

Bernoulli-szűrőn alapuló közúti objektumdetektálás teljesítményének vizsgálata

Törő Olivér*, Bécsi Tamás*, Aradi Szilárd*

*Budapesti Műszaki és Gazdaságtudományi Egyetem, Közlekedés- és Járműirányítási Tanszék
(e-mail: toro.oliver@mail.bme.hu, becsi.tamas@mail.bme.hu, aradi.szilard@mail.bme.hu).

Kivonat: A cikk egy multiszenzoros objektum detektáló és követő algoritmus közúti közlekedésben nyújtott teljesítményének és skálázódásának vizsgálatát mutatja be. A választott becslő eljárás a Bernoulli részecske szűrő, mely ideális kooperatív környezetérzékelés során szerzett adatok feldolgozására. A beérkező mérések száma és az objektum láthatósága egyaránt változó, amely körülményt az algoritmus természetes módon tud kezelni. A vizsgálat során szimulált radar mérések távolság, irányszög és sebesség értékeket szolgáltatnak. A szűrő algoritmus teljesítményét négy irányból vizsgáltuk: felhasznált részecskék száma, időlépés, szenzor és rendszermodell zaj nagysága. Az alkalmazott zajmodellek a szenzorok minőségét és a rendszerre vonatkozó tudásunk hiányosságát jellemzik, így a szűrő robusztusságát vizsgálhatjuk a változtatásukkal. A felhasznált részecskék száma és a az időlépés az algoritmus számításigényét és a becslési hibát befolyásolják. Minden paraméter konfigurációban 50 futtatás képezte egy statisztikailag kiértékelhető sokaság alapját.

1. BEVEZETÉS

A közúti járművekben megfigyelhető egyre növekvő automatizáció következtében az utasok biztonsága és a vezetők kényelme egyaránt növekszik. A kooperatív környezetérzékelés és forgalmi szituáció értelmezés a jövő autonóm járműiben működő vezetőtámogató rendszerek alapvető funkciói, melyekhez szükséges információ minősége és mennyisége új adatfúziós eljárások fejlesztését kívánja meg.

Autonóm funkciókkal ellátott közúti járműveknek megbízhatóan kell a környezetet érzékelniük. A fejlett vezető támogató rendszerek (ADAS), legyen az akadály elkerülés vagy sávváltás asszisztens, elengedhetetlen követelménye az aktuális forgalmi szituáció pontos értelmezése. Olyan magas szintű feladatok ellátásához, mint az intelligens forgalom menedzsment vagy az utazási idő becslés floating car data (FCD) segítségével (Rahmani et al., 2014), az információt minden lehetséges járműből és út menti egységből ki kell nyerni (Danczyk et al., 2016). Az információ fúzió nagy és heterogén rendszerekben, ahol a kommunikáció V2V vagy V2I formájában valósul meg, egy nehéz feladat (Bachmann et al., 2013). A Bayes formalizmusban dolgozó szűrő eljárások igen népszerűek (El Faouzi et al., 2011), azonban a Kálmán-szűrő és változatai nem mindig ideálisak, különösen, ha változó a megfigyelt objektumok és a beérkező mérések mennyisége.

A vezetőtámogató rendszereket valós időben futtatható algoritmusokkal kell megvalósítani. Szinte minden valós rendszer komplex és nemlineáris, így közelítéseket kell alkalmazni, amelyek a probléma dimenzióját vagy a kapott eredmények pontosságát csökkentik. Nantes et al. (2015) inkrementális kiterjesztett Kálmán-szűrővel készített közúti forgalmat becslő eljárást, ahol heterogén, nem szinkronizált

szenzor adatokat dolgozott fel. Wright & Horowitz (2016) egy Rao-Blackwellizált részecske szűrőt implementált autópályás forgalomsűrűség becslésére.

Jelen munka egy valószínűségi halmazokat használó szűrő eljárást mutat be és elemzi közúti forgalomban nyújtott teljesítményét. A vizsgálatokhoz fejlesztett program a járművek és szenzorjaik működését szimulálja egy autópályás forgalmi szituációban. Mivel a szűrő eljárás egyenleteinek nincsenek zárt megoldásai, numerikus közelítések szükségesek. Ebben a munkában a közelítések részecske szűrő formájában valósultak meg, az eljárás skálázódásának vizsgálatát, mint célt szem előtt tartva.

A cikk felépítése a következő. A 2. fejezet bemutatja az elméleti alapokat és a modellt. A szimuláció paramétereit a 3. fejezet tartalmazza. A 4. fejezet bemutatja a szimuláció eredményeit és kiértékelésüket. Végül az összegzés és kitekintés az 5. fejezetben található.

2. SZŪRŐ ELJÁRÁS ÉS RENDSZERMODELL

2.1 Elméleti háttér

Ebben a munkában a becslendő mennyiség egy állapotvektor \mathbf{x} , amely egy véletlen vektor változó, és a megfigyelt objektum sebesség és helykoordinátáit tartalmazza. A hozzá tartozó valószínűségi sűrűségfüggvény $p(\mathbf{x})$, amelyre a Bayes formalizmus keretében egy adott k időpontban az alábbi formában tudunk becslést adni (Khaleghi et al., 2013):

$$p(\mathbf{x}_k | \mathbf{z}_{1:k}) = \frac{g(\mathbf{z}_k | \mathbf{x}_k) \int \pi(\mathbf{x}_k | \mathbf{x}_{k-1}) p(\mathbf{x}_{k-1} | \mathbf{z}_{1:k-1}) d\mathbf{x}_{k-1}}{p(\mathbf{z}_k | \mathbf{z}_{1:k-1})} \quad (1)$$

A jelölések magyarázata a következő. A mérési vektorokat a k időpontig $\mathbf{z}_{1:k}$ tartalmazza. Az állapotátmenet sűrűségfüggvényét π jelöli és a rendszermodell tesztelési meg. A szenzormodell a g likelihoodba van ágyazva.

Vektorok helyett halmazokat is használhatunk állapotok leírására. Egy véges valószínűségi halmaz egy olyan valószínűségi változó, amely véges halmazokat vesz fel értékül. A valószínűségi halmazok elemei állapotvektorok, kardinálisuk pedig véletlen szám, így alkalmasak változó számosságú objektum leírására. A jól ismert Bayes keretrendszerben való alkalmazásukhoz szükséges matematikai formalizmust (FISST, finite set statistics) Mahler (2001) dolgozta ki.

Egy véges X valószínűségi halmaz FISST sűrűségfüggvénye n kardinálissal:

$$f(X) = n! \rho(n) p_n(x_1, \dots, x_n) \quad (2)$$

ahol $\rho(n)$ a kardinális diszkrét eloszlása, p_n az x_1, \dots, x_n állapotvektorok együttes, szimmetrikus eloszlása.

Számos valószínűségi halmaz áll rendelkezésünkre rendszerek leírására. Ebben a munkában a Bernoulli-halmazt használjuk, amely üres vagy egy elemű halmaz, tehát egy objektum leírására szolgál. Két mennyiség szükséges a definiálásához: q annak a valószínűsége, hogy létezik az objektum és $s(x)$ hagyományos sűrűségfüggvény, amely az objektum állapotát írja le. A Bernoulli szűrő egy egzakt Bayes típusú szűrő, amely q és $s(x)$ mennyiségeket viszi tovább a rekurzió során.

2.2 Szűrő egyenletek

A követett objektum feltűnését és eltűnését a születés (p_b) és túlélés (p_s) valószínűségekkel vesszük figyelembe. Ha az objektum nem megfigyelhető, akkor p_b valószínűséggel tűnik elő. Hasonlóan, ha az objektum megfigyelhető, akkor $1 - p_s$ valószínűséggel tűnik el. A születő objektum a $b(x)$ sűrűségfüggvénynek megfelelő sokaságból vesz fel értéket. Amennyiben a detektorok fals méréseket regisztrálnak, ezek a mérések a $c(z)$ eloszlásból vehetnek fel értékeket λ kardinálissal. A felsorolt eloszlások és valószínűségek segítségével a szűrő egyenletek felírhatók. A részletes levezetés megtalálható Ristic (2013) könyvében.

A k időponthoz tartozó predikciós lépésben az objektum létezési valószínűsége:

$$q_{(k|k-1)} = p_b(1 - q_{k-1}) + p_s q_{k-1} \quad (3)$$

állapotának sűrűségfüggvénye:

$$s_{(k|k-1)}(x) = \frac{p_b(1 - q_{k-1})b_{(k|k-1)}(x)}{q_{(k|k-1)}} + \frac{p_s q_{k-1} \int \pi'_{(k|k-1)}(x|x') s_{k-1}(x') dx}{q_{(k|k-1)}} \quad (4)$$

A korrekciós lépés során az alábbi egyenleteket kell kiértékelni:

$$q_k = \frac{1 - \Delta_k}{1 - q_{(k|k-1)} \Delta_k} q_{(k|k-1)} \quad (5)$$

$$s_k(x) = \frac{1 - p_d(x) + p_d(x) \sum_{z \in Z_k} \frac{g_k(z|x)}{\lambda c(z)}}{1 - \Delta_k} s_{(k|k-1)}(x) \quad (6)$$

ahol

$$\Delta_k = \int p_d(x) s_{(k|k-1)}(x) dx - \sum_{z \in Z_k} \frac{\int p_d(x) g_k(z|x) s_{(k|k-1)}(x) dx}{\lambda c(z)} \quad (7)$$

2.3 Részecske szűrős megvalósítás

A Bernoulli szűrőt részecske szűrőként kerül implementálásra. A (4),(6-7) egyenletekben szereplő sűrűségfüggvényeket részecskékkel, azaz súlyozott mintákkal közelítjük. Kétféle részecske szükséges: normál, az objektum követéséhez ((4) jobb oldalának első tagja) és születő, a feltűnés modellezéséhez ((4) jobb oldalának második tagja).

A részecske szűrők működése szerint a predikciós lépésben a részecskéket egy előzetes eloszlásból kell sorsolni, majd fontossági súlyok szerint újra mintavételezni. Amennyiben az előzetes eloszlás az állapotátmenet sűrűségfüggvénye, úgy a fontossági súlyok megegyeznek a likelihooddal. Az így működő eljárást nevezik bootstrap particle filter-nek.

A születő részecskék számára az előzetes eloszlás a előző lépésben beérkezett mérések segítségével áll elő. A méréseknek megfelelő állapotvektort az állapotátmeneti sűrűségfüggvény szerint transzformáljuk a Chapman-Kolmogorov egyenleten keresztül (Ristic & Arulampalam, 2012). Ez a módszer biztosítja, hogy az állapottér azon részalmazából sorsolunk születő részecskéket, amelyek nagy valószínűség szerint tartalmazzák az objektumot.

Jelen cikk a szűrő eljárás skálázódását vizsgálja, így a véletlen hatásokat lehetőség szerint kiküszöböltük. A futási sebességet és becslési pontosságot közvetlenül a beérkező mérések száma befolyásolja a legnagyobb mértékben. A születő részecskék száma arányos a mérések számával (lásd (6) és (7) egyenletek szummái). Részecskéket generálni és likelihoodokat számolni hozzájuk számításgényes művelet, így a mérések számának véletlen ingadozását ki kell küszöbölni, hogy az algoritmus skálázódását elemezhesük.

Ezt úgy érjük el, hogy a szimulációt megfelelően preparáljuk: a követendő objektum végig a látómezőben marad, így a mérések száma állandó, maximális és az algoritmus a lehető legnagyobb számítási teljesítményt igényli. Születő részecskék használata ilyen felállásban elvileg nélkülözhető lenne, azonban a skálázódási vizsgálatok miatt mindenképpen szükség van rájuk.

2.4 Modell bemutatása

A síkban mozgó objektum állapotát leíró vektor négy elemű, két koordinátát és két sebesség értéket tartalmaz: $\mathbf{x} = (x, \dot{x}, y, \dot{y})^T$. Az állapot fejlődését egy diszkrét, lineáris rendszer jellemzi, amit additív normal eloszlású zaj terhel:

$$(8)$$

T_s időlépéssel a rendszer mátrix az alábbi alakot ölti:

$$(9)$$

ami egy konstans sebességű modellnek felel meg. A zaj kovariancia mátrixa:

$$\Sigma_m = \begin{bmatrix} \Xi & \mathbf{0}_{2 \times 2} \\ \mathbf{0}_{2 \times 2} & \Xi \end{bmatrix}, \Xi = k_m \begin{bmatrix} T_s^3 & T_s^2 \\ 3 & 2 \\ T_s^2 & T_s \end{bmatrix} \quad (10)$$

ahol k_m a zaj intenzitását takarja hossz²/idő³ egységekben. A szenzor modell formálisan a

$$(11)$$

egyenlet írja le. A nemlineáris h függvény adja a mért mennyiségeket: távolság (d), irányszög (b) és sebesség (v). Ezek a megfigyelőhöz relatív mennyiségek, számításuk a szokásos euklideszi távolságok alapján történik. A sebesség a megfigyelő látóirányára eső vetületet takarja. A méréseket egymástól függetlennek tekintjük, így a w normál zaj kovariancia mátrixa diagonális:

$$\Sigma_s = k_s \begin{bmatrix} \sigma_d^2 & 0 & 0 \\ 0 & \sigma_b^2 & 0 \\ 0 & 0 & \sigma_v^2 \end{bmatrix} \quad (12)$$

A dimenziótlan km mennyiség a zaj intenzitását skálázza. A fenti modellek használatával megalkotható az állapot átmeneti sűrűségfüggvény és a likelihood (Mahler, 2013):

$$\pi(\mathbf{x}_k | \mathbf{x}_{k-1}) = N(\mathbf{x}_k; \mathbf{F}\mathbf{x}_{k-1}, \Sigma_m) \quad (13)$$

$$\mathbf{g}(z_k | \mathbf{x}_k) = N(z_k; \mathbf{h}(\mathbf{x}_k), \Sigma_s) \quad (14)$$

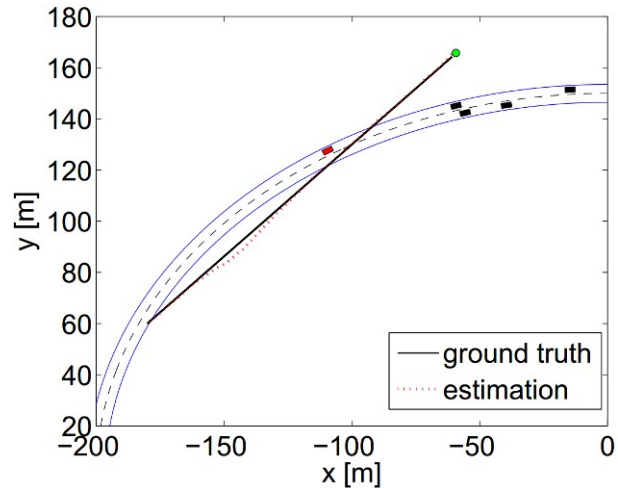
3. SZIMULÁCIÓS KÖRNYEZET

Egy MATLAB-ban készült szimulált autópályás forgalmi szituáció segítségével értékeltük a szűrőeljárást (1. ábra).

A kiértékeléshez több paraméterkészletet hoztunk létre, de minden egyes futtatás esetén csak egy paramétert változtattunk meg. A becslési hiba a következőképpen van meghatározva. Minden időpontban kiszámoljuk a becslt és valós pozíció euklideszi távolságát, majd a futtatás végén az adatsorra szórást számolunk (σ_{err}). A futtatások paraméterkészletét az I. táblázat foglalja össze. A mérésenként alkalmazott születő és normál részecskék számát együtt változtattuk, így összesen $N = 6N_p$ részecskét használtunk. A szimuláció időtartama $T = 15$ s, ami $N_p = T/T_s$ lépést tesz ki. A radar mérésekhez

I. Táblázat Szimuláció paraméterkészlete

Paraméter	Jelölés	Érték					
Időlépés	T_s	1	0,5	0,1	0,05	0,01	0,005
Részecskék	N_p	1	10	102	103	104	-
Szenzor zaj	k_s	0,5	1	1,5	2	2,5	3
Rendszerzaj	k_m	0,5	1	1,5	2	2,5	3



1. ábra Szimulációs környezet: öt jármű detektál és követ egy objektumot. A valós trajektóriát fekete, a becsltet vörös jelzi

és a rendszermodellhez tartozó zaj intenzitását az I. táblázat alsó két sorában található együtthatók skálázzák. A mérésekre rakódó zajok szórásai: $\sigma_d = 0.2$ m, $\sigma_b = 0.3$ °, $\sigma_v = 0.6$ m/s. Az alapértelmezett paraméter értékek: $T_s = 0.1$ s, $N_p = 100$, . Minden paraméter kombinációra egy 50 futtatásból álló sorozat készült, hogy statisztikailag kiértékelhető eredményeket kapjunk. A kapott σ_{err} értékeket valószínűségi változónak tekintettük és normál eloszlást illesztettünk rájuk. A kapott eloszlások maximum helyét (σ_{err}) fogadtuk el a szűrő teljesítményeként egy adott beállítással.

4. EREDMÉNYEK

A szűrő teljesítményének kiértékelése két aspektusból történt. A szenzor és rendszermodell zaj a detektor minőségét illetve a rendszerről rendelkezésünkre álló tudást jellemzi. A zajok intenzitásának változtatásával a szűrő robusztusságát tudjuk vizsgálni, míg az eljárás számításiigénye az alkalmazott időlépéstől és a részecskék számától függ.

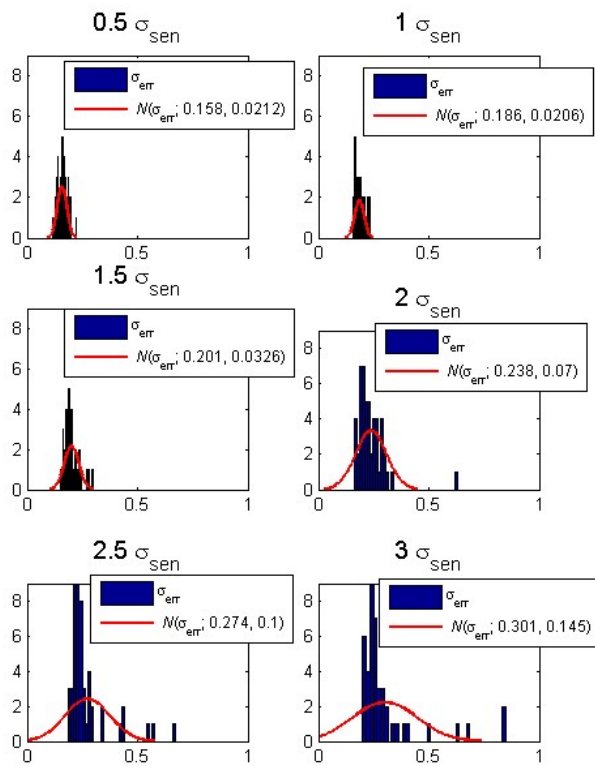
4.1 Megjelenítés

Minden futtatás sorozathoz egy hisztogram készült, 50 osztással. A hisztogramok a szűrő becslési hibáinak tapasztalati eloszlást szemléltetik. Az illesztett haranggörbék és az illesztési paraméterek szintén fel vannak tüntetve az ábrákon.


A szűrő teljesítményének skálázódását egy adott paraméter tekintetében a haranggörbék maximumának és az adott paraméter értékének grafikonja szemlélteti.

4.1.1 Szenzor zaj

A szenorzaj intenzitásának változtatása egyértelmű hatást gyakorol a szűrő teljesítményére. A k_s együtttható növelése a haranggörbét laposabbá teszi és a maximumát jobbra tolja el (2. ábra). Az összefüggés lineáris jellegű (3. ábra).



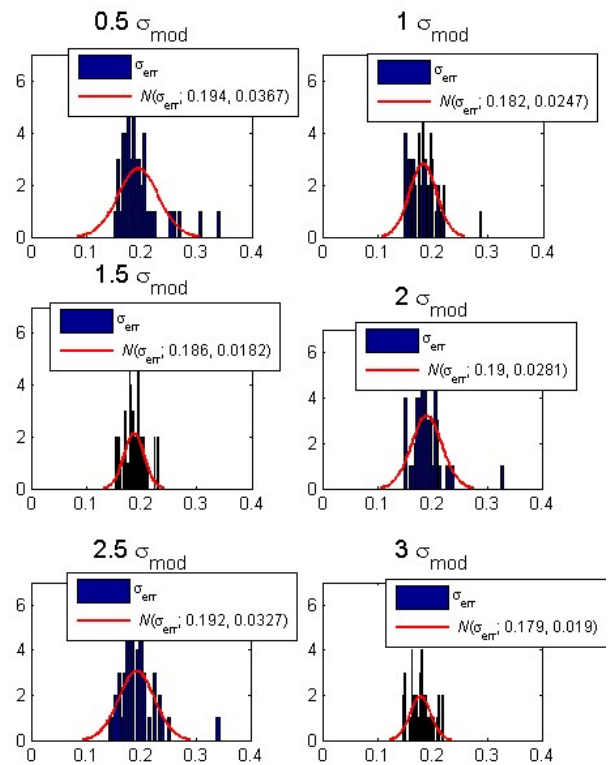
2. ábra A szűrő teljesítménye a szenorzaj függvényében




3. ábra Skálázódás a szenorzaj tekintetében

4.1.2 Rendszer zaj


A rendszerzaj változtatása elhanyagolható hatást gyakorol a teljesítményre. A várható érték és a szórás is közel konstans marad a vizsgált intervallumban.



4. ábra A szűrő teljesítménye a szenorzaj függvényében



5. ábra Skálázódás a rendszerzaj tekintetében




7. ábra Skálázódás a részecskeszám tekintetében

4.1.3 Részecskék

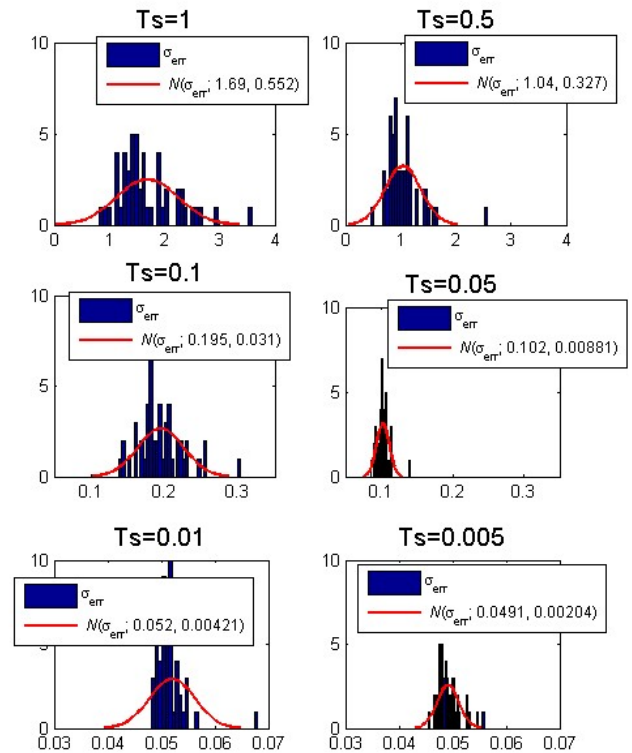
A részecskeszám hatása a teljesítményre egyértelmű. A részecskeszám csökkenésével σ_{err} várható értéke és szórása egyaránt csökken (6. ábra). Egy optimális érték jelölhető ki $N_p = 100$ körül, ahol a részecskeszám növelésének hatása elenyészik (7. ábra). A futásidőre szintén jelentős hatást gyakorol a részecskeszám, ezt a következő fejezetben elemezzük.

4.1.4 Időlépés


Az időlépés változtatása erőteljes hatást gyakorol a szűrő teljesítményére (8. ábra) és a futásidőre is. Közúti közlekedési



6. ábra Részecskeszám hatása a teljesítményre



8. ábra Időlépés hatása a teljesítményre




9. ábra Skálázódás az időlépés tekintetében

situációkat szem előtt tartva, ahol a sebességek 100m/s alattiak a 0,01s-os lépték alá nem szükséges menni (9. ábra).

4.2 Futásidő

A jelenlegi implementáció keretei között az algoritmus valós idejű futásra képes 42000 részecskével $T_s=0,1s$ mellett.



10. ábra Futásidő a részecskeszám függvényében

6. ÖSSZEFOGLALÁS

Fejlett vezetőtámogató rendszerek számára, ahol a valós idejű futás nélkülözhetetlen, az algoritmusok számításiigénye és skálázódása lényeges tényező. A részecskeszűrő megoldások szűrő eljárások olyan megvalósításai, amelyek futásidőben optimalizálhatók. A részecskék száma illetve particionálása tetszőlegesen változtatható, hogy az eljárás alkalmazkodjon az aktuális forgalmi szituációhoz, megkívánt pontossághoz és a feldolgozandó adatok mennyiségéhez. Ebben a munkában a Bernoulli részecske szűrő teljesítményének és skálázódásának vizsgálatát végeztük el. Négy szempont szerint analizáltuk a becslő eljárást. A felhasznált részecskék száma és időlépés a skálázódásról ad információt, míg az alkalmazott szenzor és rendszermodell zaj segítségével a szűrő robusztusságát vizsgálhatjuk. Míg a rendszerzaj elhanyagolható mértékben befolyásolja a szűrő teljesítményét, addig a szenzorzaj hatása jó közelítéssel lineáris. Az algoritmus sebességét illetően elmondhatjuk, hogy 42000 részecske és $T_s = 0,1$ mellett valós idejű

futtatás lehetséges. A mintavételezés egy eloszlásból esetenként igen számításiigényes lehet, így hatékony megvalósításokra van szükség. Jelen implementációban az állapotátmenet sűrűségfüggvénye és a likelihood egy többváltozós normál eloszlásként reprezentált, melyekből a mintavételezés mátrix invertálást tesz szükségessé. Ez a számításiigényes művelet gyorsítható a kovariancia mátrix blokkdiagonális szerkezetének kihasználásával.

IRODALOMJEGYZÉK

- Bachmann, C., Abdulhai, B., Roord, M. J. & Moshiri, B., (2013). A comparative assessment of multi-sensor data fusion techniques for freeway traffic speed estimation using microsimulation modeling. *Transportation Research Part C*, **Volume 26**, pp. 33-48.
- Bar-Shalom, Y., Li, X. R. & Kirubarajan, T., (2001). *Estimation with applications to tracking and navigation: theory algorithms and software*. Canada: John Wiley & Sons.
- Danczyk, A., Di, X. & Liu, H. X., (2016). A probabilistic optimization model for allocating freeway sensors. *Transportation Research Part C*, **Volume 67**, pp. 378-398.
- El Faouzi, N.-E., Leung, H. & Kurian, A., (2011). Data fusion in intelligent transportation systems: Progress and challenges-A survey. *Information Fusion*, **12**(1), pp. 4-10.
- Khaleghi, B., Khamis, A., Karray, F. O. & Razavi, S. N., (2013). Multisensor data fusion: A review of the state-of-the-art. *Information Fusion*, **14**(1), pp. 28-44.
- Mahler, R., (2001). Engineering statistics for multi-object tracking. *Proceedings of 2001 IEEE Workshop on Multi-Object*, pp. 53-60.
- Mahler, R., (2007). *Statistical Multisource-Multitarget Information Fusion*. Boston, MA: Artech House.
- Mahler, R., (2013). Statistics 102 for Multisource-Multitarget Detection and Tracking. *IEEE Journal of Selected Topics in Signal Processing*, **7**(3), pp. 376-389.
- Nantes, A. et al., (2015). Real-time traffic state estimation in urban corridors from heterogeneous data. *Transp. Res. Part C Emerg. Technol*, **Volume 66**, pp. 99-118.
- Rahmani, M., Jenelius, E. & Koutsopoulos, H. N., (2014). Floating car and camera data fusion for non-parametric route travel time estimation. *17th International IEEE Conference on Intelligent Transportation Systems (ITSC)*, pp. 1286-1291.
- Ristic, B., (2013). *Particle filters for random set models*. New York: Springer-Verlag.
- Ristic, B., Vo, B.-T. & Vo, B.-N., (2013). A Tutorial on Bernoulli Filters: Theory, Implementation and Applications. *IEEE Transactions on Signal Processing*, **61**(13), pp. 3406-3430.
- Wright, M. & Horowitz, R., (2016). Fusing Loop and GPS Probe Measurements to Estimate Freeway Density. *IEEE Transactions on Intelligent Transportation Systems*, **17**(12), pp. 3577-3590.