

Analyse und Verbesserung des Federated Filters zur Multi-Sensor-Integration

A. Maier und G. F. Trommer

KIT - Institut für Theoretische Elektrotechnik und Systemoptimierung
Fritz-Haber Weg 1, 76131 Karlsruhe, Deutschland

Zusammenfassung

Dieses Paper zeigt einen Vergleich zwischen zentralem Kalman-Filter und Federated Filter am Beispiel eines in zukünftigen Unmanned Aerial Vehicles (UAV) eingesetzten multisensoriellen Navigationssystems, das GPS-Messungen, Radarhöhenmessungen (TRN) und Landmarkendetektionen aus Synthetic Aperture Radar (SAR) Aufnahmen mit einem inertialen Navigationssystem (INS) fusioniert. Das Federated Filter bietet gegenüber einem herkömmlichen zentralen Kalman-Filter mehrere Vorteile wie Modularität und Flexibilität. Zusätzlich verfügt das Federated Filter im No-Reset-Mode über eine verbesserte Fehlerdetektion. Demgegenüber stehen Nachteile des Federated Filters, vor allem die geringfügig ungenauere Navigationslösung. Dieser Genauigkeitsverlust wurde am Beispiel eines SAR/TRN/GPS/INS-Systems untersucht. Es konnte simulativ gezeigt werden, dass der Genauigkeitsverlust relativ gering ist und durch die genannten Vorteile des Federated Filters in vielen Fällen überwogen wird. Zusätzlich wird eine sehr einfache und effektive Methode zur Verbesserung der Gewichtung der lokalen Filterlösungen gezeigt. Besonders das GPS/INS-Filter zeigt aufgrund von zeitlich korrelierten GPS-Messungen typischerweise ein überoptimistisches Verhalten, das zu einer zu starken Gewichtung des GPS/INS-Filters im Master-Filter führt. Durch eine einfache Korrektur der Kovarianz dieses Filters konnte die Gewichtung angepasst und die Positionsschätzung des Federated Filters verbessert werden.

1. EINLEITUNG

Ziel dieses Papers ist ein Vergleich zwischen zentralem Kalman-Filter und Federated Filter am Beispiel eines in zukünftigen Unmanned Aerial Vehicles (UAV) eingesetzten multisensoriellen Navigationssystems, das GPS-Messungen, Radarhöhenmessungen (TRN) und Landmarkendetektionen aus Synthetic Aperture Radar (SAR) Aufnahmen mit einem inertialen Navigationssystem (INS) fusioniert. Das angesprochene Federated Filter bildet eine Unterklasse der dezentralen Kalman-Filter. Im Gegensatz zum herkömmlichen zentralen Kalman-Filter besteht das Federated Filter aus mehreren parallelen, lokalen Kalman-Filtern, die jeweils einzelne Sensoren mit dem inertialen Navigationssystem (INS) fusionieren. Ein sogenanntes Master-Filter fügt anschließend die Schätzwerte der lokalen Filter in optimaler Weise zu einer Gesamtlösung zusammen. Im Unterschied zu anderen dezentralen Filtermethoden wird im Federated Filter das Prinzip der Informationsteilung angewandt. Da die Messwerte der inertialen Messeinheit (IMU) in jedem lokalen Filter verarbeitet werden, wird das Systemrauschen der lokalen Filter mit der Anzahl der lokalen Filter multipliziert. Dies ist gleichbedeutend mit einer gleichmäßigen Aufteilung der IMU-Information, womit eine mehrfache Verwendung der Messwerte berücksichtigt und eine überoptimistische Gesamtlösung vermieden wird.

Dezentrale Filter bieten Vorteile gegenüber einem zentralen Kalman-Filter. Ein entscheidender Vorteil ist deren Modularität und Flexibilität. So können verschiedene existierende Systeme, wie beispielsweise ein GPS/INS-Filter und ein TRN/INS-Filter, zu einem multisensoriellen Navigationssystem zusammengefügt werden, ohne genauere Kenntnis über die einzelnen Filter zu besitzen. Das Federated Filter im No-Reset-Mode

bietet weitere Vorteile im Bereich der Fehlerdetektion, was speziell in UAVs ein sehr wichtiges Kriterium darstellt. Aufgrund von mehreren parallelen und unabhängigen lokalen Filtern kann ein fehlerhaftes Filter mittels der weiteren lokalen Filter erkannt werden. Das fehlerhafte Filter wird anschließend nicht weiter zur Bestimmung der Gesamtlösung herangezogen und kann gegebenenfalls neu initialisiert werden. Ein nicht erkannter Messfehler im herkömmlichen zentralen Kalman-Filter würde hingegen sofort die Navigationslösung verfälschen. Besonders bei kleinen oder schleichenden Fehlern, die zunächst schwer erkannt werden können, zeigt das Federated Filter Vorteile [3-4].

Demgegenüber stehen Nachteile des Federated Filters. Die Navigationslösung des Federated Filters ist üblicherweise aufgrund der konservativ getunten lokalen Filter geringfügig ungenauer. Außerdem profitieren verschiedene Sensoren durch die unabhängigen lokalen Filter nicht voneinander. Dieser Genauigkeitsverlust wurde am Beispiel eines SAR/TRN/GPS/INS-Systems untersucht. Es konnte simulativ gezeigt werden, dass der Genauigkeitsverlust relativ gering ist und durch die genannten Vorteile des Federated Filters in vielen Fällen kompensiert wird. Zusätzlich wird eine sehr einfache aber effektive Methode zur Verbesserung der Gewichtung der lokalen Filter gezeigt. Besonders das GPS/INS-Filter zeigt aufgrund von zeitlich korrelierten GPS-Messungen typischerweise ein überoptimistisches Verhalten, das zu einer zu starken Gewichtung des GPS/INS-Filters im Master-Filter führt. Durch eine einfache Anpassung der Kovarianz dieses Filters konnte die Gewichtung angepasst und die Positionsschätzung des Federated Filters verbessert werden.

In den folgenden Abschnitten werden zunächst die Filtermethoden sowie die Modellierung der Sensoren kurz

vorgestellt. Anschließend werden beide Filter anhand verschiedener Simulationsläufe miteinander verglichen. Danach wird näher auf das durch die Kovarianzanpassung modifizierte Federated Filter eingegangen sowie Simulationsergebnisse dieses Filters gegeben. Abschließend folgt eine Zusammenfassung.

2. ZENTRALES KALMAN-FILTER

Das bekannte zentrale Kalman-Filter ist unter Einhaltung verschiedener Randbedingungen ein Optimalfilter. Das System- wie auch das Messraschen sind als weiß, normalverteilt und zeitlich unkorreliert vorausgesetzt. Zusätzlich müssen die Voraussetzung der Unkorreliertheit von Mess- und Systemrauschen und die Voraussetzung der Linearität von System- und Messmodell eingehalten werden. In vielen Fällen können diese Voraussetzungen jedoch nicht vollständig eingehalten werden. Üblicherweise sind System- und Messmodelle nichtlinear und müssen über das erweiterte (engl: extended) Kalman-Filter (EKF) berücksichtigt werden. Existieren nur schwache Nichtlinearitäten, so kann das EKF als quasi-optimales Filter betrachtet werden, weshalb das zentrale EKF in diesem Paper als Vergleichsmaßstab zur Beurteilung des Federated Filters eingesetzt werden kann.

Das Kalman-Filter ist ein rekursiver Schätzer mit den Schritten Prädiktion und Estimation. Während der Prädiktion werden der Filterzustand und die zugehörige Kovarianzmatrix nach den Gleichungen (1) und (2) zeitlich fortgeschrieben. Der zukünftige Zustand \hat{x}_{k+1}^- des Filters ist abhängig vom aktuellen Zustand \hat{x}_k^+ sowie dem Systemeingang \tilde{u}_k . Die zukünftige Kovarianz ist abhängig von der aktuellen Kovarianz P_k^+ und dem Systemrauschen Q_k . Die Transitionsmatrix Φ_k entspricht der Jakobi-Matrix der Systemfunktion $f_k(\cdot)$ an der Stelle des aktuellen Zustands.

$$(1) \quad \hat{x}_{k+1}^- = \tilde{f}_k(\hat{x}_k^+, \tilde{u}_k)$$

$$(2) \quad P_{k+1}^- = \Phi_k P_k^+ \Phi_k^T + G_k Q_k G_k^T$$

Während der Estimation bzw. des Messschritts wird die aktuelle Zustandsschätzung durch Sensormesswerte \tilde{y}_k nach Gleichung (4) korrigiert, wobei die optimale Gewichtungsmatrix K_k in Gleichung (3) den aktuellen Einfluss der Messwerte abhängig von dessen Unsicherheit R_k bestimmt. Die Kovarianz der Zustandsschätzung verkleinert sich durch den Messschritt nach Gleichung (5)

$$(3) \quad K_k = P_k^- H_k^T (H_k P_k^- H_k^T + R_k)^{-1}$$

$$(4) \quad \hat{x}_k^+ = \hat{x}_k^- + K_k (\tilde{y}_k - \tilde{h}_k(\hat{x}_k^-))$$

$$(5) \quad P_k^+ = (I - K_k H_k) P_k^-$$

Das Blockdiagramm des zentralen Kalman-Filters ist in Bild 1 grob dargestellt. Alle Sensormesswerte der verschiedenen Sensoren werden zentral von einem einzelnen Kalman-Filter verarbeitet.

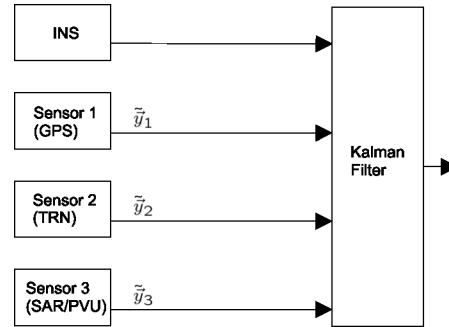


BILD 1. Zentrales Kalman-Filter

3. FEDERATED FILTER

Im Gegensatz zum herkömmlichen zentralen Kalman-Filter besitzt das Federated Filter eine dezentrale Filterstruktur, die mehrere parallele lokale Filter sowie ein Master-Filter umfasst. Das Federated Filter ist ein spezielles dezentrales Kalman-Filter, das das Prinzip der Informationsteilung anwendet und maßgeblich von Carlson [1-2] vorangetrieben wurde. Bild 2 zeigt die grundsätzliche Struktur des Federated Filters.

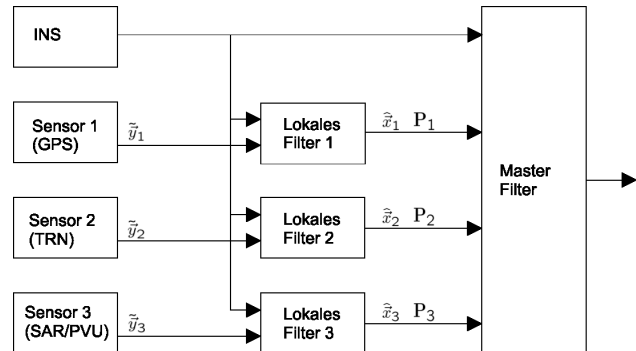


BILD 2. Federated Filter im No-Reset-Mode

Die Sensoren werden mittels eines eigenen lokalen Kalman-Filters mit dem Referenzsystem (INS) fusioniert. Die Gesamtlösung des Master-Filters ergibt sich schließlich aus einer optimalen Kombination der Lösungen der lokalen Filter mittels der Methode der kleinsten Fehlerquadrate. Die globale Navigationslösung des Master-Filters sowie die entsprechende Kovarianz werden nach Gleichungen (7) und (6) in Abhängigkeit der lokalen Zustände und Kovarianzen bestimmt [2].

$$(6) \quad P_M^{-1} = \sum_{i=1}^N P_i^{-1}$$

$$(7) \quad P_M^{-1} \hat{x}_M = \sum_{i=1}^N P_i^{-1} \hat{x}_i$$

Die Inversen der Kovarianzmatrizen werden üblicherweise als Informationsmatrizen bezeichnet. Die Information des Master-Filters in Gleichung (6) ist somit anschaulich die Summe der Informationen der lokalen Filter. In Gleichung (7) geht jede lokale Lösung mit dem Gewicht ihrer eigenen Information in die globale Lösung des Master Filters ein.

Die genannte Fusion der lokalen Lösungen zur globalen Lösung ist jedoch nur optimal unter der Voraussetzung der Unabhängigkeit der lokalen Lösungen. Diese Voraussetzung ist zunächst nicht erfüllt, da jedes lokale Filter dasselbe Referenzsystem verwendet. Es bauen sich dadurch während der Prädiktion Korrelationen zwischen den einzelnen lokalen Lösungen auf, die jedoch nicht bekannt sind. Um die Existenz dieser Korrelationen zu zeigen, kann ein erweitertes Systemmodell angenommen werden. Der Zustand dieses erweiterten Systemmodells umfasst alle Zustände der lokalen Kalman-Filter. Unter Annahme der Linearität der Systemgleichung lässt sich die Prädiktion aller lokalen Filter wie folgt beschreiben:

$$(8) \quad \begin{pmatrix} \hat{x}_1 \\ \hat{x}_2 \\ \hat{x}_3 \end{pmatrix}_{k+1}^- = \begin{pmatrix} \Phi_1 & 0 & 0 \\ 0 & \Phi_2 & 0 \\ 0 & 0 & \Phi_3 \end{pmatrix}_k \begin{pmatrix} \hat{x}_1 \\ \hat{x}_2 \\ \hat{x}_3 \end{pmatrix}_k^+ + \begin{pmatrix} G_1 \\ G_2 \\ G_3 \end{pmatrix}_k \tilde{u}_k$$

Die Kovarianz des zukünftigen erweiterten Zustands ist in Gleichung (9) gezeigt. Es wurde angenommen, dass zum Zeitpunkt k keine Korrelationen zwischen den lokalen Filterlösungen vorhanden sind. Trotz dieser Annahme entstehen diese Korrelationen durch das vollständig korrelierte Systemrauschen.

$$(9) \quad \begin{pmatrix} P_{11}^- & P_{12}^- & P_{13}^- \\ P_{21}^- & P_{22}^- & P_{23}^- \\ P_{31}^- & P_{32}^- & P_{33}^- \end{pmatrix}_{k+1} = \begin{pmatrix} \Phi_1 & 0 & 0 \\ 0 & \Phi_2 & 0 \\ 0 & 0 & \Phi_3 \end{pmatrix}_k \begin{pmatrix} P_{11}^+ & 0 & 0 \\ 0 & P_{22}^+ & 0 \\ 0 & 0 & P_{33}^+ \end{pmatrix}_k \begin{pmatrix} \Phi_1 & 0 & 0 \\ 0 & \Phi_2 & 0 \\ 0 & 0 & \Phi_3 \end{pmatrix}_k + \begin{pmatrix} G_1 & 0 & 0 \\ 0 & G_2 & 0 \\ 0 & 0 & G_3 \end{pmatrix}_k \begin{pmatrix} Q & Q & Q \\ Q & Q & Q \\ Q & Q & Q \end{pmatrix}_k \begin{pmatrix} G_1 & 0 & 0 \\ 0 & G_2 & 0 \\ 0 & 0 & G_3 \end{pmatrix}_k$$

Um die Annahme der Unkorreliertheit der lokalen Zustände treffen zu können, kann das Systemrauschen abgeschätzt werden.

$$(10) \quad \begin{pmatrix} \gamma_1 Q & 0 & 0 \\ 0 & \gamma_2 Q & 0 \\ 0 & 0 & \gamma_3 Q \end{pmatrix} \geq \begin{pmatrix} Q & Q & Q \\ Q & Q & Q \\ Q & Q & Q \end{pmatrix}$$

Die Abschätzung nach Gleichung (10) ist so zu verstehen, dass auf der rechten Seite eine zusätzliche Kovarianzmatrix addiert werden kann, um die linke Seite zu erhalten. Die Kovarianzmatrix kann somit als eine Abschätzung nach oben interpretiert werden. Die Faktoren γ_i in Gleichung (10) müssen die Bedingung in

Gleichung (11) erfüllen. Die Gültigkeit dieser Abschätzung ist in [11] gezeigt.

$$(11) \quad \sum_{i=1}^N \frac{1}{\gamma_i} = 1$$

Dies ist anschaulich so zu verstehen, dass die Information des gemeinsamen Referenzsystems auf die lokalen Filter aufgeteilt wird, wobei der Informationsanteil des i . Filters genau $1/\gamma_i$ beträgt. Die gesamte Information des Referenzsystems bleibt erhalten. Die Prädiktion der Kovarianz der lokalen Filter ist somit:

$$(12) \quad P_{k+1,i}^- = \Phi_{k,i} P_{k,i}^+ \Phi_{k,i}^T + G_{k,i} \gamma_i Q_k G_{k,i}^T$$

Die Multiplikation des Systemrauschens mit γ_i in Gleichung (12) führt zu einem konservativen Tuning der lokalen Filter. Meist werden alle Faktoren γ_i identisch gewählt, sodass alle Faktoren der Anzahl der lokalen Filter entsprechen [1][2]. Es ist jedoch ebenfalls möglich unter Einhaltung von Gleichung (11) unterschiedliche Faktoren zu wählen. So können einzelne lokale Filter weniger konservativ ausgelegt werden. Die Wahl der optimalen γ_i gestaltet sich jedoch meist sehr schwierig. Hier wurden ebenfalls identische γ_i verwendet.

4. SENSOREN

Die erreichbare Genauigkeit beider Filtermethoden wurde am Beispiel eines multisensoriellen Navigationssystems, das GPS-Pseudorange und GPS-Deltarange, Radarhöhenmessungen, SAR-Landmarkenmessungen und Dopplermessungen fusioniert, untersucht. Die Modellierung der genannten Sensoren, die zur Korrektur der Navigationslösung herangezogen werden, ist in den folgenden Abschnitten erläutert.

4.1. Global Positioning System

Meist werden in multisensoriellen Navigationssystemen inertielle Messeinheit und GPS fusioniert. Es wurde ein typischer GPS-Pseudorange und GPS-Deltarange-Messschritt verwendet (tightly coupled). Innerhalb der Simulationsumgebung wurden die Pseudoranges nach folgender Gleichung modelliert:

$$(13) \quad \tilde{\rho}_j = \rho_j + c\delta t_U + v_{\rho_j}$$

Die gemessene Pseudorange setzt sich zusammen aus tatsächlichem Abstand von GPS-Satellit und GPS-Empfänger, GPS-Uhrenfehler des Empfängers sowie weiteren Fehlerquellen. Hauptfehlerquellen der Pseudorange-Messung sind unter anderem die atmosphärischen Fehler, die sich aus Ionosphärenfehler und Troposphärenfehler zusammensetzen. Beide atmosphärischen Fehler wurden als zeitkorrelierte Gauß-Markov-Prozesse mit einer Korrelationszeit von einer Stunde modelliert.

Die Deltarange-Messung wurde äquivalent durch Addition des Uhrenfehlerdrifts und Aufbringen von weiteren

Fehlerquellen modelliert, die einen weißen Rauschterm sowie einen beschleunigungsabhängigen Fehler enthalten.

$$(14) \quad \dot{\hat{p}}_j = \dot{p}_j + c\delta i_U + v\dot{p}_j$$

Zur Bestimmung des GPS-Uhrenfehlers sowie des GPS-Uhrenfehlerdrifts wurde folgendes zeitkontinuierliches Modell verwendet. Die Rauschterme wurden als gaußsches, weißes Rauschen angenommen.

$$(15) \quad \begin{pmatrix} t_U \\ i_U \end{pmatrix} = \begin{pmatrix} 0 & 1 \\ 0 & 0 \end{pmatrix} \begin{pmatrix} t_U \\ i_U \end{pmatrix} + \begin{pmatrix} w_e \\ w_d \end{pmatrix}$$

Das zentrale Kalman-Filter sowie das Federated Filter verarbeiten Pseudorange und Deltarange sequenziell mit einem Updateintervall von einer Sekunde.

4.2. Terrain Referenced Navigation System

Im Gegensatz zu GPS ist ein Terrain Referenced Navigation System (TRN) unabhängig von externen Signalen. In einem TRN-System werden Messungen der Höhe des Flugzeugs über Grund zur Stützung der Navigationslösung verwendet. Als Sensoren werden üblicherweise Radarhöhenmesser aber auch Laser eingesetzt. In diesem Paper wurde ein Radarhöhenmesser angenommen.

Ein Radarhöhenmesser wertet zur Höhenmessung die erste Reflektion vom Erdboden eines zuvor ausgesandten Signals aus. Die Höhenmessung entspricht demnach immer dem kürzesten Abstand von Flugzeug zur Erdoberfläche. Dabei wird angenommen, dass der Abstand genau der Differenzhöhe zwischen Flugzeug und Nadirpunkt entspricht. Diese Annahme kann getroffen werden, da üblicherweise relativ große Antennenöffnungswinkel verwendet werden, sodass sich der Nadirpunkt auch bei vorhandenen Roll- oder Pitchwinkeln innerhalb der Antennenkeule befindet.

Die Radarhöhenmessungen wurden nach Gleichung (16) synthetisiert. Die gemessene Höhe setzt sich zusammen aus der Differenz von Flugzeughöhe h_A und Geländehöhe am Nadirpunkt $h_{Terrain}$ und einem zusätzlichen Rauschterm v_{Radar} . Das Rauschen des Radars wird meist höhenabhängig modelliert und besitzt hier eine Standardabweichung von 1.5% der aktuellen Höhe über Grund.

$$(16) \quad \tilde{h}_{Radar} = h_A - h_{Terrain} + v_{Radar}$$

Zur Verarbeitung der Radarhöhenmessung existieren grundsätzlich zwei verschiedene Verfahren. Diese sind zum einen die blockweise Verarbeitung, zum anderen die sequenzielle Verarbeitung der Höhenmessungen. Verschiedene Methoden sind in [7] und [8] dargestellt. Üblicherweise zeigt die blockweise Verarbeitung Vorteile während der Akquisitionsphase, während sequenzielle Methoden gute Positionsschätzungen ermöglichen, falls schon eine ausreichend genaue Positionslösung zur Berechnung des Geländegradienten zur Verfügung steht. Der Hauptvorteil der sequenziellen Verarbeitung liegt jedoch darin, dass sie relativ wenig Rechenlast erzeugt.

Während der sequenziellen Verarbeitung der Radarhöhenmesswerte wird jeder Höhenmesswert separat genutzt. Während des Updates wird zunächst die Differenz von gemessener Höhe über Grund und aktuell geschätzter Höhe über Grund, die aus Höhengschätzung und Referenzdaten gewonnen wird, bestimmt. Diese Differenz geht über die Kalman-Verstärkungsmatrix nach Gleichung (4) zur Korrektur in den Zustand ein. Zur Bestimmung der K-Matrix ist jedoch die Messmatrix H erforderlich, die die Jakobi-Matrix der Messfunktion darstellt. Die Ableitung der Messfunktion, die dem Geländegradient entspricht, kann jedoch nicht analytisch berechnet werden, sondern wird anhand der Referenzkarte und der vorherigen Positionsschätzung bestimmt. Hierzu ist eine möglichst genaue Positionsschätzung notwendig, die einen Fehler von einigen hundert Meter nicht überschreiten sollte. Andernfalls kann eine stabile Positionslösung nicht garantiert werden.

4.3. Synthetic Aperture Radar

Als dritter Sensor zur Stützung der Navigationslösung wurde ein Synthetic Aperture Radar (SAR) angenommen. Ein SAR liefert zweidimensionale Aufnahmen in Range- und Doppler-Koordinaten, in denen aus einer Referenzkarte bekannte und eindeutige, natürliche oder künstliche Landmarken entdeckt und zur Korrektur herangezogen werden können. Als Landmarken eignen sich gut sichtbare Merkmale wie beispielsweise Straßenkreuzungen und Flussläufe, die im SAR-Bild dunkler als die Umgebung erscheinen, da die ausgesandte Radarstrahlung an ihrer eher glatten Oberfläche wegreflektiert wird und sehr wenig Energie zur Radarantenne zurückgestreut wird. Die eindeutige und sichere Erkennung solcher Landmarken ist jedoch eine der schwierigsten Aufgaben der Navigationsstützung mittels SAR. In [5] wurde angenommen, dass Landmarken von einem „Operator“ erkannt werden. In [9] und [10] wurden dagegen Methoden des Matchings von Landmarken und SAR-Aufnahmen beziehungsweise des Matchings von optischen Bildern und SAR-Aufnahmen untersucht. Bild 3 zeigt beispielhaft eine Landmarke in einer SAR-Aufnahme.




BILD 3. Beispiel einer Landmarke

Sobald eine eindeutige und bekannte Landmarke entdeckt ist, kann diese zur Korrektur der Navigationslösung verwendet werden. Zu einer

detektierten Landmarke kann eine Range-Messung und eine Range-Rate-Messung generiert werden, die mittels Kalman-Filter mit dem Referenzsystem fusioniert wird. Layne beschrieb in [5] ein Modell zur realistischen Erzeugung von Range- und Range-Rate-Messungen unter Berücksichtigung verschiedener Fehlerquellen des SAR-Sensors sowie der Fehlerquellen des Matchings.

$$(17) \quad \tilde{r}_{SAR} = r_{SAR} + v_{r_{SAR}}$$

$$(18) \quad \dot{\tilde{r}}_{SAR} = \dot{r}_{SAR} + v_{\dot{r}_{SAR}}$$

Die Fehlerquellen $v_{i_{SAR}}$ und $v_{r_{SAR}}$ des SAR-Sensors wurden nach [5] modelliert und umfassen in der Simulationsumgebung Timingfehler, Quantisierungsfehler, Doppler-Messfehler und Unsicherheiten der Sendefrequenz sowie der Lichtgeschwindigkeit. Zusätzliche Fehler entstehen durch eine ungenaue Position der Referenzlandmarke und Unsicherheiten des Matchingprozesses zwischen SAR-Aufnahme und Referenzlandmarke.

Während des Messschritts werden erwartete Range und erwartete Range-Rate nach Gleichungen (19) und (20) berechnet.

$$(19) \quad \hat{r}_{SAR} = |\hat{\vec{p}}_A - \vec{p}_L|$$

$$(20) \quad \hat{\dot{r}} = -\hat{\vec{u}}_{LA}^T \cdot \hat{\vec{v}}_A$$

Die Range entspricht dem Betrag der Positionsdivergenz von Flugzeugposition und Landmarkenposition der Referenzkarte. Die Range-Rate entspricht der Projektion der Flugzeuggeschwindigkeit in Richtung der Landmarke. $\hat{\vec{u}}_{LA}$ beschreibt hier den Einheitsvektor von Flugzeug in Richtung der Landmarke. Die Differenz von erwarteter Messung und tatsächlicher Messung geht anschließend nach (4) über die Kalman-Verstärkungsmatrix zur Korrektur in die Zustandsschätzung ein. Der Kalman-Messschritt des SAR ist sehr ähnlich zum GPS-Pseudorange- und Delta-Range-Messschritt. Im Unterschied zu GPS wird jedoch die Abhängigkeit der Range-Rate von der Flugzeugposition in der Messmatrix mit berücksichtigt [5].




BILD 4. SAR-Geometrie

Zur eindeutigen Bestimmung der Position und Geschwindigkeit des Flugzeugs mittels SAR sind mehrere (mindestens drei) Landmarkenmessungen in unterschiedlichen Richtungen notwendig. Hier wurde angenommen, dass gelegentliche Landmarkenmessungen in Intervallen von 200 Sekunden auftreten. Während dieser Zeitdauer müssen Positions- und Geschwindigkeitsfehler gering gehalten werden, weshalb SAR oft mit weiteren Stützsensoren z.B. einem Doppler-Radar [1] kombiniert wird.

Ein Doppler-Radar ermöglicht durch Doppler-Messungen in mindestens drei Richtungen die Bestimmung der dreidimensionalen Geschwindigkeit in körperfesten Koordinaten. Meist werden Doppler-Messungen mittels einer Janus-Konfiguration in 4 verschiedenen Richtungen verwendet [12].

Durch die Verwendung von Doppler-Messungen, auch Precision Velocity Update (PVU) genannt, wird ein zu schnelles anwachsen von Positions- und Geschwindigkeitsfehlern verhindert, sodass größere Zeiträume ohne SAR-Landmarkendetektionen überbrückt werden können. Doppler-Messungen führen bei Kenntnis der Lage zu einer langzeitgenauen Geschwindigkeitslösung und einem nährungsweise nur linear wachsenden Positionsfehler.

5. SIMULATIONSERGEBNISSE

Beide Filtervarianten wurden über Simulationsläufe anhand des gegebenen multisensoriellen Systems miteinander verglichen. Alle lokalen Filter des implementierten Federated Filters besitzen 15 gemeinsame Zustandsgrößen, die Positions-, Geschwindigkeits- und Lagefehler sowie alle Biasfehler der Inertialsensoren umfassen. Zusätzlich enthält der Zustandsvektor des GPS/INS-Filters den GPS-Uhrenfehler und die Drift des GPS-Uhrenfehlers. Das SAR/INS-Filter schätzt zusätzlich die Ausrichtungsfehler der PVU-Antenne. Im Master-Filter werden ausschließlich die gemeinsamen Zustandsvariablen aller lokalen Filter fusioniert. Das entsprechende zentrale Kalman-Filter, das als Referenz dienen soll, besitzt einen Zustandsvektor der alle genannten Größen umfasst.

Die Messwerte der IMU sowie der weiteren beschriebenen Sensoren wurden synthetisch durch Beaufschlagung von realistischen Fehlertermen auf die wahren Werte generiert. In allen Simulationsläufen wurden die Fehlerterme einer typischen tactical grade IMU angenommen. Die Standardabweichung des Rauschens des Radarhöhenmessers betrug 1,5% der aktuellen Höhe. Die Matching-Genauigkeit der SAR Landmarken wurde zu 5 Metern angenommen und die Standardabweichung des Rauschens der Doppler-Geschwindigkeitsmessung betrug 0,3% der aktuellen Geschwindigkeit.

Um aussagekräftige Ergebnisse zu erhalten wurden jeweils 25 Monte-Carlo-Durchläufe simuliert. Die gezeigten Plots enthalten die RMS-Werte dieser Simulationsläufe.

Bilder 5-7 zeigen gemittelte Positions-, Geschwindigkeits-, und Lagefehler des Federated Filters im Vergleich zum zentralen Kalman-Filter. Die Positionsgenauigkeit beider Filtertypen ist nahezu identisch und hängt fast

ausschließlich von der GPS-Genauigkeit ab. Geschwindigkeitsfehler und Lagefehler des Federated Filters sind jedoch wie erwartet leicht größer.

Bilder 8-10 zeigen Positions-, Geschwindigkeits- und Lagefehler bei einem GPS-Ausfall zwischen der 1000. und 1550. Sekunde. Beide Filtertypen reagieren ähnlich auf den Ausfall, wobei das Federated Filter auch hier leicht größere Fehler aufweist. Während des GPS-Ausfalls werden die Schätzfehler durch SAR und TRN begrenzt. Besonders die Korrekturen durch SAR in der 1200. Sekunde und der 1400. Sekunde sind gut zu sehen.




BILD 5. Positionsfehler




BILD 6. Geschwindigkeitsfehler




BILD 7. Lagefehler

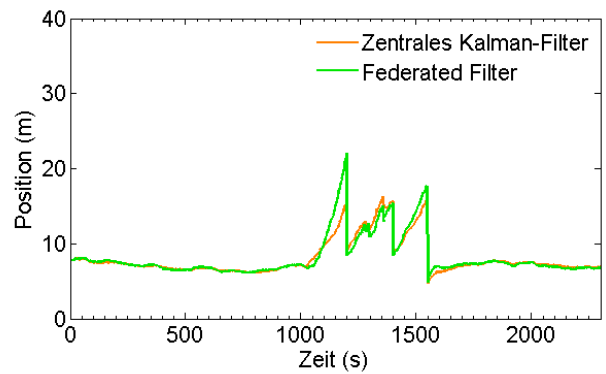


BILD 8. Positionsfehler bei GPS-Ausfall




BILD 9. Geschwindigkeitsfehler bei GPS-Ausfall

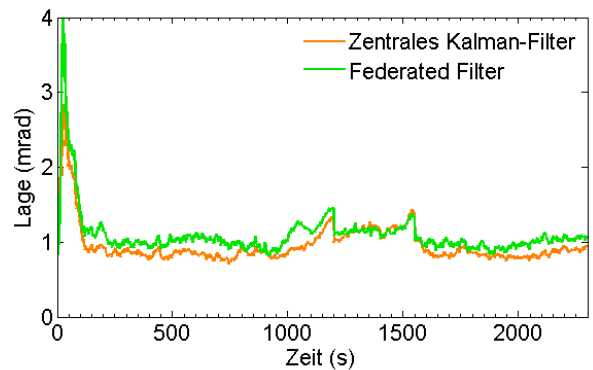


BILD 10. Lagefehler bei GPS-Ausfall

6. MODIFIKATION DES FEDERATED FILTERS

Bei der Fusion der Lösungen der lokalen Filter zur globalen Navigationslösung ist vor allem das Filtertuning von entscheidender Bedeutung, um möglichst realistische Kovarianzen P_i der lokalen Filter zu bestimmen. Stimmen die lokalen Kovarianzen nicht mit den tatsächlichen Unsicherheiten der lokalen Zustände \hat{x}_i überein, werden die lokalen Zustände im Master-Filter durch Gleichungen (6) und (7) in einer suboptimalen Weise fusioniert.

Neben schlechtem Filtertuning können unrealistische Kovarianzen durch zeitkorrelierte Messungen auftreten. Das Kalman-Filter geht immer von unkorrelierten Messungen aus und liefert nur unter dieser Bedingung optimale Schätzergebnisse. Zeitkorrelationen führen zu einer überoptimistischen Kovarianzmatrix, da sich korrelierte oder gar konstante Messfehler nur schwach bzw. nicht mitteln. Die Kovarianz sinkt jedoch auf einen zu tiefen Wert, da das Filter von unkorrelierten Messungen ausgeht.

Dieses Verhalten ist besonders in der Positionslösung des lokalen GPS/INS-Filters aufgrund von langzeitkorrelierten atmosphärischen Fehlern der GPS-Pseudorangemessung zu beobachten. Die Korrelationszeiten der atmosphärischen Fehler, die Troposphärenfehler sowie Ionosphärenfehler beinhalten, bewegen sich in der Größenordnung von einer Stunde. Die Bilder 11-13 zeigen die Positionsfehler aller lokalen Filter in Ostrichtung. Es ist zu sehen, dass das SAR/INS-Filter sowie das TRN/INS-Filter realistische Werte für die Standardabweichung bestimmen. Die Standardabweichung des GPS/INS-Filters ist jedoch signifikant kleiner als der tatsächliche Fehler der Navigationslösung. Dies führt im Master-Filter zu einer zu starken Gewichtung der GPS/INS-Lösung. Dadurch kann auch erklärt werden, warum die Positionslösung in Bild 5 des zentralen und des Federated Filter sehr stark von der GPS-Genauigkeit abhängt und die Positionskorrekturen der anderen Sensoren praktisch nicht berücksichtigt werden.

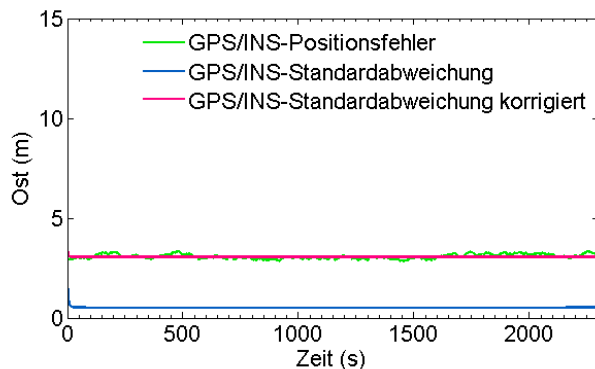


BILD 11. Positionsfehler des GPS/INS-Filters in Ostrichtung

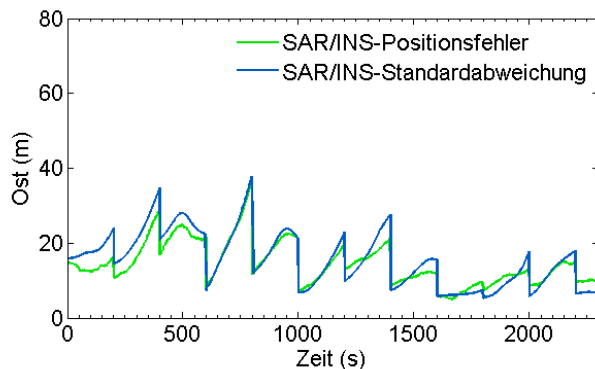


BILD 12. Positionsfehler des SAR/INS-Filters in Ostrichtung

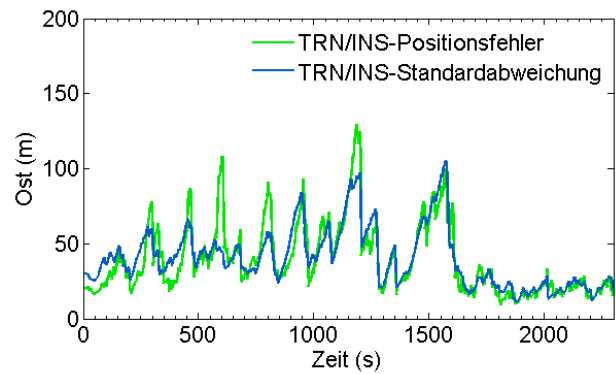


BILD 13. Positionsfehler des TRN/INS-Filters in Ostrichtung

Es ist aus diesem Grund notwendig, realistische Kovarianzen der lokalen Filter zu bestimmen. In der Literatur werden unterschiedliche Ansätze genannt um Zeitkorrelationen im Kalman-Filter zu berücksichtigen bzw. deren negative Auswirkung abzuschwächen. Dazu gehören die Vergrößerung des Messintervalls, die Schätzung von Rauschparametern des zeitkorrelierten Rauschens oder die Verwendung eines Schmidt-Kalman-Filters.

- 1) Die einfachste Möglichkeit besteht in der Vergrößerung des Messintervalls, wobei die Zeitdauer zwischen zwei Messschritten der Korrelationszeit entsprechen sollte. Diese Methode ist jedoch nur für relativ kurze Korrelationszeiten praktikabel einsetzbar. Durch Vergrößerung des Messintervalls steigen gleichzeitig die Konvergenzzeit des Filters sowie dessen Ungenauigkeit.
- 2) Eine weitere Methode zur Berücksichtigung der Zeitkorrelationen ist die Aufnahme der Parameter des zeitkorrelierten Rauschens in den Zustandsvektor. Die Rauschparameter sind jedoch in vielen Fällen nicht beobachtbar.
- 3) Das Schmidt-Kalman-Filter kommt ohne eine Erweiterung des Zustandsvektors aus. Hier werden lediglich Kovarianzen der Rauchparameter sowie deren Korrelationen mit den ursprünglichen Filterzuständen berechnet und berücksichtigt. Durch Verwendung des Schmidt-Kalman-Filters steigt jedoch die Komplexität des Systems.

Es wird hier deshalb eine weitere, sehr einfache und effektive Methode zur Berücksichtigung des zeitkorrelierten Rauschens vorgestellt. Wie bereits beschrieben, führen zeitkorrelierte Messungen zu überoptimistischen (zu kleinen) Kovarianzmatrizen der lokalen Filter. Diese zu kleinen Kovarianzen können durch Addition einer zusätzlichen Kovarianz auf einen realistischen Wert angehoben werden. Das Master-Filter ist damit in der Lage die lokalen Filterlösungen optimaler zu gewichten und zu fusionieren. Bild 5 zeigt das Prinzip dieses Korrekturschritts.

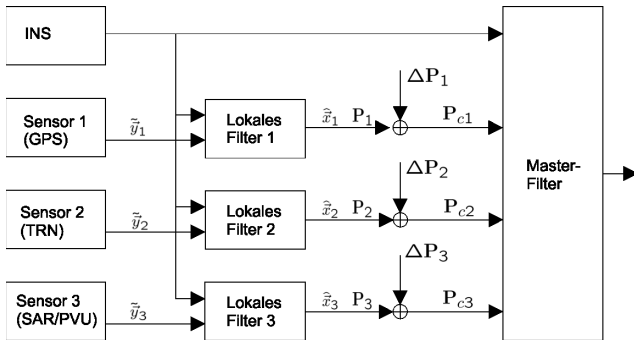


BILD 14. Modifiziertes Federated Filter mit Anpassung der Kovarianzen

Die von den lokalen Filtern bestimmten Kovarianzen P_i werden nach Gleichung (21) über die zusätzliche Kovarianz ΔP_i korrigiert.

$$(21) \quad P_{ci} = P_i + \Delta P_i$$

Die daraus resultierende korrigierte Kovarianz wird anschließend vom Master-Filter zur Fusion der lokalen Lösungen nach Gleichungen (22) und (23) in der üblichen Weise verwendet.

$$(22) \quad P_M^{-1} = \sum_{i=1}^N P_{ci}^{-1}$$

$$(23) \quad P_M^{-1} \hat{x}_M = \sum_{i=1}^N P_{ci}^{-1} \hat{x}_i$$

Die zusätzliche Kovarianz besitzt Diagonalgestalt und konnte über vorherige Simulationsläufe empirisch ermittelt werden. Der p. Eintrag dieser Kovarianz entspricht genau der Differenz aus tatsächlichem mittleren quadratischen Schätzfehler des p. Zustands und der vom lokalen Filter ermittelten Varianz dieses Zustands.

$$(24) \quad \Delta P_i^p = \frac{1}{K} \sum_{k=k_0}^{K+k_0-1} (\hat{x}_{k,i}^p - \bar{x}_{k,i}^p)(\hat{x}_{k,i}^p - \hat{x}_{k,i}^p)^T - P_{k,i}^p$$

Im Beispiel des hier vorgestellten multisensoriellen Navigationssystems wurden lediglich die überoptimistischen Positionseinträge der Kovarianz des lokalen GPS/INS-Filters durch eine zusätzliche Kovarianz korrigiert. Die zusätzliche Kovarianz besitzt somit die Form nach Gleichung (25).

$$(25) \quad \Delta P_1 = \begin{pmatrix} \Delta P_{nn} & 0 & 0 & \cdot & 0 \\ 0 & \Delta P_{ee} & 0 & \cdot & 0 \\ 0 & 0 & \Delta P_{dd} & \cdot & 0 \\ \cdot & \cdot & \cdot & \cdot & \cdot \\ 0 & 0 & 0 & \cdot & 0 \end{pmatrix}$$

Alle anderen Kovarianzeinträge des GPS/INS-Filters sowie die Kovarianzen des SAR/INS und des TRN/INS-Filters entsprechen den tatsächlichen Fehlern und wurden deshalb nicht verändert.

Bild 15 bis Bild 17 zeigen die Positions-, Geschwindigkeits- und Lagefehler des Federated Filters mit und ohne Korrektur der Kovarianz. Die globale Positionslösung des Master Filters konnte signifikant verbessert werden. Die gesamte Positionslösung hängt nicht mehr nahezu ausschließlich von GPS ab, sondern profitiert von den weiteren Sensoren. Geschwindigkeits- und Lageschätzung bleiben durch diese Korrektur weitgehend unverändert.




BILD 15. Positionsfehler des modifizierten Federated Filters im Vergleich zum zentralen Kalman-Filter




BILD 16. Geschwindigkeitsfehler des modifizierten Federated Filters im Vergleich zum zentralen Kalman-Filter




BILD 17. Lagefehler des modifizierten Federated Filters im Vergleich zum zentralen Kalman-Filter

Die hier beschriebene Methode der Korrektur führt nicht zu einer verlängerten Konvergenzzeit und ist sehr einfach zu implementieren. Alle lokalen Filter bleiben unverändert. Die zusätzlich notwendige Rechenleistung ist vernachlässigbar.

7. ZUSAMMENFASSUNG

Die Ergebnisse haben gezeigt, dass die Positionsgenauigkeit von zentralem Kalman-Filter und Federated Filter sehr ähnlich ist und hauptsächlich von der Positionsgenauigkeit des GPS abhängen. Geschwindigkeits- und Lageschätzung des Federated Filters sind dagegen leicht schlechter. Die genannten Vorteile des Federated Filters, wie Modularität und verbesserte Fehlerdetektionseigenschaften, wiegen diesen Nachteil jedoch in vielen Fällen auf.

Die gezeigte Modifikation des Federated Filters, bei der die zu kleinen Kovarianzen angehoben wurden, führte zu einer verbesserten Gewichtung der lokalen Filterlösungen. Die Positionsgenauigkeit könnte damit signifikant verbessert werden. Die zusätzlich benötigte Rechenleistung ist vernachlässigbar.

8. SCHRIFTTUM

[1] Carlson, Neil A., "Federated Filter for Distributed Navigation and Tracking Applications", Proceedings of the ION 58th Annual Meeting, 2002, 340-353.

[2] Carlson, Neil A., "Federated Filter for Fault-Tolerant Integrated Navigation Systems", IEEE Position Location and Navigation Symposium, 1988, 110-119.

[3] Lawrence, Paul J.; Berarducci Michael P., "Navigation Sensor, Filter, and Failure Mode Simulation Results Using the Distributed Kalman Filter Simulator (DKFSIM)", IEEE Position Location and Navigation Symposium, 1996, 697-710.

[4] Lawrence, Paul J.; Berarducci Michael P., "Comparison of Federated and Centralized Kalman Filters with Fault Detection Considerations", IEEE Position Location and Navigation Symposium, 1994.

[5] Layne, Jeff R.; Paschall Randall N. "Performance Analysis of an Integrated SAR/GPS/INS Targeting and Navigation System," Institute of Navigation, 50th Annual Meeting, 1994.

[6] Deng, Zi-Li; Gao, Yuan; Mao, Lin; Li, Yun; Hao, Gang. "New approach to information fusion steady-state Kalman filtering", Automatica 2005, vol. 41, no 10, 1695-1707.

[7] Metzger, Jürgen; Maier, Andreas; Trommer, Gert F. "Comparison of Modular and Central Terrain Referenced Navigation Filters", 13th Saint Petersburg International Conference on Integrated Navigation Systems, 2006

[8] Metzger, Jürgen; Andreas Maier; Trommer, Gert F. "Non-linear stochastic filters for terrain referenced navigation using directional distance measurements", European Navigation Conference, 2006

[9] Caves, Ronald G; Harley, Peter J.; Quegan, Shaun, "Matching Map Features to Synthetic Aperture Radar (SAR) Images Using Template Matching", IEEE Transactions on Geoscience and Remote Sensing, 1992, 680-685.

[10] Li, Yang; Xin, Yuan; ShuHua, Wang. "Fast SAR image matching algorithm in navigation system", IEEE Aerospace Conference, 2003 Proceedings, 2003, 4_1639-4_1645.

[11] Paik, B.S.; Oh, J.H. "Gain fusion algorithm for decentralized parallel Kalman filters," Control Theory and Applications, IEE Proceedings, 2000.

[12] Fried, W.R.; Buell, H. and Hager, J.R. "Doppler and Altimeter Radars", in Avionics Navigation Systems, 2nd edition, Kayton M. and Fried W.R., New York: Wiley, 1997, 449-502.