítása a következő formában történik:

$$\alpha_{act} = \alpha_0 - \phi a_y. \quad (19)$$

Komplex feladat azon paraméterek (α_0, ϕ) kiválasztása, amelyekkel a legkisebb követési hiba érhető el. A probléma megoldása érdekében több szimuláció kerül futtatásra, és adatvezérelt elemzés segítségével az optimális érték meghatározható. A szimulációk során a járműnek véletlenszerűen generált sávváltási trajektóriákat kell követnie az említett paraméterek változtatása mellett. A mentett adatpontok segítségével a következő optimalizálási probléma írható fel:

$$\arg \min_{\alpha_0, \phi} \left(\frac{\beta}{n} \sum_{j=1}^n (y_{ref,j,i} - y_{ms,j,i})^2 + \max(y_{ref,i} - y_{ms,i}) \right), \quad (20)$$

ahol i jelöli i . tesztet. A referenciapályát y_{ref} adja, a mért laterális pozíció pedig y_{ms} . A minimalizálandó költségfüggvény felírásában az adott teszt során létrejövő átlagos és a maximális hibaérték kerül figyelembevételre. Végsőzetül, β a költségfüggvényben a két hiba súlyozásért felelős skálázási paraméter.

Állapottér kibővítése Az állapottér-reprezentáció kiterjesztésének célja, hogy a hiba alapú ultra-lokális modell hatását is figyelembe lehessen venni a szabályzó tervezése során. A hiba-alapú ultra-lokális modell jelei a következőképpen kerülnek megválasztásra: $\ddot{y}_{ref} = \ddot{y}_{p,ref}$, és $u_{nom,ref} = \delta_{ref}$, ezen jelek a szabályzástervezés során külső, mérhető zavarásaként kerülnek figyelembevételre. Mindazonáltal, az \ddot{y}_e és u jelek bevonása nagyobb kihívást jelent, mivel $y_{p,ref}$ egy prediktált hiba, amelynek a második deriváltja szükséges hiba-alapú ultra-lokális modell számításához. Ezen derivált másodrendű átviteli függvény segítségével kerül kiszámításra az $\dot{y}_{p,ref}$ alapján. A szűrő algoritmusok, illetve a nominális járműmodell használatával a következő kibővített állapottér modell írható fel:

$$\dot{x}_e = A_e(\rho)x_e + B_e(\rho)u_e + B_{e,w}(\rho)w_e, \quad (21a)$$

$$A_e(\rho) = \begin{bmatrix} A_v & B_v C_{f,1}^T & -B_v C_{f,2}^T / \alpha \\ 0_{2 \times 3} & A_{f,1} & -B_{f,1} C_{f,2}^T / \alpha \\ B_{f,2} A_v^{1 \times 3} & 0_{2 \times 2} & A_{f,2} \end{bmatrix}, \quad (21b)$$

$$B_e(\rho) = \begin{bmatrix} B_v \\ 0_{2 \times 1} \\ 0_{2 \times 1} \end{bmatrix}, \quad B_{e,w}(\rho) = \begin{bmatrix} B_v / \alpha & -B_v \\ B_{f,1} / \alpha & -B_{f,1} \\ 0_{2 \times 1} & 0_{2 \times 1} \end{bmatrix}, \quad (21c)$$

ahol $u_e = [\delta]$, $x_e^T = [\dot{\psi}, \dot{y}_p, y_p, x_{f,1}, x_{f,2}]$, $w_e^T = [\ddot{y}_{p,ref}, u_{nom,ref}]$ és $A_v^{1 \times 3} = e^T A_v$, $e^T = [0, 1, 0]$. $B_v = [\frac{C_f l_f}{I_z}, \frac{C_f}{m}, 0]^T$, $\rho = [v_x, \alpha]$. $u = [0, 1]x_{f,1} \ddot{y}_p = [0, 1]x_{f,2}$. A kibővített állapotter-reprezentáció alapjául szolgál a robusztus irányítástervezésnek.

4. tézis *Kidolgoztam egy új, ultra-lokális modell alapú szabályozási struktúrát, ahol az eredeti struktúra kibővítésre kerül egy nominális modellel, amely egy hiba-alapú ultra-lokális modellt fog eredményezni. Ezen túlmenően, a struktúrában található tervezési paraméterhez hangolási módszert javasoltam, amellyel az irányítási algoritmus minőségi jellemzőinek szintje növelhető. A hiba-alapú ultra-lokális modell kiterjesztett állapotter-reprezentációját meghatározva lineáris változó paraméterű (LPV) szabályzót terveztem. Az irányító algoritmus működése valós tesztjárműves teszteken keresztül került illusztrálásra.*

Kapcsolódó publikációk: [HFNG22, HFS+22c, FHS+22, HFS+22b]

További részletek a disszertáció 5. fejezetében találhatóak.

3.5. Garantált minőségi specifikációval rendelkező megfigyelő tervezés autonóm járművek számára

Gyakori probléma, hogy a rendszer szabályzásához szükséges állapotok nem mérhetőek közvetlenül, vagy a szenzorok finansiális okokból adódó széleskörű alkalmazása nem kivitelezhető. Ezen probléma megoldása érdekében, becslő és megfigyelő algoritmusok kerülnek alkalmazásra. A modell-alapú megfigyelők nagy mértékben függenek az alkalmazott modell pontosságától, így sok esetben nem megfelelő eredményeket szolgáltatnak. Ezzel ellentétben, a gépi tanuláson alapuló algoritmusok lehetőséget biztosítanak a minőségi jellemzők javítására. A cél a modellalapú, és a tanulás-alapú megfigyelőtervezési módszerek ötvözése, hogy mindkét technika előnyeit hatékonyan ki lehessen használni. A tézis a következő két fő részre bontható:

- Az első megoldás során olyan módszertan kerül bemutatásra, amelyben a tanuláson alapuló megfigyelő egy robusztus megfigyelővel kerül kombinálásra.
- A második megoldás egy LPV-alapú megfigyelő tervezés bevonásával kerül kivitelezésre.

Robusztus \mathcal{H}_∞ -alapú megfigyelő tervezése A javasolt módszerben egy neurális hálózat kerül alkalmazásra, ami a rendszer tényleges, mérhető állapotainak felhasználásával meghatározza a nehezen mérhető állapotot. A megfigyelő célja a rendszer állapotai és a becsült állapotok közötti különbség

minimalizálása:


$$\lim_{t \rightarrow \infty} (x(t) - \hat{x}(t))^2 \rightarrow \min. \quad (22)$$

A megfigyelőtervezés célja, azon L vektor megtalálása, amely minimalizálja a (22) függvényt. A L vektor és a rendszer modelljét tartalmazó megfigyelő struktúra a következő:

$$\dot{\hat{x}} = A(\hat{x} + \Delta) + B_2 u + L(y_m - C_2 \hat{x}), \quad (23)$$

ahol Δ vektor a megengedett eltérés a klasszikus, illetve a gépi tanuláson alapuló módszertan megfigyelt állapotai között. A megfigyelő tervezésének fő gondolata az, hogy a Δ és u vektorok ismert zavarokként kezelhetők. $\Delta = [\Delta_1 \dots \Delta_i \dots \Delta_n]^T$, amelyek határai a következőképp kerülnek megadásra: $\Delta_{min,i}, \Delta_{max,i}$, illetve $\Delta_i = \max(\min(\hat{x}_i - \hat{x}_{L,i}; \Delta_{max,i}); \Delta_{min,i}), \forall i \in n$, ahol i index $\hat{x}_{L,i}, \hat{x}_i$ az állapotvektor elemeit képviseli.

LPV-alapú megfigyelő tervezése Az előző módszerben a tanuláson alapuló megfigyelőtől vett maximális eltérés mértéke beépítésre kerül a modellalapú megfigyelő tervezésébe. A következőkben bemutatandó módszer alapját egy LPV-alapú algoritmus adja, amely független a gépi tanulási módszertől. Az algoritmus működése egy állapotfrissítési eljárásan alapszik, amely eldönti, hogy a tanulásalapú becslő kimenete elfogadható-e, vagy sem. A teljes algoritmus felépítését a 3. ábra szemlélteti. A $t - n$. időbéllyegnél lévő álla-



3. ábra. A megfigyelő felépítése

potbecslést a $\hat{x}_m(t - n)$ jelöli, a $\hat{x}_a(t - n)$ pedig a tanulás-alapú megfigyelő ugyanezen időbéllyegnél lévő eredményének felhasználásával frissített állapotbecslés. Továbbá, y_m a mért állapotváltozót adja meg, x_{all} pedig egy mérési vektor, amely tanulás-alapú megfigyelő által használt a mérhető állapotokat tartalmazza.

A $\hat{x}_a(t - n)$ és $\hat{x}_m(t - n)$ becsléseket kezdeti feltételként használva a mérhető kimenet \hat{y}_a és \hat{y}_m becslései az n időhorizontra az LPV-alapú megfigyelő segítségével kerülnek kiszámításra, amely hatékonyan képes kezelni a rendszer

paramétereiben létrejövő változásokat. A cél a kiszámított kimeneti jelek (\hat{y}_a , \hat{y}_m) és a mért (y_m) kimenet közötti eltérés meghatározása n időhorizonton. Az tanulásalapú megfigyelő pontosságának értékeléséhez $t - n$ időpontban a \hat{y}_a és \hat{y}_m konvergenciája a következő módon kerül ellenőrzésre:

$$e_a = y_m - \hat{y}_a, \quad e_m = y_m - \hat{y}_m, \quad (24)$$

ahol e_a és e_m tartalmazza a becslés, illetve a mérhető kimenet közötti hiba vektort. Az állapotfrissítési eljárás ezen hibavektor segítségével kerül meghatározásra, ahol a vektort súlyozzuk: $W = [\omega_1, \dots, \omega_n]$ értékekkel az n hosszúságú horizonton. Jelen megoldásban az állapotvektor a tanulásalapú megoldás kimenetét felhasználva frissül, ha az n becslési hiba csökkenését eredményezi a tanulás-alapú megoldás a klasszikus becslési eljáráshoz viszonyítva. Formálisan az állapotvektor akkor frissíthető, ha a következő feltétel teljesül:

$$\begin{array}{ll} \text{ha} & |e_a^T|W < |e_m^T|W, \\ \text{akkor} & \hat{x}(t) = \hat{x}_a(t). \end{array}$$

A W súlyvektor kiválasztása az algoritmus működésének szempontjából döntő jelentőségű, tekintve, hogy garantálnia kell a becslés konvergenciáját. A gyakorlatban ajánlott növekvő súlyokat használni ($\omega_1 \leq \omega_2 \leq \dots \leq \omega_n$), ami a konvergencia szigorúbb korlátozását eredményezi.

5 tézis *Két új keretrendszert dolgoztam ki lineáris, időinvariáns dinamikus rendszerek állapotbecslési problémáinak kezelésére. Az első módszerben a neurális hálózat alapú megfigyelőt egy robusztus \mathcal{H}_∞ alapú megfigyelővel kombináltam, amelynek alkalmazásával a legnagyobb becslési hiba minimális performancia szintje garantálható. A kombinált megfigyelő tervezési módszert egy modell-alapú szabályzó tervezési módszerrel történő kibővítést követően, egy robusztus \mathcal{H}_∞ szabályzó-megfigyelő közös tervezési feladatot írtam fel. A második megoldás során a tanulás alapú megfigyelőt és egy lineáris változó paraméterű (LPV) megfigyelőt közös tervezési struktúrába építettem be. A javasolt megoldások hatékonyságát, jármű-orientált példákon keresztül szemléltettem.*

Kapcsolódó publikációk: [NHG21, FHNG21a, HN20, HFS⁺22a].

További részletek a disszertáció 6. fejezetében találhatóak.

4. Jövőbeni kutatási irányok

A javasolt módszerek és algoritmusok felhasználásával több kapcsolódó, lehetséges jövőbeli kutatási irányt vázoltam fel a dolgozatban:

- A döntéshozatali algoritmusokat nehéz valós tesztjárművön tesztelni, mivel a mindennapi forgalomban nem lehet autonóm módon közlekedni. A SZTAKI RC autóinak felhasználásával a cél az 1. és 2. tézisben bemutatott módszerek minőségi jellemzőinek összehasonlítása. A rendszer előnye, hogy egy adott forgalmi szituációban nem csak fizikai járművek vehetők figyelembe, hanem virtuális járművek is, amelyekkel több forgalmi szituáció is hatékonyan vizsgálható. Továbbá, érdekes jövőbeli kutatási téma annak vizsgálata, hogy a módszerek hogyan hatnak az ember által vezetett járművekre.
- A gráf-alapú döntéshozatali algoritmusok más jármű-központú irányítási problémákra is alkalmazhatók, például földi és légi járművek kooperatív mozgástervezésére. Az Autonóm Rendszerek Nemzeti Laboratóriumában, a SZTAKI-ban található tesztelési platform és környezet, amely alapját képezheti ennek a jövőbeli kutatásnak.
- 3. tézis vonatkozásában, a kutatás jövőbeli kihívása a zárt hurkú illesztési folyamat külső zavarok és bizonytalanságok (pl. a tömeg változása) hatása figyelembe vétele, amellyel a bemutatott módszer robusztussága javítható. Ezenkívül további vizsgálatok tárgyát képezi, hogy a neurális hálózat képzési folyamata más tanulási módszerek, például transzfer tanulás alkalmazásával mennyiben javítható.
- Fontos szempont lehet az oldalirányú irányítási algoritmusok validálási folyamata egy valós tesztjármű segítségével. Bár az ultra-lokális modell-alapú szabályozó tesztjárművön került tesztelésre, a többi szabályozási és megfigyelési módszer működését csak a CarMaker szimulációs szoftverben elemeztem. A jövőbeli kutatások során a validálással és a megvalósítással kapcsolatos kihívásokra tervezem helyezni.

A Jelölt publikációi

- [FHN⁺20] Dániel Fényes, Tamás Hegedűs, Balázs Németh, Péter Gáspár, Damien Koenig, and Olivier Sename. LPV control for autonomous vehicles using a machine learning-based tire pressure estimation. *2020 28th Mediterranean Conference on Control and Automation (MED)*, pages 212–217, 2020.
- [FHNG21a] Dániel Fényes, Tamás Hegedűs, Balázs Németh, and Péter Gáspár. Observer design with performance guarantees for vehicle control purposes via the integration of learning-based and LPV approaches. *2021 IEEE Intelligent Vehicles Symposium Workshops (IV Workshops)*, pages 122–127, 2021.
- [FHNG21b] Dániel Fényes, Tamás Hegedűs, Balázs Németh, and Péter Gáspár. Robust control design for autonomous vehicles using neural network-based model-matching approach. *Energies*, 14(21), 2021.
- [FHS⁺22] Dániel Fényes, Tamás Hegedűs, Zoltán Szabó, Balázs Németh, and Péter Gáspár. Robust control design using ultra-local model-based approach for vehicle-oriented control problems. *European Control Conference (ECC)*, 2022.
- [HFNG20] Tamás Hegedűs, Dániel Fényes, Balázs Németh, and Péter Gáspár. Handling of tire pressure variation in autonomous vehicles: an integrated estimation and control design approach. *2020 American Control Conference (ACC)*, pages 2244–2249, 2020.
- [HFNG21] Tamás Hegedűs, Dániel Fényes, Balázs Németh, and Péter Gáspár. Improving sustainable safe transport via automated vehicle control with closed-loop matching. *Sustainability*, 13(20), 2021.
- [HFNG22] Tamás Hegedűs, Dániel Fényes, Balázs Németh, and Péter Gáspár. Design of model free control with tuning method on ultra-local model for lateral vehicle control purposes. *American Control Conference, 2022*, 2022.
- [HFS⁺22a] Tamás Hegedűs, Dániel Fényes, Zoltán Szabó, Balázs Németh, and Péter Gáspár. Combined observer design for road vehicles using LPV-based and learning-based methods. *11th IFAC Symposium on Fault Detection, Supervision and Safety for Technical Processes.*, 2022.
- [HFS⁺22b] Tamás Hegedűs, Dániel Fényes, Zoltán Szabó, Balázs Németh, and Péter Gáspár. Coordinated control design for steering and torque-vectoring in model-free control structure. *11th IFAC Symposium on Fault Detection, Supervision and Safety for Technical Processes.*, 2022.
- [HFS⁺22c] Tamás Hegedűs, Dániel Fényes, Zoltán Szabó, Balázs Németh, and Péter Gáspár. Robust LPV design within the model free control framework for road vehicles. *10th IFAC Symposium on Robust Control Design*, 2022.
- [HN20] Tamás Hegedűs and Balázs Németh. LPV irányítás gépi tanuláson alapuló abroncsnyomás-becsléssel autonóm járművek számára. *XIV.*

Innováció és fenntartható felszíni közlekedés konferencia, IFFK 2020, pages 1–7, 2020.

- [HNG19] Tamas Hegedűs, Balázs Németh, and Péter Gáspár. Graph-based multi-vehicle overtaking strategy for autonomous vehicles. *IFAC-PapersOnLine*, 52(5):372–377, 2019. 9th IFAC Symposium on Advances in Automotive Control AAC 2019.
- [HNG20a] Tamás Hegedűs, Balázs Németh, and Péter Gáspár. Challenges and possibilities of overtaking strategies for autonomous vehicles. *Periodica Polytechnica Transportation Engineering*, 48(4):320–326, 2020.
- [HNG20b] Tamás Hegedűs, Balázs Németh, and Péter Gáspár. Design of a low-complexity graph-based motion-planning algorithm for autonomous vehicles. *Applied Sciences*, 10(21), 2020.
- [HNG20c] Tamás Hegedűs, Balázs Németh, and Péter Gáspár. Multi-objective trajectory design for overtaking maneuvers of automated vehicles. *IFAC-PapersOnLine*, 53(2):15566–15571, 2020. 21st IFAC World Congress.
- [HNG21a] Tamás Hegedűs, Balázs Németh, and Péter Gáspár. Control design framework for automated vehicles using an advanced feedback linearization. *Advances in Dynamics of Vehicles on Roads and Tracks. IAVSD 2021*, 2021.
- [HNG21b] Tamás Hegedűs, Balázs Németh, and Péter Gáspár. MPC based semi-active suspension control for overtaking maneuvers. *Periodica Polytechnica Transportation Engineering*, 49(3):224–230, 2021.
- [NGH18] Balázs Németh, Péter Gáspár, and Tamás Hegedűs. Optimal control of overtaking maneuver for intelligent vehicles. *Journal of Advanced Transportation*, 2018.
- [NHG19] Balázs Németh, Tamás Hegedűs, and Péter Gáspár. Model predictive control design for overtaking maneuvers for multi-vehicle scenarios. *2019 18th European Control Conference (ECC)*, pages 744–749, 2019.
- [NHG20] Balázs Németh, Tamás Hegedűs, and Péter Gáspár. Performance guarantees on machine-learning-based overtaking strategies for autonomous vehicles. *2020 European Control Conference (ECC)*, pages 136–141, 2020.
- [NHG21] Balázs Németh, Tamás Hegedűs, and Péter Gáspár. Design framework for achieving guarantees with learning-based observers. *Energies*, 14(8), 2021.

Hivatkozások

- [1] Andreas Eidehall and Lars Petersson. Statistical threat assessment for general road scenes using Monte Carlo sampling. *IEEE Transactions on Intelligent Transportation Systems*, 9(1):137–147, 2008.

- [2] Florent Alché and Arnaud de La Fortelle. An LSTM network for highway trajectory prediction. *IEEE ITSC 2017*, 2018.
- [3] Liting Sun, Wei Zhan, Ching-Yao Chan, and Masayoshi Tomizuka. Behavior planning of autonomous cars with social perception. *2019 IEEE Intelligent Vehicles Symposium (IV2019)*, 2019.
- [4] Pengwei Wang, Song Gao, Liang Li, Shuo Cheng, and Hai xia Zhao. Research on driving behavior decision making system of autonomous driving vehicle based on benefit evaluation model. *Archives of Transport*, 53:21–36, 2020.
- [5] Árpád Fehér, Szilárd Aradi, and Tamás Bécsi. Q-learning based reinforcement learning approach for lane keeping. *2018 IEEE 18th International Symposium on Computational Intelligence and Informatics (CINTI)*, pages 31–36, 2018.
- [6] Emese Szádeczky-Kardoss and Bálint Kiss. Continuous-curvature paths for mobile robots. *Periodica Polytechnica Electrical Engineering*, 53(1-2):63–72, 2009.
- [7] Ernő Horváth and Claudiu Radu Pozna. Clothoid-based trajectory following approach for self-driving vehicles. *2021 IEEE 19th World Symposium on Applied Machine Intelligence and Informatics (SAMII)*, pages 251–254, 2021.
- [8] Ferenc Hegedüs, Tamás Bécsi, Szilárd Aradi, and Péter Gápár. Model based trajectory planning for highly automated road vehicles. *IFAC-PapersOnLine*, 50(1):6958–6964, 2017.
- [9] József Bokor, Péter Gáspár, and Zoltán Béla Szabó. *Robust control theory with automotive applications*. Typotex, 2012.
- [10] Fitri Yakub and Yasuchika Mori. Comparative study of autonomous path-following vehicle control via model predictive control and linear quadratic control. *Proceedings of the Institution of Mechanical Engineers Part D Journal of Automobile Engineering*, 229:1695–1714, 2015.
- [11] Daniel Fenyés, Balázs Nemeth, and Peter Gaspar. Impact of big data on the design of MPC control for autonomous vehicles. *2019 18th European Control Conference (ECC)*, pages 4154–4159, 2019.
- [12] Olivier Sename, Peter Gaspar, and Jozsef Bokor. *Robust Control and Linear Parameter Varying approaches: Application to Vehicle Dynamics*, volume 437 of *Lecture Notes in Control and Information Sciences (LNCIS, volume 437)*. Springer, 2013.
- [13] Dániel Fényes, Balázs Németh, and Péter Gáspár. LPV-based autonomous vehicle control using the results of big data analysis on lateral dynamics. *2020 American Control Conference (ACC)*, pages 2250 – 2255, 2020.
- [14] R. Rajamani. *Vehicle dynamics and control*. Springer, 2005.
- [15] P. E. Gill, W. Murray, and M.H. Wright. *Practical Optimization*. Academic Press, London UK, 1981.
- [16] William M. Bolstad. *Introduction to Bayesian Statistics*. John Wiley and Sons, Ltd, 2007.