

Közúti jármű mozgásmodelljének meghatározása kényszerezett multimodelles szűrő eljárásokkal

A közúti közlekedésben alkalmazott manőverdetektálás fontos kutatási téma, hiszen az autonóm járművek elterjedéséhez szükséges a nagy megbízhatóságú eljárások fejlesztése. Különösen számottevő a járművek, illetve a vezetők szándékainak felismerése és az ezekre való gyors reagálás, mivel az autonóm és az emberek által vezetett járművek várhatóan együtt fognak részt venni a forgalomban, és ezért az ezekkel összefüggő körülmények vizsgálata és a fejlesztések elengedhetetlenek. A módszer ígéretesnek tűnik, de a bemutatott eljárást egyelőre csak Matlab szimulációkban tesztelték, de érdemes lenne valós körülmények között szenzor adatokkal is kipróbálni a leírt koncepciót.

DOI: <https://doi.org/10.24228/KTSZ.2021.6.2>

Törő Olivér – Dr. Bécsi Tamás, PhD

járműmérnök, közlekedésmérnök,
tudományos segédmunkatárs egyetemi docens
BME Közlekedés- és Járműirányítási Tanszék
e-mail: toro.oliver@mail.bme.hu, becsi.tamas@mail.bme.hu

1. BEVEZETÉS

A közúti közlekedésben a fejlett vezetőtámogató és autonóm működést biztosító rendszerek elengedhetetlen követelménye a forgalomban résztvevő járművek, személyek és egyéb objektumok állapotának megbízható becslése és a forgalmi szituáció pontos felismerése. Az állapotbecslés egy igen tág fogalom, az állapot bármilyen mennyiséget, jellemzőt magába foglalhat, ami számunkra érdekes.

A tanulmány a közúti járművek manőverdetektálásával foglalkozik egy másik, a for-

galomban haladó megfigyelő szemszögéből. A manőver detektálását a jármű mozgási modelljének és paramétereinek azonosítására vezetjük vissza, klasszikus állapotbecslő eljárásokkal.

Egy tetszőleges pályán mozgó objektum állapotának leírására kétféle állapotterezes megközelítést alkalmazhatunk. Használhatunk egy komplexebb modellt, amivel minden lehetséges mozgást leírhatunk vagy előre definiálhatunk bizonyos mozgásformákra specializált modelleket.

Egy manőverező objektum állapotának becslése nehéz feladat, ha a rendszermodell változik a vizsgált időtartamban. Jól használható eljárásnak bizonyult a multimodelles (MM) leírás, amelyben minden figyelembe veendő mozgásformához különböző modellt illesztnek, majd a jobban teljesítő modellt fogadják el [1]. A kölcsönható multimodelles becslő (Interacting Multiple Model, IMM) egy közelítő megoldása az általános multimodelles problémának [2][3], amely lineárisan skálázódik a tekintetbe vett járműmodellek számával. Az IMM becslőt eredetileg Kálmán szűrőkkel mutatták be [4], de megvalósítható részecskeszűrőkkel [5][6][14], vagy valószínűségi halmazokkal együtt is használható [7][8].

Kényszerezett szűrők segítségével pontosabb becslést tudunk adni egy olyan környezetben, ahol a rendszermodell nem foglal magában bizonyos korlátozó körülményeket, fizikai akadályokat. Közúti forgalomban kényszerekre felhozhatjuk példaként az út görbületét vagy a felfestéseket, amelyeket a járművek általában követnek. Járművek kinematikai vagy dinamikai modellezésénél a futóművek kialakításából fakadó anholonom kényszerek is szóba jönnek.

Ebben a munkában egy olyan módszert mutatunk be, amely képes megbecslülni egy manőverező jármű állapotát és egy előre definiált halmazból kijelölni az éppen érvényben lévő mozgási modellt. Az eljárás közúti forgalomban használható, ahol a megfigyelő jármű részt vesz a forgalomban. A járművet pontszerűnek tekintjük, amit egy absztrakt szenzor érzékel. A jármű síkmozgást végez, az út egyenletlenségeit vagy a jármű lengéseit nem modellezzük.

2. ELMÉLETI HÁTTER

Az alkalmazott diszkrét lineáris rendszermodellek az alábbi formát öltik:

$$\mathbf{x}_{k+1} = F_k \mathbf{x}_k + G \mathbf{w}_k \#(1)$$

$$\mathbf{z}_k = H_k \mathbf{x}_k + \mathbf{v}_k \#(2)$$

Az F rendszermátrix és a H mérési mátrix k indexe azt jelzi, hogy a modell időben vál-

tozhat, továbbá \mathbf{w} az \mathbf{x} állapotot, \mathbf{v} a \mathbf{z} mérést terhelő additív normál zaj Q és R kovariancia mátrixszal. A \mathbf{w} zaj a G mátrixon keresztül fejti ki hatását. A továbbiakban áttekintést adunk a klasszikus Kálmán szűrőn és részecskeszűrőn alapuló állapotbecslésről és az ezekre támaszkodó multimodelles és kényszerezett becslő eljárásokról.

2.1. Kálmán szűrő

A klasszikus Kálmán szűrő normál zajjal terhelt lineáris időinvariáns rendszerek optimális állapotbecslője, amelynek algoritmusai:

$$\hat{\mathbf{x}}_{k|k-1} = F_{k-1} \hat{\mathbf{x}}_{k-1} \#(3)$$

$$P_{k|k-1} = F_{k-1} P_{k-1} F_{k-1}^T + G Q_{k-1} G^T \#(4)$$

$$S_k = H_k P_k^- H_k^T + R_k \#(5)$$

$$\Lambda_k = \mathcal{N}(\mathbf{z}_k, H_k \hat{\mathbf{x}}_{k|k-1}, S_k) \#(6)$$

$$K_k = P_k^- H_k^T S_k^{-1} \#(7)$$

$$\hat{\mathbf{x}}_{k|k} = \hat{\mathbf{x}}_{k|k-1} + K_k (\mathbf{z}_k - H_k \hat{\mathbf{x}}_{k|k-1}) \#(8)$$

$$P_{k|k} = (I - K_k H_k) P_{k|k-1} \#(9)$$

Az állapot várható értékére és kovarianciájára a (3)-(4) egyenletek adnak becslést. A $\mathbf{z}_k - H_k \hat{\mathbf{x}}_{k|k-1}$ innováció és S_k kovarianciája segítségével kapjuk az Λ_k likelihoodot. Ez a mennyiség lehetővé teszi különböző szűrők összehasonlítását a multimodelles eljárásoknál. A Kálmán erősítés (7) segítségével kapjuk meg a szűrő kimenetét (8),(9).

2.2. Részecskeszűrő

A részecskeszűrő egy véletlenszerű mintavételezésen alapuló rekurzív eljárás, amely nemlineáris rendszerek állapotának becslésére használható [13]. Az állapotvektorra és a mérésre rakódó zaj tetszőleges lehet, továbbá nem paraméteres eloszlás is közelíthető ezzel az eljárással. A részecskeszűrő egy tetszőle-

ges függvényt súlyozott mintákkal, vagyis részecskékkel közelít. A részecskékhez súlyokat a likelihood alapján társítunk, amelyet a mérési modellből származtatunk. A szűrő kimenete a részecskesokaság, ami egy diszkrét halmaz. Pontbecslést a mintapontok súlyozott átlagaként kaphatunk. Amennyiben sűrűségfüggvényre van szükségünk, magfüggvényes becsléssel kaphatunk egy analitikus formát.

A részecskeszűrő algoritmus a alábbiak szerint épül fel. A predikciós lépésben részecskéket sorsolunk az előzetes φ eloszlásból:

$$\mathbf{x}_{k|k-1}^i \sim \varphi(\mathbf{x} | \mathbf{x}_{k-1}^i) \#(10)$$

Ha az előzetes eloszlásnak a mozgási modellből származtatott sűrűségfüggvényt választjuk, akkor bootstrap részecskeszűrőről beszélünk. A részecskesúlyok ebben az esetben a likelihood értékek egységnyire normálásával adódnak:

$$w_k^i = \frac{g_k(\mathbf{z}_k | \mathbf{x}_{k|k-1}^i)}{\sum g_k(\mathbf{z}_k | \mathbf{x}_{k|k-1}^i)} \#(11)$$

Pontbecslés számítása súlyozott átlagaként:

$$\hat{\mathbf{x}}_k = \sum w_k^i \mathbf{x}_{k|k-1}^i \#(12)$$

A társított kovariancia mátrix:

$$P_k = \sum_{i=1}^N w_k^i (\mathbf{x}_{k|k-1}^i - \hat{\mathbf{x}}_k)(\mathbf{x}_{k|k-1}^i - \hat{\mathbf{x}}_k)^T \#(13)$$

Szinte minden részecskeszűrő algoritmus tartalmazza az újramintavételezés lépést, amely során a valószínűbb részecskéket megtöbbszörözzük. Minden részecskét a súlyával arányos valószínűséggel sorsolunk ki visszatevéselesen az $\mathbf{x}_{k|k-1}^i$ sokaságból. Az újramintavételezett részecskék azonos súlyt kapnak.

2.3. Multimodelles állapotbecslés

A multimodelles állapotbecslés alap gondolata, hogy egyszerre több, eltérően konfigurált szűrőt futtatunk párhuzamosan, majd valamilyen kritérium alapján kiválasztjuk a legjobb becslést vagy több becslés súlyozott keverékét. A legegyszerűbb eljárás a statikus multimodelles becslő, amely az egyes szűrők kimeneteit a likelihoodjaik alapján hasonlítja össze a Bayes-formula segítségével. Amennyiben az egyik szűrő modellje pontosan leírja a vizsgált mozgást, a szűrőhöz társított valószínűség egyhez fog konvergálni. A megfigyelt rendszer modellváltásait a statikus multimodelles becslő nem tudja kezelni. A dinamikus multimodelles becslő figyelembe veszi, hogy a megfigyelt objektum manőverezhet, tehát a mozgást leíró modell időben változhat. A modellváltásokat egy Markov-lánc modellezi a hozzá társított átmeneti valószínűségeket tartalmazó mátrixszal. A modellvalószínűségeket ugyanúgy számoljuk, mint a statikus esetben, a becslő kimenete viszont figyelembe veszi az összes szűrő eredményét egy Gauss keverékmódel formájában.

A dinamikus multimodelles becslő elméletileg az összes modell hipotézist figyelembe veszi az adott időpontig, a gyakorlatban azonban ez nem alkalmazható az exponenciálisan növekvő számítási igény miatt. Jól használható szuboptimális megoldások közé tartoznak az egy vagy két lépésnyi modell történettel dolgozó algoritmusok, amelyek egybeolvasztják azokat a modell történeteket, és csak a régebbi modellekben térnek el egymástól. Ezen eljárások összefoglaló neve általánosított pseudo-Bayes becslők (generalized pseudo-Bayesian, GPB). Ha m modellel tekintünk, akkor m , m^2 , m^3 szűrő szükséges az első, második és harmadrendű GPB implementálásához [4].

A kölcsönható multimodelles becslő eljárás (IMM) jó kompromisszumot képez a teljesítmény és számítási igény között. Az algoritmus filozófiája hasonlít a másodrendű GPB-hez, teljesítménye kevésbé marad el tőle, de az implementálandó szűrők száma megegyezik a modellek számával (1. ábra). Az eljárást

eredetileg Kálmán szűrőkkel mutatták be, de megvalósítható kiterjesztett Kálmán szűrővel vagy részecskeszűrővel is.

Az IMM algoritmus az alábbiak szerint épül fel. A $k-1$ pillanattól megkapjuk minden szűrő becsült \hat{x}_{k-1} állapotát és a hozzá kapcsolódó P_{k-1}^j kovariancia mátrixot ($j=1\dots m$). Minden szűrő egy egyedi keveréket kap, amit a v_{k-1}^{ij} mátrix segítségével állítunk össze. A v_{k-1}^{ij} mátrixot a μ_{k-1}^i modell valószínűségekből és a π_{ij} átmeneti valószínűségekből kapjuk:

$$v_{k-1}^{ij} = \frac{\pi_{ij} \mu_{k-1}^i}{\sum_{l=1}^m \pi_{il} \mu_{k-1}^l} \#(14)$$

és segítségével képezzük az egyedi keverékeket:

$$\hat{x}_{k-1}^{0j} = \sum_{i=1}^m v_{k-1}^{ij} \hat{x}_{k-1}^i \#(15)$$

$$P_{k-1}^{0j} = \sum_{i=1}^m v_{k-1}^{ij} \left[P_{k-1}^i + (\hat{x}_{k-1}^i - \hat{x}_{k-1}^{0j})(\hat{x}_{k-1}^i - \hat{x}_{k-1}^{0j})^T \right] \#(16)$$

A szűrők kimenete az \hat{x}_k^j állapot, P_k^j kovariancia és a L_k^j likelihood. A modell valószínűségek

$$\mu_k^j = \frac{L_k^j c_k^j}{\sum_{i=1}^m L_k^i c_k^i} \#(17)$$

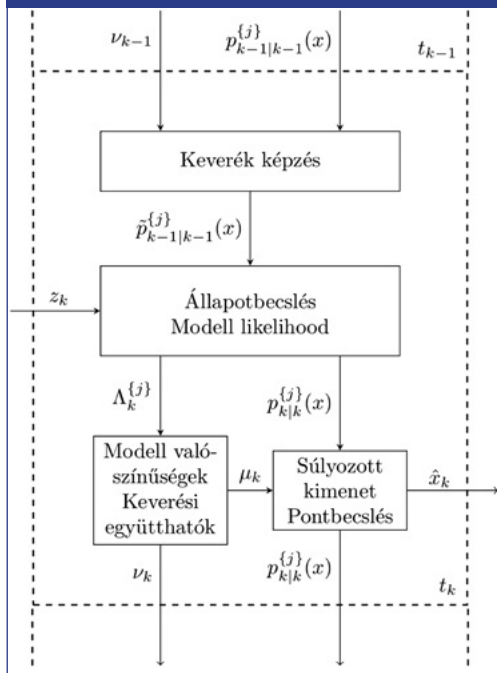
$$c_k^j = \sum_{i=1}^m \pi_{ij} \mu_k^i \#(18)$$

szerint adódnak. A modell valószínűségek segítségével számítható egy globális pontbecslés:

$$\hat{x}_{k|k} = \sum_{j=1}^m \mu_j \hat{x}_{k|k}^j \#(19)$$

$$P_k = \sum_{j=1}^m \mu_k^j \left[P_{k|k}^j + (\hat{x}_{k|k}^j - \hat{x}_{k|k})(\hat{x}_{k|k}^j - \hat{x}_{k|k})^T \right] \#(20)$$

1. ábra: Állapotbecslés az IMM struktúrában



2.4. Kényszerezett becslés

Lineáris gaussi rendszerek esetén a Kálmán szűrő adja az optimális becslést, kényszerek használatával azonban képesek vagyunk növelni az optimális becslő teljesítményét. Ez természetesen csak azért lehetséges, mert az eredeti rendszermodellünk nem tartalmaz minden információt, a kényszerek általi korlátozások nincsenek figyelembe véve.

A kényszereket többféleképpen csoportosíthatjuk: vannak egyenlőségi és egyenlőtlenségi, lineáris és nemlineáris, illetve kemény és puha kényszerek. A puha kényszerek a keményekkel ellentétben csak megközelítőleg teljesülnek. Puha kényszerekkel modellezhetjük azt, hogy nem vagyunk biztosak a kényszert kijelölő határértékekben.

Lineáris egyenlőségi kényszereket

$$Dx = d \#(21)$$

alakban tudunk megadni, ahol \mathbf{x} az n_x dimenziós állapotvektor, \mathbf{d} egy n_c dimenziós vektor és a D mátrix $n_c \times n_x$ méretű. Lineáris egyenlőtlenségi kényszerek esetén $D\mathbf{x} \leq \mathbf{d}$ irándó. Nemlineáris kényszereket $f(\mathbf{x}) = \mathbf{d}$ vagy $f(\mathbf{x}) \leq \mathbf{d}$ alakban adhatunk meg.

A kényszerek többféleképpen is beépíthetők a becslő eljárásokba. A mechanikai rendszerek tárgyalásánál elterjedt módszer a modell redukció. Ilyenkor állapotokat kombinálunk, esetleg teljesen új bázisra állunk át. A kényszerek alkalmazása tehát egy pontosabb rendszermodell felállítását jelenti. A módszer korlátozottan használható, mivel csak kemény egyenlőségi kényszereket tud figyelembe venni, ami hátrányt jelenthet, hogy az új állapotok esetleg nehezen értelmezhetők, elvész fizikai jelentésük.

2.4.1. Kényszerezett Kálmán szűrő

Egyenlőségi kényszereket figyelembe lehet venni hibamentes mérésekként. Ezt a módszert alkalmazva a mérési egyenleteket kibővítjük a kényszereket leíró egyenletekkel:

$$\begin{bmatrix} \mathbf{z}_k \\ \mathbf{d} \end{bmatrix} = \begin{bmatrix} H_k \\ D \end{bmatrix} \mathbf{x}_k + \begin{bmatrix} \mathbf{v}_k \\ 0 \end{bmatrix} \#(22)$$

Amennyiben nem zérus hibát tételezünk fel, úgy puha kényszereket is modellezhetünk:

$$\begin{bmatrix} \mathbf{z}_k \\ \mathbf{d} \end{bmatrix} = \begin{bmatrix} H_k \\ D \end{bmatrix} \mathbf{x}_k + \begin{bmatrix} \mathbf{v}_k \\ \mathbf{r}_k \end{bmatrix} \#(23)$$

Az állapot projekció módszerével egyenlőségi és egyenlőtlenségi kényszereket is beépíthetünk a becslő eljárásba. Ha egyenlőségi kényszereket tekintünk, akkor az

$$\tilde{\mathbf{x}}_k = \operatorname{argmin}_{\mathbf{x}_k} (\mathbf{x}_k - \bar{\mathbf{x}}_k)^T W_k (\mathbf{x}_k - \bar{\mathbf{x}}_k) \#(24)$$

egyenlet megoldását keressük

$$D\mathbf{x}_k = \mathbf{d} \#(25)$$

teljesülése mellett. A megoldást

$$\tilde{\mathbf{x}}_k = \mathbf{x}_k - W_k^{-1} D^T (D W_k^{-1} D^T)^{-1} (D \mathbf{x}_k - \mathbf{d}) \#(26)$$

alakban kapjuk. W_k egy súlymátrix, aminek értékét választhatjuk $W_k = P_{k|k}$ vagy $W_k = I$ szerint. $W_k = P_{k|k}$ választással a minimális varianciájú becslést kapjuk, $W_k = I$ esetén pedig a legkisebb négyzetek értelmében optimálisat [9]. Azonos kezdeti állapottal indított szűrők ugyanazt a kényszerezett becslést eredményezik és ez az eredmény megegyezik a hibamentes mérés módszerével kapottal [10].

Egyenlőtlenségi kényszerek esetén úgy járunk el, hogy a

$$D\mathbf{x}_k \leq \mathbf{d} \#(27)$$

kényszeregyüttesből kiválasztjuk az aktívakat, ezeket összegyűjtjük egy új

$$D^* \mathbf{x}_k = \mathbf{d}^* \#(28)$$

egyenletrendszerbe és alkalmazzuk (26)-ot D^* és \mathbf{d}^* -gal.

2.4.2. Kényszerezett részecskeszűrő

A részecskeszűrő kényszerezése többféleképpen is elvégezhető [12]. A predikciós lépésben lehetőségünk van olyan eloszlásból sorsolni részecskéket, amely kompatibilis a kényszerekkel. Ha a predikció során nem vetjük tekintetbe a kényszereket, akkor a kényszerfeltételekből kilógó részecskék súlyának módosításával elérhetjük, hogy ezek a részecskék kicsi vagy nulla valószínűséggel éljék túl az újramintavételezést. Megfelelő eloszlás vagy likelihood függvény választásával tetszőleges kényszer beépíthető a részecskeszűrő algoritmusba.

2.5. Manőver klasszifikálás

Multimodelles szűrők használhatók manőverklasszifikálásra, ehhez azonban az alkalmazott rendszermodelleknek az egyes mozgásformákhoz kell igazodniuk. A gyakorlatban egy rendszermodellel több mozgásformát is leírunk, illetve nem alkalmazunk túl bonyolult modelleket. A kényszerek használata lehetővé teszi, hogy az általánosan használt (egyes


vonaltól vagy kanyarodó mozgás) modelleket finomhangoljuk, és a felismerni kívánt manőverekhez illesszük. A klasszifikálás stratégiája a következőképpen foglalható össze. Kényszereket definiálunk, amelyek bizonyos állapotokra megszorításokat tesznek. Például gyorsítás esetén a gyorsulás pozitív, távolságtartás esetén a relatív távolság konstans. A szűrőket kiegészítjük ezekkel a kényszerekkel és beillesztjük egy multimodelles struktúrába. Egy jármű természetesen többféle manővert is végrehajt, így mindenképpen dinamikus eljárás van szükségünk.

A kényszerezett szűrők eltérő eredményeket adnak. Amelyik kényszerezett becslt állapot nem illeszkedik a mérésre, az kis likelihood értéket kap és így kis valószínűségűnek ítél az IMM algoritmus.

3. ESETTANULMÁNY

Egy esettanulmányt mutatunk be a kényszerezett multimodelles szűrővel történő állapotbecslés és manőverdetektálás alkalmazásból. A bemutatott becslő eljárást Matlab szimulációban teszteltük. A felépített közúti forgalmi szituáció a következő. A megfigyelő jármű a megfigyelt járművet követi egy kétsávos úton (2. ábra). A megfigyelő jármű szenzorait nem volt célunk modellezni, így egy absztrakt szenzort választottunk, amely megadja a megfigyelt jármű relatív koordinátáit és sebességvektorát. A hátsó, megfigyelő jármű állandó 60 km/h sebességgel követte a megfigyelt járművet, amely különböző manővereket hajtott végre. A járművek közötti kezdeti követési távolság 50 m volt. A megfigyelt jármű manővereit az 1. táblázat tartalmazza. A manőver-

2. ábra: Járművek elhelyezkedése a kétsávos úton a kezdeti pillanatban

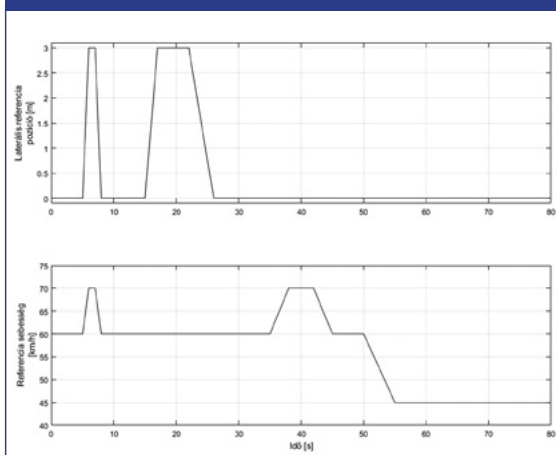


1. táblázat: Szimulált manőverek szekvenciája

Idő	Előrehaladás	Megnevezés	Megjegyzés
0 s	0 m	Jobboldali sávban haladás	
5 s	83,5 m	Előzési manőver	
8 s	133,5 m	Jobboldali sávban haladás	
15 s	250,2 m	Sávváltás balra	1,5 m/s oldalirányú sebességgel
17 s	283,5 m	Baloldali sávban haladás	
22 s	366,8 m	Sávváltás jobbra	0,8 m/s oldalirányú sebességgel
26 s	433,5 m	Jobboldali sávban haladás	
35 s	583,5 m	Távolodás	Maximálisan 2,8 m/s sebességkülönbséggel
45 s	750,2 m	Jobboldali sávban haladás	
50 s	833,5 m	Közeledés	Maximálisan 4,2 m/s sebességkülönbséggel
~ 67.25 s	1132 m	Ráfutás	Amikortól a két jármű közti távolság ≤ 10 m
~ 69.65 s	1172 m	Esemény, szimuláció vége	Amikor a két jármű távolsága eléri a nullát

váltásokat jellemző állapotátmeneti mátrixot a 2. táblázatban szereplő értékekszerint vettük fel. A manőverező jármű vezérlőjeleit a 3. ábra mutatja. A szimuláció akkor ér véget, amikor a hátsó jármű utoléri az elsőt.

3. ábra: Megfigyelt jármű vezérlőjelei



2. táblázat: Manőrváltási valószínűségek

	Jobb oldali sávban	Sávváltás	Bal oldali sávban	Előzés	Távolodás	Közeledés	Ráfutás
Jobboldali sávban	90%	2%	0	0	4%	4%	0
Sávváltás	1%	90%	1%	8%	0	0	0
Bal oldali sávban	0	2%	90%	0	4%	4%	0
Előzés	0	10%	10%	80%	0	0	0
Távolodás	5%	0	5%	0	90%	0	0
Közeledés	5%	0	5%	0	0	80%	10%
Ráfutás	0	0	0	0	10%	10%	80%

3.1. Szűrők konfigurálása

A megfigyelő jármű koordináta-rendszerében a rendszermodell:

$$\mathbf{x}_{k+1} = F\mathbf{x}_k + \mathbf{w}_k \quad \#(29)$$

$$\mathbf{z}_k = H\mathbf{x}_k + \mathbf{v}_k \quad \#(30)$$

Az állapotvektor a megfigyelő járműre nézve relatív komponensekből tevődik össze:

$$\mathbf{x}_k = [x \quad v_x \quad y \quad v_y] \quad \#(31)$$

vagyis, a hosszirányú távolság és sebesség, illetve a laterális távolság és sebesség. Az ennek megfelelő egyenes vonalú egyenletes mozgást leíró rendszer-mátrix a következő:

$$F = \begin{bmatrix} 1 & dt & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & dt \\ 0 & 0 & 0 & 1 \end{bmatrix} \quad \#(32)$$

A H mérési mátrix az absztrakt szenzor-modellnek megfelelően egy négydimenziós egységmátrix. A modell és mérési zajt nulla várható értékű, additív normál eloszlásúnak feltételezve a kovariancia mátrixok:

$$Q = \text{diag}\left(\frac{dt^2}{2}, dt, \frac{dt^2}{2}, dt\right) \quad \#(33)4.$$

$$R = \text{diag}(0.1, 0.3, 0.2, 0.3) \quad \#(34)$$

A következőkben definiáljuk az észlelni kívánt manőverek kényszervezését:

- Haladás a jobb sávban egyenletes sebességgel: kényszeríteni a hosszirányú sebességet, valamint a keresztirányú távolságot és sebességet kell $D\mathbf{x}=\mathbf{d}$ formában:

$$\begin{bmatrix} 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix} \begin{bmatrix} x \\ v_x \\ y \\ v_y \end{bmatrix} = \begin{bmatrix} 0 \\ 0 \\ 0 \end{bmatrix} \quad \#(35)$$

A haladás a bal oldali sávban ettől annyiban különbözik, hogy az y állapotra nem nullát írunk elő, hanem egy sávnyi értéket.

- Sávváltás: a sebességkomponensekre írunk fel kényszerveket:

$$\begin{bmatrix} 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix} \begin{bmatrix} x \\ v_x \\ y \\ v_y \end{bmatrix} = \begin{bmatrix} 0 \\ v_{ch} \end{bmatrix} \quad \#(36)$$

- Távolodás: a longitudinális sebességkomponensre alsó határt szabunk meg:

$$\begin{bmatrix} v_{min} \\ 0 \\ 0 \end{bmatrix} \leq \begin{bmatrix} 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix} \begin{bmatrix} x \\ v_x \\ y \\ v_y \end{bmatrix} < \begin{bmatrix} \infty \\ 0 \\ 0 \end{bmatrix} \quad \#(37)$$

Közeledés esetén ugyanilyen struktúrában felső határt adunk meg.

- A ráfutás esemény hasonló a közeledéshez, de csak egy bizonyos távolságon belül értelmezzük:

$$\begin{bmatrix} 0 \\ -\infty \\ 0 \\ 0 \end{bmatrix} < \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix} \begin{bmatrix} x \\ v_x \\ y \\ v_y \end{bmatrix} \leq \begin{bmatrix} d_{min} \\ -v_{min} \\ 0 \\ 0 \end{bmatrix} \#(38)$$


- Az előzést egy előre meghatározott sebességprofil segítségével detektáljuk:

$$\begin{bmatrix} 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & 0 \end{bmatrix} \begin{bmatrix} x \\ v_x \\ y \\ v_y \end{bmatrix} = \begin{bmatrix} f(x) \\ d_{sáv} \end{bmatrix} \#(39)$$

Az előzési manőver sebességprofilja (4. ábra) volt az alapja a kapcsolódó nemlineáris $f(x)$ kényszerfeltétel megalkotásának.

Az alkalmazott kényszerek a következő konkrét alakokat öltik. A jobb és bal oldali sávban haladás és a sávváltás kényszert a mérési egyenlet kiegészítésével modellezzük. Jellegükből adódóan ezeket a mozgásformákat puha kényszerekkel írjuk le, tehát a mérési egyenlet kovarianciamátrixát nem zérus mátrixokkal bővítjük (3. táblázat). Ezek a kényszerek könnyen implementálhatók Kálmán szűrő segítségével.

4. ábra: Longitudinális sebesség kényszer a távolság függvényében és trapezoid közelítése



A közeledés, a távolodás és a ráfutás kényszereket egyenlőtlenségekkel adjuk meg (4. táblázat). Ezek a kényszerek becslés projekció módszerével a Kálmán szűrő kimenetére alkalmazhatók. Az előzést egy nemlineáris kényszerrel írjuk le, amely állapotfüggő. Ezt részecskeszűrő segítségével valósítjuk meg, a kényszerből kilógó részecskék újramintavételezésével. Az 5. táblázat összegzi a manővereket és a társított kényszereket.

4. EREDMÉNYEK

A szimuláció $dt=10$ ms lépéssel futott, a mérések 100 ms időközönként érkeztek. A manőverező jármű mozgását egy kinematikus biciklimodell írja le, az előírt trajektórián egy nemlineáris laterális szabályozó, a Stanley controller segítségével halad végig [11].

3. táblázat: Sávban haladás és sávváltás kényszer paraméterei

Manőver	Kényszer mátrix (D)	Kényszer (d)	Kényszer bizonytalansága (r)
Jobboldali sávban haladás	$\begin{bmatrix} 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix}$	$\begin{bmatrix} 0 \\ 0 \\ 0 \end{bmatrix}$	$\begin{bmatrix} 0.1 & 0 & 0 \\ 0 & 0.2 & 0 \\ 0 & 0 & 0.2 \end{bmatrix}$
Baloldali sávban haladás	$\begin{bmatrix} 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix}$	$\begin{bmatrix} 0 \\ 3 \\ 0 \end{bmatrix}$	$\begin{bmatrix} 0.1 & 0 & 0 \\ 0 & 0.2 & 0 \\ 0 & 0 & 0.2 \end{bmatrix}$
Sávváltás	$\begin{bmatrix} 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix}$	$\begin{bmatrix} 0 \\ 1 \end{bmatrix}$	$\begin{bmatrix} 0.1 & 0 \\ 0 & 1 \end{bmatrix}$


4. táblázat: Közeledés, távolodás, ráfutás és előzés kényszer paraméterei

Manőver	Kényszer mátrix (D)	Kényszer (d[min, max])
Közeledés	$\begin{bmatrix} 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix}$	$\begin{bmatrix} -\infty & -4 \\ 0 & 0 \\ 0 & 0 \end{bmatrix}$
Távolodás	$\begin{bmatrix} 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix}$	$\begin{bmatrix} 4 & \infty \\ 0 & 0 \\ 0 & 0 \end{bmatrix}$
Ráfutás	$\begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix}$	$\begin{bmatrix} -\infty & 10 \\ -\infty & -4 \\ 0 & 0 \\ 0 & 0 \end{bmatrix}$
Előzés	$\begin{bmatrix} 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & 0 \end{bmatrix}$	$\begin{bmatrix} f(x) \\ 0.5 & 3.5 \end{bmatrix}$

5. táblázat: Manőverek kényszerkezési módjai összefoglalva


Mozgás modell	Kényszerkezés
Jobb oldali sávban haladás	Mérési egyenlet kibővítése
Sávváltás	Mérési egyenlet kibővítése
Bal oldali sávban haladás	Mérési egyenlet kibővítése
Előzés	Kényszerkezett részecske-szűrés
Távolodás	Becslés projekció
Közeledés	Becslés projekció
Ráfutás detektálás	Becslés projekció

5. ábra: A becsült modell valószínűségei

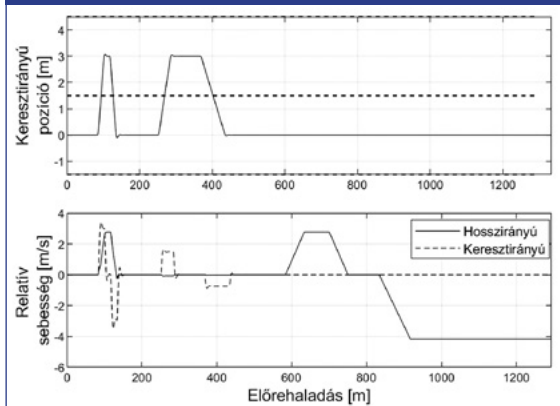


Az 5. ábrán az egyes manőverekhez társított szűrők modellvalószínűségei láthatók. A vékony tüskék transziens jelenségek, ezek kis bizonytalanságot tükröznek, amelyek manőverváltáskor következnek be. A 6. ábra egyszerre mutatja az összes manőver valószínűségét az idő függvényében. A kitöltés indikálja az éppen aktuálisnak becsült, vagyis a pillanatnyi legnagyobb valószínűségű manővert.

6. ábra: A becsült aktuális manőverek



7. ábra: A megfigyelt jármű becsült állapotai



A bemutatott eljárás fő célja a manőverdetektálás. A szűrők azonban a teljes állapotot becslik, ennek performanciáját szemlélteti a 7. ábra, ahol a megfigyelt jármű becsült pozíció és sebesség koordinátáit láthatjuk. Az egyes állapotokhoz tartozó mérési és becslési hibákat összehasonlítóképpen a 8. ábrán és a 6. táblázatban tüntettük fel.

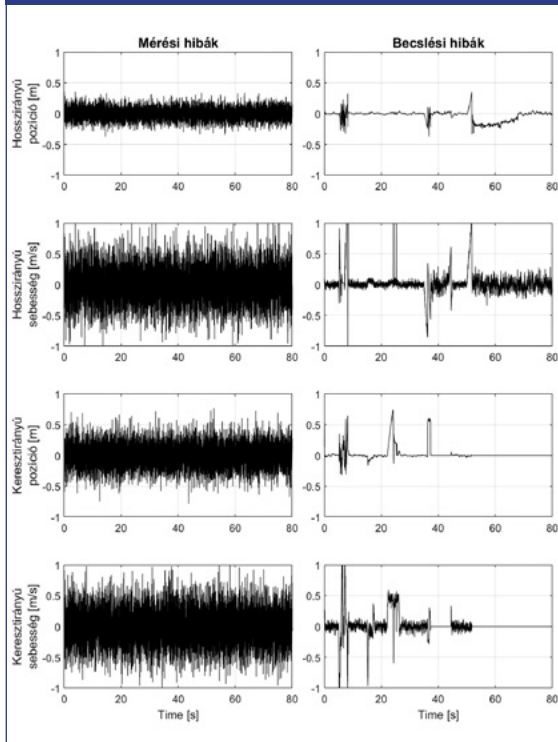
6. táblázat: Mérési és szűrés utána RMSE a relatív állapotokon

Állapot	Mérés RMSE	Szűrés RMSE
Longitudinális távolság	0.1	0.1531
Longitudinális sebesség	0.3	0.2159
Laterális távolság	0.2	0.1150
Laterális sebesség	0.3	0.1786

5. ÖSSZEFOGLALÁS

Egy kis számításigényű, valós időben futtatható eljárást mutattunk be, amely járművek állapotának becslésére és a végrehajtott manőver észlelésére használható. A becslés során egyszerű egyenes vonalú egyenletes mozgást leíró modellt használtunk, amit kényszerekkel igazítottunk az előre definiált mozgásformákhoz. Lineáris egyenlőségi és nem egyenlőségi kényszerekhez Kálmán szű-

8. ábra: Mérés és becslés zaja



rőt, nemlineáris kényszerhez részecskeszűrőt társítottunk és multimodelles struktúrába illesztettük azokat. Szimulált tesztkörnyezetben az eljárás sikeresen azonosította a manővereket és becsülte a megfigyelt jármű állapotát. A bemutatott módszer klasszikus elméleti alapokon nyugszik, kiegészítője lehet egy mesterséges intelligenciát használó algoritmusnak.

Sávdetektáló kamera segítségével az út ívét előre lehet jelezni, amely információ alapján a manőverváltási valószínűségeket és a kényszerek paramétereit változtatni lehet, így egy adaptív algoritmust kapunk.

FELHASZNÁLT IRODALOM

- [1] X. R. Li and V. P. Jilkov, "Survey of maneuvering target tracking. part v. multiple-model methods," IEEE Transactions on Aerospace and Electronic

- Systems, vol. 41, no. 4, pp. 1255–1321, 2005. DOI: <https://doi.org/fn8tfr>
- [2] H. A. Blom and Y. Bar-Shalom, “The interacting multiple model algorithm for systems with markovian switching coefficients,” IEEE transactions on Automatic Control, vol. 33, no. 8, pp. 780–783, 1988. DOI: <https://doi.org/cwbf76>
- [3] E. Mazor, A. Averbuch, Y. Bar-Shalom, and J. Dayan, “Interacting multiple model methods in target tracking: a survey,” IEEE Transactions on aerospace and electronic systems, vol. 34, no. 1, pp. 103–123, 1998. DOI: <https://doi.org/c9b8j9>
- [4] Y. Bar-Shalom, X. R. Li, and T. Kirubarajan, Estimation with applications to tracking and navigation: theory algorithms and software. John Wiley & Sons, 2004. DOI: <https://doi.org/dfqbsw>
- [5] Z. Messaoudi, A. Ouldali, and M. Oussalah, “Comparison of interactive multiple particle filter and interactive multiple model unscented particle filter for tracking multiple manoeuvring targets in sensors array,” in Cybernetic Intelligent Systems (CIS), 2010 IEEE 9th International Conference on. IEEE, 2010, pp. 1–6. DOI: <https://doi.org/bbrxrf>
- [6] M. Zhang and W. Chen, “Variable structure multiple model particle filter for maneuvering radar target tracking,” in Microwave and Millimeter Wave Technology (ICMMT), 2010 International Conference on. IEEE, 2010, pp. 1754–1757. DOI: <https://doi.org/cvkvz2>
- [7] Törő, O., Bécsi, T., Aradi, S. and Gáspár, P., 2018. Imm bernoulli filter for cooperative object tracking in road traffic. IFAC-PapersOnLine, 51(9), pp.355-360. DOI: <https://doi.org/gt4j>
- [8] Törő, O., Bécsi, T., Aradi, S. and Gáspár, P., 2018. IMM Bernoulli Gaussian Particle Filter. IFAC-PapersOnLine, 51(22), pp.274-279. DOI: <https://doi.org/gt4k>
- [9] D. Simon, Optimal state estimation : Kalman, H_∞ and nonlinear approaches. Hoboken, N.J: Wiley-Interscience, 2006. DOI: <https://doi.org/bmzttv>
- [10] Teixeira, B. O., Chandrasekar, J., Tórres, L. A., Aguirre, L. A., & Bernstein, D. S. (2009). State estimation for linear and non-linear equality-constrained systems. International Journal of Control, 82(5), 918-936. DOI: <https://doi.org/bfwshc>
- [11] O. Törő, L. Bécsi, and S. Aradi, “Design of lane keeping algorithm of autonomous vehicle,” Periodica Polytechnica Transportation Engineering, vol. 44, no. 1, pp. 60–68, 2016. DOI: <https://doi.org/ggfvvq>
- [12] Z. Zhao, B. Huang, and F. Liu, “Constrained particle filtering methods for state estimation of nonlinear process,” AIChE Journal, vol. 60, no. 6, pp. 2072–2082, 2014. DOI: <https://doi.org/gt4m>
- [13] Chen, Z., 2003. Bayesian filtering: From Kalman filters to particle filters, and beyond. Statistics, 182(1), pp.1-69. DOI: <https://doi.org/bkztpw>
- [14] A. A. Saucan, T. Chonavel, C. Sintés, and J. M. L. Caillec, “Interacting multiple model particle filters for side scan bathymetry,” in 2013 MTS/IEEE OCEANS - Bergen, June 2013, pp. 1–5. DOI: <https://doi.org/gt4n>



Determination of road vehicle motion model by constrained multiple model filtering procedures

The paper presents a solution based on traditional methods for manoeuvring detection in road traffic. The method works in a multiple model structure with Kálmán filters and particle filters. Each manoeuvre is defined and fitted into the elementary filters using different state constraints so that a unique filter is associated with each manoeuvre. The multiple model structure evaluates the accuracy of the estimation of each filter and accepts the manoeuvre associated with the better performing filter as current. The efficiency of the procedure is demonstrated in a simulated traffic situation where the observed object was examined from the perspective of the observation vehicle.



Bestimmung des Straßenfahrzeug-Bewegungsmodells durch beschränkte Multimodell-Filterverfahren

Der Beitrag stellt eine Lösung vor, die auf traditionellen Methoden zur Manövriererkennung im Straßenverkehr basiert. Das Verfahren arbeitet in einer multiplen Modellstruktur mit Kálmán-Filtern und Partikelfiltern. Jedes Manöver wird unter Verwendung verschiedener Zustandsbeschränkungen definiert und in die elementaren Filter eingepasst, so dass jedem Manöver ein individueller Filter zugeordnet ist. Die Multimodellstruktur bewertet die Genauigkeit der Schätzung jedes Filters und akzeptiert das Manöver, das dem Filter mit der besseren Leistung zugeordnet ist, als aktuell. Die Effizienz des Verfahrens wird in einer simulierten Verkehrssituation demonstriert, bei der das beobachtete Objekt aus der Perspektive des Beobachtungsfahrzeugs untersucht wurde.



E számunk lektorai

Dr. Gáspár Péter ■ Dr. Katona András
Mika Péter ■ Dr. Tóth János ■ Dr. Tóth László