

Autonóm járművek utaskényelemre optimalizált laterális szabályozóinak összehasonlítása

Bokor Ákos Márk* Szabó Ádám**

*Rendszer és Irányításméleti Kutatólaboratórium, HUN-REN Számítástechnikai és Automatizálási Kutatóintézet (SZTAKI), Kende utca 13-17., H-1111~Budapest, Hungary (e-mail: bokor.akos.mark@sztaki.hun-ren.hu).

**Budapesti Műszaki és Gazdaságtudományi Egyetem, Közlekedés-és Járműirányítás Tanszék, Műegyetem rkp. 3., H-1111~Budapest, Magyarország (e-mail: szabo.adam@kjk.bme.hu)

Kivonat: Ez a cikk az autonóm járművek utaskényelemre optimalizált laterális szabályozóinak tervezésére és összehasonlítására összpontosít. Miközben a szabályozási feladat referencia pályától való eltérés minimalizálása, az utaskomfort javítása érdekében a tervezett szabályozókat egy genetikus algoritmus hangolja, amelynek költségfüggvénye az ISO 2631 szabványt követi. Három modell-alapú szabályozó - egy Lineáris Kvadratikus, egy Lineáris Kvadratikus Szervo, valamint egy Modell Prediktív Szabályozó – került összehasonlításra, szimulációs környezetben. A tesztet egy külvárosi útszakaszból áll, ahol a járművek különböző sebességek mellett haladva, minimalizálják az utasokat érő oldalirányú gyorsulást és annak deriváltját. A rendszer sebességfüggő dinamikájának figyelembevétele érdekében a szabályozók a rendszer lineáris paraméter-változó modelljén alapulnak. Az eredmények azt mutatják, hogy a tervezett szabályozók megfelelnek a meghatározott követelményeknek az úgynevezett Equivalent Acceleration és Motion Sickness Dose Value értékek, valamint a kívánt pályától való eltérés tekintetében.

1. BEVEZETÉS

A járművek laterális szabályozásának kutatása az 1950-es évek óta folyamatban van, és továbbra is kritikus szempont az autonóm járművek tervezésében a technológiai igények és kihívások változása mellett. A geometriai elveken alapuló algoritmusok, mint a Pure Pursuit (Samuel et al., 2016) és a Stanley (AbdElmoniem et al., 2020) szabályozók, számos esetben sikeresnek bizonyultak, de gyakran nem képesek kezelni a bonyolultabb, dinamikus vezetési feladatokat. Ezt a problémát hivatottak kezelni a modell-alapú megoldások, amelyek kezdetben lineáris modellekre épültek, de fokozatosan áttértek a bonyolultabb, nemlineáris modellekre (Menhour et al., 2012). Mindegyik megoldásnak megvannak az előnyei és korlátai, különösen a változó rendszerparaméterek kezelésével kapcsolatban.

Az évek során számos kulcsfontosságú szempont alakította a laterális szabályozók tervezését, mint például a robusztus stabilitás, a számítási kapacitás és a pontos referenciajelkövetés (Gáspár et al., 2016; Tagne et al., 2015). Az utaskomfort integrálása a szabályozórendszerek tervezésébe elengedhetetlenné vált, ahogy az iparág egyre jobban közelít az SAE 5. szintű autonómia elérése felé. Ehhez, és a piacképesség növeléséhez, az emberi vezetéshez hasonló érzet biztosítása szükséges (Cascetta et al., 2022). Az utóbbi években ezt a célt szolgálja a gépi tanuláson alapuló algoritmusok alkalmazása. Például (Zhang et al., 2018) egy dupla Q-tanuláson alapuló algoritmus segítségével valósítja meg az emberre jellemző viselkedést. (Zhu et al., 2018) egy mély megerősítéses tanuláson alapuló járműkövető modellt prezentál, melynek performanciája

felülmúlja a hagyományos modell- és adatalapú modelleket, miközben jó generalizációs képességgel rendelkezik.

A vizuális alapú laterális szabályozók, például a gépi látás és a szabályozási modulok kombinálása (Li et al., 2019), szintén ígéretes megközelítés lehet. Ezen megoldások előnyei ellenére, a referencia jelkövetés pontosságának növelése gyakran magasabb oldalirányú gyorsulással jár, ami negatívan befolyásolhatja az utaskomfortot (Tagne et al., 2015; Mesghali, 2021). A pontos követés és az utaskomfort közötti egyensúly különösen nagy sebességeknél válik kritikussá, ahol az éles manőverek nagyobb oldalirányú gyorsulást eredményeznek. Ennek hatásait sebességfüggő szabályozó tervezésével lehet enyhíteni. Az olyan technikák, mint a Gain Scheduling és a Lineáris Változó Paraméterű (LPV) szabályozás, lehetőséget kínálnak a szabályozók erősítésének járműsebesség alapján történő meghatározására (Németh and Gáspár, 2011; Zin et al., 2008; Tóth, 2010), optimalizálva mind a performanciát, mind a kényelmet különféle vezetési körülmények között.

1.1 Kapcsolódó kutatások

Számos módszer létezik az utaskomfortra optimalizált szabályozók tervezésére. (Moreno-Gonzalez et al., 2022) által javasolt model-free algoritmus a jármű dinamikáját kezelve csökkenti az utasok mozgás okozta kellemetlenségeit. A Lineáris Kvadratikus Szabályozó (LQR) és a Modell Prediktív Szabályozás (MPC) tervezésekor is figyelembe vették az utaskomfortot, ahol (Sever et al., 2021), valamint (Luciani et al., 2020) munkái kiemelik a komfort és a járműdinamika egyensúlyának fontosságát. Ezek a megoldások javítják a

komfortot anélkül, hogy jelentősen csökkentenék a szabályozók pályakövető képességeit, hangsúlyozva a további összehasonlító elemzések szükségességét a különböző megközelítések hatékonyságának jobb megértéséhez.

1.2 Kontribúció

Jelen cikk három modell-alapú laterális szabályozót mutat be, melyek hangolása egy genetikus algoritmus (GA) segítségével történik. A GA költségfüggvénye a követési pontosságra és az utaskomfortra vonatkozó követelményeket ötvözi. A cikkben bemutatott szabályozók az ISO 2631-1 szabvány szerint számított egyenértékű gyorsulás (EA), Motion Sickness Dose Value (MSDV) értékek és az oldalirányú pozícióhiba alapján kerültek kiértékelésre és összehasonlításra.

A cikk felépítése a következő: a 2. fejezet bemutatja a használt lineáris változó paraméterű modellt, amely az oldaldinamikát írja le. A 3. és 4. fejezetek a megvalósított szabályozási algoritmusokat és az alkalmazott optimalizálási algoritmust ismerteti. Az 5. szakasz a szimulációs környezettel és a tesztesetekkel foglalkozik, míg a 6. fejezet az eredmények értékelését tartalmazza. A levont következtetések a 7. fejezetben kerülnek ismertetésre.

2. LATERÁLIS JÁRMŰMODELL

Ez a cikk egy módosított változatát alkalmazza a széles körben ismert dinamikus kerékpár modellnek, amely a járművet egy kéttengelyű, egynyomvonalú rendszerként ábrázolja. Az 1. ábra mutatja a jármű oldaldinamikáját. A mozgásegyenletek Newton második törvényének alkalmazásából származnak, figyelmen kívül hagyva az út lejtésének a szögének hatását.

$$m(\ddot{y} + V_x \dot{\psi}) = F_{yf} + F_{yr}, \quad (1)$$

ahol m a jármű tömege, \ddot{y} a jármű oldalirányú gyorsulása, V_x a hosszirányú sebesség a tömegközéppontban, és $\dot{\psi}$ a legyezési szögsebesség. Az F_{yf} és F_{yr} az első és hátsó kerekek oldalirányú erői. A jármű nyomatéki egyensúly egyenlete, amely a kormányzási dinamikát határozza meg, a következő képpen számolható:

$$I_z \ddot{\psi} = l_f F_{yf} - l_r F_{yr}, \quad (2)$$


ahol I_z a jármű tehetetlensége a z tengely mentén, $\ddot{\psi}$ a legyezési szöggyorsulás, valamint l_f és l_r a jármű tömegközéppontjától az első és hátsó kerekéig mért távolságok. A kerékabroncsok és a kormányzási dinamika kölcsönhatását figyelembe véve, a keresztirányú abroncserők a csúszásszög és a keresztirányú erő közötti kapcsolat alapján számíthatók ki. Feltételezve a lineáris összefüggést, az első és

hátsó keresztirányú abroncserők meghatározása a következő módon lehetséges:

$$F_{yf} = 2C_f(\delta - \theta_{yf}), \quad (3)$$

$$F_{yr} = 2C_r(-\theta_{yr}), \quad (4)$$

ahol C_f és C_r az első és hátsó abroncsok kanyarodási merevségének együtthatóit jelöli, δ a kormányaszög, míg θ_{yf} és θ_{yr} az első és hátsó kerék sebesség vektorainak szögeit jelöli.



1. Ábra: Az egynyomvonalú járműmodell

Az alkalmazott modell jármű állapota helyett (Rajamani, 2011) alapján azok referenciapályától való eltéréseit használja, mint a jármű oldalirányú eltérése a referencia pályától ($e1$) és az útirányhoz viszonyított orientációs hibája ($e2$). A kívánt pálya követéséhez szükséges állapotok deriváltjai a jármű oldalirányú sebességének és a kívánt, és aktuális fordulási sebesség különbségének figyelembevételével határozhatók meg:

$$\dot{e}_1 = \dot{y} + V_x(\dot{\psi} - \dot{\psi}_{des}), \quad (5)$$

$$\dot{e}_2 = \dot{\psi} - \dot{\psi}_{des}, \quad (6)$$

$$\ddot{e}_1 = \ddot{y} + V_x(\ddot{\psi} - \ddot{\psi}_{des}), \quad (7)$$

$$\ddot{e}_2 = \ddot{\psi} - \ddot{\psi}_{des}, \quad (8)$$

ahol \dot{y} a jármű oldalirányú sebessége, ψ_{des} a kívánt legyezési szög. A $\ddot{\psi}_{des}$ nullának tekintése után az egyenletek állapotter reprezentációba írhatók át. Az így kapott állapot- és bemeneti mátrixok a jármű hosszirányú sebességétől függenek, így a rendszer időben változó tulajdonságokat mutat. Ennek megfelelően a modell a (9) egyenlettel leírható, grid alapú LPV reprezentációval írható le. A bemutatott algoritmusok Gain Schedulinget használnak a rendszer időben változó természetének kezelésére.

$$\frac{d}{dt} \begin{bmatrix} e_1 \\ \dot{e}_1 \\ e_2 \\ \dot{e}_2 \end{bmatrix} = \begin{bmatrix} 0 & 1 & 0 & 0 \\ 0 & -\frac{2C_f+2C_r}{mV_x} & \frac{2C_f+2C_r}{mV_x} & -\frac{2C_f l_f+2C_r l_r}{mV_x} \\ 0 & 0 & 0 & 1 \\ 0 & -\frac{2C_f l_f-2C_r l_r}{I_z V_x} & \frac{2C_f l_f-2C_r l_r}{I_z} & -\frac{2C_f l_f^2+2C_r l_r^2}{I_z V_x} \end{bmatrix} \begin{bmatrix} e_1 \\ \dot{e}_1 \\ e_2 \\ \dot{e}_2 \end{bmatrix} + \begin{bmatrix} 0 \\ \frac{2C_f}{m} \\ 0 \\ \frac{2C_f l_f}{I_z} \end{bmatrix} \delta + \begin{bmatrix} 0 \\ -\frac{2C_f l_f+2C_r l_r}{mV_x} - V_x \\ 0 \\ -\frac{2C_f l_f^2+2C_r l_r^2}{I_z V_x} \end{bmatrix} \dot{\psi}_{des} \quad (9)$$

3. SZABÁLYOZÓ ALGORITMUSOK

Ez a fejezet bemutatja a szabályozók elméleti hátterét és megvalósítását, beleértve a Lineáris Kvadratikus Szabályozót (LQR), a Lineáris Kvadratikus Szervót (LQ-Servo) és a Modell Prediktív Szabályozót (MPC). A bemutatott szabályozók diszkrét időben, $1ms$ mintavételezési idővel lettek implementálva.

3.1 Lineáris Kvadratikus Szabályozó

A lineáris kvadratikus szabályozási probléma alapvető az irányításméletben (Athans and Falb, 2013). Az LQR szintézis első lépése a (9) egyenletben bemutatott modell átalakítása diszkrét idejű állapottér modellé:

$$x(k+1) = Ax(k) + Bu(k), \quad (10)$$

$$y(k) = Cx(k) + Du(k), \quad (11)$$

ahol $x(k)$ az állapotvektor a k -adik idő lépésében, $u(k)$ a bemeneti vektor, A az állapotátmeneti mátrix, és B a bemeneti mátrix. $y(k)$ a kimeneti vektor, C a kimeneti mátrix, és D az segédmátrix.

Az LQR szabályozó célja egy kvadratikus költségfüggvény minimalizálása, amely az állapot- és az bemeneti vektorok súlyozott összegét veszi figyelembe végtelen horizonton:

$$J = \sum_{k=0}^{\infty} (x(k)^T Q x(k) + u(k)^T R u(k)), \quad (12)$$

ahol Q és R pozitív (szemi)definit mátrixok, amelyek az állapothibákat- és bemeneteket súlyozzák. A költségfüggvényt minimalizáló optimális megoldás a diszkrét idejű Riccati-egyenlet (DARE) megoldásával határozható meg:

$$A^T P A - P - A^T P B (B^T P B + R)^{-1} B^T P A + Q = 0, \quad (13)$$

ahol P egy pozitív definit mátrix, a Riccati-egyenlet megoldása. P felhasználásával az optimális visszacsatolási erősítés K a következőképpen írható fel:

$$K = (B^T P B + R)^{-1} B^T P A. \quad (14)$$

Az optimális szabályozási bemenet, amely minimalizálja a költségfüggvényt, a következő:

$$u(k) = -Kx(k). \quad (15)$$

3.2 Lineáris Kvadratikus Szervo

A lineáris kvadratikus szervo megközelítés kiegészíti a rendszer kimenetét egy integrátorral, a nulla állandósult állapotú hiba biztosítása, és a pontosabb pályakövetés érdekében:

$$\begin{bmatrix} x(k+1) \\ z(k+1) \end{bmatrix} = \begin{bmatrix} A & 0 \\ -C & I \end{bmatrix} \begin{bmatrix} x(k) \\ z(k) \end{bmatrix} + \begin{bmatrix} B \\ 0 \end{bmatrix} u(k), \quad (16)$$

ahol I egy egységmátrix, és $z(k)$ a kimeneti hiba integrálja.

A Riccati-egyenlet megoldása az augmentált rendszerre a következő visszacsatolási erősítést adja:

$$K_I = \begin{bmatrix} K \\ K_z \end{bmatrix} = -(R + B^T P B)^{-1} (B^T P A). \quad (17)$$

Ezután az LQ-Servo optimális szabályozási bemenete a következőképpen írható fel:

$$u(k) = -Kx(k) - K_z z(k). \quad (18)$$

3.3 Model Predictive Control

Végül egy MPC került megvalósításra (Wang, 2009) alapján. Minden időlépésnél egy véges horizontú optimalizálási problémát old meg az algoritmus, figyelembe véve a jövőbeli állapotokat és szabályozási lépéseket. Az állandósult állapotbeli hiba kiküszöbölésének az érdekében az állapottér modellt az állapot megváltozására írjuk fel két diszkrét időlépés között:

$$\Delta x(k+1) = A \Delta x(k) + B \Delta u(k), \quad (19)$$

ahol Δx az állapot megváltozása, míg Δu a beavatkozás megváltozása.

Ezután, az augmentált állapottér egyenletek a következőképpen írhatók fel:

$$\hat{x}(k+1) = \hat{A}x(k) + \hat{B}u(k), \quad (20)$$

$$\hat{y}(k) = \hat{C}\hat{x}(k), \quad (21)$$

ahol \hat{x} az augmentált állapotvektor, \hat{A} , \hat{B} és \hat{C} az augmentált állapot-, bemeneti és kimeneti mátrixok, és \hat{y} a becsült kimeneti vektor.

Az MPC algoritmus célja a következő feltételes optimalizálási probléma megoldása, az augmentált rendszerre:

$$\min_{\Delta U} J(\Delta U) = \sum_{k=1}^{N_p} y_i^T Q y_i + \sum_{k=1}^{N_c} \Delta u_i^T R \Delta u_i, \quad (22)$$

$$\begin{aligned} \Delta u_{min} &\leq \Delta u(k) \leq \Delta u_{max} & \forall k \in N_c, \\ u_{min} &\leq u(k) \leq u_{max} & \forall k \in N_c, \end{aligned} \quad (23)$$

ahol N_p a predikciós horizont, N_c a szabályozási horizont, és Δu a bemeneti jel változásának nagyságát jelenti. Az optimalizálási problémát általában kvadratikus programozás (QP) segítségével oldják meg, mivel ez hatékonyan kezeli az aktív korlátokat. A futásidő minimalizálása érdekében a kényszereket (feltételeket) csak a megoldás első elemére alkalmazzuk.

Ezek a szabályozók szimulációs környezetben lettek kiértékelve, hogy meghatározható legyen a hatékonyságuk, a járműdinamika és az utaskomfort szempontjaiból különböző sebességek esetén.

4. OPTIMALIZÁCIÓ

A tervezett szabályozók egy be- és kimenetű (SISO) rendszerek, ezért elegendő az R paraméter hangolása a költségfüggvényben, a megadott utaskomfort kritériumok betartása érdekében. Ez a megközelítés felgyorsítja az optimalizálási folyamatot és csökkenti a számítási igényt. A szabályozó paraméterek optimalizálásához a Genetikus Algoritmus (GA) módszer került alkalmazásra, melynek egyszerűsített folyamata a 2. ábrán látható.

A GA folyamata a populáció inicializálásával kezdődik, amely ebben a kutatásban 20 egyedből állt. Minden egyed egy potenciális megoldást kódol az optimalizálási problémára. Az egyedek minőségét egy fitness függvény alapján értékelhetők, amely az oldalirányú gyorsulás, annak deriváltja (jerk),

referencia pályától való eltérés és a kormányzási szög büntetéseit tartalmazza:

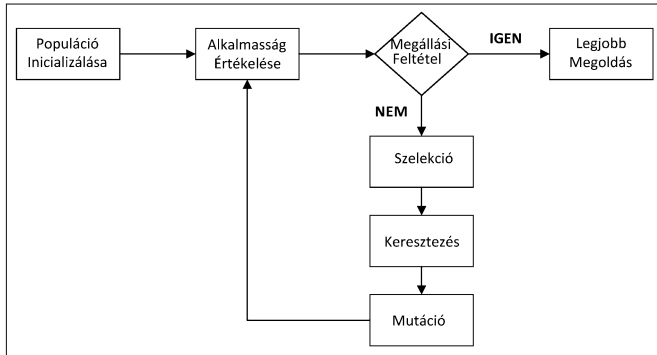
$$J_{\text{total}} = J_{a_y} + J_{a_x} + J_{e_1} + J_{\delta}, \quad (24)$$

$$J_{a_y} = \begin{cases} \frac{\int_{t=0}^T (a_{y,\max} - |a_y|)^2}{T} W_{a_y} & \text{if } |a_y| > a_{y,\max} \\ 0 & \text{egyébként} \end{cases} \quad (25)$$

A fitness függvény minden tagja a (25) egyenlet alapján került kiszámításra, ahol az oldalirányú gyorsulás szerepel példaként. Az egyes tagok súlya a Bryson szabály szerint, a maximálisan megengedett értékek pedig az ISO 2631 szabvány, a kívánt követési pontosság és a kormányzás fizikai korlátai alapján kerültek meghatározásra. A cél a beavatkozáskor fellépő oszcillációk minimalizálása, valamint az oldalirányú eltérések és gyorsulás csökkentése.

Az alkalmasság értékelése után, az algoritmus ellenőrzi a kilépési feltételt, amely ebben az esetben a 60 generáció elérése volt. Ha a feltétel nem teljesül, az algoritmus folytatja az egyedek kiválasztását, keresztezését és mutációját a következő generáció számára. A kereszteződés során az egyedek új utódokat hoznak létre, miközben a mutáció véletlenszerű változásokat vezet be a genetikai sokféleség fenntartása érdekében. Minden iteráció új R értéket határoz meg, amely az fitness függvény újraértékelésére használható a következő iterációban.

Ez az iteratív folyamat addig folytatódik, amíg az fitness függvény konvergál egy optimális megoldáshoz, biztosítva, hogy a GA hatékonyan hangolja az R paramétert a megadott utaskomfort előírások teljesítéséhez.




2. Ábra. Genetikus Algoritmus Blokkdiagrammja

5. SZIMULÁCIÓS KÖRNYEZET

A szimulációk során a CarMaker alapértelmezett járműmodellje került alkalmazásra. Az oldalirányú gyorsulás és a pályától való eltérés beépített inerciális és útszenzorok segítségével volt mérhető. A jerk a gyorsulás deriválásával és egy aluláteresztő szűrő alkalmazásával számolható, hogy csökkenteni lehessen a numerikus deriválásból eredő zajt.

A tesztet egy külvárosi útszakaszból áll, ahol a jármű sebessége maximálisan 50 km/h. A 3. ábra illusztrálja a fordulási sugarakat és a pályát. (Kilinc and Baybura, 2012) és (Jagelčák et al., 2022) alapján az út ideális görbületi sugara 230 m és 280 m között van, ami 1.47 m/s² oldalirányú

gyorsulásnak felel meg. Ennek megfelelően az út ívei 230 m és 280 m fordulási sugárnak felelnek meg.



3. Ábra. Referencia pálya és útgörbület

6. EREDMÉNYEK

Számos kulcsfontosságú mérőszám került figyelembevételre az átfogó összehasonlítás érdekében. (Luciani et al., 2020) és az ISO 2631 szabvány alapján az EA és az MSDV értékek lettek választva az utaskomfort mérésére. Az utasok kényelemérzetét az Equivalent Acceleration alapján különböző kategóriákra lehet osztani, melynek meghatározásához először a frekvencia-súlyozott négyzetes középérték (WRMS) gyorsulás számolása szükséges a fő tengelyek mentén:

$$a_{w_d,RMS} = \left(\frac{1}{T_f} \int_0^{T_f} a_{w_i}^2(t) dt \right)^{\frac{1}{2}}, \quad (26)$$

ahol T_f az integrációs idő, a_{w_d} a frekvencia-súlyozott függvény, és $a_{w_d,RMS}$ az a_{w_d} négyzetes középértéke.

Ezután az Equivalent Acceleration kiszámítható:


$$a_{eq} = \sqrt{k_x^2 a_{x,w}^2 + k_y^2 a_{y,w}^2}, \quad (27)$$

itt $a_{x,w}$ és $a_{y,w}$ a frekvencia-súlyozott RMS gyorsulások az x és y tengelyek mentén, valamint k_x és k_y súlyozási tényezők. Feltételezve, hogy $k_x = k_y = 1$ és elhanyagolva a hosszanti gyorsulást (mivel az állandó volt), a_{eq} kiszámítható $a_{y,w}$ RMS értékeként az egész pályán.

A második értékelt index a Mozgási Betegség Dózis Érték (MSDV), amely a utazási betegség előfordulásának valószínűségét írja le az oszcilláló mozgás miatt. Ez az index hasonlóan számolható, mint az a_{eq} , de a W_f -et használja frekvencia-súlyozott függvényként. Az ISO 2631 szabvány szerint a rosszullet (nausea) tüneteinek valószínűsége a következőképpen számítható:

$$a_{MSDV} [\%] = \frac{1}{3} \cdot a_{MSDV} \times 10. \quad (28)$$

Ezen túlmenően a szabályozók teljesítménye is értékelve lett a referencijel követés és a szabályozási bemenet szempontjából az utaskomfort mellett.



1.3 4. Ábra. A járművek oldalirányú gyorsulása 50 km/h-nál

Ahogy a 4. ábrán látható, a gyorsulási csúcsok elsősorban a hirtelen irányváltások eredményei. Ezek a csúcsok jelentősen eltérnek a különböző szabályozók esetében. Az LQR esetében a csúcsok kisebb határok között maradnak a szabályozási stratégia természetéből adódóan. Ezzel szemben a másik két szabályozó nagyobb gyorsulási csúcsokat mutat a hibákra felírt modell és a szabályozók integráló tulajdonsága miatt.

1. Táblázat: Szabályozó performancia összehasonlítás 50 km/h-nál

Metrika	LQR	LQ-Servo	MPC
a_{eq} [m/s ²]	0.090642	0.096871	0.11723
a_{MSDV} [%]	3.9759	3.9034	4.0441
a_{peak} [m/s ²]	1.193	1.42	1.752
Max. Jerk [m/s ³]	6.63	10.77	13.96
Átlagos / max. Oldalirányú hiba [m]	0.0295 / 0.0731	0.0071 / 0.0594	0.007 / 0.0395
Beállási idő [s]	0.376	0.426	0.837

A szabályozó teljesítménymutatóinak az 1. táblázat mutatja be részletesen.

Az adatok azt mutatják, hogy mindhárom szabályozó a "nem kényelmetlen" kategóriába esik az egyenértékű gyorsulás (a_{eq}) szempontjából (Luciani et al., 2020) által meghatározott táblázat alapján. Ez azt jelzi, hogy a szabályozók viszonylag egyenletes teljesítményt nyújtanak az utaskomfort szempontjából az egész pályán.

Különösen az LQR és LQ-Servo szabályozók a_{eq} értékei mutattak hasonló eredményeket, ezzel szemben a Modell

Prediktív Szabályozás (MPC) valamivel magasabb a_{eq} értékeket mutat.

Az MSDV értékeket tekintve mindhárom szabályozó körülbelül 4%-ot ért el, ami megfelel a kritériumoknak. A gyorsulási csúcsok nagyságát tekintve a legnagyobb értékek az MPC szabályozó esetében voltak, majdnem 50%-kal magasabbak, mint az LQR esetében. Ez kiemeli az MPC szabályozó nagyobb érzékenységét, amelyet a módosított dinamikus kerékpár modell augmentációja okoz.


2. Táblázat: Szabályozó performancia összehasonlítás különböző sebességeknél

Metrika	LQR	LQ-Servo	MPC
50 km/h			
a_{eq} [m/s ²]	0.090642	0.096871	0.11723
a_{MSDV} [%]	3.9759	3.9034	4.0441
Abszolút maximum a_y [m/s ²]	1.2421	1.4737	1.7523
70 km/h			
a_{eq} [m/s ²]	0.18601	0.18636	0.23495
a_{MSDV} [%]	10.5429	10.6457	10.5926
Abszolút maximum a_y [m/s ²]	2.3904	2.427	3.0725
100km/h			
a_{eq} [m/s ²]	0.35503	0.37098	0.52087
a_{MSDV} [%]	22.9865	23.5348	22.5547
Abszolút maximum a_y [m/s ²]	3.8248	3.9982	5.6173

A szabályozókat ugyanazon a pályán 70 km/h és 100 km/h sebességgel is teszteltük. Ezeknek a teszteknek az eredményei a 2. táblázatban láthatók. Megfigyelhető, hogy a maximális abszolút gyorsulás és az MSDV értékek jelentősen növekednek, mivel az ív kisebb maximális sebességre lett definiálva. Az egyenértékű gyorsulás (a_{eq}) szempontjából azonban még 100 km/h sebességnél is csak az MPC szabályozó esik a "kissé kényelmetlen" tartomány közepébe, míg a másik két szabályozó közel áll a "nem kényelmetlen" kategóriához.

Az 5. ábra bemutatja a laterális pozíció hiba összehasonlítását. Az LQR szabályozó nem csökkenti az állandósult hibát az integráló komponens hiánya miatt. Ezzel szemben, bár nagyobb átmeneti eltéréseket mutat, az LQ-Servo szabályozó hatékonyan nullára csökkenti az állandósult hibát. Ez a viselkedés az LQ-Servo szabályozó integráló elemének köszönhető, amely a hosszú távú állandósult hibák korrekciójára szolgál. Az integrált hibák kezdeti csökkenése és az ezt követő túllövés azonban késleltetett választást eredményezhet a szabályozónál. Az MPC a legjobb referencia követési pontosságot nyújtja, mivel az egész pályán egy nagyságrenddel kisebb maximális laterális pozíció hibát ér el

az LQR szabályozóhoz képest. Az MPC a legagresszívabban hangolt, ugyanakkor a legnagyobb beállási idővel is az MPC rendelkezik.



5. Ábra. Oldalirányú pozíció hibák összehasonlítása

7. KONKLÚZIÓ

Jelen kutatás három modell-alapú szabályozót hasonlított össze az oldalirányú gyorsulás és a jerk, mint az utaskomfort mutatói és a referencijel követés szempontjából. Ezek a tulajdonságok egy genetikus algoritmus segítségével lettek optimalizálva, a szabályozók megadott kritériumoknak való megfelelése érdekében. Mindhárom szabályozó megfelelt a vonatkozó szabályozásokban leírt szabványoknak.

Mindhárom szabályozó alacsony referencia jel követési hibát ért el, miközben teljesítette az utaskomfort követelményeit az adott kerékpár modell és a megadott szimulációs jármű esetében a kijelölt pályán. Az összteljesítményt tekintve, beleértve az Equivalent Acceleration értékét, MSDV-t, oldalirányú eltérést, jerket és a szabályozási jel csillapodási idejét, az LQ-Servo szabályozó bizonyult a legoptimálisabbnak. Bár kissé alulmaradt az MPC-vel szemben a referencijel követésében, kétszer gyorsabb beállási időket és 20%-kal alacsonyabb csúszértékű gyorsulásokat mutatott, így ez lett a legjobb választás ebben a szimulációs- és modellszerkezetben. Ezenkívül az a_{eq} értékek alacsonyabbak voltak, különösen nagyobb sebességeknél.

A bemutatott eredmények alapján az LQ-Servo szabályozó ígéretes választás lehet a valós járműtesztekhez.

8. KÖSZÖNETNYILVÁNÍTÁS

A publikációban szereplő kutatás az Európai Unió támogatásával valósult meg, az Autonóm Rendszerek Nemzeti Laboratórium keretében. (RRF-2.3.1-21-2022-00002)

HIVATKOZÁSOK

Abdelmoniem, A., Osama, A., Abdelaziz, M., and Maged, S. A. (2020). A path-tracking algorithm using predictive Stanley lateral controller. *International Journal of Advanced Robotic Systems*, 17(6):1729881420974852.

Athans, M. and Falb, P. L. (2013). *Optimal control: an introduction to the theory and its applications*. Courier Corporation.

Cascetta, E., Carteni, A., and Di Francesco, L. (2022). Do autonomous vehicles drive like humans? A Turing approach and an application to SAE automation level 2 cars. *Transportation Research Part C: Emerging Technologies*, 134:103499.

Gáspár, P., Szabó, Z., Bokor, J., and Németh, B. (2016). Robust control design for active driver assistance systems. *Springer*, DOI, 10:978–3.

Jagelčák, J., Gnap, J., Kuba, O., Frnda, J., and Kostrzewski, M. (2022). Determination of turning radius and lateral acceleration of vehicle by GNSS/INS sensor. *Sensors*, 22(6):2298.

Kilinc, A. S. and Baybura, T. (2012). Determination of minimum horizontal curve radius used in the design of transportation structures, depending on the limit value of comfort criterion lateral jerk. *TS06G-Engineering Surveying, Machine Control and Guidance*.

Li, D., Zhao, D., Zhang, Q., and Chen, Y. (2019). Reinforcement learning and deep learning based lateral control for autonomous driving [application notes]. *IEEE Computational Intelligence Magazine*, 14(2):83–98.

Luciani, S., Bonfitto, A., Amati, N., and Tonoli, A. (2020). Model predictive control for comfort optimization in assisted and driverless vehicles. *Advances in Mechanical Engineering*, 12(11):1687814020974532.

Menhour, L., Lechner, D., and Charara, A. (2012). Design and experimental validation of linear and nonlinear vehicle steering control strategies. *Vehicle System Dynamics*, 50(6):903–938.

Mesghali, K. (2021). Control tuning of autonomous vehicles considering performance-comfort trade-offs. Master's thesis, School of Industrial and Information Engineering.

Moreno-Gonzalez, M., Artuñedo, A., Villagra, J., Join, C., and Fliess, M. (2022). Speed-adaptive model-free lateral control for automated cars. *IFAC-PapersOnLine*, 55(34):84–89.

Németh, B. and Gáspár, P. (2011). Road inclinations in the design of LPV-based adaptive cruise control. *IFAC Proceedings Volumes*, 44(1):2202–2207.

Rajamani, R. (2011). *Vehicle dynamics and control*. Springer Science & Business Media.

Samuel, M., Hussein, M., and Mohamad, M. B. (2016). A review of some pure-pursuit based path tracking techniques for control of autonomous vehicle. *International Journal of Computer Applications*, 135(1):35–38.

Sever, M., Zengin, N., Kirli, A., and Arslan, M. S. (2021). Carsickness-based design and development of a controller for autonomous vehicles to improve the comfort of occupants. *Proceedings of the Institution of Mechanical Engineers, Part D: Journal of Automobile Engineering*, 235(1):162–176.

Tagne, G., Talj, R., and Charara, A. (2015). Design and comparison of robust nonlinear controllers for the lateral dynamics of intelligent vehicles. *IEEE Transactions on Intelligent Transportation Systems*, 17(3):796–809.

Tóth, R. (2010). *Modeling and identification of linear parameter-varying systems*, volume 403. Springer.

- Wang, L. (2009). *Model predictive control system design and implementation using MATLAB*, volume 3. Springer.
- Zhang, Y., Sun, P., Yin, Y., Lin, L., and Wang, X. (2018). Human-like autonomous vehicle speed control by deep reinforcement learning with double Q-learning. In *2018 IEEE Intelligent Vehicles Symposium (IV)*, pages 1251–1256. IEEE.
- Zhu, M., Wang, X., and Wang, Y. (2018). Humanlike autonomous car-following model with deep reinforcement learning. *Transportation Research Part C: Emerging Technologies*, 97:348–368.
- Zin, A., Sename, O., Gaspar, P., Dugard, L., and Bokor, J. (2008). Robust LPV- H_∞ control for active suspensions with performance adaptation in view of global chassis control. *Vehicle System Dynamics*, 46(10):889–912.

Appendix A. FIRST APPENDIX

Appendix B. SECOND APPENDIX