

## Közúti járművek manőverklasszifikációja kényszerezett szűrési eljárásokkal

Kolat Máté\*, Dr. Bécsi Tamás\*

\* Közlekedés és- Járműirányítási Tanszék, Budapesti Műszaki és Gazdaságtudományi Egyetem  
(email: mate.kolat@edu.bme.hu, becsi.tamas@kjk.bme.hu).

Kivonat: A környezetérzékelés és a helyzetfelismerés kulcsfontosságúak az autonóm közúti járművek esetén. A cikkben a közúti jármű manővereinek az osztályozásának problémájával foglalkozunk a multiple-model állapotbecslés keretein belül, figyelembe véve a modell bizonytalanságot. A hagyományos megközelítés a különböző mozgásmoделlek meghatározása, amelyek megfelelnek a kívánt mozgástípusnak. A becslés a multiple-model rendszer keretein belül végezzük, ahol minden egyes kényszerezett szűrő megfeleltethető egy manőver típusnak. A publikációban egy mozgási modell volt használva. A manőverek meghatározásához lineáris egyenlőségi, illetve egyenlőtlenégi kényszerek voltak alkalmazva. A feladat bemutatásához egy szimulációs környezetet alkalmaztunk, amelyben egy megfigyelő, illetve egy manőverező jármű vesz részt.

### 1. BEVEZETŐ

A környezetérzékelés a járműipar aktívan kutatott területe. Az aktív biztonsági és autonóm funkciókhoz egyaránt szükség van helyzetfelismerésre, a környező tárgyak és a forgalom résztvevőinek robusztus érzékelésére a biztonság és hatékony működéshez. A rendelkezésre álló szenzorok és a lehetséges szenzorfüziós megoldások széles skálát kínálnak költség, illetve teljesítmény terén. (Van Brummelen és munkatársai, 2018, Zhu és munkatársai, 2017). Az autonóm járműipar növekedésével, habár költséges, de nő a valós tesztkörnyezet iránti kereslet. (Szalay et és munkatársai, 2018). Ennek ellenére az autonóm funkciók fejlesztésének és tesztelésének jelentős része szimulált környezetben történik (Rosique és munkatársai, 2019, Amer és munkatársai, 2017), ami különösen igaz a biztonsági funkciókra (Kale és munkatársai, 2019). Azonban a jelenlegi szenzorok, szoftverek és adatfüziós megoldások nem tudják biztosítani a legmagasabb önvezető szintet. De Ponte Müller (2017) és Kuutti és munkatársai, (2018) arra a következtetésre jutottak, hogy a kooperatív és a nem kooperatív módon szerzett megfigyelések füziója a legjobb relatív pozícióbecslési teljesítményt nyújthatják.

A manőverező járművek állapotbecslése olyan problémának tekinthető, ahol a mozgási modell bizonytalan, vagyis nem tudjuk előre, hogy melyik modellt használjuk a becslési eljárás során. A bizonytalanság csökkentésének egyik módja, ha minden egyes manőverhez saját szűrőt tervezünk, majd különböző mérési adatok alapján figyelembe vesszük azt, amelyik a legjobb kimenetet adja.

A multiple-model szűrés kiterjedt irodalommal és alkalmazásokkal rendelkezik a manőverkövetés területén (Li és Jilkov, 2005).

A multiple-model becslési probléma megoldása minden egyes lépésnél figyelembe veszi az előre meghatározott modellek minden lehetséges kombinációját, ami az exponenciálisan növekvő komplexitás miatt numerikusan megoldhatatlan problémát okozna. A gyakorlati algoritmusok oly módon csökkentik a problémát, hogy csak az előző egy vagy két lépésköznyi becslési adatot használja fel, egy első- vagy másodrendű általános pseudo-Bayes becslőként (Watanabe és Tzafestas, 1993). Az Interacting Multiple Model (IMM) becslő egy másik megközelítés a multiple-model probléma megoldására, amelyet Blom és Bar-Shalom (1988) mutatott be. Az algoritmus képes különböző típusú Kálmán-szűrőkkel és részecskeszűrőkkel dolgozni (Törő és munkatársai, 2019).

Azokban az esetekben, amikor a rendszer elérhető állapotait fizikai korlátok korlátozzák, a becslés teljesítménye növelhető, ha ezeket a kiegészítő információkat kényszer egyenletként illesztjük be a szűrési folyamatba (Gupta és Hauser, 2007). A manőverkövetés témakörében nagyszámú, különböző módszert feldolgozó irodalom található.

Ormsby és munkatársai (2006) elemezték a multiple-model becslési problémát pre-fit, post-fit és generalizált reziduálok felhasználásával. Seifzadeh (2013) multiple-model eljárást alkalmazott, kényszerezett részecskeszűrővel, felhasználva személyes adatokat követéshez. Jia és Evans (2017) egy módszert mutattak be, ahol a kamerás videókat simították ki, multiple-model szűrés segítségével, ahol lineáris

egyenlőtlenségi kényszerek reprezentálták a képek fekete szegélyeit.

A publikációban egy olyan módszer kerül bemutatásra, amely felhasználható a közúti járművek manővereinek felismerésére és klasszifikálásra. A megvalósítás fő részei a multiple-model megoldás, illetve a kényszerezett szűrés. A tanulmány célja nem a kifinomult mozgási modellek és járműdinamika alkalmazása volt, ezért gyorsulás zajjal terhelt konstans sebesség mozgási modell került alkalmazásra. A kényszerezett szűrők az IMM-ben belül futnak párhuzamosan. Minden szűrőhöz külön kényszer van rendelve, amelyek pedig egy adott manővernek feleltethetők meg. Az adott szűrő teljesítménye a post-fit reziduál alapján kerül kiértékelésre.

A publikáció az alábbiak szerint épül fel. A 2. fejezetben a bemutatott módszer elméleti háttérét foglalja össze. A teszteléshez használt szimulációs keretrendszert és a manőver detektáláson alapuló megoldást a 3. fejezet mutatja be. A 4. fejezet vizsgálja a szűrési eljárás teljesítményét. A konklúzió az 5. fejezetben kerül bemutatásra.

## 2. MANŐVER KLASSZIFIKÁCIÓN ALAPULÓ MEGOLDÁSOK

A publikációban a vizsgált rendszert egy lineáris diszkrét dinamikai modell írja le:

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

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

ahol  $k$  az időindex,  $\mathbf{x}_k \in \mathbb{R}^{n_x}$  az állapotvektor, amely az  $F_k \in \mathbb{R}^{n_x \times n_x}$  mátrix alapján változik,  $\mathbf{w}_k \in \mathbb{R}^{n_w}$  pedig az állapotvektorhoz tartozó zaj, a hozzátartozó mátrix pedig  $G_k \in \mathbb{R}^{n_x \times n_w}$ . A mérési vektor  $\mathbf{z}_k \in \mathbb{R}^{n_z}$  a  $H_k \in \mathbb{R}^{n_z \times n_x}$  mátrixon keresztül frissül,  $\mathbf{v}_k \in \mathbb{R}^{n_z}$  pedig additív zajvektor. Mind  $\mathbf{w}_k$ , mind  $\mathbf{v}_k$  nulla középértékű Gauss-eloszlás,  $Q_k$  és  $R_k$  kovarianciával.

Az alapja a használt klasszifikációs eljárásnak a Kálmán-szűrő, amely optimális becslő lineáris Gauss-rendszerek esetén. A Kálmán-szűrő alapvető koncepciója a következő:

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

$$P_{k|k-1} = F_k P_{k-1|k-1} F_k^T + G_k Q_k G_k^T \quad (4)$$

$$\mathbf{r}_{k|k-1} = \mathbf{z}_k - H_k \hat{\mathbf{x}}_{k|k-1} \quad (5)$$

$$S_{k|k-1} = H_k P_{k|k-1} H_k^T + R_k \quad (6)$$

$$K_k = P_{k|k-1} H_k^T S_{k|k-1}^{-1} \quad (7)$$

$$\hat{\mathbf{x}}_{k|k} = \hat{\mathbf{x}}_{k|k-1} + K_k \mathbf{r}_{k|k-1} \quad (8)$$

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

A (3) és (5) a rendszermodell használatával becsléseket ad az állapothoz és a hibakovarianciához. A pre-fit reziduál az (5), a hozzá tartozó kovarianciát pedig a (6) adja. A pre-fit reziduál vagy innováció (5) egy általánosan használt jellemző, amelyből a becslés minőségére vonatkozó mutatók származtathatók. A pre-fit reziduál és annak kovarianciája (6) segítségével kiértékelésként egy nulla középértékű normális eloszlású sűrűségfüggvényt számolhatunk:

$$\Lambda = \mathcal{N}(\mathbf{r}; 0, S) \quad (10)$$

amely skalár értékkel tér vissza és a becslés minőségéről ad számszerű visszajelzést. A post-fit reziduál meghatározása az alábbiak szerint történik:

$$\mathbf{r}_{k|k} = \mathbf{z}_k - H_k \hat{\mathbf{x}}_{k|k} \quad (11)$$

A pre-fit és a post-fit reziduál közötti kapcsolat lineáris transzformációval írható le:

$$\mathbf{r}_{k|k} = \mathbf{z}_k - H_k (\hat{\mathbf{x}}_{k|k-1} + K_k \mathbf{r}_{k|k-1}) \quad (12)$$

$$= \mathbf{r}_{k|k-1} - H_k K_k \mathbf{r}_{k|k-1} \quad (13)$$

$$= (I - H_k K_k) \mathbf{r}_{k|k-1} \quad (14)$$

A post-fit reziduálhoz tartozó kovariancia pedig:

$$S_{k|k} = (I - H_k K_k) S_{k|k-1} (I - H_k K_k)^T \quad (15)$$

### 2.1 Multi-modell becslés

A modell bizonytalansága több okból is növekedhet. Manőverkövetés szempontjából a bizonytalanságot okozhatja, hogy nem tudjuk előre, hogy a megfigyelt objektum milyen manővert hajt végre, ezáltal nem tudhatjuk előre, hogy melyik mozgási modell az optimális választás. Ebből adódóan a publikációban egyszerű mozgásmodellt használtunk nagy dimenziójú állapottal. Ez utóbbi oka részben az, hogy a rendszer megfigyelhetőségéhez nagyobb számú és sokféle szenzorra lenne szükségünk, amely a járműmodell magasabb fokú hangolását is igényelné (Tin Leung és munkatársai, 2011, Schubert és munkatársai, 2008).

Az egyik megoldás a modellbizonytalanság csökkentésére a multi-modell (MM) becslés. Ha a rendszert leíró modell nem ismert vagy bizonytalan, de rendelkezünk előre



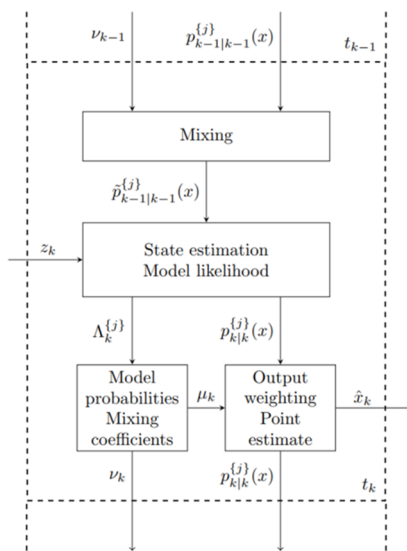
valószínűsíthető modell halmazzal, akkor a multi-modell eljárás egy optimális megoldás lehet. Az egyik előnye ennek az eljárásnak, hogy ha olyan modellt használunk, amely helyes vagy közel áll a valósághoz, a becslés minősége jobb lesz. Másrészt a tényleges modell ismerete fontos információ lehet, amely megmondja nekünk, hogyan viselkedik a megfigyelt rendszer. A multi-modell alapelve több szűrő implementálása, párhuzamos futtatása és a legjobb teljesítményű szűrő kiválasztása. Az IMM becslő lineáris skálázási karakterisztikával rendelkezik a figyelembe vett modellek tekintetében (Bar-Shalom és munkatársai, 2004).

Az IMM becslő szerkezetét az 1. ábra mutatja be. A rekurzív algoritmus bemenetei  $k$  lépésben a módfüggő állapotbecslések, a mixing súlyokat pedig  $v^{(i,j)}$  mátrix adja. Az állapotbecslések egy Gauss-eloszlást leíró átlagértékből és egy kovarianciamátrixból állnak. A keverési szakaszban a szűrő bemenete  $j \in 1 \dots J$  a Gaussok súlyozott összegeként adódik:

$$\tilde{\mathbf{x}}_{k-1}^{(j)} = \sum_{i=1}^J v_{k-1}^{(i,j)} \mathbf{x}_{k-1}^{(i)} \quad (16)$$

$$\tilde{\mathbf{P}}_{k-1}^{(j)} = \sum_{i=1}^J v_{k-1}^{(i,j)} \left[ \mathbf{P}_{k-1}^{(i)} + (\mathbf{x}_{k-1}^{(i)} - \tilde{\mathbf{x}}_{k-1}^{(j)}) (\mathbf{x}_{k-1}^{(i)} - \tilde{\mathbf{x}}_{k-1}^{(j)})^T \right] \quad (17)$$

Ezeket az értékeket és a  $\mathbf{z}_k$  mérési vektort továbbítodnak az egyes szűrőknek.



1. ábra Az IMM becslő egy rekurziója

Az állapotbecslés mellett a szűrők a reziduálokat és a hozzátartozó kovarianciamátrixokat is előállítják. Ezekből a modell likelihood-ot az alábbi módon számítjuk:

$$\mathcal{L}_k^{(j)}(\mathbf{z}_k) = \mathcal{N}(\mathbf{r}_k; 0, \mathbf{S}_k^{(j)}) \quad (18)$$

A különböző manőverekhez tartozó valószínűségek nem csupán likelihood-ok, mivel a manőverek közötti váltás dinamikája a  $\pi$  állapotátmeneti mátrix segítségével valósul meg a korábbi valószínűség felhasználásával:

$$\mu_{k|k-1}^{(j)} = \sum_{i=1}^J \pi_{ij} \mu_{k-1}^{(i)} \quad (19)$$

A frissített valószínűségek:

$$\mu_{k|k}^{(j)} = \frac{\mathcal{L}_k^{(j)} \mu_{k|k-1}^{(j)}}{\sum_{i=1}^J \mathcal{L}_k^{(i)} \mu_{k|k-1}^{(i)}} \quad (20)$$

Az összesített becslés kiszámolható a szűrőkimenetek súlyozásával, amelyet a valószínűségek adnak:

$$\hat{\mathbf{x}}_{k|k} = \sum_{j=1}^J \mu_{k|k}^{(j)} \mathbf{x}_{k|k}^{(j)} \quad (21)$$

A hozzátartozó kovarianciamátrix:

$$\mathbf{P}_{k|k} = \sum_{j=1}^J \mu_{k|k}^{(j)} \left[ \mathbf{P}_{k|k}^{(j)} + (\mathbf{x}_{k|k}^{(j)} - \hat{\mathbf{x}}_{k|k}) (\mathbf{x}_{k|k}^{(j)} - \hat{\mathbf{x}}_{k|k})^T \right] \quad (22)$$

A mixing együttható a következő lépésben a rekurzió alapján:

$$v_{k-1}^{(i,j)} = \frac{\pi_{ij} \mu_{k-1}^{(i)}}{\sum_{m=1}^J \pi_{mj} \mu_{k-1}^{(m)}} \quad i, j = 1 \dots J \quad (23)$$

## 2.2 Kényszerezett szűrés

A Kálmán-szűrő teljesítménye, habár alapvetően optimális, különleges esetekben növelhető. Ha a vizsgált rendszer bizonyos korlátozásoknak van kitéve, amelyek nem szerepelnek a (1)-(2) rendszermodellben, a szűrő olyan becsléseket készíthet, amelyek megsértik a korlátozásokat. Különböző módszerek léteznek, amelyek lehetővé teszik a korlátozó információk (kényszerek) beépítését a rendszermodellbe vagy a szűrési folyamatba (Simon és Chia, 2002). A rendszermodell átalakítható úgy, hogy megfeleljen a kényszereknek. Ezt az állapotok kombinálásával vagy generalizált koordináták bevezetésével lehet elérni. A koordináták eredeti, esetleg fizikai jelentése azonban elvesznek. A rendszer modelljét változatlanul hagyva, a

szűrési egyenletek módosíthatók annak biztosítására, hogy a becslés ne sértse a kényszereket.

A kényszereket különböző szempontok szerint osztályozhatjuk: lineáris vagy nemlineáris, egyenlőségi vagy egyenlőtlenégi, időfüggő vagy időfüggetlen, kemény vagy lágy korlátozások. Ebben a publikációban csak lineáris egyenlőségi és egyenlőtlenégi kényszerek kerülnek bemutatásra, amelyeknek az alábbi formája van:

$$D_k \mathbf{x}_k = \mathbf{d}_k \quad (24)$$

$$D_k \mathbf{x}_k \leq \mathbf{d}_k \quad (25)$$

ahol  $\mathbf{d}_k \in \mathbb{R}^{n_c}$  a kényszervektor és  $D_k \in \mathbb{R}^{n_c \times n_x}$  a kényszermátrix.

### 2.3 Measurement Augmentation

Az egyik optimális megoldás az egyenlőségi kényszerek becslésbe való beillesztés, amely a mérési egyenlet (2) (24)-es egyenlettel való kiegészítésével történik. Ezt a módszert Measurement Augmentation Kalman Filter-nek (MAKF) nevezik (Teixeira és munkatársai, 2007). Ha a kényszerek lágyak, vagyis a (24)-es egyenletet csak megközelítőleg kell teljesíteni, akkor egy további hozzáadott zaj feleltethető meg ennek a tulajdonságnak:

$$D_k \mathbf{x}_k = \mathbf{d}_k + \delta_k \quad (26)$$

A kibővített mérési egyenlet pedig:

$$\begin{bmatrix} \mathbf{z}_k \\ \mathbf{d}_k \end{bmatrix} = \begin{bmatrix} H_k \\ D_k \end{bmatrix} \mathbf{x}_k + \begin{bmatrix} \mathbf{v}_k \\ \delta_k \end{bmatrix} \quad (27)$$

rövidebb formában:

$$\mathbf{z}_k^d = H_k^d \mathbf{x}_k + \mathbf{v}_k^d \quad (28)$$

A kibővített kovariancia mátrix  $R_k^d$ , amely egy blokkdiagonális mátrix  $R_k$  és  $R_k^{\delta} = Cov[\delta_k]$  összetevőkkel. Kemény kényszerek esetén az extra mérési egyenlet zajmentes, ahol  $\delta_k = 0$  és  $R_k^{\delta} = 0$ , amelyből adódik Perfect Measurement (PM) elnevezés.

Az MAKF az eredeti Kálmán-szűrő egyenleteket használja a becslési, illetve a frissítési lépésben. A kibővített egyenletek a következők:

$$\mathbf{r}_{k|k-1}^d = \mathbf{z}_k^d - H_k^d \hat{\mathbf{x}}_{k|k-1} \quad (29)$$

$$S_{k|k-1}^d = H_k^d P_{k|k-1} (H_k^d)^T + R_k^d \quad (30)$$

$$K_k^d = P_{k|k-1} (H_k^d)^T + R_k^d \quad (31)$$

$$\hat{\mathbf{x}}_{k|k} = \hat{\mathbf{x}}_{k|k-1} + K_k^d \mathbf{r}_{k|k-1}^d \quad (32)$$

$$P_{k|k} = (\mathbf{I} - K_k^d H_k^d) P_{k|k-1} \quad (33)$$

Ha a Perfect Measurements-nek megfelelően  $R_k^{\delta} = 0$  blokk van használva  $R_k^d$  mátrixban, az egy olyan Kálmán erősítést hoz létre, hogy a frissített becslés összhangban lesz a kényszerekkel.

### 2.4 Estimation projection

Az estimation projection egy másik módja annak, hogy a kényszereket tartalmazza a szűrési folyamat. A frissített becslés figyelembevételével, a kényszerezett optimalizálási probléma a következő módon írható le:

$$\hat{\mathbf{x}}_{k|k}^d = \underset{\mathbf{x}}{\operatorname{argmin}} (\mathbf{x} - \hat{\mathbf{x}}_{k|k})^T W (\mathbf{x} - \hat{\mathbf{x}}) \quad (34)$$

amely során (24) vagy (25) teljesül (Teixeira és munkatársai, 2009). A  $W$  súlymátrix pozitív-definit mátrix és ha az értéke  $W = P_{k|k}^{-1}$ , akkor a legkisebb szórású kényszerezett becslőt kapjuk az alábbi formában:

$$\hat{\mathbf{x}}_{k|k}^d = \hat{\mathbf{x}}_{k|k} + K_k^p (d_k \hat{\mathbf{x}}_{k|k}), \quad (35)$$

ahol  $K_k^p$ :

$$K_k^p = P_{k|k} D_k^T (D_k P_{k|k} D_k^T)^{-1} \quad (36)$$

A kovarianciája a kényszerezett becslésnek:

$$P_{k|k}^d = P_{k|k} - K_k^p D_k P_{k|k}. \quad (37)$$

Ennek az eljárásnak a nagy előnye, hogy lehetővé teszi az egyenlőtlenégi kényszerek használatát is (Simon, 2010). Figyelembe egyenlőtlenégi egyenletet (25), kiválasztjuk a  $D_k$  mátrix azon sorát  $a$  és  $d_k$  azon értékét amely megfeleltethetőek az adott aktív kényszereknek, tehát amelyeket megsért  $\hat{\mathbf{x}}_{k|k}$ . Ezekből a sorokból létrehozunk egy új  $D_k^*$  mátrixot és  $d_k^*$  vektort és megoldjuk az optimalizálási problémát (34) az alábbi módon:

$$D_k^* \hat{\mathbf{x}}_{k|k} = d_k^* \quad (38)$$

## 3. ESETTANULMÁNY

Ebben a fejezetben az IMM struktúrában kényszerezett Kálmán-szűrő által megvalósított manőverklasszifikáció kerül bemutatásra. A megfigyelő jármű halad az út mentén, és radarméréseket végez a manőverező járművön.

A mérések az érzékelőhöz rögzített poláris koordinátarendszerben értelmezhető. A manőverező járművet leíró állapotvektor a megfigyelőhöz viszonyított helyzet- és sebességkomponenseket tartalmaz. A megfigyelő jármű képes a sávok geometriájának észlelésére is. Ezen információk



alapján határozzák meg, hogy a megfigyelt jármű melyik sávban halad.

A megfigyelt jármű előre meghatározott manővereket hajt végre, amelyek állandó sebességű mozgásból állnak, a manőverek pedig a bal vagy a jobb sávban való haladás, illetve a sávváltás. A manőverek sorrendjét az 1. táblázat tartalmazza.

Táblázat 1. A megfigyelt jármű manőverei

Manőver	Kezdési idő	Befejezés
CV right lane	0	2
Lane changing	2	4
CV left lane	4	8
Lane changing	8	10
CV right lane	10	14
Turning right lane	14	21
CV right lane	21	25

A megfigyelő járműhöz csatolt radar relatív távolságot, két jármű közötti szöveget, illetve sebességet mér. A megfigyelt jármű mozgását leíró állapotter-modell az  $\mathbf{x} = [x, \dot{x}, y, \dot{y}]^T$  állapotvektort használja a megfigyelő referenciakeretében értelmezve.

Ennek az egyszerű Descartes-koordinátákkal rendelkező állapotvektornak az egyik oka az, hogy gyakorlatilag bármilyen mozgást képes modellezni. Míg más mozgásmodellek, amelyek polár pozíciót vagy sebességkomponenseket tartalmaznak, jobban teljesíthetnek (Gustafsson és Isaksson, 1996), az IMM algoritmusnak nehézségeket okoz. A különböző komponensű vagy méretű állapotvektorokat nem lehet összemixelni Granstrom által leírt további eljárás nélkül (2015). A másik ok, hogy a derékszögű koordinátarendszer megválasztása természetesen azért következik be, mert - amint az látható lesz - ebben az ábrázolásban az általunk használt helyzet- és sebességkényszerek szétválasztottak egymástól.

A radarmérések egy poláris koordinátarendszerben értelmezettek, amely megköveteli, hogy az állapotvektorral kompatibilis transzformációt hajtssunk végre. Az átalakítás elvégezhető a szűrési folyamat frissítési szakaszában vagy korábban. Mivel több modellt használunk, számításilag olcsóbb az átalakítás előzetes alkalmazása és a derékszögű komponensekben végzett mérések átadása az IMM becslőbe, ahelyett, hogy minden szűrőben nemlineáris mérési modellt használnánk.

Az eredeti mérési vektor tartalmazza a két jármű között bezárt szöveget, illetve a távolság- és sebességkülönbséget:  $\mathbf{z}^p = [\vartheta, r, v]$ . A mérési vektor szög- és távolságrészéhez tartozó kovarianciamátrix  $R_1 = \text{diag}(\sigma_\vartheta^2, \sigma_r^2)$ , a szög- és sebességrészhez pedig  $R_2 = \text{diag}(\sigma_\vartheta^2, \sigma_v^2)$ . A transzformált mérési vektor az állapotterben értelmezve  $\mathbf{z} = [x, \dot{x}, y, \dot{y}]$ .

Egyszerűsítés kedvéért a pozíciókomponensek számítását mutatjuk be, a sebességkomponenseket analóg módon kaphatjuk meg. A transzformált pozíció méréshez tartozó  $R_1^p$  kovarianciamátrixot a Jacobi-mátrix segítségével kaphatjuk az alábbi módon:

$$R^p = J R_1 J^T \quad (39)$$

ahol

$$J = \begin{bmatrix} -r \sin \vartheta & \cos \vartheta \\ r \cos \vartheta & \sin \vartheta \end{bmatrix} \quad (40)$$

A végső mátrixos forma pedig:

$$R_1^p = \begin{bmatrix} \sigma_r^2 \cos^2 \vartheta + \sigma_\vartheta^2 r^2 \sin^2 \vartheta & (\sigma_r^2 - \sigma_\vartheta^2 r^2) \cos \vartheta \sin \vartheta \\ (\sigma_r^2 - \sigma_\vartheta^2 r^2) \cos \vartheta \sin \vartheta & \sigma_\vartheta^2 r^2 \cos^2 \vartheta + \sigma_r^2 \sin^2 \vartheta \end{bmatrix} \quad (41)$$

### 3.1 Kényszerek

Az állandó sebességű bal, illetve jobb sávban való haladást a következő kényszerek jellemzik. Az  $y$  koordinátának kemény felső és alsó határai vannak, meghatározva a jármű helyzetét sávon belül vagy sávok között. Az  $\dot{y}$  sebességkomponens kényszert nulla középértékű Gauss-eloszlásként értelmezzük. Ez utóbbi oka, hogy nem akarjuk korlátozni az irányt, és nem engedünk magas értéket az oldalirányú sebességkomponensnek. A sávváltási manőverhez  $y$  és  $\dot{y}$  esetén is felső és alsó határt határoztunk meg. A kényszereket a 2. táblázat tartalmazza. A megfigyelt jármű állapotvektorának a meghatározott kényszerekkel történő becslésének módszereit a 3. táblázat foglalja össze. A 2. táblázatban szereplő kényszeregyenletek  $y$  koordinátáját kompenzálni kell az út görbületével, az oldalirányú elmozdulás a megfigyelt jármű távolságában kivonódik belőle. A sávváltási manőver sebességkorlátozása nem lineáris, azonban a megvalósításban nem okoz nehézségeket. A becslő oldalsebesség előjele dönti el, hogy  $\dot{y} > 0.5$  vagy  $\dot{y} < -0.5$  értéket kell-e használni, ami egyszerű lineáris egyenlőtlenségi kényszer. A kényszerek a következő módon vannak alkalmazva. Először a lágy kényszereket kell figyelembe venni, ha vannak ilyenek, kiterjesztett méréseként. Ezután a becslő állapotvektor a sebességkorlátozásnak megfelelően kerül vetítésre. A sávváltási manővernél csak egyenlőtlenségi korlátok vannak, ezért a 2.4. Szakaszban leírt módszert kell alkalmazni.

Táblázat 2. Adott manőverekhez tartozó kényszerek. A sáv szélességét  $l$  jelöli

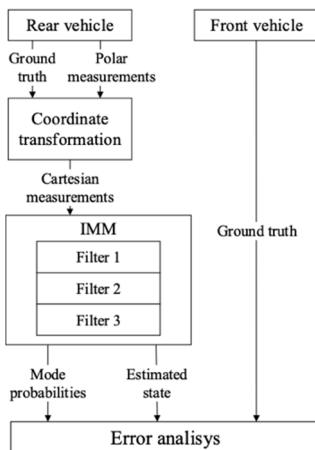
Manőver	Pozíció kényszer	Sebesség kényszer
Jobb sáv CV	$\frac{1}{2l} - 0.5 < y < \frac{1}{2l} + 0.5$	$\dot{y} \in \mathcal{N}(0,1)$
Bal sáv CV	$\frac{3}{2l} - 0.5 < y < \frac{3}{2l} + 0.5$	$\dot{y} \in \mathcal{N}(0,1)$
Sávváltás	$\frac{1}{2l} + 0.5 < y < \frac{3}{2l} - 0.5$	$ \dot{y}  > 0.5$



2. ábra Megfigyelő (hátról) és manőverező (előlről) jármű a szimuláció során

### 3.2 Szimulációs környezet

A tesztkörnyezet a PreScan szimulátorban lett implementálva (Hendriks és munkatársai, 2010). A környezet egy kétsávos útból áll, egyenes és ívelt szegmensekkel. Két jármű halad egymás mögött az út mentén (2. ábra). A hátsó jármű a megfigyelő, amely 15 m/s állandó sebességgel mozog, míg az első jármű manővereket végez. A ground truth adatait és a PreScan szimulációban generált megfigyeléseket valós idejű kommunikációval továbbítják a Simulinkhez. Az adatáramlás és a becslési folyamat sémáját a 3. ábra mutatja be.



3. ábra Becslési folyamat


## 4. EREDMÉNYEK

Az alkalmazott szűrőket Simulinkben valósítottuk meg. A mozgási modell zaját, diszkrét fehér gyorsulási zajként értelmeztük  $Q = \text{diag}(\sigma_x^2, \sigma_y^2)$  kovarianciával, ahol  $\sigma_x = \sigma_y = 1m/s$ . A rendszer mátrixok az alábbiak:

$$\mathbf{F} = \mathbf{I}_2 \otimes \begin{bmatrix} 1 & T_s \\ 0 & 1 \end{bmatrix} \quad (42)$$

$$\mathbf{G} = \mathbf{I}_2 \otimes \begin{bmatrix} T_s^2 \\ T_s \end{bmatrix}, \quad (43)$$

ahol  $T_s$  a mintavételi idő. A  $\mathbf{H}$  mátrix, mivel a mérési tér és az állapotter azonos, egységmátrix.



4. ábra Vizsgált manőverek valószínűségei

A mode transition valószínűség mátrix az alábbi módon épül fel:

$$\pi = \begin{bmatrix} 0.8 & 0.1 & 0.1 \\ 0.1 & 0.8 & 0.1 \\ 0.1 & 0.1 & 0.8 \end{bmatrix} \quad (44)$$

A figyelembe vett manőverek valószínűségét a 4. ábra mutatja. A 15....20 másodperc közötti oszcillációt a sávgeometria detektálásának a bizonytalansága okozza, mialatt a jármű a görbén mozog, mivel az egyszerűsítés kedvéért a polinómillesztés felbontását mesterségesen csökkentették PreScanben.

Táblázat 3. Kényszerek megvalósításának módja

Manőver	Kényszer típusa	Eljárás
Jobb sáv CV	Kemény egyenlőtlenségi	Estimation projection
	Lágy egyenlőség	Measurement augmentation
Bal sáv CV	Kemény egyenlőtlenségi	Estimation projection
	Lágy egyenlőség	Measurement augmentation
Sáv váltás	Kemény egyenlőtlenségi	Estimation projection

#### 4. KONKLÚZIÓ

A publikáció a közúti járművek manőverezéseinek osztályozási módszerét mutatja be. Az algoritmus kényszerezett szűrőket használ IMM szerkezetben, és a jelenlegi formában képes észlelni egy sávváltási manővert, továbbá megmondani, hogy melyik sávban halad a megfigyelt jármű. A javasolt módszer rugalmas az alkalmazott kényszerek típusa tekintetében, és más típusú manővereket is tartalmazhat. Egy átfogó tanulmány feltárná, hogy mely manővereket melyik kényszerrel lehet a legjobban észlelni, esetleg különböző mozgásmodelleket használva. Útgörbület esetén, CT mozgásmodell jobb becslést adhat megfigyelt jármű állapotára, amihez a változó szerkezetű IMM becslőre van szükség. A részecskeszűrőn alapuló megoldás nagyobb rugalmasságot kínálhat a rendszer modellje és a zajjellemzők tekintetében, és ami még fontosabb, a kényszerek esetében. Ha a részecskéket bizonyos kényszereket tükröző eloszlásból merítenénk, az összetettebb osztályozást tenné lehetővé.

#### 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.

#### HIVATKOZÁSOK

- Amer, N.H., Zamzuri, H., Hudha, K., and Kadir, Z.A. (2017). Modelling and control strategies in path tracking control for autonomous ground vehicles: a review of state of the art and challenges. *Journal of Intelligent & Robotic Systems*, 86(2), 225–254.
- Bar-Shalom, Y., Li, X.R., and Kirubarajan, T. (2004). Estimation with applications to tracking and navigation: theory algorithms and software. John Wiley & Sons.
- Blom, H.A. and Bar-Shalom, Y. (1988). The interacting multiple model algorithm for systems with markovian switching coefficients. *IEEE transactions on Automatic Control*, 33(8), 780–783.
- De Ponte Müller, F. (2017). Survey on ranging sensors and cooperative techniques for relative positioning of vehicles. *Sensors*, 17(2), 271.
- Granström, K., Willett, P., and Bar-Shalom, Y. (2015). Systematic approach to IMM mixing for unequal dimension states. *IEEE Transactions on Aerospace and Electronic Systems*, 51(4), 2975–2986.
- Gupta, N. and Hauser, R. (2007). Kalman filtering with equality and inequality state constraints. arXiv preprint arXiv:0709.2791.
- Gustafsson, F. and Isaksson, A.J. (1996). Best choice of coordinate system for tracking coordinated turns. In *Proceedings of the IEEE Conference on Decision and Control*, volume 3, 2355–3592. IEEE.
- Hendriks, F., Tideman, M., Pelders, R., Bours, R., and Liu, X. (2010). Development tools for active safety systems: Prescan and vehil. In *Proceedings of 2010 IEEE International Conference on Vehicular Electronics and Safety*, 54–58. IEEE.
- Jia, C. and Evans, B.L. (2017). Online motion smoothing for video stabilization via constrained multiple-model estimation. *EURASIP Journal on Image and Video Processing*, 2017(1), 25.
- Kale, J.G., Subramaniam, A., Karle, M.L., and Karle, U.S. (2019). Simulation based design and development of test track for adas functions validation and verification with respect to indian scenario. Technical report, SAE Technical Paper.
- Kuutti, S., Fallah, S., Katsaros, K., Dianati, M., McCullough, F., and Mouzakitis, A. (2018). A survey of the state-of-the-art localization techniques and their potentials for autonomous vehicle applications. *IEEE Internet of Things Journal*, 5(2), 829–846.
- Li, X.R. and Jilkov, V.P. (2005). Survey of maneuvering target tracking. part v. multiple-model methods. *IEEE Transactions on Aerospace and Electronic Systems*, 41(4), 1255–1321.
- Ormsby, C.D., Raquet, J.F., and Maybeck, P.S. (2006). A new generalized residual multiple model adaptive estimator of parameters and states. *Mathematical and computer modelling*, 43(9-10), 1092–1113.
- Rosique, F., Navarro, P.J., Fernández, C., and Padilla, A. (2019). A systematic review of perception system and simulators for autonomous vehicles research. *Sensors*, 19(3), 648.
- Schubert, R., Richter, E., and Wanielik, G. (2008). Comparison and evaluation of advanced motion models for vehicle tracking. In *2008 11th international conference on information fusion*, 1–6. IEEE.
- Seifzadeh, S., Khaleghi, B., and Karray, F. (2013). Soft-data-constrained multi-model particle filter for agile target tracking. In *Proceedings of the 16th International Conference on Information Fusion*, 564–571. IEEE.

Simon, D. (2010). Kalman filtering with state constraints: a survey of linear and nonlinear algorithms. *IET Control Theory & Applications*, 4(8), 1303–1318.

Simon, D. and Chia, T.L. (2002). Kalman filtering with state equality constraints. *IEEE transactions on Aerospace and Electronic Systems*, 38(1), 128–136.

Szalay, Z., Tettamanti, T., Esztergár-Kiss, D., Varga, I., and Bartolini, C. (2018). Development of a test track for driverless cars: vehicle design, track configuration, and liability considerations. *Periodica Polytechnica Transportation Engineering*, 46(1), 29–35.

Teixeira, B.O., Chandrasekar, J., Torres, L.A., Aguirre, L.A., and Bernstein, D.S. (2009). State estimation for linear and nonlinear equality-constrained systems. *International Journal of Control*, 82(5), 918–936.

Teixeira, B.O.S., Chandrasekar, J., Torres, L.A., Aguirre, L., and Bernstein, D.S. (2007). State estimation for equality-constrained linear systems. In *2007 46th IEEE Conference on Decision and Control*, 6220–6225. IEEE.

Tin Leung, K., Whidborne, J.F., Purdy, D., and Dunoyer, A. (2011). A review of ground vehicle dynamic state estimations utilising gps/ins. *Vehicle System Dynamics*, 49(1-2), 29–58.

Tořó, O., Bécsi, T., Aradi, S., and Gáspár, P. (2019). Sensitivity and performance evaluation of multiple-model state estimation algorithms for autonomous vehicle functions. *Journal of Advanced Transportation*, 2019.

Van Brummelen, J., O'Brien, M., Gruyer, D., and Najjaran, H. (2018). Autonomous vehicle perception: The technology of today and tomorrow. *Transportation research part C: emerging technologies*, 89, 384–406.

Watanabe, K. and Tzafestas, S.G. (1993). Generalized pseudo-bayes estimation and detection for abruptly changing systems. *Journal of Intelligent and Robotic Systems*, 7(1), 95–112.

Zhu, H., Yuen, K.V., Mihaylova, L., and Leung, H. (2017). Overview of environment perception for intelligent vehicles. *IEEE Transactions on Intelligent Transportation Systems*, 18(10), 2584–2601.