

LPV irányítás gépi tanuláson alapuló abroncsnyomás-becsléssel autonóm járművek számára

Hegedűs Tamás*, Németh Balázs.**

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

**Számítástechnikai és Automatizálási Kutatóintézet,
Rendszer és Irányításméleti Kutatólaboratórium
1111 Budapest, Kende u. 13-17.
(e-mail:nemeth.balazs@sztaki.hu)

Absztrakt: Jelen cikkben egy big-data alapú guminyomás becslő módszer kerül bemutatásra, melynek eredményei egy LPV szabályzóban kerül felhasználásra. A becslési algoritmus alapját a járműre szerelt érzékelőkből elérhető jelek képezik. A guminyomás igen nagy hatással van a jármű stabilitására, hiszen a jármű az abroncsokon keresztül fejt ki erőt. Az abroncsok nyomásának változása az említett erők maximális értékének csökkenését vonhatja maga után, mely bizonyos manőverek kivitelezése közben stabilitás veszteséssel járhat. Szélsőséges esetben, a jármű egy manőver kivitelezése közben defektet kaphat, mely könnyen katasztrofális kimenettel végződhet. Így az abroncsnyomások becslésének igen nagy jelentősége lehet az autonóm járműrendszerek körében. Jelen cikk fő iránya az új, big-data alapú nyomásbecslési módszer bemutatása, amelynek eredménye egy LPV alapú laterális irányításban, mint ütemezési paraméter játszik szerepet. Végezetül egy járműdinamikai szoftverben végzett szimuláció kerül bemutatásra, mely az algoritmus hatékonyságát hivatott illusztrálni.

1. BEVEZETÉS

Napjainkban az autópálya egyik fő célja az egyre nagyobb automatizálási szintet biztosító funkciók kifejlesztése, mely a biztonságos utazás feltételeit képesek biztosítani az utasok számára. Ezen feladat számos kihívást hordoz magával amelyekkel a gyártóknak meg kell küzdeniük. Elmondható, hogy további cél az egyes járművek költségeinek csökkentése is. A költségsökkentés többek között elérhető a járműbe szerelt szenzorok redukálásával (pl.: nyomászenzorok, nagy pontosságú GPS). Fontos megjegyezni, hogy a modern járművek több, alacsony költségű érzékelővel fel vannak szerelve (pl.: gyorsulásmérők, giroszkópok). A már meglévő szenzorok által szolgáltatott jelek fúziója további információkat szolgáltathat a jármű egyes paramétereiről. További alkalmazási lehetősége az így kinyert információnak az érzékelők redundanciája csökkentése, vagy éppen az adott szenzor meghibásodásának jelzése.

Számos cikk foglalkozik az érzékelők fúziójának kérdéskörével. (Fényes *et al.*, 2018) egy oldalcsúszás-becslési módszert mutat be, amely csak a járművekben már megtalálható szenzorok jeleit használja. Továbbá, a járműre vonatkozó stabil tartományokat a (Fényes *et al.*, 2018) -ben bemutatott gépi tanulási technikák segítségével meg lehet határozni. A gumibroncs-nyomás becslése esetén vannak módszerek, amelyek klasszikus megközelítéseket alkalmaznak, pl. (Li *et al.*, 2003) bemutat egy módszert a

gumibroncs-nyomás hibájának detektálására a wavelet-alapú valószínűség-becslés alkalmazásával. Ezenkívül (Mayer *et al.*, 1995) indirekt megközelítést mutat be a gumibroncsok nyomásának becsléséhez. Ennek a módszernek a fő koncepciója az első és a hátsó tengely függőleges gyorsulásai közötti virtuális átviteli függvények meghatározására. Ezen megközelítés kihasználja azt az összefüggést, hogy a gumibroncs merevsége erősen korrelál a nyomás értékével. Hasonló megközelítés található (Solmaz *et al.*, 2015)-ben, amelyben a jármű laterális dinamikájához tartozó állapotok mérésével detektálják a nyomásvesztésget.

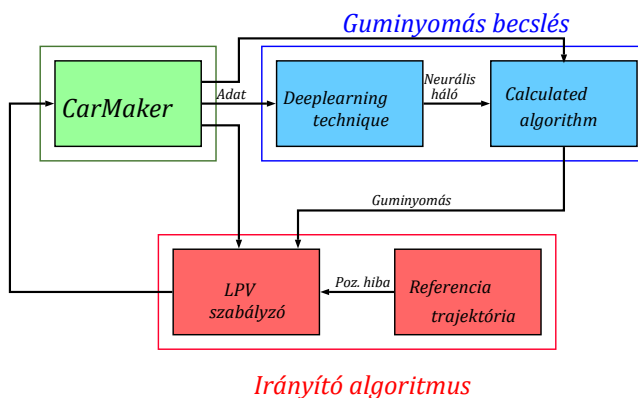
A szakirodalomban további megközelítések is találhatóak, amelyek a gumibroncsok nyomásvesztését szabályzási problémaként kezelik. Abban az esetben, mikor egy gumibroncsban található nyomás csökken, a jármű manőverezhetősége is csökken, mivel a megvalósítható oldalirányú erő maximális értéke nagymértékben függ a nyomástól. Az előbb leírt problémát járja körül (Guo *et al.*, 2012) egy H_∞ -alapú irányítórendszert használva. Ez az irányítóalgoritmus képes garantálni a jármű mozgásának robusztus működését nyomásvesztés esetén is. Egy másik megoldást mutat be (Nielsen *et al.*, 2015), amelyben a szerzők modellt prediktív irányítást használnak a jármű stabilitásának biztosításához. A bemutatott publikációk csak a becslési eljárással, vagy a kontroll problémával foglalkoztak külön-külön. Jelen cikkben azonban a két probléma együttesen kerül kezelésre. A cikk első felében egy big-data adatalapú becslési

módszer kerül bemutatásra, amelynek fő feladata a guminyomás értékének becslése. A cikk második felében a becslési eredmények kerülnek felhasználásra az oldalirányú irányítás tervezése során. A cikk fő kontribúciója egy LPV-alapú irányítás megvalósítása, amely képes garantálni a jármű stabilitását a kormányzó és a differenciális féknyomaték együttes alkalmazásával.

A cikk felépítése a következő: A 2. fejezet az adatgyűjtés és az elemzés módszerét hivatott bemutatni. Az LPV alapú irányítástervezés a 3. fejezetben kerül ismertetésre. Ezenkívül a 4. fejezet bemutatja a szimulációs eredményeket. Végezetül a 5. fejezetben kerül a cikk összefoglalásra.

2. AZ ADATGYŰJTÉS MÓDSZERE ÉS ELEMZÉSE

Amint azt az előző fejezetben említésre került, ezen cikk a nagy adatelemzésen alapuló LPV irányítási stratégiát mutat be az autonóm járművek számára. A teljes irányító algoritmus több részből áll, amelyek három fő rétegre vannak felosztva: Szimulációs környezet, Gumiabroncs nyomás-becslés és az Irányítási réteg. Az 1. ábrán a struktúra került bemutatásra.



1. ábra: Az algoritmus struktúrája

A szimulációs réteg kizárólag a CarMaker járműdinamikai szimulációs szoftvert tartalmazza. Míg az irányításért felelős réteg a referencia pálya előállításából és az LPV alapú irányítástervezésből áll, amely a III. fejezetben kerül részletezésre. A gumiabroncs nyomásának becslése ezen fejezetben kerül bővebben kifejtésre.

Tekintve, hogy a gumiabroncsok nyomásának pontos mérése igen nehézkes és költséges lehet, egy új, big-data alapú gumiabroncs-nyomásbecslőt kerül bemutatásra, amely csak azokat a jeleket használja, amelyek elérhetők a fedélzeti rendszerekből, pl.: gyorsulások, sebességek, szögsebességek stb.

2.1 Adatok rögzítése szimulációkból

A gépi tanulási algoritmusok alapját sok mérési adat képezi. Emiatt, számos szimuláció került futtatásra a széles körben

alkalmazott járműdinamikai szoftver segítségével. A szimulációk futtatását több gumimodell generálása előzi meg. Az egyes modellek, a nyomásértékben térnek el egymástól. A nyomás maximális értékét a nominális $p_{max}=2,5$ bar-ra választjuk, míg a legkisebb értéknek a $p_{min} = 1$ bar lett megadva. A lépésköz $\Delta p = 0,3$ bar értékre került beállításra.

A szimulációk során, ugyanazon pálya mentén lett a jármű a szimulációs szoftverben található vezetővel végigvezetve. A jármű sebessége 11-15 m/s között került variálásra. A jármű sebességének irányításáért egy PI szabályzó került implementálásra. A szimulációk során $T_s=0,01$ s-os mintavételezési idő lett beállítva. A szimulációk során számos adat került rögzítésre, csakúgy mint a sebességek, kormányzó, szögsebességek, gyorsulások, az egyes kerekek fordulatszámai, az abroncsokon ébredő erők ... stb.

Végül több mint 1 millió adatpont került lementésre. Mivel a jármű hosszirányú sebessége nagy tartományt fedett le, előfordult olyan eset, hogy a jármű nem volt képes az előre meghatározott útvonalat követni. Ezek az eseteket a jármű instabil viselkedéséből adódtak, emiatt az adatok feldolgozása előtt eltávolításra kerültek.

2.2. A neurális hálók rövid ismertetése

A neurális hálók a mély/gépi tanulás családjának részét képezik, amelyek emberi agy viselkedését hivatottak modellezni. Ezen hálók alkalmazásával összetett, nemlineáris problémák oldhatók meg. A fő előnye, amely megkülönbözteti ezt a technikát a hagyományos mély/gépi tanulási algoritmusoktól, azon képesség, hogy képes kezelni különböző típusú optimalizálási feladatokat, pl.: klaszterezés, osztályozás, előrejelzés stb. A neurális hálók felépítését tekintve súlyokból és aktivációs függvényekből állnak, melyeket neuronoknak nevezünk. Ezen neuronok rétegekbe vannak rendezve. A hálózatnak egy bemeneti és egy kimeneti rétege, és legalább egy rejtett rétege van. A rejtett rétegek száma és az aktivációs függvény típusa szabadon választhatók, amelyek a neurális hálózat fő paraméterei. Mint említettük, a cikkben neurális háló alapú rendszer kerül alkalmazásra a gumiabroncsok nyomásának becslésére. A neurális hálókhoz kapcsolatos részletesebb leírás a (Nielsen, 2015)-ben található.


Jelen cikkben egy olyan neurális háló kerül alkalmazásra, amely egy bemeneti, egy kimeneti és 3 rejtett rétegből áll. A rejtett rétegek 55-45-55 neuront tartalmaznak. A rejtett rétegek és a neuronok számát az úgynevezett kereszt validációs eljárással határozzuk meg. Kezdetben ez a módszer két részhalmozra osztja az adatkészletet. Az első részhalmoz a tanítás során kerül felhasználásra, míg a másik részhalmoz a neurális háló kiértékelésére szolgál. A háló másik fontos része az aktivációs függvények. Mint említettük, rengeteg függvény használható a tanítási folyamatban. Ebben az esetben rectified linear unit (ReLU) és log-sigmoid függvényeket alkalmazunk, mivel könnyen beállíthatók a nemlineáris problémákhoz. A hálózat tanítása során a Levenberg-Marquardt algoritmus kerül használatra, amely egy széles körben használt optimalizálási módszer a gépi tanulási technikák területén. A

hálózatok létrehozását és kiértékelését a következő alfejezet ismerteti.


2.3. Neurális hálók kiértékelése

A következőkben a mély tanuláson alapuló becslés eljárás eredményei kerülnek szemléltetésre. A neurális háló célja az első gumiabroncsok nyomásának külön-külön történő megbecslése. Számos neurális háló került létrehozásra különböző attribútumok felhasználásával annak érdekében, hogy a legjobban alkalmazható becslési modellt sikerüljön meghatározni.

Az összes mentett attribútum felhasználásakor a neurális háló pontos becslést ad. A 2. ábrán a becslült nyomás látható, amikor a jármű sebességét a CarMaker Driver irányítja, amely a szimulációs szoftver beépített vezető modellje. A neurális hálózat kimenetét 0,1-re kerekítjük. Tekintve, hogy a méréseket zajosak, 0,2 bar széles intervallum kerül meghatározásra. A becslés ezen intervallumon belül elfogadhatónak mondható. Az ábrán feltüntetett szaggatott vonalak szemléltetik az intervallum határait. A szimuláció során egy rövid szakaszt leszámítva, nyomásbecslések pontosak, mivel a gumiabroncsok tényleges értéke 1,5, 2,0, illetve 2,5 bar volt. Azon intervallum, ahol nem kaptunk pontos becslést abból adódik, hogy a jármű a stabilitás határán haladt az adott szakaszon.



2. ábra: A becslült nyomás értéke




3. ábra: A becslült nyomás értéke

Mindazonáltal érdemes megjegyezni, hogy az összes összegyűjtött attribútum nem mérhető közvetlenül az autón. Következő lépésként, új neurális hálók kerülnek felépítésre, melyek kizárólag a fedélzeti szenzor által szolgáltatott jelek felhasználásával igyekeznek a nyomás pontos értékét megbecsülni (pl.: keréksebességek, gyorsulások, hosszirányú sebesség és kormányzás szög).


Az felhasznált adatok csökkentése mellett betanított háló eredménye a 3. ábrán látható. Amint az ábra is mutatja, ez a hálózat kevésbé pontos becslést ad, mint az előző esetben. Ezen jelenség magyarázható azzal, ahogy már korábban említésre került, ebben az esetben csak a fedélzeti szenzorok jelei kerültek felhasználásra.

A becslés pontosságát a múltbeli értékek felhasználásával igyekszünk javítani a következő lépésben. A legbefolyásosabb múltbeli értékek meghatározásához spektrálanalízist hajtunk végre, amelynek eredményét a 4. ábra mutatja. Látható, hogy a jel információtartalma 6 Hz alatt van, ezen érték felett csak a zajok jelennek meg. Ezért két egymást követő pont közötti időintervallumot $T=1/6 \text{ Hz}=0,15 \text{ s}$ értékűre lett megválasztva. Ily módon kiválaszthatók a legjelentősebb értékek, és csökkenthető a felhasznált múltbeli értékek száma.



4. ábra: A spektrálanalízis eredménye

A kibővített tanulási készlet felhasználásával új becslési modell épül fel. Az új hálózat eredményét az 5. ábra mutatja. Bár látható, hogy ez a hálózat több hullámzó kimenetet szolgáltat, a hibajel csúcserőke jelentősen csökkent.



5. ábra: A becslült nyomás értékei a múltbeli adatokkal

Az I. táblázatban a bemutatott neurális háló összehasonlítása található, ahol a háló átlagos hibája, illetve a háló pontossága kerül feltüntetésre. Ahogy a táblázat is mutatja, a legjobb eredményt az a háló adja, amely az összes attribútumot használja (100% és 96,1%). Azonban már korábban említettük, nem minden tulajdonság mérhető közvetlenül a fedélzeti szenzorok segítségével, ezért ez a háló nem alkalmazható az irányításban. Elmondható továbbá, hogy a második legpontosabb becslést azzal a hálóval kaptuk, amely a múltbeli értékeket is felhasználja a becslési folyamat során.

Gumi	Összes adat	Múltbeli érték	Pontosság	Átlagos hiba
Bal	✓	✗	100%	0.00
Jobb	✓	✗	96.1%	0.0072
Bal	✗	✓	90.3%	0.01522
Jobb	✗	✓	94.4%	0.00552
Bal	✗	✗	83.3%	0.0554
Jobb	✗	✗	92.2%	0.01

1. Táblázat: Neurális háló pontossága

2. LPV ALAPÚ IRÁNYÍTÁSTERVEZÉS

Ezen fejezetben az LPV módszeren alapuló laterális irányítás kerül bemutatásra. A becslő algoritmus eredményét a irányítórendszerben ütemezési paraméterként kerül felhasználásra. A vezérlő algoritmusnak van egy további ütemezési paramétere, amely a jármű hosszirányú sebessége. Az irányító rendszernek két vezérlő bemenete van, a kormányzási szög és a differenciális féknyomaték, amelyek kompenzálják az oldalirányú erő veszteségét, amikor a gumibroncs nyomása csökken. A következőkben az LPV alapú irányítástervezés került bemutatásra (Gaspár *et al.*, 2012).

3.1. Járműdinamika modellezése

Ezen cikkben a jól ismert biciklimodell került felhasználásra a laterális dinamika leírására. Ez a modell a következő egyenletekből áll (Rajamani, 2004):

$$I\ddot{\psi} = F_{f,y}(\alpha_1)l_1 - F_{r,y}(\alpha_2)l_2 + M_d + \Delta F(p_1)l_1 \quad (1)$$

$$mv_x(\dot{\psi} + \dot{\beta}) = F_{f,y}(\alpha_1) + F_{r,y}(\alpha_2) + \Delta F(p_1) \quad (2)$$

$$\dot{v}_y = v_x(\dot{\psi} + \dot{\beta}) \quad (3)$$

$$\alpha_f = \delta - \beta - \frac{\dot{\psi}l_1}{v_x} \quad (4)$$

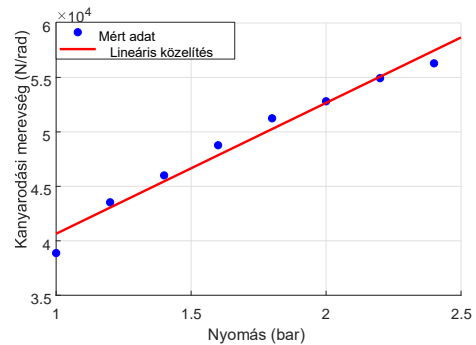
$$\alpha_r = \beta - \frac{\dot{\psi}l_2}{v_x} \quad (5)$$

ahol I az inerciát jelöli, míg $F_{i,y}$ az első és a hátsó tengely oldalirányú erőit adja meg. $l_{1,2}$ az első, illetve a hátsó tengely távolságát adja meg a jármű súlypontjától mérve. Továbbá a jármű kerekein ébredő kúszási szöget $\alpha_{1,2}$ jelöli, illetve M_d a

differenciális féknyomaték által generált forgatónyomaték. A nyomásvesztés által generált oldalirányú erő vesztesége a ΔF -en keresztül lett figyelembe véve. A jármű legyezési szögsebessége $\dot{\psi}$, illetve az oldalkúszási szög β is feltüntetésre kerül. Végezetül, a jármű elkormányzási szögét a δ adja meg.

Érdemes megjegyezni, hogy a p_1 nyomás nem jelenik meg az egyenletekben, mindazonáltal ez a változó szoros összefüggésben van a kanyarmerevséggel (C), amelyet a következőképp határozunk meg (Pacejka, 2004).

$$F_y(p_1) = C(p_1)\alpha \quad (6)$$



6. ábra: Kanyarodási merevség változása

A nyomás és a kanyarmerevség közötti összefüggést lineárisnak feltételezzük a CarMakeren végzett szimulációk figyelembe vételével. A C maximális értéke 57000 N/rad, míg a minimum 39000 N/rad értékre adódik, ahogy ez leolvasható a 6. ábráról. A bemutatott laterális modell a következőképp írható át állapotter reprezentációvá:

$$\dot{x}_v = A_v(v_x, p_1)x_v + B_v(v_x, p_1)u_v \quad (7)$$

A rendszer állapotai a következők: $x_v = [\psi \ \beta \ \dot{v}_y \ y]^T$. A rendszer bemenetei $u_v = [\delta \ M_d]$, ahol δ az első kerék kormányzási szögét jelöli. A (v_x, p_1) jelek a rendszer ütemezési paraméterei.

3.2. Kormányrendszer modellezése

A kormányrendszer dinamikája jelentős bír a az oldalirányú szabályzó performanciáira. Ezt szemelöltve, az irányítástervezés során a kormánymű dinamikája is figyelembe vételre kerül. Másodrendű rendszerként kerül modellezésre:

$$G_s(s) = \frac{b_2s^2 + b_1s + b_0}{s^2 + a_1s + a_0} \quad (8)$$

ahol b_i és a_i paraméterek, melyek identifikációs eljárás mentén kerül meghatározásra.

Jelen cikkben az ARX struktúrát használjuk a rendszer paramétereinek meghatározásához, mely a következőképp néz ki (Ljung *et al.*, 2003):

$$y(t) + a_1y(t-1) + \dots + a_{n_a}y(t-n_a) = b_1u(t-1) + \dots + b_{n_b}u(t-n_b) + e(t) \quad (9)$$

ahol y a rendszer kimenetét jelöli, ami esetünkben az első kerekek kormányzási szöge. Ezenkívül u jelöli a rendszer bemenetét, amely a kormánykerék szöge, illetve $e(t)$ a hibafüggvény. A paramétereket a következőképp vektorba lehet rendezni:

$$\sigma = [a_0 \ a_1 \ \dots \ a_{t-n_a} \ b_0 \ b_1 \ \dots \ b_{t-n_b}]^T \quad (10)$$

A q^{-1} eltolás operátor használatával a (9) egyenlet két egyenletre bontható:

$$A(q) = 1 + a_1q^{-1} + \dots + a_{n_a}q^{-n_a} \quad (11)$$

$$B(q) = b_1q^{-1} + \dots + b_{n_b}q^{-n_b} \quad (12)$$

Végül az identifikált rendszer átviteli függvénye kiszámítható:

$$G(q, \sigma) = \frac{B(q)}{A(q)} \quad (13)$$

Az eredményül kapott átviteli függvény diszkrét idejű, ami azt jelenti, hogy a kapott rendszert folytonossá kell konvertálni. A transzformációhoz $T_s = 0,01s$ mintavételi idő és zérus rendű tartó elem kerül használatra. A diszkrét rendszer átalakítása után a következő folytonos állapottér reprezentáció írható fel:

$$\dot{x}_s = A_s x_s + B_s u_s, \quad y_s = c_s^T x_s \quad (14)$$

ahol u_s a kormányzóg, y_s a kormányzott tengelyen található kerék szöge, illetve A_s , B_s és c_s^T mátrixok. Az x_s állapotvektor a kormányrendszer állapotából áll.

3.3. LPV irányítás tervezése

A bemutatott két állapottér reprezentáció (7), (14) egyesítve a következőképpen írható fel:

$$\dot{x}_e = A_e(v_x, p_1)x_e + B_e(v_x, p_1)u_e \quad (15)$$

ahol $u_e = [u_s \ M_d]^T$ és $x_e = [x_s \ x_v]^T$.

$$A_e(v_x, p_1) = \left[\begin{array}{c|c} A_s & 0_{2 \times 4} \\ \hline B_{v,1}(v_x, p_1)C_s^T & A_v(v_x, p_1) \end{array} \right] \quad (16a)$$

$$B_e(v_x, p_1) = \left[\begin{array}{c|c} B_s & 0_{2 \times 1} \\ \hline 0_{4 \times 1} & B_{v,2}(v_x, p_1) \end{array} \right] \quad (16b)$$

Az irányító rendszer felelős a jármű pályájának követéséért és a beavatkozó jel minimalizálásáért, emiatt a következő négy performancia kerül definiálásra:

1. *Az oldalirányú hiba minimalizálása*
A megfelelő követés miatt minimalizálásra kerül a referencia útvonal, illetve a jármű pozíciója közti eltérés értéke.
2. *A legyezési szögsebesség hiba minimalizálása*
Az oldalirányú hiba minimalizálása mellett, a legyezési szögsebességtől való eltérés minimalizálását is előírjuk, a pontos és sima követés érdekében.
3. *A kormányzóg minimalizálása*
Természetesen, az irányítás során a szabályzó által felhasznált energiát is igyekszünk csökkenteni, amely a kormányzóg minimalizálását jelenti.
4. *A differenciális féknyomaték minimalizálása*
Az előző ponthoz hasonlóan, igyekszünk a differenciális féknyomatéket is minimalizálni.

Az irányítás tervezésénél számos átviteli függvény kerül használatra a mért jelek skálázásának és az adott performanciák elérésének érdekében. Ezen eljárásom keresztül elérhető a rendszer előírt viselkedésének biztosítása. A súlyozó függvények, amelyek a referencia jel skálázásáért felelősek, a következőképpen állnak elő:

$$W_{ref,1} = \frac{0.1}{100s + 1} \quad (17)$$

$$W_{ref,2} = \frac{0.01}{100s + 1} \quad (18)$$

Továbbá, a $W_{z,1}$ és $W_{z,2}$ függvények feladata a referencia jel pontos követésének biztosítása.

$$W_{z,1} = \frac{s + 1}{s^2 + 2s + 1} \quad (19)$$

$$W_{z,2} = \frac{1}{s + 1} \quad (20)$$

A következő két súlyozó függvény fő feladata az aktuátorok közötti egyensúly biztosítása.

$$W_{z,3} = \left(\frac{p_{max}}{p_{est}} \right)^2 \frac{5s + 5}{0.1s + 1} 10^{-2} \quad (21)$$

$$W_{z,4} = \left(\frac{p_{est}}{p_{max}} \right)^6 \frac{1s}{2s + 1} 10^{-1} \quad (22)$$

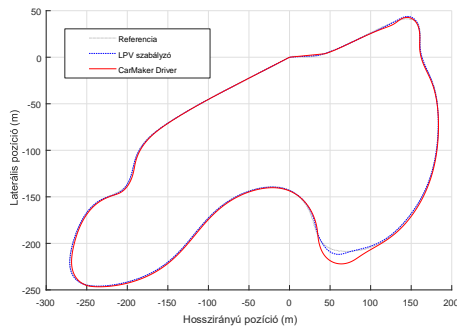
A skálázás fő oka, hogy az elérhető laterális erő maximális értéke a gumibroncs nyomásával együtt csökken. Ezért alacsony nyomáson a differenciális fekezéssel kerül kompenzálásra a kormányzás. Ezen korlátozások figyelembe vételével a paraméterváltozós szabályzó megtervezhető $K(v_x, p_1)$.

4. EREDMÉNYEK


Ebben a fejezetben egy átfogó szimuláció kerül prezentálásra a bemutatott algoritmus hatékonyságának szemléltetése érdekében. A szimuláció során a jármű a méretarányosan csökkentett Melbourne Forma-1-es pályán kerül végigvezetésre. Tekintve, hogy a CarMaker környezetben a

gumiabroncs nyomása a szimuláció során nem módosítható, több futtatás kerül végrehajtásra különböző gumiabroncsnyomások mellett. A gumiabroncsok nyomása alacsony értékű a szimulációk során.


A szimuláció több esetre került lefuttatásra, első esetben a beépített CarMaker Driver vezette végig a járművet az adott útszakaszon, amíg a második esetben a cikkben bemutatott algoritmus tette meg ugyanazt. A jármű által bejárt útvonalat a 7. ábra szemlélteti. Látható, hogy az autó nem képes követni a referencia trajektóriát, és egy éles kanyarban elhagyja az utat, amelyet a 8. ábra emel ki. A második esetben a gumiabroncsnyomásának azonos értékűre választása mellett, az autót a bemutatott algoritmus irányítja. A jármű így bejárt útvonala megtalálható ugyanezen ábrán. Mint látható, az előző esettől eltérően a jármű a bemutatott irányítási algoritmus segítségével képes követni az utat. Az oldalirányú hibákat a 8. ábra mutatja. Látható, hogy az LPV irányító rendszer kisebb hibákat biztosít az egész szimuláció során. Az oldalsó hiba csökkenése szembetűnő 45-50s között, amely időintervallum az éles kanyarhoz tartozik.




7. ábra: A megtett utak a szimulációk során



8. ábra: Az adott szakasz kiemelése és a hiba értéke



9. ábra: A kormánysszög alakulása



10. ábra: A súlyponti nyomaték alakulása

Végezetül, a 9. ábrán a kormánysszög alakulása látható a szimuláció során. A differenciális féknyomaték a 10. ábrán kerül bemutatásra. Összességében elmondható, hogy a bemutatott algoritmussal sikerült az oldalirányú hibát csökkenteni a pályán való haladás során.

5. KONKLÚZIÓ

Jelen cikkben egy új, big-data alapuló gumiabroncsnyomásbecslési módszer került bemutatásra, amely képes volt megbecsülni a gumi aktuális nyomását csak a fedélzeti szenzorok felhasználásával. A gumiabroncs merevsége a becslési algoritmus eredményeképp adott nyomásértékből került meghatározásra. Továbbá, a meghatározott merevségi érték került használatra, mint ütemezési paraméter az LPV vezérlés tervezésében. Végül, egy a CarMaker-ben végzett szimulációval került bizonyításra az irányítási rendszer hatékonysága és működése.

KÖSZÖNETNYILVÁNÍTÁS

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

Hegedűs Tamás kutatása az Innovációs és Technológiai Minisztérium ÚNKP-20-3 kódszámú Új Nemzeti Kiválósági Programjának a Nemzeti Kutatási, Fejlesztési és Innovációs Alapból finanszírozott szakmai támogatásával készült.

Németh Balázs kutatása a Bolyai János Kutatási Ösztöndíj és az Innovációs és Technológiai Minisztérium ÚNKP-20-5 kódszámú Új Nemzeti Kiválósági Programjának a Nemzeti Kutatási, Fejlesztési és Innovációs Alapból finanszírozott szakmai támogatásával készült.

IRODALOMJEGYZÉK

D. Fényes, B. Németh, M. Asszonyi, and P. Gáspár, Side-slip angle estimation of autonomous road vehicles based on big data analysis, 26th Mediterranean Conference on Control and Automation, June 2018, pp. 849–854., 2018

D. Fényes, B. Németh, and P. Gáspár, "Analysis of autonomous vehicle dynamics based on the big data approach," in European Control Conference, June 2018, pp. 219–224.

L. Li, F.-Y. Wang, Q. Zhou, and G. Shan, "Automatic tire pressure fault monitor using wavelet-based probability density estimation," *Vehicle System Dynamics*, pp. 80–84, 2003.

H. Mayer, "Model based detection of tyre deflation by estimation of a virtual transfer function," *Proceedings of IEEE Conference on Control Applications*, pp. 285–290, 1995.

S. Solmaz, "A novel method for indirect estimation of tire pressure," 9th Asian Control Conference (ASCC), 2013. [6] F. Wang, H. Chen, H. Guo, and D. Cao, "Constrained h8 control for road vehicles after a tire blow-out," *Mechatronics*, pp. 371–382, 2015.

H. Guo, F. Wang, H. Chen, and D. Guo, "Stability control of vehicle with tire blowout using differential flatness based mpc method," *Proceedings of the 10th World Congress on Intelligent Control and Automation*, pp. 2066–2071, 2012.

M. Nielsen, *Neural Networks and Deep Learning*. Determination Press, 2015.

P. Gáspár, Z. Szabó, and J. Bokor, "LPV design of fault-tolerant control for road vehicles," *International Journal of Applied Mathematics and Computer Science*, vol. 22, no. 1, 2012.

R. Rajamani, "Vehicle dynamics and control," Springer, 2005.

H. B. Pacejka, *Tyre and vehicle dynamics*. Oxford: Elsevier Butterworth-Heinemann, 2004.

L. Ljung, *System identification: theory for the user*. USA: PrenticeHall, 2003.