

## تصميم مرشح جسيمات هجين عائم متكيف من نوع (Unscented)

وجدان معاني تক্রوري<sup>1\*</sup> هيام خدام<sup>2</sup>

<sup>1\*</sup> . طالبة ماجستير ، جامعة دمشق ، كلية الهندسة الميكانيكية والكهربائية - قسم هندسة الحواسيب

والأتمتة، [wijdan.takrouri@damascusuniversity.edu.sy](mailto:wijdan.takrouri@damascusuniversity.edu.sy)

<sup>2</sup> عضو هيئة تدريسية دكتورة، جامعة دمشق، كلية الهندسة الميكانيكية والكهربائية - الاختصاص تحكّم رقمي

- قسم هندسة الحواسيب والأتمتة ، [h.khaddam@damascusuniversity.edu.sy](mailto:h.khaddam@damascusuniversity.edu.sy)

### الملخص:

مع التطورات السريعة في تكنولوجيا الكمبيوتر، أصبح مرشح الجسيمات PF مرغوباً أكثر في تطبيقات الملاحة فهو قادر على التعامل مع الأنظمة اللاخطية وضجيج القياسات غير الغاوسي. ومع ذلك، لا يزال العبء الحسابي الكبير له يحد من استخدامه على نطاق واسع. على عكس مرشح كالمان من نوع Unscented رغم أنه غير مكلف حسابياً ويعطي دقة تقدير عالية لحالة النظام إلا أنه يفرض قيود غاوسية على ضجيج القياس وحساس لأي تغيرات مفاجئة في ديناميكية النظام. تتمثل إحدى طرق تقليل العبء الحسابي لمرشح PF بدون أي تدهور لدقة تقدير النظام في دمجها مع المرشحات الأخرى، في هذا البحث، تم اقتراح خوارزمية جديدة لمرشح هجين تجمع ما بين خوارزمية مطورة لمرشح الجسيمات PF وخوارزمية تكيفية مطورة لمرشح UKF، بحيث يتم الاستفادة من مزايا كلا الخوارزميتين والحصول على مرشح متين ضد الضجيج غير الغاوسي والمتغير مع الزمن وقادر على التكيف مع الأنظمة اللاخطية والديناميكية وبأقل كلفة حسابية. أظهرت النتائج أن الخوارزمية المقترحة نجحت بالتكيف مع ديناميكية النظام اللاخطي والتعامل مع الضجيج غير الغاوسي للقياسات وذلك بتقديم دقة عالية ومثانة أثناء تقدير حالة النظام.

**الكلمات المفتاحية:** تتبّع مناورة هدف، مرشح الجسيمات (PF)، مرشح كالمان من نوع Unscented (UKF)، طريقة تعظيم التوقعات (EM)، طريقة تصنيف نموذج الانحدار العائم (FCRM)، نموذج T-S العائم، الترشيح التكيفي، خطط البيانات، الترشيح اللاخطي، الضجيج الإحصائي المجهول.

تاريخ الإيداع: 2023/5/31

تاريخ القبول: 2023/8/3



حقوق النشر: جامعة دمشق -  
سورية، يحتفظ المؤلفون بحقوق  
النشر بموجب CC BY-NC-SA

# Designing an Adaptive Fuzzy Hybrid Unscented Particle Filter

Wijdan Maani Takroui<sup>\*1</sup> . Hiyam Khaddam<sup>2</sup>

<sup>\*1</sup>. MSC student - Department of Automation and Computers Engineering - The Faculty of Mechanical and Electrical Engineering – Dr, Damascus University - [wijdan.takroui@damascusuniversity.edu.sy](mailto:wijdan.takroui@damascusuniversity.edu.sy)

<sup>2</sup>. A member of the faculty teaching staff – major: Digital Control - Department of Automation and Computers Engineering - The Faculty of Mechanical and Electrical Engineering - Damascus University - [h.khaddam@damascusuniversity.edu.sy](mailto:h.khaddam@damascusuniversity.edu.sy)

## Abstract:

With the rapid developments in computer technology, the particle filter is becoming more desirable in navigation applications as it is able to handle nonlinear systems and non-Gaussian measurement noise. However, its computational cost still limits its widespread use. Unlike the Unscented Kalman filter, although it is computationally inexpensive and gives a high accuracy of displaying the system's state, it imposes Gaussian restrictions on measurement noise. It is also sensitive to any sudden change in the system dynamics. One way to reduce the computational cost of PF without any degradation of the system estimation accuracy is to combine the particle filter with other filters. In this paper, a new algorithm of an adaptive fuzzy hybrid filter between a developed particle filter and an adaptive UKF is proposed, in which the advantages of both algorithms are taken, and obtaining a robust filter against non-Gaussian, time-varying noise, and being adaptive for dynamic nonlinear systems with the lowest computational cost. The results showed that the proposed algorithm succeeded in adapting to the dynamics of the nonlinear system and dealing with the non-Gaussian noise of the measurements by providing high accuracy and robustness while estimating the state of the system.

**Keywords:** Maneuvering Target Tracking, Particle Filter (PF), Unscented Kalman Filter (UKF), Expectation Maximization (EM), Fuzzy C – Regressive Model (FCRM), T-S Fuzzy Model, Adaptive Filtering, Data Fusion, Non-Linear Filtering, Unknown Noise Statistics.

Received: 31/5/2023

Accepted: 3/8/2023



**Copyright:** Damascus University- Syria, The authors retain the copyright under a **CC BY- NC-SA**

**المقدمة:**

تتطلب أنظمة المناورة والتتبع، مثل تلك الموجودة في الملاحة الجوية والبرية، تقنيات ترشيح دقيقة لمعالجة قياسات أجهزة الاستشعار وتحسين أدائها. ومع ذلك، قد لا تكون تقنيات الترشيح التقليدية، مثل مرشح كالمان KF، كافية للتعامل مع الطبيعة اللاخطية والضجيج غير الغاوسي لهذه الأنظمة. أظهرت المرشحات الهجينة، التي تجمع بين تقنيات متعددة، حلول واعدة في التغلب على هذه القيود.

تم تطوير مرشح كالمان KF لأول مرة في الستينيات من قبل رودولف كالمان (Sinopoli، وآخرون، Kalman filtering with intermittent observations، 2004). مرشح كالمان عبارة عن خوارزمية رياضية تستخدم سلسلة من القياسات لتقدير حالة النظام، نظراً لأن النظام يخضع للاضطرابات والضجيج العشوائي. تم تطبيق مرشح كالمان KF على نطاق واسع في العديد من المجالات، بما في ذلك هندسة الطيران والسيارات والتحكم. فهو مفيد للأنظمة الخطية، حيث يمكن لمجموعة من المعادلات الخطية وصف ديناميكية النظام. من جهة أخرى، فإن مرشح كالمان KF له قيود عند التعامل مع الأنظمة اللاخطية أو الأنظمة ذات الضجيج غير الغاوسي. بعد ذلك، تم اقتراح مرشح كالمان الممتد EKF لتطبيق نظرية مرشح كالمان KF على النظام اللاخطي (Yu, Chen, Zhang, & Wang, From Static to Dynamic Tag Population Estimation: An Extended Kalman Filter Perspective, 2016). الفكرة الأساسية لمرشح كالمان الممتد جعل النظام اللاخطي خطياً باستخدام تقريب تايلور من الدرجة الأولى وتنفيذ KF.

خلاف ذلك، مع تقاوم اللاخطية للنظام الديناميكي، ينخفض أداء EKF بشكل حاد. من أجل حل هذه المشكلة، اقترح جولير وألمان خوارزمية مرشح كالمان غير المعطر (UKF) (Julier & Uhlmann, 1996). على عكس EKF، فإن UKF يقارب توزيع متغيرات الحالة العشوائية عن طريق

الاختيار المباشر لعدد صغير من نقاط العينة، باستخدام النموذج اللاخطي. لكن، نظراً لأن EKF و UKF ليس لهما طريقة للتخلص من القيد الغاوسي للنظام، فإن تأثير المعالجة على النظام غير الغاوسي ليس جيداً. تم تطوير مرشح الجسيم PF (Gordon, Salmond, & Smith, 1993)، والمعروف أيضاً باسم طريقة مونت كارلو التسلسلية، في أواخر الثمانينيات كوسيلة لتتبع الأهداف. تعتمد الطريقة على التمثيل الاحتمالي لحالة النظام، والذي يتم تحديثه بشكل متكرر عند توفر بيانات جديدة.

يمكن لمرشح الجسيمات التعامل مع الأنظمة اللاخطية والضجيج غير الغاوسي، والتي غالباً ما يتم مواجهتها في تطبيقات الواقع. يتم تحقيق ذلك من خلال تمثيل حالة النظام كمجموعة من الجسيمات المنفصلة، يتم تعيين وزن لكل منها بما يعكس احتمال كونها الحالة الحقيقية.

يعتبر مرشح الجسيمات مفيد بشكل خاص في الحالات التي يكون فيها النظام لاخطي، أو عندما يكون الضجيج غير غاوسي، أو عندما يكون النظام ديناميكي أي عرضة لتغيرات مفاجئة في سلوكه. ومع ذلك، فإن مرشح الجسيمات مكلف حسابياً ويمكن أن يعاني من مشاكل مثل تنكس الجسيمات وإفكار العينات. اقترح لاين و كايم خوارزمية هجينة PAUKF ما بين مرشح UKF ومرشح الجسيمات ليعالج الضجيج غير الغاوسي وذلك أثناء تحديد موقع لمركبة ذاتية القيادة من خلال تمثيله بنموذج حركي وحيد فبدلك لم يعالج الديناميكية المتغيرة للنظم اللاخطية والضجيج المتغير مع الزمن (Lin & Kim, 2020)، كما اعتمد غرومز وروبنسون على تصنيفات درجة اللاخطية للنظم، فتم اقتراح خوارزمية هجينة P-EKF لنظام ذو درجة لاخطية متوسطة (Grooms & Robinson, 2021)، ونظراً لقصور المرشح الهجين UPF عن تغطية مساحة الحالة المستهدفة بالكامل عند التعامل مع مشكلة تتبع الهدف المناورة، قام الباحثين دو و دينغ باقتراح تطوير DCS-UPF من خلال تحليل فضاء الحالة ومعالجة كل متغير على حدى

خوارزمية مطورة عن مرشح الجسيمات PF مقاد بمتحكم عائم (Weixin, Xiaoli, و Liangqun, 2019).

## 1.2 الخوارزمية الأولى Adaptive

### : Unscented Kalman Filter (AUKF)

تعتمد هذه الخوارزمية كما في مرشح UKF الأساسي على تطبيق تحويل لاخطي لبضعة نقاط مولدة من تابع الاحتمال الغاوسي لحالة النظام والتي تسمى بـ Sigma points وحساب أول لحظتين من المجموعة المحولة وكتطوير على المرشح الأساسي (Ge, Zhang, Jiang, Li, & Butt, 2019) تم اقتراح معادلة تكيفية خطية لحساب مصفوفة تغاير خطأ النظام وطريقة منفصلة لحساب مصفوفة تغاير خطأ القياسات وذلك بالاعتماد على القياسات في اللحظات الزمنية السابقة وتعدد الحسابات (Li, Zhang, Zhou, & Che, 2017) ، على عكس كثير من الخوارزميات الأخرى التي يتم حساب مصفوفة تغاير خطأ القياسات بمساعدة مصفوفة تغاير خطأ النظام.

**الخوارزمية (1):** تتمثل خطوات الخوارزمية كما يلي:

$$1. \text{ تهيئة شعاع الحالة } \hat{X}_0 \text{ ومصفوفة التغاير } P_0$$

$$\begin{cases} \hat{X}_0 = E\{X_0\} \\ \hat{P}_0 = E\{(X_0 - \hat{X}_0)(X_0 - \hat{X}_0)^T\} \end{cases} \quad (2)$$

2. حساب نقاط سيغما:

$$\begin{aligned} \chi_{k-1}^0 &= \hat{X}_{k-1} \\ \chi_{k-1}^i &= \hat{X}_{k-1} + \sqrt{(n+1)P_{k-1}} \cdot e_i, \quad i=1, \dots, n \end{aligned} \quad (3)$$

$$\chi_{k-1}^i = \hat{X}_{k-1} - \sqrt{(n+1)P_{k-1}} \cdot e_i, \quad i=n+1, n+2, \dots, 2n$$

حيث  $n$  بعد شعاع الحالة، وعامل القياس المركب  $\lambda$  يتم ضبطه كقيمة مثلى  $\alpha = e^{-3}$  ويتم ضبط  $\kappa = 0$  ضمن معيار UT2 لمعايرة انتشار نقاط سغما حول المركز.

3. تطبيق الخوارزمية التكيفية innovation & residual لحساب المعادلة الخطية واستنتاج قيم مصفوفة خطأ ضجيج

(Du & Deng, 2021)، كما تم اقتراح خوارزمية هجينة-WT) UKF و (IPSO-SVM) من أجل تحسين دقة إشارة التخطيط الكهربائي للقلب (Li, et al., 2022).

في هذا البحث، تم اقتراح مرشح هجين عائم متكيف يجمع بين مزاي خوارزمية Fuzzy Expectation Maximization Takagi-Sugino Particle Filter (FEMT-SPF) وخوارزمية Adaptive Unscented Kalman Filter للتعامل مع الضجيج غير الغاوسي والمتغير مع الزمن لنظام تتبع مناورة هدف. من خلال الدمج، يمكننا تحسين متانة المرشح وتكيفه مع الديناميكيات المتغيرة مع الزمن للنظام اللاخطي (Xiaoli, Weixin, & Liangqun, 2019) و (Ge, Zhang, Jiang, Li, & Butt, 2019).

## 1 طرق البحث ومواده:

### 1.1 حالة الدراسة:

بالنظر إلى نظام ديناميكي متقطع لاخطي عام، يمكننا وصف نموذج النظام ونموذج رصد القياسات:

$$\begin{cases} X_k = f(X_{k-1}) + W_{k-1} \\ Z_k = h(X_k) + V_k \end{cases} \quad (1)$$

حيث أن  $X_k \in R^{n \times 1}$  شعاع الحالة،  $Z_k \in R^{m \times 1}$  شعاع القياسات،  $f(\cdot)$  و  $h(\cdot)$  يمثلان تابع انتقال الحالة وتابع القياسات اللاخطيان بالتسلسل.  $W_{k-1}$  و  $V_k$  هما ضجيج غير غاوسي وغير مرتبطان خطياً ومصفوفتا التغاير لهما  $Q_{k-1}$  و  $R_k$  بالتسلسل.

يشمل هذا البحث العمل على دراسة تتبع نظام مناورة وذلك من خلال تصميم خوارزمية هجينة.

بناءً على ذلك يركّز البحث على الخوارزميتين التاليتين:

- الخوارزمية الأولى: تعتمد على تتبع نظام مناورة ديناميكي مع ضجيج قراءات أبيض من خلال خوارزمية مطورة عن مرشح UKF

(Ge, Zhang, Jiang, Li, و Butt, 2019).

- الخوارزمية الثانية: تعتمد على تتبع نظام مناورة ديناميكي لاخطي مع ضجيج قراءات غير غاوسي من خلال

حيث أن  $Z_k$  القراءة الحالية،  $Z_k^R$  القراءة المكررة. ومن أجل سلسلة تقدير التغيرات، تم استخدام صيغة التقدير العودية التالية حيث أن  $b$  هو عامل التخامد،  $0 < b \leq 1$ :

$$\begin{cases} \hat{R}_k = (1 - d_k)R_{k-1} + d_k R_k \\ d_k = \frac{1-b}{1-b^{k+1}} \end{cases} \quad (9)$$

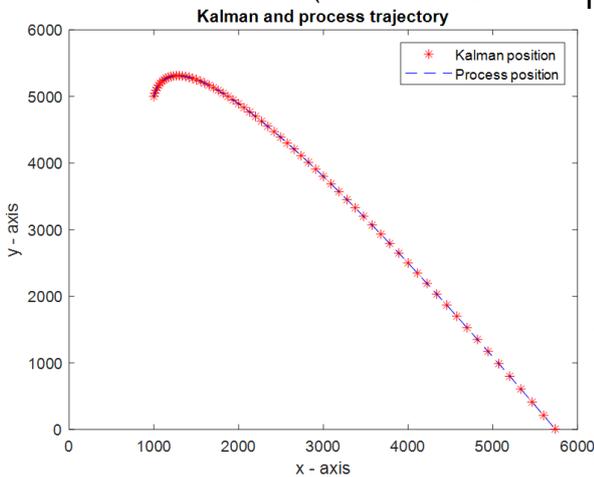
6. يتم حساب ربح كالمان والحلول بعد الترشيح من خلال:

$$\begin{cases} \zeta_{k/k-1}^i = h(\chi_{k/k-1}^i, k), i = 0, 1, 2, \dots, 2n \\ \hat{Z}_{k/k-1} = \sum_{i=0}^{2n} w_i^m \zeta_{k/k-1}^i \\ P_{XZ} = \sum_{i=0}^{2n} w_i^c (\chi_{k-1}^i - \hat{X}_{k/k-1}) (\zeta_{k-1}^i - \hat{Z}_{k/k-1})^T \\ P_{ZZ} = \sum_{i=0}^{2n} w_i^c (\zeta_{k-1}^i - \hat{Z}_{k/k-1}) (\zeta_{k-1}^i - \hat{Z}_{k/k-1})^T + R_k \\ K_k = P_{XZ} P_{ZZ}^{-1} \end{cases} \quad (10)$$

$$\begin{cases} \hat{X}_k = \hat{X}_{k/k-1} + K_k (Z_k - \hat{Z}_{k/k-1}) \\ P_k = P_{k/k-1} - K_k P_{ZZ} K_k^T \end{cases} \quad (11)$$

### 1.3 نتائج تنجيز الخوارزمية AUKF:

تم تنجيز الخوارزمية تبعاً لمثال المرجع (Zhang, Ge),



الشكل (1) مسار الهدف للخوارزمية الأولى

يظهر الشكل (1) تقدير مسار الهدف باستخدام AUKF كما يوضح الشكل (2) جذر الخطأ التريبيعي للخوارزمية أثناء اختبارها لـ 100 مرة. فبالنظر إلى النتائج السابقة نجد أنها مقاربة للنتائج التي عرضها الباحث في بحثه.

$$\begin{aligned} H_{k/k-1} \Gamma_{k-1} Q_{k-1} \Gamma_{k-1}^T H_{k/k-1}^T &= E [(\eta_k - \varepsilon_k)(\eta_k - \varepsilon_k)^T] - \\ &w_i^c (\chi_{k-1}^i - \hat{X}_{k/k-1}) \\ H_{(k/k-1)} [\sum_{i=0}^{2n} w_i^c (\chi_{k-1}^i - \hat{X}_{k/k-1})^T] &+ \\ &H_k P_k H_k^T. \end{aligned} \quad (4)$$

حيث أن  $H_k$  المصفوفة اليعقوبية لتابع القياس وأن  $\Gamma_{k-1}$  مصفوفة انتقال ضجيج النظام و  $w_i^c$  أوزان ستعرف لاحقاً و  $E [(\eta_k - \varepsilon_k)(\eta_k - \varepsilon_k)^T]$  يمكن حسابها من:

$$E [(\eta_k - \varepsilon_k)(\eta_k - \varepsilon_k)^T] = \frac{1}{M} \sum_{j=1}^{M-1} (\eta_{k-j} - \varepsilon_{k-j}) (\eta_{k-j} - \varepsilon_{k-j})^T \quad (5)$$

حيث  $M$  هو حجم نافذة التقريب وأن  $\varepsilon_k$  و  $\eta_k$  هما عاملا الابتكار (Innovation) والترسيب (Residual):

$$\begin{aligned} \varepsilon_k &= Z_k - h(X_{k/k-1}) \\ \eta_k &= Z_k - h(X_k) \end{aligned} \quad (6)$$

4. حساب التنبؤ بالحالة والقياس وفقاً للمعادلات:

$$w_i^m = w_i^c = \frac{1}{2(n+\lambda)}, i = 1, \dots, 2n. \quad n: \text{state dimension}$$

$$w_0^c = \frac{\lambda}{\lambda+n} + (1 - \alpha^2 + \beta), w_0^m = \frac{\lambda}{\lambda+n}$$

$$\chi_{k/k-1}^i = f(\chi_{k-1}^i, k-1), i = 0, 1, 2, \dots, 2n$$

$$\hat{X}_{k/k-1} = \sum_{i=0}^{2n} w_i^m \chi_{k/k-1}^i \quad (7)$$

$$P_{xx} = \sum_{i=0}^{2n} w_i^c (\chi_{k-1}^i - \hat{X}_{k/k-1}) (\chi_{k-1}^i - \hat{X}_{k/k-1})^T$$

5. باستخدام القياسات الأولية والمكررة يتم حساب مصفوفة تغيرات خطأ القياسات  $R$  من خلال:

$$R_k = \left\{ \begin{array}{l} E[\nabla Z(k) \nabla Z(k)^T] \\ + E \left[ \begin{array}{l} (Z_k - Z_{k-1}) \\ (Z_k - Z_{k-1})^T \end{array} \right] \\ - E \left[ \begin{array}{l} (Z_k^R - Z_{k-1}^R) \\ (Z_k^R - Z_{k-1}^R)^T \end{array} \right] \end{array} \right\} / 4 \quad (8)$$

$$\nabla Z(k) = (Z_k - Z_{k-1}) - (Z_k^R - Z_{k-1}^R)$$

model clustering (Chang & Tao, A Novel Approach to Implement Takagi-Sugeno Fuzzy Models, 2017) لتسريع عملية التقارب وإيجاد الحل الأدق، وبذلك تعالج هذه الخوارزمية مشاكل اللاخطية وغير الغاوسية لأنظمة التتبع.

للسهولة سيتم شرح قسم من الخوارزمية بشكل منفصل في الخوارزمية 2-1 ومن ثم سرد كلي للخوارزمية 2-2.

**الخوارزمية 2-1:** تتلخص خطوات خوارزمية التوقع الأعظمي

العائم المطورة التي تم اقتراحها في الدراسة [8]

1. التهيئة: وذلك بفرض قيم ابتدائية لمتغيرات توابع انتماء الدخل للنظام العائم  $(\tau, \sigma)^0$ ، ومعيار التوقف  $\xi$ ، دالة الاحتمال  $L(\theta)$  حيث  $\theta_k^m$  الدخل  $m$  للمتحكم العائم.

2. من أجل  $i = i + 1$

a. حساب المتغير العائم لخوارزمية FEM من خلال FCRM

$$u_{k,l}^i = \frac{\exp(-\beta[(D_{k,l}^i)^2 + \sum_{m=1}^G \omega_k^{i,m} \theta_k^m])}{\sum_{q=1}^{N_f} \exp(-\beta[(D_{k,l}^q)^2 + \sum_{m=1}^G \omega_k^{q,m} \theta_k^m])} \quad (12)$$

حيث  $\omega_k^{i,m}$  هو وزن الدخل  $m$  في النموذج  $i$  وأن:

$$(D_{k,l}^i)^2 = \frac{1}{p_i(z_{k,l} | \hat{x}_k^i)} \quad (13)$$

b. خطوة التوقع E-step من خلال حساب دالة الحد الأدنى  $B(\tau, \sigma)$  من خلال نظرية جينسن عدم المساواة:

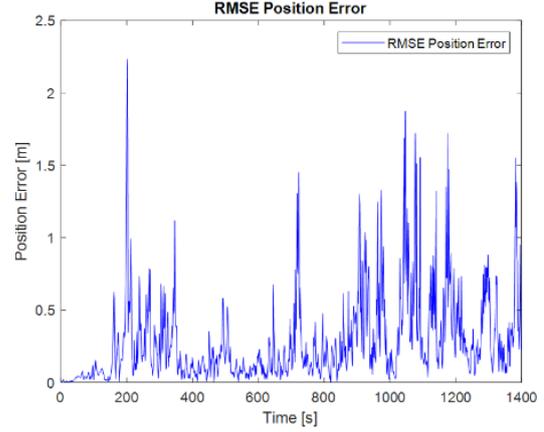
$$B(\theta_k^m) = \sum_{l=1}^C \sum_{i=1}^{N_f} u_{k,l}^i \log \frac{\pi_k^i p_{A_k^{i,m}}(\theta_k^m)}{u_{k,l}^i} \quad (14)$$

c. خطوة التعظيم M-step: من خلال حساب القيم الجديدة:  $(\tau_k^{i,m}, \sigma_k^{i,m})$

$$\begin{cases} \tau_k^{i,m} = \frac{\sum_{l=1}^C u_{k,l}^i \theta_k^m}{\sum_{l=1}^C u_{k,l}^i} \\ \sigma_k^{i,m} = \frac{\sum_{l=1}^C u_{k,l}^i (\theta_k^m - \tau_k^{i,m}) (\theta_k^m - \tau_k^{i,m})^T}{\sum_{l=1}^C u_{k,l}^i} \end{cases} \quad (15)$$

3. يتوقف تكرار الخطوات السابقة عندما:

$$B((\tau, \sigma)^{i+1}, (\tau, \sigma)^i) - B((\tau, \sigma)^{i+1}, (\tau, \sigma)^i) \leq \zeta \quad (16)$$



الشكل (2) جذر الخطأ التربيعي للخوارزمية الأولى

#### 1.4 مشكلة الخوارزمية AUKF:

تتميز الخوارزمية السابقة بتطويرها لمرشح UKF بحيث يكون قادر على التكيف مع الضجيج المتغير مع الزمن. وفي حال لم يتم الحساب الصحيح لمصفوفة تغاير خطأ النظام المتغيرة مع الزمن سيؤثر بشكل مباشر على حساب مصفوفة تغاير النظام في المرشح والذي سيؤدي إلى توليد نقاط سيغما خاطئة في المرحلة التالية ومع مرور الزمن سيؤدي ذلك إلى عدم استقرار المرشح وتباعده عن التقدير الصحيح.

ولكن، وبناءً على ذلك نجد أن التوزيع الغاوسي للنظام والقياسات أساس الخوارزمية السابقة ومرشح UKF بشكل عام، إلا أن معظم الأنظمة الحقيقية لا تعتمد التوزيع الغاوسي كما أن ضجيج القياسات عادة ما يكون غير غاوسي وهذا ما يؤدي إلى قصور الخوارزمية السابقة في معظم التطبيقات.

#### 1.5 الخوارزمية الثانية FEM T-S Particle Filter (FEMT-SPF):

تعتمد هذه الخوارزمية على دمج المعلومات المكانية والزمانية Spatial Data في مرشح الجسيمات PF وذلك من خلال اقتراح نموذج النظام العائم T-S (Li, Wang, Xie, & Liu, 2019) وتحديد متغيرات توابع الانتماء للنظام بشكل تكيفي من خلال خوارزمية التوقع الأعظمي العائم (Prakash FEM T-S Particle Filter & Kumari, 2017) ولتجنب أي تأثير ناجم عن القيم الابتدائية المفترضة سيتم حساب المتغير العائم FEM من خلال طريقة تجميع نموذج c الانحداري fuzzy C-regressive

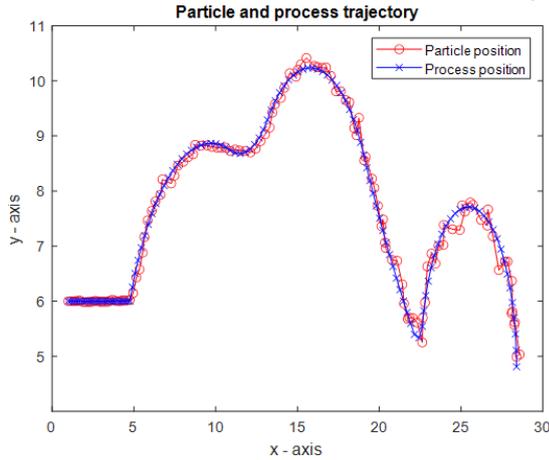
$$\left\{ \begin{array}{l} p(z_k | x_{k,j}) \\ p(\theta_k | x_k) \\ \omega_{k,j} \propto \omega_{k-1,j} \frac{p(x_{k,j} | x_{k-1,j})}{q(x_{k,j} | x_{k-1,j}, z_k)} \\ \psi_{k,j} = w_{k,j} / \sum_{j=1}^M \omega_{k,j} \end{array} \right. \quad (22)$$

(e) حساب الحالة ومصفوفة تباين النظام:

$$\left\{ \begin{array}{l} \hat{x}_k = \sum_{j=1}^M \psi_{k,j} x_{k,j} \\ P_k = \sum_{j=1}^M \psi_{k,j} [\bar{P}_{k,j} + (\hat{x}_k - x_{k,j})(\hat{x}_k - x_{k,j})^T] \end{array} \right. \quad (23)$$

### 1.6 نتائج تنجيز الخوارزمية FEMT-SPF:

فيما يلي تنجيز الخوارزمية الثانية حيث يظهر الشكل (3) تقدير مسار الهدف. تم تتبع مسار طائرة مناورة من خلال رادارين حيث استخدم نموذج دوران ثابت مع معدل دوران معروف وتم اعتماد جميع الشروط والقيم الابتدائية تبعاً لمثال المرجع (Ge، Zhang، Jiang، Li، و Butt، 2019)



الشكل (3) مسار الهدف باستخدام الخوارزمية الثانية يوضح الشكل (4) جذر الخطأ التربيعي للخوارزمية الثانية أثناء اختبارها لـ 100 مرة.

4. عندها يكون  $(\tau, \sigma) = (\tau, \sigma)^{i+1}$

الخوارزمية 2-2: تتمثل خطوات الخوارزمية ككل في الدراسة [8] كما يلي:

1 التهيئة:

ضبط عدد قواعد النظام العائم ليساوي  $N_f$ ، وفرض أن الجسيمات  $(x_{0:k-1}^j)_{j=1}^M$  تم توليدهم من تابع الكثافة الاحتمالية  $p(x_0)$ ، وعدد الجسيمات  $M$ .

2 من أجل  $k = 1, 2, \dots$

(a) تحديد متغيرات النظام العائم T-S:

I. تحديد معادلات خرج كل قاعدة للنظام العائم وذلك من خلال خوارزمية تتبع قوية (Jia-Qiang, Rong-Hua, Jin-Li, Chun-Yan, & Yan-Ping, 2016).

II. تحديد متغيرات توابع انتماء الدخل من خلال خوارزمية 1-2.

(b) حساب خرج النظام العائم من خلال

$$\left\{ \begin{array}{l} \mu_k^i(\theta_k) = \frac{\bar{\mu}_k^i(\theta_k)}{\sum_{j=1}^{N_f} \bar{\mu}_k^j(\theta_k)} \\ \bar{\mu}_k^i(\theta_k) = \prod_{m=1}^G p_{A_k^{i,m}}(\theta_k^m) \end{array} \right. \quad (17)$$

$$x_k = \sum_{i=1}^{N_f} \mu_k^i(\theta_k) \left( \begin{array}{l} \phi_{k-1}^i x_{k-1}^i \\ + e_{k-1}^i \end{array} \right) \quad (18)$$

تم اعتماد الشكل الغاوسي لتوابع انتماء المجموعة العائمة:

$$p_{A_k^{i,m}}(\theta_k^m) = \exp \left\{ -\frac{1}{2} \left( \frac{\theta_k^m - \tau_k^{i,m}}{\sigma_k^{i,m}} \right)^2 \right\} \quad (19)$$

(c) تشكيل تابع الكثافة وتوليد جسيمات  $\{x_{k,j}\}_{j=1}^M$  من المعادلة التالية:

$$q(x_{k,j} | x_{k-1,j}, z_k) = N(\tilde{x}_{k,j}, \tilde{P}_{k,j}) \quad (20)$$

حيث أن:

$$\left\{ \begin{array}{l} \tilde{x}_k = \sum_{i=1}^{N_f} \mu_k^i \hat{x}_k^i \\ \tilde{P}_k = \sum_{i=1}^{N_f} \mu_k^i [P_k^i + (\tilde{x}_k - \hat{x}_k^i)(\tilde{x}_k - \hat{x}_k^i)^T] \end{array} \right. \quad (21)$$

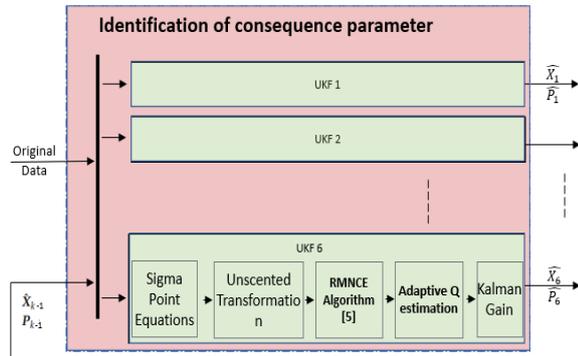
(d) حساب أوزان الجسيمات Particles



الشكل (5) المراحل الأساسية للخوارزمية الهجينة المقترحة

### 1.1.1 تحديد معادلات خرج كل قاعدة للنظام العائم:

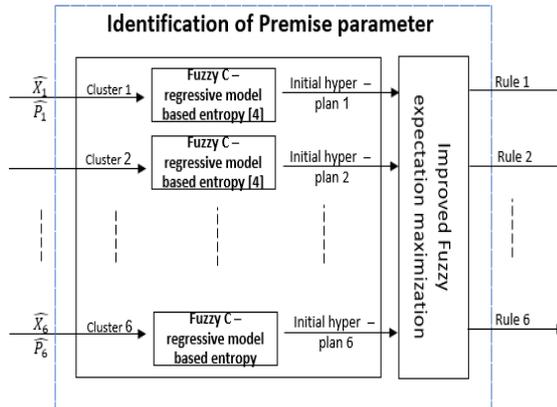
بما أن خرج كل قاعدة من النموذج العائم T-S يمثل النظام اللاخطي كنظام خطي بمجال عمل محدد، سيتم تطبيق الخوارزمية AUKF على خرج كل قاعدة من النظام العائم. يبين الشكل (6) آلية تحديد معادلات خرج النظام العائم.



الشكل (6) آلية تحديد معادلات خرج النظام العائم

### 1.1.2 تحديد متغيرات توابع انتماء الدخل:

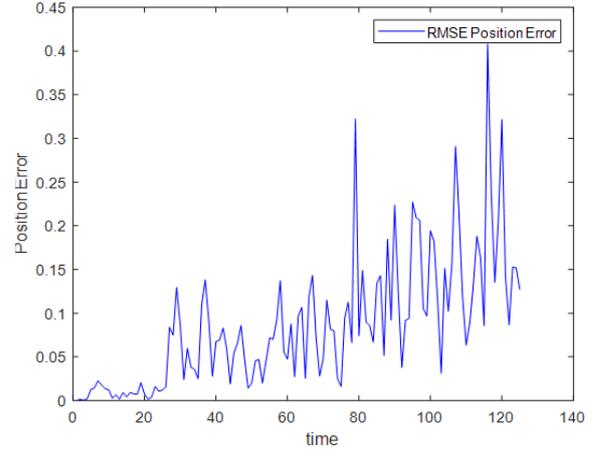
كما في الخوارزمية FEMT-SPF تم فرض توابع انتماء الدخل التابع الغاوسي وسيتم تحديد متغيراته من المنتصف والتباين من خلال خوارزمية FEM.



الشكل (7) تحديد متغيرات توابع انتماء الدخل

### 1.1.3 تحديث النموذج النهائي:

يتم حساب  $\hat{X}_k, P_k$  من النموذج العائم، نظراً لدقة خوارزمية AUKF في الحساب الدقيق للحالة سيتم اعتماد  $\hat{X}_k$  كخرج



الشكل (4) جذر الخطأ التربيعي للخوارزمية الثانية

بالنظر إلى منحنى RMSE للنتائج السابقة نجد أنها مقارنة للنتائج التي عرضها الباحث في بحثه.

### 1.7 مشكلة الخوارزمية FEMT-SPF:

- أي خطأ في مرحلة حساب الأنظمة الخطية الفرعية باستخدام الخوارزمية التكيفية سيسبب تباعد وتدهور أداء المرشح وفشل في جميع المراحل التالية للخوارزمية.
- القيم الخاطئة لمصفوفتي الخطأ للنظام والقياسات لهما دور كبير في استدراج خوارزمية التتبع القوية في حساب الأنظمة للتباعد وجعل المرشح غير مستقر.
- التكلفة الحسابية الكبيرة.

### 1.1 طريقة تصميم الخوارزمية الهجينة المقترحة:

تعتمد الخوارزمية المقترحة على دمج مزايا الخوارزمية FEMT-SPF ليلائم الأنظمة اللاخطية والضجيج غير الغاوسي، إضافة إلى التقدير الدقيق والمتانة من أي ضجيج متغير مع الزمن من خلال الخوارزمية التكيفية للمرشح AUKF وبأقل كلفة حسابية وذلك نتيجة لخوارزمية الدمج التي قللت من الكلفة الحسابية للخوارزمية الثانية.

يبين الشكل (5) المراحل الأساسية للخوارزمية الهجينة:

- تحديد معادلات خرج كل قاعدة للنظام العائم
- تحديد متغيرات توابع انتماء الدخل.
- تحديث النموذج النهائي.

d. حساب مصفوفة تباين النظام  $P_k$  من خلال المعادلة (23).

### 3 النتائج والمناقشة:

#### 3.1 نتائج الاختبار للخوارزمية المقترحة:

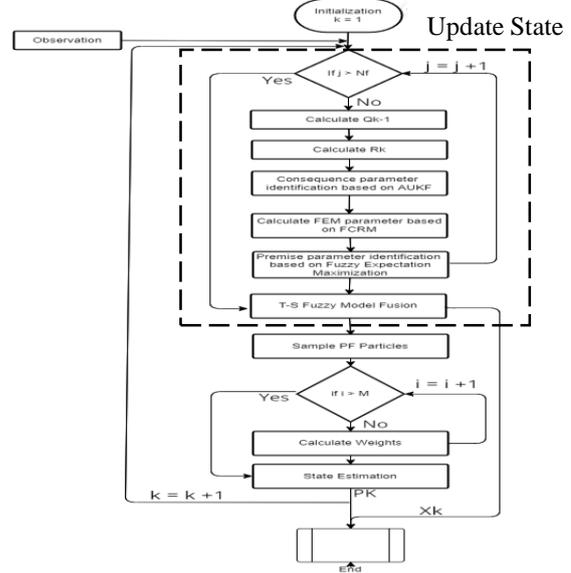
تم استخدام نموذج تتبع الهدف Bearings-Only Tracking (BOT) ذو سرعة زاوية معروفة والذي يُمثل بمعادلات الحالة والقياسات الآتية:

$$\begin{cases} x_k^i = \phi_{k-1}^i(T, \omega_i)x_{k-1}^i + e_{k-1} \\ z_k^i = H_k^i x_k^i + v_k \quad i = 1, 2, 3, \dots, N_f \end{cases} \quad (24)$$

حيث أن  $N_f$  هو عدد قواعد النظام العائم، وشعاع الحالة  $x_k = [x_k, x'_k, y_k, y'_k]^T$  وضجيج النظام  $e_k$  هو ضجيج غاوسي ذو وسط صفري وانحراف معياري  $\sigma_{i,e}$  (الجدول 1 يبين قيم هذه المتغيرات)

نهائي، بالاستعانة بـ PF ليقوم بحساب  $\hat{P}_k$  النهائي للحصول على مصفوفة تغاير للنظام اللاخطي أدق.

يبين الشكل (8) مخطط الهيمنة



الشكل (8) مخطط التدفق للخوارزمية الهجينة

#### الخوارزمية 3: الخوارزمية الهجينة المقترحة

1. تهيئة شعاع الحالة  $\hat{x}_0$  ومصفوفة التغاير  $P_0$  وضبط عدد قواعد النظام العائم ليساوي  $N_f$ ، وفرض أن الجسيمات  $(x_{0:k-1}^j)_{j=1}^M$  تم توليدهم من تابع الكثافة الاحتمالية  $p(x_0)$ ، وعدد الجسيمات هو  $M$ .

2. من أجل  $k = 1, 2, \dots$

a. تحديد متغيرات النظام العائم T-S:

i. تحديد معادلات خرج كل قاعدة للنظام العائم وذلك من خلال خوارزمية 1 الخطوات 1-6.

ii. تحديد متغيرات توابع انتماء الدخل من خلال خوارزمية 1-2.

b. تحديث شعاع الحالة وحسابه من خلال خرج النظام العائم المعادلة (18).

c. توليد جسيمات من خلال تابع الكثافة المعادلات (21) و (20) وحساب أوزان الجسيمات من خلال المعادلة (22).

الجدول (1) قيم  $w_i, \sigma, i, e$  من أجل  $\Delta v, \Delta \theta$

$\Delta \theta_k$ (rad)	$\Delta v_k$ (km)		
	Negative Large (NL)	Small (S)	Positive Large (PL)
Small (S)	-0.0324, 0.15	0, 0.015	0.0324, 0.015
arge L (L)	-0.0124, 0.005	0, 0.015	0.0124, 0.015

وضجيج القياسات يعبر بتابع غير غاوسي، وتكون مصفوفة

$$R = \begin{bmatrix} \frac{N(0,\sigma)+N(0,\sigma)}{2} \\ \frac{N(0,\sigma)+N(0,\sigma)}{2} \end{bmatrix}, \sigma = 0.001$$

القيم الابتدائية لشعاع الحالة والذي يمثل الموضع والسرعة:

$$x_{0|0} = [1km, 0.15km/s, 6km, 0.26km/s]^T$$

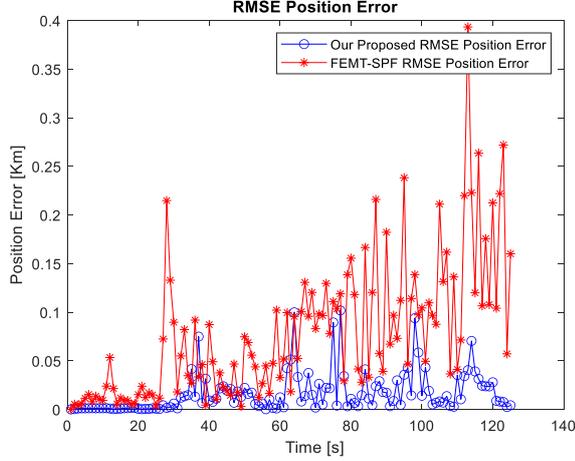
$$P_{0|0} = [\sigma^2 0 0 0; 0 \sigma^2 0 0; 0 0 \sigma^2 0; 0 0 0 \sigma^2]^T$$

تم تحديد Innovation و heading angle difference

كمعلومات دلالية، والتي يمكن أن تعكس بشكل فعال الحالة الحركية للهدف. تُعرّف مصفوفة انتقال الحالة بـ:

تم اعتماد معيارين أساسيين لتقدير أداء الخوارزمية:

- مربع خطأ التربيع RMSE
- الكلفة الحسابية Computational Cost



الشكل (10) جذر الخطأ التربيعي للخوارزمتين

تم مقارنة نتائج الخوارزمية المقترحة مع الخوارزمية الثانية تبعاً للنظام المعتد في الدراسة.

يبين الشكل (10) مقارنة ما بين جذر الخطأ التربيعي للخوارزمية الهجينة والخوارزمية FEMT-SPF وتظهر النتائج أن الخوارزمية المقترحة أقل بنسبة 70% من الخوارزمية الأخرى.

فيما يلي أيضاً جدول يقارن ما بين الخوارزمتين.

الجدول (2) مقارنة تبعاً للكلفة الحسابية وجذر الخطأ التربيعي

Algorithm	RMSE		Computational Cost
	Worst Case	Normal Case	
FEM T-S Particle Filter	0.5 km	0.35 km	6 <sup>^</sup> 200
Proposed Algorithm	0.14 km	0.08 km	6+200

#### 4 الاستنتاجات:

في هذه المقالة تم اقتراح خوارزمية لمرشح هجين، حيث تم استخدام خوارزمية مطوّرة عن مرشح الجسيمات من أجل التطبيقات اللاخطية وللإستفادة من المعلومات المكانية والزمانية للهدف تم استخدام النموذج العائم T-S. يتم حساب متغيرات توابع انتماء دخله من خلال خوارزمية FEM، كما

$$\phi_{k-1}^i = \begin{bmatrix} 1 & \frac{\sin(\omega_i T)}{\omega_i} & 0 & -\frac{1-\cos(\omega_i T)}{\omega_i} \\ 0 & \cos(\omega_i T) & 0 & -\sin(\omega_i T) \\ 0 & \frac{1-\cos(\omega_i T)}{\omega_i} & 1 & \frac{\sin(\omega_i T)}{\omega_i} \\ 0 & \sin(\omega_i T) & 0 & \cos(\omega_i T) \end{bmatrix}$$

كما تُعرّف مصفوفة تغاير الضجيج بـ:

$$Q_{k-1}^i = \begin{bmatrix} \frac{\omega_i T - \sin(\omega_i T)}{\omega_i^3} & \frac{1-\cos(\omega_i T)}{\omega_i^2} & 0 & \frac{\omega_i T - \sin(\omega_i T)}{\omega_i^2} \\ \frac{1-\cos(\omega_i T)}{\omega_i^2} & T & -\frac{\omega_i T - \sin(\omega_i T)}{\omega_i^2} & 0 \\ 0 & -\frac{\omega_i T - \sin(\omega_i T)}{\omega_i^2} & \frac{2(\omega_i T - \sin(\omega_i T))}{\omega_i^3} & \frac{1-\cos(\omega_i T)}{\omega_i^2} \\ \frac{\omega_i T - \sin(\omega_i T)}{\omega_i^2} & 0 & \frac{1-\cos(\omega_i T)}{\omega_i^2} & T \end{bmatrix} \cdot \sigma_{i,e}^2$$

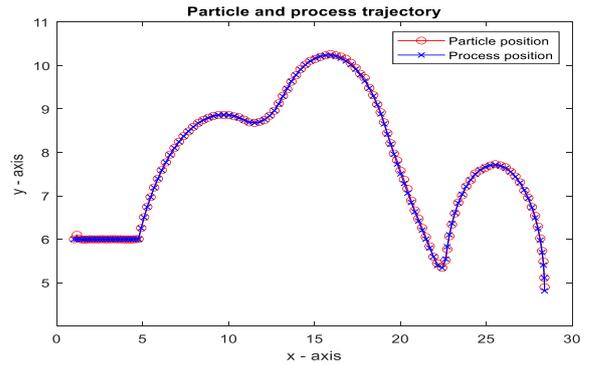
تم وضع حساسين في الموضع (0,5) فيكون تابع القراءة:

$$h(x_k) = \begin{bmatrix} \beta_1 \\ \beta_2 \end{bmatrix} = \begin{bmatrix} \arctan\left(\frac{y-S_{1,y}}{x-S_{1,x}}\right) \\ \arctan\left(\frac{y-S_{2,y}}{x-S_{2,x}}\right) \end{bmatrix}$$

حيث أن  $S_{i,y}, S_{i,x}$  هي إحداثيات موضع الحساس،  $i = 1, 2, \dots$  هي زاوية azimuth، وبالتالي تكون المصفوفة اليعقوبية لها:

$$H_k^i = \begin{bmatrix} -\frac{y-S_{1,y}}{(y-S_{1,y})^2 + (x-S_{1,x})^2} & 0 & \frac{x-S_{1,x}}{(y-S_{1,y})^2 + (x-S_{1,x})^2} & 0 \\ -\frac{y-S_{2,y}}{(y-S_{2,y})^2 + (x-S_{2,x})^2} & 0 & \frac{x-S_{2,x}}{(y-S_{2,y})^2 + (x-S_{2,x})^2} & 0 \end{bmatrix}$$

#### 1.2 مناقشة النتائج:



الشكل (9) مسار الهدف باستخدام الخوارزمية الهجينة المقترحة

يبين الشكل (9) مسار الهدف الأساسي والمسار المقدّر من قبل الخوارزمية الهجينة.

يتم حساب المتغير العائم الابتدائي لطريقة FEM بواسطة FCRM، وذلك من أجل تسريع التقارب وتجنب التأثير الذاتي الناتج عن الإعداد الاصطناعي للقيم الابتدائية الثابتة. أما بالنسبة لخرج قواعد النظام العائم فتم حسابهم من خلال خوارزمية تكيفية مطورة عن UKF لمعالجة الضجيج غير المعروف والمتغير عبر الزمن وذلك باستخدام معادلة خطية لإيجاد مصفوفة تغاير خطأ النظام، وإيجاد مصفوفة تغاير ضجيج القياسات بشكل منفصل اعتماداً على قيم القياسات السابقة وتعدد الحساسات، وبالتالي الحصول على قيم حسابية دقيقة.

## 5 جدول الاختصارات:

UKF	Unscented Kalman Filter
PF	Particle Filter
FEM	Fuzzy Expectation Maximization
T-S	Takagi -Sukeno
FCRM	Fuzzy C-Regressive System
RMSE	Root Mean Square Error
PAUKF	particle-aided unscented Kalman filter
P-EKF	Particle-Ensemble Kalman Filter
UPF	Unscented Particle Filter
DCS-UPF	divide-and-conquer sampling UPF
WT-UKF	Wavelet Transform Unscented Kalman Filter
IPSO-SVM	Improved Particle Swarm Optimization Support Vector Machine

**التمويل:** هذا البحث ممول من جامعة دمشق وفق رقم التمويل (501100020595).

i, N., Zhu, L., Ma, W., Wang, Y., He, F., Zheng, A., & Zhang, X. (2022). The Identification of ECG Signals Using WT-UKF and IPSO-SVM. *Sensors*.

Li, Z., Zhang, H., Zhou, Q., & Che, H. (2017). An Adaptive Low-Cost INS/GNSS Tightly-Coupled Integration Architecture Based on Redundant Measurement Noise Covariance Estimation. *MDPI*.

Lin, M., & Kim, B. (2020). Extended Particle-Aided Unscented Kalman Filter Extended Particle-Aided Unscented Kalman Filter. *Appl. Sci. MDPI*.

Prakash, R., & Kumari, R. (2017). Spatial Fuzzy C Means and Expectation Maximization Algorithms with Bias Correction for Segmentation of MR Brain Images. *J. Med Syst*, 41(41), 15-23.

Qi, J., Sun, K., Wang, J., & Liu, H. (2018). Dynamic State Estimation for Multi-Machine Power System by Unscented Kalman Filter With Enhanced Numerical Stability. *IEEE Transactions on Smart Grid*.

Qi, J., Sun, K., Wang, J., & Liu, H. (2018). Dynamic State Estimation for Multi-Machine Power System by Unscented Kalman Filter With Enhanced Numerical Stability. *IEEE Trans. Smart Grid*.

Sinopoli, B., Schenato, L., Franceschetti, M., Poolla, K., Jordan, M., & Sastry, S. (2004). Kalman filtering with intermittent observations. *IEEE Transactions on Automatic Control*, 49(9), 1453 - 1464.

Sinopoli, B., Schenato, L., Franceschetti, M., Poolla, K., Jordan, M., & Sastry, S. (2004). Kalman filtering with intermittent observations. *IEEE*, 49(9), 1453 - 1464.

Xiaoli Wang, L. L. (2019). A Novel FEM Based T-S Fuzzy Particle Filtering for Bearings-Only Maneuvering Target Tracking. *Sensors*.

Xiaoli, W., Weixin, X., & Liangqun, L. (2019). A Novel FEM Based T-S Fuzzy Particle Filtering for Bearings-Only Maneuvering Target Tracking. *Sensors*.

Yu, J., Chen, L., Zhang, R., & Wang, K. (2016). From Static to Dynamic Tag Population Estimation: An Extended Kalman Filter Perspective. *IEEE Transactions on Communications* , 64(11), 4706 - 4719.

Yu, J., Chen, L., Zhang, R., & Wang, K. (2016). From Static to Dynamic Tag Population Estimation: An Extended Kalman Filter Perspective. *IEEE*, 64(11), 4706 - 4719.

## References:

Baoshuang Ge, H. Z. (2019). Adaptive Unscented Kalman Filter for Target Tracking with Unknown Time-Varying Noise Covariance. *Sensors*.

Chang, C., & Tao, C. (2017). A Novel Approach to Implement Takagi-Sugeno Fuzzy Models. *IEEE Transactions on Cybernetics*(47), 2353–2361.

Chang, C., & Tao, C. (2017). A Novel Approach to Implement Takagi-Sugeno Fuzzy Models. *IEEE Trans*(47), 2353–2361.

Du, S., & Deng, Q. (2021). Unscented Particle Filter Algorithm Based on Divide-and-Conquer Sampling for Target Tracking. *Sensors*.

Gao, B., Hu, G., Gao, S., Zhong, Y., & Gu, C. (2016). Multi-sensor Optimal Data Fusion for INS/GNSS/CNS Integration. *Int. J. Control Autom. Syst.*

Ge, B., Zhang, H., Jiang, L., Li, Z., & Butt, M. (2019). Adaptive Unscented Kalman Filter for Target Tracking with Unknown Time-Varying Noise Covariance. *Sensors*.

Gordon, N., Salmond, D., & Smith, A. (1993). Novel approach to nonlinear/non-Gaussian Bayesian state estimation. *IEE Proceedings F (Radar and Signal Processing)* , 140(2), 107 – 113.

Grooms, I., & Robinson, G. (2021). A hybrid particle-ensemble Kalman filter for problems with medium nonlinearity. *PLOS ONE*.

Ishihara, S., & Yamakita, M. (2016). Gain constrained robust UKF for nonlinear systems with parameter uncertainties. *IEEE European Control Conference (ECC)*.

Ishihara, S., & Yamakita, M. (2016). Gain constrained robust UKF for nonlinear systems with parameter uncertainties. *IEEE*.

Jia-Qiang, L., Rong-Hua, Z., Jin-Li, C., Chun-Yan, Z., & Yan-Ping, Z. (2016). Target tracking algorithm based on adaptive strong tracking particle filter. *IET Sci. Meas. Technol*(10), *IET Sci. Meas. Technol.*

Julier, S., & Uhlmann, J. (1996). A General Method for Approximating Nonlinear Transformations of Probability Distributions. *UK: Robotics Research Group, Department of Engineering Science, University of Oxford*.

Li, L.-Q., Wang, X.-L., Xie, W.-X., & Liu, Z.-X. (2019). A novel recursive T-S fuzzy semantic modeling approach for discrete state-space systems. *Neurocomputing*, 340, 222–232.

