

Метода сједињавања честица трага и могућности примене за праћење циљева

Рад по позиву

Звонко Радосављевић
Војнотехнички институт
Београд, Република Србија
zvonko.radosavljevic@gmail.com

Бранко Ковачевић
Електротехнички факултет Универзитета у Београду
Београд, Република Србија
kovacevic_b@etf.rs

Сажетак— Без обзира на физикалну основу сензора, савремене методе за праћење циљева, свакодневно су експанзији. Због тога је важно повећање ефикасности и смањење рачунарских ресурса алгоритма. Када у естимирани регион објекта праћења падне ново мерење, појављује се конфликт о могућим стањима циља, које треба да разреши алгоритми за асоцијацију података. У раду је предложена нова, секвенцијална метода асоцијације података заснована на познатом 'честичном' (*Particle Filter-PF*) филтру, названа филтар за сједињавање честица трага (*Integrated Particle Filter-IPF*). За разлику од познатих метода за праћење циљева, које се не баве мерењем квалитета трага, рекурзивни *IPF* алгоритам, у свакој итерацији (периоди) израчунава вероватноћу постојања трага, која се користи у процесу одлуке о квалитету трага и праћењу и постојању циља. Низ рачунарских експеримената са сложеним сценаријима праћења једног или више објеката и у окружењу густог Поасоновог клатера је потврдио квалитет и робустност предложене методе. Ова чињеница отвара многе примене предложеног алгоритма у разним технолошким сферама, почев од војних система за вођење и управљање ракета и беспилотних летелица, тако и цивилних примена као што су контрола ваздушног саобраћаја, медицина, роботика, интернет претраживања, итд.

Кључне речи: *particle filter*, секвенцијалне методе, вероватноћа егзистенције трага.

I. УВОД

Постојање циљева и естимација трајекторије циљева одређују се на основу мерења (опсервације) од сензора, без обзира од ког извора потичу та мерења. Свако пристигло мерење може да потиче од лажних или клатер (*clutter*) мерења од шума, или од циља. Сваки циљ се детектује (генерише мерења) у сваком скену (временском интервалу) са неком вероватноћом детекције. Траг се иницијализује коришћењем мерења са сензора, тако што оба, стварни трагови (који прате циљ) и лажни трагови (који не прате циљ) симултано настају. Одбацивања лажних трагова (*False Track Discrimination-FTD*) је процедура која препознаје и гаси лажне трагове и препознаје и потврђује тачне трагове. Корисник претпоставља да је сваки потврђен траг у ствари тачан. Потребно је спровести мерење квалитета трага, како би се постигла успешна *FTD*

процедура. Алгоритми *MHT* (*Multiple Hypothesis Testing*), *IPDA* (*Integrated Probabilistic Data Association*) и *ITS* (*Integrated Track Splitting*) засновани су на изведеним претпоставкама линеарне порпагације трајекторије и линеарног модела мерења. Неке нелинеарности се могу свести конверзијом мерења [1] или заменом стандарног Калмановог филтра (*Kalman Filter-KF*) проширеним Калмановим филтром (*Extended Kalman Filter-EKF*) [2] или необрађеним Калмановим филтром (*Unscented Kalman Filter-UKF*) [3] унутар *MHT* [4], [5], *IPDA* и *ITS* [6] алгоритма. Нелинеарна мерења као што су "праћење углавном координатама" (*Bearings Only*), "праћење временске разлике пристизања" (*Time Difference of Arrival-TDOA*), "праћење узимањем података од групе антена (*Multistatic antenna*), имају веродостојност мерења која немају Гаусову расподелу [7], [8].

Овај приступ се користи у *ITS* апроксимацији комбиновањем Гаусовске веродостојности мерења (*Gaussian Mixture Measurement likelihood approximation ITS-GMM-ITS*) [9], који апроксимира веродостојност мерења и функцију густине вероватноће – *pdf* (*probability density function*) постериорног стања трајекторије помоћу комбинације Гаусових расподела. Апроксимација *GMM-ITS* се користи у веома сложеним ситуацијама праћења, где *EKF* и *UKF* не могу да постигну адекватне перформансе [10]–[12]. Филтер са "честицама" (*PF*) [13] одабира нелинеарну (не-Гаусову) *pdf* стања скупом случајних честица. Они се прилагођавају нелинеарним мерењима и нелинеарној пропагацији стања. Филтер са честицама може се успешно применити у веома широком дијапазону примена. Негативна страна овог филтра је често потреба за великим бројем честица за примену у комплексним вишедимензионим сценаријима кретања, који типично резултују у око два реда величине већим амплитудама рачунарске сложености у односу на *GMM-ITS* [14];

У ситуацијама где се могу применити оба алгоритма. Међутим, убрзани развој технологије може овај проблем учинити мање важним. Филтер са честицама за праћење у окружењу клатера предложен је у литератури [15]. Међутим, у овим радовима, пажња је посвећена углавном естимацији трајекторије, без израчунавања и мерења квалитета трага и њихових укључивања у процес *FTD*.

Шта више, сви они подразумевају униформну расподелу клатера, која се ретко јавља у реалним ситуацијама.

У раду је предложено решење у облику сједињавања честица (*Integrated Particle Filter-IPF*) за праћење циља у окружењу клатера. Свака *pdf* трајекторије трага је репрезентована преко раздвојеног скупа честица, и вероватноћа постојања циља се сједињује у јединствено стање трага [16]. Вероватноћа постојања циља је мерење квалитета трага, и корисно је за *FTD*. Стандардни *IPF* је предвиђен за праћење једног циља, али се лако може уредити за праћење више циљева (трагова).

II. ОПИС ПРОБЛЕМА

У теорији праћења, обично се користи термин "систем за праћење циља" Овај термин није у потпуности прикладан, с обзиром да је циљ увек непознат за систем. Тачније, овај систем обично формира траг чији је репрезент скуп сукцесивних мерења од сензора, за који се претпоставља да потиче од циља. Претпоставимо да суперскипт τ означава траг. Траг се иницијализује и ажурира коришћењем случајних мерења, чије су порекло и настанак непознати, тако да сваки траг може да буде стварни траг (који прати циљ) или лажни траг. Постојање циља τ у временском тренутку k , \mathcal{X}_k^τ је случајан процес, за који се претпоставља да пропагира као Марковљев процес [17] дефинисан помоћу:

$$p_{11} = P\{\mathcal{X}_k^\tau | \mathcal{X}_{k-1}^\tau\}, P\{\mathcal{X}_k^\tau | \bar{\mathcal{X}}_{k-1}^\tau\} = 0 \quad (1)$$

где је $\bar{\mathcal{X}}_k^\tau$ комплемент \mathcal{X}_k^τ . Поред тога, претпоставимо да сваки циљ прати модел константан модел трајекторије између временских интервала, и може да се пребаци у било који други модел у било којем временском интервалу [18].

$$x_k^\tau = g(x_{k-1}^\tau, \sigma_k^\tau, \nu_k^\tau) \quad (2)$$

где је $g(\cdot)$ потенцијално нелинеарна функција $\sigma_k^\tau \in [1, M]$, редни број модела пропације трајекторије и ν_k^τ је шум процеса са познатом *pdf* $p_\nu(\nu_k^\tau; \sigma_k^\tau)$. Модел линеарне пропације стања трага је специјалан случај, и дат је помоћу израза:

$$x_k^\tau = F_{\sigma_k^\tau} x_{k-1}^\tau + \nu_k^\tau(\sigma_k^\tau) \quad (3)$$

Где је адитивни шум процеса $\nu_k^\tau(\sigma_k^\tau)$ -бела Гаусова секвенца шума нулте средње вредности и коваријансе $Q_{\sigma_k^\tau}$ претпоставимо да је модел пропације трајекторије Марковљев процес са [19]:

$$P\{\sigma_k^\tau = \sigma_2 | \sigma_{k-1}^\tau = \sigma_1\} = \pi_{\sigma_1, \sigma_2} \quad (4)$$

A. Модел мерења која потичу од циља

Сваки циљ τ у сваком временском интервалу k , генерише једно мерење z_k^τ са вероватноћом детекције $p_D(x_k^\tau)$ који зависи од стања трајекторије циља. Једначина мерења у општем случају дата је изразом [20]:

$$z_k^\tau = h(x_k^\tau, \omega_k^\tau) \quad (5)$$

где је $h(\cdot)$ потенцијално нелинеарна функција и ω_k^τ означава шум мерења, за који се претпоставља да је бели шум. Линеарни модел мерења је специјалан случај и дат је помоћу израза[21]:

$$z_k^\tau = Hx_k^\tau + \omega_k^\tau \quad (6)$$

где адитивни шум мерења ω_k^τ је секвенца белог Гаусовог шума нулте средње вредности са коваријационом матрицом R , некорелисан са секвенцом V_k^τ . Коришћењем *pdf* функције $p_\omega(\omega_k^\tau)$ и израза (5) може се израчунати условна *pdf*, односно $p_{z|x_k^\tau}(z_k^\tau | x_k^\tau)$ [22].

B. Модел мерења која потичу од клатера

Клатер мерења у сваком скену прате Поасоновоу расподелу, која се може описати нехомогеном расподелом клатер мерења. Овде се претпоставља да је расподела клатер мерења $\rho(z)$ у тачки u у простору мерења, позната или естимирана [23]. У сваком временском интервалу k случајни скуп мерења z_k је расположив, без претходне индикације од чега потиче мерење (од циља или од клатера). Означимо са $z_{k,j}$ j -то мерење из z_k и нека је $\rho_{k,j} \equiv \rho(z_{k,j})$. Означимо даље, са Z^k секвенцу скупова мерења закључно са z_k , укључујући и z_k , односно $Z^k = \{z_k, Z^{k-1}\}$ [24].

III. АЛГОРИТАМ СЈЕДИЊАВАЊА ЧЕСТИЦА ТРАГА

У општем случају, сваки траг τ се састоји од догађаја да циљ постоји \mathcal{X}_k^τ , стање трајекторије циља x_k^τ , и модела стања трајекторије σ_k^τ . Праћење циља пропагира и ажурира *pdf* стања за сваки траг понаособ:

$$p[\mathcal{X}_k^\tau, x_k^\tau, \sigma_k^\tau | Z^l] = P\{\mathcal{X}_k^\tau | Z^l\} p[x_k^\tau, \sigma_k^\tau | \mathcal{X}_k^\tau, Z^l] \quad (7)$$

где је $l = k-1$ за пропацију и $l = k$ за ажурирање стања. Трајекторија и модел стања израчунавају се условно на постојање циља. Стање трага се развија између два скена као Марковљев процес и ажурира се у сваком скену са

новим мерењима. Такође, из разлога једноставности, може се увести смена вероватноће егзистенције трага

$$\bar{\psi}_k^r = P\{\mathcal{X}_k^r | Z^{k-1}\} \cdot \hat{\psi}_k^r = P\{\mathcal{X}_k^r | Z^{k-1}\} \quad (8)$$

A. Кораци алгоритма сједињавања честица

Алгоритам сједињавања честица трага је итеративни алгоритам, који се састоји од следећих пет корака:

- Корак предикције трага,
- Корак селекције мерења,
- Корак асоцијације података и ажурирање тежина честица трага,
- Поновно одабирање честица (*resampling*),
- Израчунавање излазних стања и коваријасе.

B. Иницијализација функције густине вероватноће трага

Претпоставимо да је у $k - 1$ -ом и k -том скену стигао скуп мерења са сензора, описан као: $Z^{k-1} = \{z_{k-1,j}\}_{j=1}^{m_{k-1}}$, $Z^k = \{z_{k,i}\}_{i=1}^{m_k}$, респективно и нека је

$$w_{k-1}^p = p(x_k^p | Z^{k-1}) \quad (9)$$

$$w_k^p = p(x_k^p | Z^k), p = 1, \dots, N_p \quad (9a)$$

скуп тежина честица пре и после корака корекције, еспективно. Даље, нека је са R_k дата матрица шума мерења као:

$$R_k = \begin{bmatrix} \sigma_x^2 & 0 \\ 0 & \sigma_y^2 \end{bmatrix} \quad (10)$$

Означимо са \mathcal{X}_k догађај да циљ постоји у скену k . Мерење које потиче од циља који постоји и који је детектабилан је дато са вероватноћом детекције P_D . Мерење од циља у скену k може се израчунати помоћу израза:

$$y_k = Hx_k + \omega_k \quad (10)$$

где је са y_k означена пројекција мерења од циља у простору обсервације, H је позната матрица мерења, ω_k означава одбирок белог Гаусовог шума средње вредности 0 са познатом коваријансом шума R , који је некорелисан са секвенцом шума процеса трајекторије кретања циља V_k . Користи се модел пропагације трајекторије циља са константном брзином без маневра (*straight line CV model*). Иницијализација трага може се извршити углавном на два начина. То је:

- Иницијализација трага помоћу сваком опсервацијом (*One Point Initializing*)
- Иницијализација трага помоћу два сукцесивна мерења (*Two Point Differencing Initializing*)

A) Иницијализација трага сваком опсервацијом

Методологија иницијализације трага сваком пристиглом опсервацијом са сензора заснована је на позицији добијеној од сваког мерења, тако да нема информација о брзини циља. Овде се углавном користи претпоставка о постојању униформне расподеле брзине. Униформна расподела се замењује Гаусовом функцијом расподеле, датом преко следеће једначине [1]:

$$\hat{x}_{k-1}^{(1)} = \begin{bmatrix} z_{k-1,j} \\ 0_{n,1} \end{bmatrix} \quad (11)$$

где је $z_{k-1,j}$ позиција мерења и $0_{n,1}$ - $n \times 1$ нула матрица ($n=2$) и индекс ⁽¹⁾ означава алгоритам иницијализације у једној тачки (*One Point Initialization Algorithm*). Свако мерење иницијализује скуп од N_p честица (*particle*) са нормалном расподелом са средњом вредношћу $\hat{x}_{k-1}^{(1)}$ и коваријансом $P_{(1|1)}$, која је дата изразом:

$$x_{k-1}^p = N(\hat{x}_{k-1}^{(1)}, P_{(1|1)}) \quad (12)$$

повлачећи одбирок из нормалне расподеле, где је коваријациона матрица дата као:

$$P_{(1|1)} = \begin{bmatrix} R_k & 0_{n \times n} \\ 0_{n \times n} & \frac{v_{\max}^2}{3} I \end{bmatrix} \quad (13)$$

где је v_{\max} максимална брзина кретања циља, I јединична матрица ($n \times n$). Стање трага после корака пропагације може се симболички написати као:

$$\{w_{k-1}^p, x_k^p\}_{p=1}^{N_p} \Rightarrow p(x_k | \mathcal{X}_k, z_{k-1,j}) \quad (14)$$

Априорна функција густине вероватноће *pdf* у тренутку k је тежинска сума средње вредности честица која је дата као (применом теореме тоталне вероватноће):

$$p_{k,i} = p(z_{k,i} | \mathcal{X}_k, Z^{k-1}) = \sum_p w_{k-1}^p p(z_{k,i} | x_k^p) \\ = \sum_p w_{k-1}^p N(z_{k,i}; Hx_{k,i}^p, R_k) \quad (15)$$

где је:

$$p_{k,i}^p = p(z_{k,i} | x_k^p) = N(z_{k,i}; Hx_{k,i}^p, R_k) \quad (16)$$

функција густине вероватноће *pdf* мерења дата за пар мерење $z_{k,i}$ -честица p . Функција густине вероватноће транзиције стања трајекторије је дата помоћу једначине

$$p(x_k | z_{k,i}) = \sum_p w_{k-1}^p \cdot \delta(\hat{x}_k - x_k^p) \quad (17)$$

Корак корекције *pdf* трајекторије трага је дат као скуп честица $\{w_k^p\}$ Бајесовом теоремом као:

$$\begin{aligned} w_k^p &= p(x_k^p | \mathcal{X}_k, z_k, Z^{k-1}) \\ &= \frac{p(z_k | x_k^p, Z^{k-1}) p(x_k^p | x_{k-1}^p, Z^{k-1})}{p(z_k | Z^{k-1})} \end{aligned} \quad (18)$$

Модел вероватноће трајекторије циља од мерења $z_{k,i}$ дат је као:

$$\beta_{k,i} = P\{\mathcal{X}_{k,i} | \mathcal{X}_k, Z^k\}_{i=0}^{m_k} \quad (19)$$

док се функција густине вероватноће трајекторије (*pdf*) може изразити преко једначине :

$$\begin{aligned} p(x_k^p | \mathcal{X}_k, z_k, Z^{k-1}) &= \sum_{i=0}^{m_k} p(x_k^p, \mathcal{X}_{k,i} | \mathcal{X}_k, z_k, Z^{k-1}) \\ &= \sum_{i=0}^{m_k} P\{\mathcal{X}_{k,i} | \mathcal{X}_k, Z^k\} p(x_k^p | \mathcal{X}_{k,i}, \mathcal{X}_k, z_k, Z^{k-1}) \\ &= \beta_{k,0} p(x_k^p | \mathcal{X}_k, Z^{k-1}) + \sum_{i=1}^{m_k} \beta_{k,i} p(x_k^p | \mathcal{X}_{k,i}, z_{k,i}, Z^{k-1}) \\ &= \beta_{k,0} p(x_k^p | \mathcal{X}_k, Z^{k-1}) + \\ &+ \sum_{i=1}^{m_k} \beta_{k,i} \frac{p(z_{k,i} | x_k^p, \mathcal{X}_k, Z^{k-1}) p(x_k^p | \mathcal{X}_{k,i}, Z^{k-1})}{p(z_{k,i} | \mathcal{X}_k, Z^{k-1})} \\ &= p(x_k^p | \mathcal{X}_k, Z^{k-1}) \\ &\left[\beta_{k,0} + \sum_{i=1}^{m_k} \beta_{k,i} \frac{p(z_{k,i} | x_k^p, \mathcal{X}_k, Z^{k-1})}{p(z_{k,i} | \mathcal{X}_k, Z^{k-1})} \right] \end{aligned} \quad (20)$$

или кратко:

$$w_k^p = w_{k-1}^p \left[\beta_{k,0} + \sum_{i=1}^{m_k} \beta_{k,i} \frac{P_{k,i}^p}{P_{k,i}} \right] \quad (21)$$

Б) Иницијализација помоћу два сукцесива мерења

Иницијализација помоћу два сукцесивна мерења, остварује се разликом стања сукцесивних опсервација (*Two point differencing initializing*) и користи мерења која се налазе у 'прозору' трага из два сукцесивна сцена за иницијализацију трага. Ова процедура се понавља за сва мерења из сцена $k-1$. Посматрајмо тако мерење $z_{k-1,j}$.

Нови траг се иницијализује помоћу мерења $z_{k-1,j}$ и сваког

селектованог мерења $z_{k,i}$, формирајући Гаусову функцију густине вероватноће са средњом вредношћу датом као:

$$\hat{x}_k^{(2)} = \begin{bmatrix} z_{k,i} \\ \frac{z_{k,i} - z_{k-1,j}}{\Delta T_k} \end{bmatrix} \quad (22)$$

где је ΔT_k једна периода окретања антене радара. С обзиром да не постоји априорно познавање брзине циља, она се може моделовати униформне расподеле априорне *pdf* жмерења у тренутку k . иницијализује се N_p честица средње вредности $\hat{x}_k^{(2)}$, симетричне и полуконичне коваријационе матрице $P_{(2|2)}$ (пропагација шума честице), преко нормалне расподеле више променљивих (Слика 3.1):

$$x_k^p = N[\hat{x}_k^{(2)}; P_{(2|2)}] \quad (23)$$

где се иницијална коваријанса грешке стања израчунава под поретпоставком да нема шума процеса:

$$P_{(2|2)} = \begin{bmatrix} R_k & R_k / T \\ R_k / T & 2R_k / T^2 \end{bmatrix} \quad (24)$$

Тежине честица се иницијализују на вредност. Иницијализација разликом две тачке даје стање трага после корака пропагације

$$\{w_{k-1}^p, x_{k-1}^p\}_{p=1}^{N_p} \Rightarrow p(x_k | \mathcal{X}_k, z_{k,i}, z_{k-1,j}) \quad (25)$$

Апостериорна *pdf* у тренутку k , под условом да циљ постоји \mathcal{X}_k , је тежинска сума честица дата (помоћу теореме тоталне вероватноће) као:

$$\begin{aligned} p_{k,i} &= p(z_{k,i} | \mathcal{X}_k, Z^{k-1}) = \sum_p w_{k-1}^p p(z_{k,i} | x_k^p) \\ &= \sum_p w_{k-1}^p N(z_{k,i}; Hx_k^p, R_k) \end{aligned} \quad (26)$$

Функција густине вероватноће транзиционог модела стања је дата као:

$$p(x_k | z_{k,i}) = \sum_p w_{k-1}^p \cdot \delta(\hat{x}_k - x_k^p) \quad (27)$$

Број честица N_p је константан током целе симулације. Функција густине вероватноће трајекторије циља после корака корекције:

$$\begin{aligned} w_k^p &= p(x_k^p | \mathcal{X}_k, z_k, Z^{k-1}) \\ &= \frac{p(z_k | x_k^p, Z^{k-1}) p(x_k^p | x_{k-1}^p, Z^{k-1})}{p(z_k | Z^{k-1})} \end{aligned} \quad (28)$$

У истом тренутку, вероватноћа модела трајекторије је дата као:

$$\beta_{k,i} = P\{\mathcal{X}_{k,i} | \mathcal{X}_k, z_{k,i}, Z^k\}_{i=0}^{m_k} \quad (29)$$

Функција густине вероватоће трајекторије после корака корекције дата је као:

$$\begin{aligned} p(x_k^p | \mathcal{X}_k, z_k, Z^{k-1}) &= \sum_{i=0}^{m_k} p(x_k^p, \mathcal{X}_{k,i} | \mathcal{X}_k, z_{k,i}, Z^{k-1}) = \\ &= \beta_{k,0} p(x_k^p | \mathcal{X}_k, Z^{k-1}) + \sum_{i=1}^{m_k} \beta_{k,i} p(x_k^p | \mathcal{X}_{k,i}, Z^{k-1}) \quad (30) \\ &= p(x_k^p | \mathcal{X}_k, Z^{k-1}) \left[\beta_{k,0} + \sum_{i=1}^{m_k} \beta_{k,i} \frac{p(z_{k,i} | x_k^p, \mathcal{X}_{k,i}, Z^{k-1})}{p(z_{k,i} | \mathcal{X}_k, Z^{k-1})} \right] \end{aligned}$$

После комбиновања овог израза са претходним, он добија следећу форму:

$$w_k^p = w_{k-1}^p \left[\beta_{k,0} + \sum_{j=1}^{m_k} \beta_{k,j} \frac{p_{k,j}^p}{p_{k,j}} \right] \quad (31)$$

IV. АЛГОРИТАМ СЈЕДИЊАВАЊА ЧЕСТИЦА ЗА ПРАЋЕЊЕ ЈЕДНОГ ЦИЉА (IPF-SINGLE TARGET TRACKING)

Алгоритам сједињавања честица трага је итеративни алгоритам, који се у основи састоји од пет корака. На крају сваке операције, формира се вектор стања трајекторију трага. У овом поглављу, биће дате формуле за праћење једног циља. На самом почетку. Потребно је увести неколико претпоставки. То су:

- Нове честице могу настати могу настати искључиво опоступком поновног одабирања (*resampling*);
- "Јаке" честице се мултиплицирају а "слабе" потискују,
- Мерења се користе за кориговање тежина честица и вероватноће постојања циља

Приметимо да се $N_{k-1} = N_k = N$ број честица из $(k-1)^{th}$ не мења од скена до скена. Скуп $\{x_{k-1}^i, w_{k-1}^i\}$, $i = 1, \dots, N_{k-1}$ - репрезентује честице из $(k-1)^{th}$ скена преко средње вредности и тежине. Нека је m_k - број мерења пристиглих у k^{th} скену. $N_p = N$ - број честица после ре- одабирања. Нека је $p_D(x_k) = P_D$ вероватноћа детекције циља. У принципу функција стања трајекторије. У принципу, претпоставка за праћење једног циља:

$$\tilde{P}_D = \sum_i w_{k-1}^i p_D(x_k^i) = P_D \sum_i w_{k-1}^i = P_D \quad (32)$$

A. Корак предикције:

На самом почетку вероватноћа егзистенције циља може се наћи као:

$$\Psi_{k|k-1} = \Delta_{11} \cdot \Psi_{k-1|k-1} \quad (33)$$

Док је средња вредност честица дата је као:

$$x_k^i = f(x_{k-1}^i, v_k^i) = Fx_{k-1}^i + v_k^i \quad (34)$$

Пропагација шума честице је аусова расподела средње вредности '0' и коваријансе Q :

$$v_k^i \approx N(0, Q) \quad (35)$$

B. Корак селекције мерења

У овом тренутку пристижу мерења са сензора, датим као скуп $Z_k = \{z_k^1, \dots, z_k^{m_k}\}$, За разлику од стандардног ITS алгоритма, у IPF-у нема гејга трага а самим тим ни селекције мерења. У овом тренутку израчунава се веродостојност мерења. Први корак је израчунавање естимације мерења \hat{y}_k^i , помоћу израза:

$$\hat{y}_k^i = Hx_k^i \quad (36)$$

На основу естимације i -те естимације мерења и j -тог мерења, може се израчунати статистичка дистанца као:

$$d_{ij}^2 = (z_{k,j} - \hat{y}_k^i)^T (R_k)^{-1} (z_{k,j} - \hat{y}_k^i), \quad j = 1, \dots, m_k \quad (37)$$

помоћу које се може изрчунати функција густине вероватноће, помоћу итраза:

$$p_{k,j}^i = \frac{1}{\sqrt{\det(2\pi R_k)}} \exp[-0.5 \cdot d_{ij}^2] \quad (38)$$

C. Корак асоцијације података и ажурирање тежине честица трага

Сада се може наћи веродостојност сваког мерења мерења, преко суме:

$$p_{k,j} = \sum_i w_{k-1}^i \cdot p_{k,j}^i \quad (39)$$

На почетку корака корекције ,Однос веродостојности на нивоу трага:

$$\Lambda_k = 1 - P_D + P_D \sum_j \frac{p_{k,j}}{p_{k,j}} \quad (40)$$

Док се корекције, релативних вероватноћа компоненти трага израчунава за случај да нема мерења од трага и за случај да су стигла мерења од сензора, помоћу познатог израза:

$$\beta_{k,j} = \frac{1}{\Lambda_k} \begin{cases} 1 - P_D, & j = 0 \\ P_D \frac{P_{k,j}}{\rho_{k,j}}, & j > 0 \end{cases} \quad (41)$$

Кориговане тежине честица за корекцију трајекторије циља може се израчунати преко израза:

$$w_k^i = w_{k-1}^i \cdot \left(\beta_{k,0} + \sum_{j=1}^{M_k} \beta_{k,j} \frac{P_{k,j}^i}{P_{k,j}} \right) \quad (42)$$

На крају једног корака рекурзије и на крају корака корекције, може се израчунати вероватноћа постојања трага, као:

$$\psi_{k|k} = \frac{\Lambda_k \psi_{k|k-1}}{1 - (1 - \Lambda_k) \psi_{k|k-1}} \quad (43)$$

D. Поновно одабирање (resampling)

На крају једне рекурзије итеративног *IPF* алгоритма, који је у ствари корак 'честичног' филтра *PF* (*Particle Filter*), налази се поновно одабирања (*resampling*). Почетно стање (улаз у корак поновно одабирања) је пар који карактерише сваку честицу, средња вредност x_k^i и тежина w_k^i , односно $\{x_k^i, w_{k,i}\}$. Процес ре-одабирања, формира исти број излазних честица, тако што мултиплицира јаке а уклања слабе честице, што се може означити као:

$$\{x_k^i, w_k^i\} \Rightarrow \left\{ x_k^l, w_k^l = \frac{S_w}{N_p} = \frac{1}{N} \right\}, l=1,2,\dots,N \quad (44)$$

где је са S_w дата сума свих улазних тежина.

$$S_w = \sum_{i=1}^{N_{k-1}} w_k^i = 1 \quad (45)$$

Новe тежине имају униформну расподелу:

$$u_1 = U \left[0, \frac{1}{N} \right] \quad (46)$$

Итеративно, израчунавају се пролазне тежине u_l на основу израза,

$$u_l = u_1^l + (l-1) \frac{1}{N}, i_c = i_{c-1} + w_k^i \quad i=1,\dots,N \quad (47)$$

тако да се на излазу из ре-одабирања добија нови пар средња вредност-тежина као:

$$\{x_k^l = x_k^i, w_k^l = 1/N\}, \text{ while } u_l > i_c, l=1,\dots,N \quad (48)$$

E. Израчунавање излаза

Стање трага, вектор стања и коваријанса грешке на излазу из *IPF* филтра $\{\hat{x}_k, P_k\}$, може се израчунати као сума производа тежина сваке честице трага и средње вредности те честице трага, добијених из корака ре-одабирања, помоћу израза:

$$\hat{x}_{k|k} = \sum_{l=1}^{N_p} w_k^l x_k^l \quad (49)$$

Док се коваријанса трага може израчунати као:

$$P_k = \left(\sum_{l=1}^{N_p} w_k^l \cdot x_k^l \cdot x_k^{lT} \right) - \hat{x}_k \cdot \hat{x}_k^T \quad (50)$$

V. РЕЗУЛТАТИ ЕКСПЕРИМЕНАТА ЗА СИМУЛАЦИОНИ СЦЕНАРИО СА ПЕТНАЕСТ ЦИЉЕВА

За симулациону студију је одабрана симулација кретања у дводимензионалном простору димензија 1000 m дужине и 1000 ширине [22]. У овом сценарију нема посебног клатера, већ близина суседних циљева и неодређеност дефинисана случајним Гаусовим шумом, додатом на брзину, пре првог скена, чини сценарио веома сложеним, нарочито при великом броју циљева који се крећу ка центру. У близини центра, у који циљеви долазе скоро истовремено, густина "клатера" је веома велика. У сваком симулационом пролазу, циљеви полазе из истог иницијалног стања. Кретање циља је моделовано у правоуглом координатном систему (*Cartesian*) као и састоји се од позиције и брзине, свака са по две координате са транзиционом матрицом F датом помоћу израза (7.3).

Шум процеса V_k представља бели Гаусов шум средње вредности нула и са познатом коваријансом $E[V_k V_j^T] = Q$, док је $q=0.75$. Алгоритми користе Марковљев ланац првог реда са параметрима $\Delta_{11} = 0.98$, $\Delta_{21} = 0$. Траг се иницијализује у сваком скену коришћењем мерења из садашњег и претходног скена.

Претпоставимо да се циљ креће праволинијски без убрзања, и да су транзициона матрица и матрица мерења дате као:


$$F = \begin{bmatrix} 1 & T & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & T \\ 0 & 0 & 0 & 1 \end{bmatrix}, H = \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 \end{bmatrix} \quad (51)$$

респективно, док су матрица мерења, и адитивни шум мерења :

$$R_k = \begin{bmatrix} \sigma_x^2 & 0 \\ 0 & \sigma_y^2 \end{bmatrix}, \Gamma = \begin{bmatrix} T^2/2 & 0 \\ T & 0 \\ 0 & T^2/2 \\ 0 & T \end{bmatrix}, \mathbf{v} = \begin{bmatrix} \nu_1 \\ \nu_2 \end{bmatrix} \quad (52)$$

респективно. Петнаест (15) блиских циљева се креће праволијски без убрзања у простору [1000m 1000m], брзином од 25 [m/s]. Укупно трајање једног пролаза експеримента је 40 скенова а експеримент се понавља у 500 Монте Карло пролаза коришћењем случајних генератора са Гаусовим белим шумом. Сваки циљ се креће равномерном брзином ка центру круга, у који би требало да стигне у 20-ом скену, након чега настављају униформним кретањем за још 20 скенова.

Случајна (*random*) компонента се додаје на вектор брзине сваког циља, тако да у скену 20, варијанса растојања између сваког циља и центра круга треба да буде двострука грешка шума мерења коваријансе матрица сензора. Почетне позиције циљева су одвојене за 10° .



Слика 1 Симулациони сценарио кретања петнаест циљева

У циљу одређивања ефикасности предложене методе, спроведени су упоредни експерименти алгоритма сједињавања честица трага у односу са познатим методама праћења циљева које имају квалитативно мерење трага, односно стандардни *ITS* и *LM ITS* алгоритми. Тестиран је *ITS* алгоритам у најбољим радним карактеристикама, т.ј. коришћењем Сингеровог меморијског филтра са највише девет меморијских секвенци ($N=1$ и $N=9$) Марковљевог ланца, као и побољшани *LM ITS*. Резултати су приказани у облику параметарских дијаграма стварних потврђених трагова, лажних потврђених трагова и дијаграма средње квадратне грешке праћења по позицији. Ако је M укупан број Монте Карло пролаза, тада се средња квадратна грешка може израчунати помоћу израза:


$$RMSE_k = \sqrt{\frac{1}{M} \sum_{i=1}^M \{[\hat{\xi}_{i,k} - \xi_k]^2 + [\hat{\zeta}_{i,k} - \zeta_k]^2\}} \quad (53)$$

а $\hat{\xi}_k$, ξ_k и $\hat{\zeta}_k$, ζ_k естимирани и стварне Картезијан координате циља, респективно.


Поред тога, дата је табела способности алгоритма да задржи циљ после укрштања са другим циљевима. Статистика задржавања циља је добијена пор претпоставком да су идентификовани стварни потврђени трагови (ако их има) сваког од циљева на након 14 скена. Ови идентификација се поново проверава у скену 38, и следеће статистике су акумулиране за сваки експеримент:

- **nCas**: укупан број случајева да потврђени траг прати циљ у 14., скену,
- **nOK**: проценат потврђених трагова који и даље прате циљ у скену 38.
- **nSw**: проценат трагова који прате други циљ у скену 38.
- **nLo**: проценат трагова који не прате ни један циљ у скену 38,
- **nMer**: проценат трагова који су изгубљени сједињавањем са другим траговима убројаним у nCases између скена 14. и 38.

Посебно, у последњој колони табеле, дата су упоредна процесорска времена (*CPU time*) потребна да се изврши једна итерација појединих наведених алгоритама.



Слика 2. Дијаграм стварних потврђених трагова ITS- параметар дубина Сингер меморије



Слика 3. Упоредни дијаграм средње квадратне грешке позиције ITS- LMITS параметар- дубина Сингерове меморије

Упоредна анализа са становишта потврђивања трагова показала је оправданост примене предложеног алгоритма сједињавања честица трага, изузев у домену рачунарских ресурса, где је предложена метода заостаје за ред величине. Ипак, имајући у виду појаву нових процесорских јединица са више од четири језгра, ова разлика се може драстично смањити. То су показали нови експерименти на рачунарским платформама које користе **i9** процесорску генерацију.

Табела 1. Статистика задржавања циља- петнаест циљева

<i>N</i>	<i>nCas</i>	<i>nOK</i>	<i>nSw</i>	<i>nLo</i>	<i>nMer</i>	<i>CPU</i>	
		[%]	[%]	[%]	[%]	[sec]	
-	IPF	5542	56.4	15.7	29.6	9,3	128.2
1	<i>ITS</i>	5884	15.07	16.41	68.52	3153	1.82
	<i>LMITS</i>	5850	40.10	23.53	36.37	1768	2.13
3	<i>ITS</i>	5886	18.58	17.56	43.86	2939	3.52
	<i>LMITS</i>	5854	48.10	27.05	24.85	1181	4.12
5	<i>ITS</i>	5886	22.56	18.41	58.03	2478	4.41
	<i>LMITS</i>	5851	40.97	30.08	28.95	887	4.99
7	<i>ITS</i>	5886	25.11	18.79	56.1	2622	4.89
	<i>LMITS</i>	5851	50.81	31.87	17.32	819	5.48
9	<i>ITS</i>	5886	26.13	20.09	53.88	2551	5.17
	<i>LMITS</i>	5851	51.37	32.09	16.54	781	5.81

VI. ПРИМЕНА АЛГОРИТМА СЈЕДИЊАВАЊА ЧЕСТИЦА ТРАГА

Примери примене алгоритама за праћења у савременом свету су веома бројни, како у војним тако и у цивилним сврхама. Подела се може извршити по типу сензора (радари, акустични сензори, видео камере, итд), области (мобилна телефонија, мреже бежичних сензора, роботика, интернет претраживачи, видео надзор, медицина, итд). Један од одлучујућих фактора у избору алгоритама јесте њихова сложеност и осетљивост на клатер и друге врсте сметњи.

ЗАХВАЛНИЦА

Рад је настао током сарадње аутора са Ханџанг Универзитетом (Ансан, Република Кореја). Заснован је на теоретским и практичним решењима насталих у току истраживања које је предложио проф. Дарко Мушички у сарадњи са истражуваким тимом који је предводио проф. Таек Лиул Сонг.

REFERENCES

[1] Kalman R.: A New Approach to Linear Filtering and Prediction Problems, Transaction on ASME - Journal of Basic Engineering, Series 82D, pp. 35-45, Mar. 1960.

[2] Singer R.: Estimate Optimal Tracking Filter Performance for Manned Maneuvering Targets, IEEE Trans. Aerospace and Electronic Systems, Vol. 6, No.4, 1970, July, 473-483.

[3] S. Blackman, Multiple-target tracking with radar applications, Artech House, 1986.

[4] D. B. Reid, An Algorithm for Tracking Multiple Targets', IEEE Transactions on Automatic Control, Vol AC-24, pp. 843-854, December 1979

[5] Y. Bar Shalom and T.E.Fortman, "Tracking and Data Association", Academic Press, San Diego, 1988.

[6] S. Challa, R. Evans, M. Morelande and D. Mušicki: "Fundamentals of Object Tracking", Cambridge University Press 2011.

[7] Bar-Shalom, Y., and Tse, E. "Tracking in a cluttered environment with probabilistic data association". Automatica, 11 (Sept. 1975), 451—460.

[8] Bar-Shalom, Y., Chang, K., and Blom, H. Multitarget Multisensor Tracking, vol. 1. Boston: Artech House, 1990, 25—42.

[9] Houles, A., and Bar-Shalom, Y. Multisensor tracking of a maneuvering target in clutter. IEEE Transactions on Aerospace and Electronic Systems, 25, 2 (Mar. 1989), 176—189.

[10] D. Musicki, and R. Evans, Integrated probabilistic data association - finite resolution, Automatica, Vol. 31, pp 559-570, April 1995.

[11] Mušicki, D., and Evans, R. Clutter map information for data association and track initialization. IEEE Transactions on Aerospace and Electronic Systems, 40, 2 (Apr. 2004), 387—398.

[12] Mušicki, D., and Morelande, M., Gate volume estimation for target tracking. In 7th International Conference on Information Fusion, Fusion 2004, Stockholm, Sweden, June 28—July 1, 2004.

[13] U. Orguner and F. Gustafsson, Target Tracking With Particle Filters Under Signal Propagation Delays, 2011, IEEE Transactions On Signal Processing, (59), 6, 2485-2495

[14] Mušicki, D., Track score and target existence. In 9th International Conference on Information Fusion, Fusion 2006, Florence, Italy, July 2006.

[15] Ristic, B., and Aralumpalam, S., Multitarget mixture reduction algorithms with incorporated target recursions. In SPIE: Signal and Data Processing of Small Targets, vol. 4048, Orlando, FL, Apr. 2000, 366—377.

[16] Z. Radosavljević, D. Mušicki, B. Kovačević, W. C. Kim, and T. L. Song, Integrated particle filter for target tracking, in 13th International Conference on Electronics, Information and Communication, ICEIC 2014, Kota Kinabalu, Malaysia, January 15-18 2014.

[17] Mušicki, D., La Scala, B., and Evans, R., The integrated track splitting filter—Efficient multi-scan single target tracking in clutter, IEEE Transactions on Aerospace and Electronic Systems, 43, 4 (Oct. 2007), 1409—1425.

[18] Colegrove, S. B., and Ayliffe, J., An extension of probabilistic data association to include track initiation and termination. In Proceedings of the 20th IREE International Convention, Melbourne, Australia, 1985, 853—856.

[19] Davey, S. J., Gray, D. A., and Colegrove, S. B., A Markov model for initiating tracks with probabilistic multi-hypothesis tracker. In 5th International Conference on Information Fusion, Fusion 2002, Annapolis, MD, July 2002, 735—742.

[20] Houles, A., and Bar-Shalom, Y., Multisensor tracking of a maneuvering target in clutter. IEEE Transactions on Aerospace and Electronic Systems, 25, 2 (Mar. 1989), 176—189.

[21] Mušicki, D., Evans, R., and La Scala, B., Integrated track splitting suite of target tracking filters. In 6th International Conference on Information Fusion, Fusion 2003, Cairns, Queensland, Australia, July 2003.

[22] Mušicki, D., and La Scala, B., Multi-target tracking in clutter without measurement assignment. IEEE Transactions on Aerospace and Electronic Systems, 44, 3 (July 2008), 877—896.

[23] Mušicki, D., Mallick, M., La Scala, B., Strange, S., and Evans, R., LMITS as an efficient MHT. In SPIE: Signal and Data Processing of Small Targets, vol. 5913, San Diego, CA, Aug. 1—4, 2005, OV1—OV12.

[24] Ross, S., Stochastic Processes. New York: Wiley, 1983.

[25] T. L. Song, D. Mušicki, D. S. Kim and Z. Radosavljević, Gaussian mixtures in multi-target tracking: a look at Gaussian mixture probability hypothesis density and integrated track splitting, IET proceedings on Radar Sonar and Navigation, Vol 6, no 5, pp. 359-364, June 2012.

[26] Z. Radosavljević, D. Mušicki, Limits of target tracking in heavy clutter, ASIA-Pacific International Conference of Synthetic Aperture Radar APSAR 2011, Seoul, Republic of Korea., 2011.

ABSTRACT

Regardless of the physical basis of the sensor, the modern method for targets tracking is an ever-expanding one.

Therefore, it is important to increase the efficiency and reduce the computer resources of the algorithm. When a new measurement falls in the estimated region of the monitoring object, a conflict arises about the possible state of the target, which should resolve algorithms for data association. A new, sequential data association method based on a known particle filter (PF) filter, called the Integrated Particle Filter-IPF, is proposed. In contrast to known methods for tracking targets that are not measuring quality traces, the recursive IPF algorithm, in each iteration (periods), calculates the probability of the existence of a tracks, which is used in the decision process on the quality of the trace and the tracking and the existence of the target. A series of computer experiments with

complex scenarios of monitoring one or multi targets and in the environment of a thick Poason's cluster has confirmed the quality and robustness of the proposed method. This fact opens many applications of the proposed algorithm in various technologies, ranging from military systems for command and control of missiles and unmanned aircraft, as well as to civilian applications such as air traffic control, medicine, robotics, search engines optimizations, internet, etc.

**THE METHOD OF INTEGRATED PARTICLE FILTER
AND APPLICATIONS CAPABILITY FOR TARGETS
TRACKING**

Zvonko Radosavljevic, Branko Kovacevic