

VIZUÁLIS INERCIÁLIS NAVIGÁCIÓ IDŐSZAKOS VAGY HAMISÍTOTT GPS INFORMÁCIÓVAL

Az elmúlt évtizedekben a pilóta nélküli légi járművek (Unmanned Aerial Vehicle, UAV) egyre népszerűbbé váltak civil, akadémiai és hadászati alkalmazásokban is, mint például felderítés, áruszállítás, geofizikai adatgyűjtés, mentési műveletek vagy éppen mezőgazdasági célú felhasználás. Az előrelépés nemcsak a technikai modernizációnak köszönhető, hanem a szélesebb körű felhasználhatóságnak, ami nagyban a hagyományos navigációs módszerek innovációjának köszönhető. A UAV-k jövőre gyakorolt hatása azon is múlik, mennyire tudnak jól navigálni GPS (Global Positioning System) nélküli környezetben például kimaradó, zavart (jamming) vagy hamisított (spoofing) jelek esetén.

A mű középpontjában egy vizuális-inerciális navigációs algoritmus áll. A tanulmány során megvalósított rendszer célja meghatározni egy légi jármű pozícióját, orientációját, sebességét és a gyorsulás és szögsebesség szenzor bias értékeit inerciális szenzorrendszer (Inertial Measurement Unit, IMU) -mérések és mono kameraképek alapján.

A javasolt rendszer egy hibaállapot Kálmán-szűrő (Error-State Kalman Filter, ESKF) alapú keretrendszerben hajtja végre az IMU és a kameraadatok integrációját. Az IMU mérésekből a repülőgép pozícióját, sebességét és orientációját lehet becsülni, és ennek korrigálása a kameraképekből nyert információval történik. A korrekció során felhasznált jellegpontok pozíciójának számítására egy háromszögelési eljárást alkalmazunk, az ún. Linear Optimal Sine Triangulation (LOST) módszert.

A tanulmány bemutatja az alap algoritmusok (ESKF és LOST) saját rendszerbe integrálását, és az ehhez kapcsolódó megfontolásokat, illetve prezentálja a navigációs rendszer teljesítményének eredményeit a szimulációs tesztek során.

Kulcsszavak: navigáció, légi jármű, vizuális, inerciális, Kálmán-szűrő

VISUAL-INERTIAL NAVIGATION WITH INTERMITTENT OR SPOOFED GPS INFORMATION

Over the past decades, Unmanned Aerial Vehicles (UAVs) have become increasingly popular in both civilian, academic, and military applications, such as exploration, cargo delivery, geophysical data collection, rescue operations, and agricultural purposes. This expansion required not only technical modernization but also advancement in traditional navigation methods.

The future impact of UAVs also depends on their ability to navigate effectively in GPS (Global Positioning System) -denied environments, for example, scenarios involving signal dropout, jamming, or spoofing.

The work focuses on a visual-inertial navigation algorithm. In this study, the implemented system's goal is to determine an aircraft's position, orientation, velocity, and bias values of the accelerometer and gyroscope based on measurements from an Inertial Measurement Unit (IMU) and monocular camera images.

The proposed system performs the integration of IMU and camera data within an Error-State Kalman Filter (ESKF) framework. The aircraft's position, velocity, and orientation are estimated from IMU measurements, and these estimates are corrected with the information obtained from camera images. During the correction, the positions of feature points are computed through triangulation using a method called Linear Optimal Sine Triangulation (LOST).

The article presents the integration of the foundational algorithms (ESKF and LOST) into the custom-made system along with the related considerations and demonstrates the performance results of the navigation system during simulation tests.

Keywords: *Navigation, aerial vehicle, visual, inertial, Kalman filter*

Bevezetés

A 2000-es évek elejéig a pilóta nélküli légitűzetei (Unmanned Aerial Vehicle, UAV) védelmi és katonai felhasználásban voltak elterjedtek a magas költségük és előállításuk bonyolultsága miatt. Azonban az elmúlt évtizedekben egyre olcsóbbá és elérhetőbbé váltak civil és tudományos alkalmazásokban is. Felhasználásuk nemcsak elterjedtebbé, hanem az általuk elvégezhető feladatok is szélesebb körűvé váltak. Néhány fontosabb alkalmazási területet említve használhatóak például mentési műveletek (ERDOS, D. – ERDOS, A. – Watkins 2013.), adatgyűjtés és geofizikai kutatás (FRAUNDORFER et. al. 2012.), felderítés (AL-KAFF et. al. 2017.) és mezőgazdasági célú feladatok (SALO – TIRRONEN – NERI 2012.) során is.

Ez az előrelépés nemcsak a technikai modernizációnak volt köszönhető, hanem a hagyományos navigációs módszerek fejlődésének is. Egy jelentős mérföldkő a globális helymeghatározó rendszerek (Global Positioning System, GPS) és az inerciális navigációs rendszerek (Inertial Navigation System, INS) kombinálása volt, létrehozva a GPS-INS rendszereket (LEUTENEGGER – SIEGWART 2012.), amelyek a két rendszer előnyös tulajdonságait ötvözik. Ezen rendszerek legnagyobb hátránya, hogy a vevő ki van szolgáltatva a GPS jelvételek minőségének, amely romolhat vagy teljesen elveszhet például:

- városi környezetben: épületek közt (árnyékolás, jelvisszaverődés), alagutakban;
- domborzati viszonyok hatására: hegyek közt;
- időjárási körülmények miatt: felhőzet, viharok, napkitörések;
- ártó emberi beavatkozások befolyására: GPS zavarás (jamming) vagy hamisítás (spoofing).

Ilyen esetekben csak az INS-rendszer használata egyre halmozza a hibát az idő múlásával, különösen alacsony költségű inerciális szenzorrendszerek (Inertial Measurement Unit, IMU) használata esetén. Idővel a rendszer által szolgáltatott becslések teljesen megbízhatatlanok, és ezt drift jelenségnek nevezzük.

Jobb becslések érdekében szenzorfüziót szokás alkalmazni, azaz az IMU és további ún. exteroceptív érzékelők (amik a külvilágról adnak információt) méréseit ötvözzük. A további érzékelő fajtája nagyban az alkalmazástól függ, használható például kamera, lézerekkenner, távolságérzékelő. A kutatás fókuszában a merevszárnyas repülőgépek viselkedése áll. Ezek mozgási dinamikájuknál és küldetési profiljuknál fogva általában magasan a földfelszín felett repülnek relatív nagy sebességgel, ezért a leggyakoribb megoldás kamera használata. Két példát említve a szakirodalomból a ANGELINO – BARANIELLO – CICALA tanulmányában bemutatott munka egy GPS-INS rendszert ötvöz kamera felhasználásával, ELLINGSON – BRINK – MCLAIN munkájukban pedig egy relatív navigációs rendszert mutatnak be, amely IMU- és kameraadatokat fuzionál, illetve könnyedén lehetővé teszi időszakos globális pozíció információ integrálását a rendszerbe.

A navigációs kör bezárása

Abszolút globális pozíció információ hiányában bármelyik IMU és optikai szenzor-alapú algoritmus képtelen bezárni a navigációs hurkot, amely előbb-utóbb a becslések driftjéhez vezet. Ennek oka, hogy az algoritmus nem képes konzisztens és pontos referenciapontokat vagy korlátozásokat létrehozni, amely korlátlanul növekvő kumulatív hibákhoz vezet, még szenzorfüzió alkalmazása esetén is, csak ebben az esetben a jelenség legfeljebb lassabban következik be.

Természetesen a legkézenfekvőbb megoldás valamilyen globális navigációs műholdrendszer (Global Navigation Satellite System, GNSS) használata, mint pl.: az amerikai GPS, az orosz GLONASS, az európai Galileo, vagy a kínai BeiDou. Azonban ezeknek a legnagyobb problémája már említésre került az előző fejezetben, hogy nem mindig elérhetőek.

Egy alternatív megoldás a szimultán lokalizációs és térképező (Simultaneous Localization and Mapping, SLAM) eljárás (GRISSETTI – KÜMMERLE – STACHNISS – BURGARD 2010.), amelynek lényege, hogy a jármű pozíciójának becslése mellett készít egy térképet is a környezetről, így valamilyen jellemző alapján helyfelismerés útján be tudja zárni a navigációs kört. A térkép elkészítéséhez valamilyen külső érzékelő használata szükséges, például kamera alkalmazásával a detektált jellegpontok alapján készíthető térkép. Egyik nagy hátránya, hogy ha nem önmagába záródó a jármű pályája, akkor a térkép pontosítása nem végezhető el.

Egy másik megoldás, amely bemutatásra kerül, a Signals of Opportunity (SOP) világába vezet, amelyeket eredetileg nem navigációs célokra hoztak létre, de mégis felhasználhatóak arra.

SOP-ok lehetnek földi jelek (pld. FM rádió, mobiltelefon, digitális televízió) vagy űrbeli jelek (pld. alacsony Föld körüli pályán keringő (Low Earth Orbit, LEO) műholdak) (NGUYEN – KASSAS 2023.). A földi SOP-ok kognitív navigációt tesznek lehetővé, amely alapelve rendkívül hasonlít a GPS-éhez, ugyanis ismert szinkronizációs szekvenciákat vagy jelzőpontokat szolgáltatnak a használt forrástól, így olyan méréseket szolgáltatnak, mint pld. érkezési idő (Time-of-Arrival, TOA), amely a jel utazási idejét jelzi; érkezési irány (Direction-of-Arrival, DOA), amely a jel irányát adja meg; és érkezési frekvencia (Frequency-of-Arrival, FOA), amely a jel frekvenciájára utal. (NEINAVAIE – KHALIFE – KASSAS 2023.) A LEO műholdak felhasználására NEINAVAIE – KASSAS publikációjában azok szélessávú kommunikációs jeleinek alkalmazását javasolják navigációs célokra.

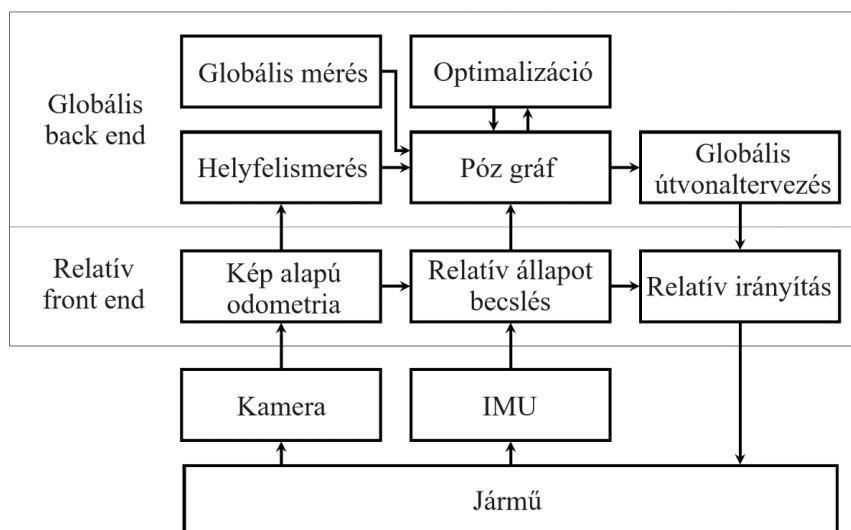
Relatív navigáció

Relatív navigációt többféle eszköz felhasználásával is meg lehet valósítani, viszont ebben a fejezetben a tanulmány témáját adó IMU- és monokamera-alapú megoldást mutatjuk be.

A szenzorfüzió és a zajszűrés valamilyen szűrő keretrendszerben történik, amelyre a leggyakrabban valamilyen módosított Kálmán-szűrőt szoktak használni, mivel a navigációs rendszerek tipikusan nemlineáris rendszerek. Az egyik gyakori megoldás a kiterjesztett Kálmán-szűrő (Extended Kalman Filter, EKF) használata, amely a rendszerdinamika és a mérési egyenlet linearizálását igényli. EKF-megoldásokra számos példa található a szakirodalomban, például a THRUN – BURGARD – FOX által jegyzett tanulmányban robotokhoz, BEARD – MCLAIN írásában pedig légitársaságokhoz. Ezek a megközelítések képesek figyelembe venni mind a szenzorhajókat és a folyamatbizonytalanságot, de csak akkor működnek jól, ha a rendszer számára bizonyos időközönként biztosított valamilyen globális mérés, így a becslésekből a drift rendszeresen eltávolítható. Ha hosszabb ideig nem elérhetőek globális mérések, akkor a globális pozíció és a legyezési szög¹ nem megfigyelhető (WEISS – ACHELIK – LYNEN – CHLI – SIEGWART 2012.), ráadásul jelentős drift felhalmozódása után érkezett globális mérés felhasználása nehezen megoldható, nagy ugrásokat okozhat a becslésekben, bizonyos esetekben a szűrődivergenciát is elősegítheti. Ennek fő oka, hogy a dinamika a driftelt becslések körül van linearizálva, amely a rendszer valós állapotához tartozó dinamikát már nem jól írja le.

Az elmúlt években egy újfajta megoldást javasoltak, a relatív navigációt (WHEELER et. al. 2016.; LEISHMAN – MCLAIN – BEARD 2014.), amely képes kezelni ezeket a megfigyelhetőségi és konzisztenciaproblémákat, amellett, hogy megtartja a Kálmán-szűrő és a szenzorfüzió előnyeit. A megközelítés alapötlete, hogy a navigációs algoritmust egy relatív front endre és egy globális back endre választja szét, a teljes architektúra az 1. ábrán látható.

¹ A jármű északi iránnyal bezárt szöge



1. ábra: Relatív navigáció blokkdiagramja

(FORRÁS: ELLINGSON – BRINK – MCLAIN 2020. 2. oldal, 2. ábra alapján saját szerkesztés)


A tagolás előnye abban rejlik, hogy a front endben implementált szűrő keretrendszer a kamerával relatívan, a helyi környezethez képest végzi a számításokat, így az állapot megfigyelhető marad, és a zajok, perturbációk pontosan reprezentálhatóak Gauss-eloszlású valószínűségi változókkal, amely lehetővé teszi a Kálmán-szűrő számítási előnyeinek kihasználását. A globális back end pedig gyakorlatilag egy térképező algoritmus, amely a front end számításai alapján egy póz gráfot készít, amely hatékonyan képes reprezentálni az időbeli fejlődés nemlinearitásait, és robusztusan optimalizálható időszakos globális mérések vagy helyfelismerés alapján.

Matematikai alapok

Ez a fejezet összefoglal néhány fontosabb matematikai jelölést, formulát, amely feltétlen szükséges a kutatás bemutatásához.

Koordináta-rendszerek

A tanulmányban összesen 3+1 koordináta-rendszer fordul elő, amelyek a 2. ábrán láthatóak.




2. ábra: Alkalmazott koordináta-rendszerek
(saját szerkesztés)

Az első koordináta-rendszer (E) a föld vagy más néven lokalizációs rendszer, de gyakran inerciarendszerként is szoktak rá hivatkozni, mert egy nagyon fontos tulajdonsága, hogy közelítőleg a Newton-féle első és második törvények érvényesek anélkül, hogy bármilyen külső erő jelen lenne. Jelen tanulmányban erre a célra a North-East-Down (NED) koordináta-rendszert alkalmazzuk, amely azért tehető meg, mert az UAV-k tipikusan kis távolságokat, néhány kilométert tesznek meg a küldetésük során, azaz a Föld görbülete elhanyagolható, így ez inerciarendszerként alkalmazható. A koordináta-rendszer origója a Föld egy pontjához rögzített a repülőgép környezetében, és mint neve is mutatja, X-tengelye a geodetikus észak (N), Y-tengelye a geodetikus kelet (E), és Z-tengelye a Föld belseje felé mutat. A jármű lokalizálása mellett ennek a rendszernek a jelentősége az útvonal tervezésben jelenik meg, ugyanis a küldetési kritériumokat pl. a repülési útvonalat ebben a koordináta-rendszerben szokás definiálni.

A második koordináta-rendszer (N) a node rendszer, amely tipikusan a relatív navigációs eljárásokban jelenik meg, ugyanis ez az a koordináta-rendszer, amelyhez képest relatívan működik a front end, de ennek jelentősége csak back end jelenlétében van, és a bemutatott munka illet még nem tartalmaz, így ez a +1. rendszer. A továbbiakban a matematikai jelölésekben mégis megjelenik az N, azonban ez a NED koordináta-rendszerre vonatkozik.


A repülőgép kinematikájának leírásában jelentős szerepet játszik a testrendszer (B), amely megkönnyíti a matematikai formalizálást, illetve alkalmazása azért is hasznos, mert a járműhöz rögzített IMU-k testrendszerben szolgáltatnak méréseket. Origója a repülőgép tömegközéppontjában van, X-tengelye a gép orra, Y-tengelye a jobb félszárny felé mutat Z-tengelye pedig ezekkel jobb sodrású rendszert alkot, amely a 3. ábrán látható.



3. ábra: Testrendszer

(Forrás: De Marco, A. 4. ábra)

Végül, az utolsó koordináta-rendszer a kamerarendszer, amely origója a kamera középpontjához rögzített, és tengelyeinek definíciója a 4. ábrán látható a képsíkhoz képest.



4. ábra: Kamerarendszer és pixel-koordinátarendszer

(Forrás: Kitani 2017. 7. oldal)

Lyukkamera-vetítés

A kamera által látott jellegpontok projekcióját a képsíkra lyukkamera-moddal írjuk le, amelyben a valódi kamerák használata esetén tapasztalható lencsetorzítás hatásait kompenzáltnak tekintjük (ez előzetes kalibrációval tehető meg).

A modellben a kamera apertúrája egy pontként van definiálva, és valójában egy invertált kép keletkezik a $z=0$ sík mögött, azonban matematikailag ekvivalens és szemléletesebb a képsíkot a $z=0$ sík előtt ábrázolni, ez látható a 4. ábrán is.

A projekció egy nemlineáris $h(\mathbf{p}_c^f)$ függvénnyel írható le a kamerarendszerbe transzformált jellegponton (\mathbf{p}_c^f), amely két részből tevődik össze:

1. A jellegpont $\mathbf{p}_c^f = [x_c^f \ y_c^f \ z_c^f]^T$ normalizálása a z_c^f koordináta szerint;
2. A pixel értékek számítása a kameramátrix segítségével, amelynek két paramétere van: a fókusztávolság (f) és a principális pont koordinátái (p_x, p_y):

$$\mathbf{K} = \begin{bmatrix} f & 0 & p_x \\ 0 & f & p_y \\ 0 & 0 & f \end{bmatrix}$$

Felhasználva a két lépést a teljes vetítés:

$$h(\mathbf{p}_c^f) = \mathbf{K} \frac{\mathbf{p}_c^f}{z_c^f} = \bar{\mathbf{u}} = \begin{bmatrix} u \\ v \\ f \end{bmatrix},$$

ahol u és v a mért pixel értékek, a Z koordináta pedig csupán azt mutatja, hogy a pont a képsíkra képződik le.

Kvaterniók

A kvaterniókat eredetileg Sir William Rowan formalizálta a 19. században (HAMILTON 1840.). Manapság számos területen alkalmazzák, például a számítógépes grafika, a robotika, a repülőgép- és űrtechnika területén is.

Röviden, a kvaterniók a kiterjesztett komplex számtérben létező négydimenziós vektorok, és ebben a tanulmányban a forgatások, orientáció leírására szolgáló matematikai eszközök. Használatuknak számos előnye van az Euler-szögekkel vagy a forgatási mátrixokkal szemben, például kevés, 4 paraméterrel leírhatóak; stabilabb és pontosabb számítás érhető el velük, mert elkerülhetőek a szingularitások és a gimbal-lock probléma.

Ha a \mathbf{q} egység hosszú kvaternió az \mathbf{e} egységvektorral definiált tengely körüli θ szögű forgatást írja le, akkor:

$$\mathbf{q} = \begin{bmatrix} \cos\left(\frac{\theta}{2}\right) \\ \sin\left(\frac{\theta}{2}\right) \mathbf{e} \end{bmatrix},$$

és egy \mathbf{v} vektoron alkalmazott forgatás a Hamiltoni-kvaternió szorzással (\otimes) és a kvaternió konjugáltjával (\mathbf{q}^*) írható le:

$$\begin{bmatrix} 0 \\ \mathbf{v}' \end{bmatrix} = \mathbf{q} \otimes \begin{bmatrix} 0 \\ \mathbf{v} \end{bmatrix} \otimes \mathbf{q}^*$$

Az alkalmazott szűrő keretrendszer

A kutatásban hibaállapot Kálmán-szűrő (Error-State Kalman Filter, ESKF) került alkalmazásra (SOLÀ 2017.), amely egy hatékony megközelítés nemlineáris rendszerek állapotbecslésére. A szűrő keretrendszerben háromféle állapot van definiálva: nominális, hiba- és valódi állapot. A nominális állapot a rendszer ideális állapota, amely nincs hibával vagy zajjal terhelve. A hibaállapot ehhez képest van definiálva, és a valódi állapottól való eltérést modellezi. A valódi állapot pedig a rendszer tényleges fizikai állapotát jelenti, amelyet az ESKF becsül a mérések és a rendszermodell alapján. A rendszer állapota magába foglalja a jármű pozícióját (\mathbf{p}), orientációját (\mathbf{q}), a sebességét testrendszerben (\mathbf{v}_b), és a gyorsulásmérő, valamint a giroszkóp bias értékeit ($\boldsymbol{\beta}_a, \boldsymbol{\beta}_\omega$), amelyek az 1. táblázatban láthatóak összefoglalva.

Valódi	Nominális	Hiba	Kompozíció	Zaj	Mért
\mathbf{p}_t	\mathbf{p}	$\delta\mathbf{p}$	$\mathbf{p}_t = \mathbf{p} + \delta\mathbf{p}$		
\mathbf{q}_t	\mathbf{q}	$\delta\mathbf{q}$	$\mathbf{q}_t = \delta\mathbf{q} \otimes \mathbf{q}$		
$\mathbf{v}_{b,t}$	\mathbf{v}_b	$\delta\mathbf{v}_b$	$\mathbf{v}_{b,t} = \mathbf{v}_b + \delta\mathbf{v}_b$		
$\boldsymbol{\beta}_{a,t}$	$\boldsymbol{\beta}_a$	$\delta\boldsymbol{\beta}_a$	$\boldsymbol{\beta}_{a,t} = \boldsymbol{\beta}_a + \delta\boldsymbol{\beta}_a$	$\boldsymbol{\eta}_{\beta_a}$	
$\boldsymbol{\beta}_{\omega,t}$	$\boldsymbol{\beta}_\omega$	$\delta\boldsymbol{\beta}_\omega$	$\boldsymbol{\beta}_{\omega,t} = \boldsymbol{\beta}_\omega + \delta\boldsymbol{\beta}_\omega$	$\boldsymbol{\eta}_{\beta_\omega}$	
\mathbf{R}_t	\mathbf{R}	$\delta\mathbf{R}$	$\mathbf{R}_t = \delta\mathbf{R}\mathbf{R}$		
\mathbf{a}_t	\mathbf{a}	$\delta\mathbf{a}$	$\mathbf{a}_t = \mathbf{a} + \delta\mathbf{a}$	$\boldsymbol{\eta}_a$	\mathbf{a}_m
$\boldsymbol{\omega}_t$	$\boldsymbol{\omega}$	$\delta\boldsymbol{\omega}$	$\boldsymbol{\omega}_t = \boldsymbol{\omega} + \delta\boldsymbol{\omega}$	$\boldsymbol{\eta}_\omega$	$\boldsymbol{\omega}_m$

1. táblázat: ESKF-állapot és változók

A táblázathoz fűzendő, hogy a bias értékek időbeli változásai Gauss-eloszlású fehérzajjal vannak modellezve, amely a biasok hőmérsékletfüggését reprezentálja.

Továbbá, a vonal alatti paraméterek nem az állapot részei, de azoknak alkalmazása előfordul a szűrő egyenletekben. \mathbf{R} a kvaternióból képzett forgatási mátrix, illetve \mathbf{a}_m és $\boldsymbol{\omega}_m$ az IMU által szolgáltatott gyorsulás és szögsebesség mérések, amelyek szintén Gauss-eloszlású fehérzajjal és biasszal terhelvek.

Rendszerdinamika

A szűrő számításokban két dinamika számolása történik, az egyik a nominális dinamika, amely a zajok és perturbációk nélküli rendszerdinamika, és ennek lokális környezetében van linearizálva a hibadinamika. Az ESKF egyik legjobb tulajdonsága abban rejlik, hogy a nominális dinamika számolható az eredeti nemlineáris modell szerint, és csak a hibadinamika linearizálása szükséges, amely azonban egy jobb közelítés, mert:

- a hibaállapot feltételezhetően mindig kis értékű marad, ezért a Kálmán-szűrő lineáris megközelítése jól alkalmazható rá;

- a hibadinamika úgy van kialakítva, hogy az kicsi és lassan változó legyen, és a nagyjelű, gyorsan változó dinamika a nominális dinamikába van integrálva, amely egy nagyon hasznos tulajdonságot kölcsönöz egy vizuális-inerciális rendszernek: a Kálmán-frissítéseket alacsonyabb frekvencián is lehet végezni, mint a predikciós lépéseket.

A nominális dinamikát leíró egyenletek folytonos időben:

$$\begin{aligned}\dot{\mathbf{p}} &= \mathbf{R}^T \mathbf{v}_b \\ \dot{\mathbf{q}} &= \frac{1}{2} \begin{bmatrix} 0 \\ -\boldsymbol{\omega} \end{bmatrix} \otimes \mathbf{q} \\ \dot{\mathbf{v}}_b &= \mathbf{a} + \mathbf{R}\mathbf{g} + [\mathbf{v}_b]_{\times} \boldsymbol{\omega} \\ \dot{\boldsymbol{\beta}}_a &= \mathbf{0} \\ \dot{\boldsymbol{\beta}}_{\omega} &= \mathbf{0}\end{aligned}$$

A hibadinamika folytonos időben, amelyet a valós és a nominális dinamika különbségéből lehet számítani:

$$\begin{aligned}\delta\dot{\mathbf{p}} &= \mathbf{R}^T [\mathbf{v}_b]_{\times} \delta\boldsymbol{\theta} + \mathbf{R}^T \delta\mathbf{v}_b \\ \delta\dot{\boldsymbol{\theta}} &= -[\boldsymbol{\omega}_m - \boldsymbol{\beta}_{\omega}]_{\times} \delta\boldsymbol{\theta} + \delta\boldsymbol{\beta}_{\omega} + \boldsymbol{\eta}_{\omega} \\ \delta\dot{\mathbf{v}}_b &= -[\mathbf{R}\mathbf{g}]_{\times} \delta\boldsymbol{\theta} - [\boldsymbol{\omega}_m - \boldsymbol{\beta}_{\omega}]_{\times} \delta\mathbf{v}_b - \delta\boldsymbol{\beta}_a - [\mathbf{v}_b]_{\times} \delta\boldsymbol{\beta}_{\omega} - \boldsymbol{\eta}_a - \boldsymbol{\eta}_{\omega} \\ \delta\dot{\boldsymbol{\beta}}_a &= \boldsymbol{\eta}_{\beta_a} \\ \delta\dot{\boldsymbol{\beta}}_{\omega} &= \boldsymbol{\eta}_{\beta_{\omega}}\end{aligned}$$

Természetesen mikrokontrolleres megvalósítás esetében a mintavételezés miatt a folytonos idejű egyenletek diszkrét idejű megfelelőjét kell alkalmazni. Továbbá, a hibadinamika esetében az egyenletek linearizálása is szükséges az állapotátmenet (\mathbf{F}_x) és a folyamat zaj bemeneti mátrix (\mathbf{F}_i) meghatározásához.

Alkalmazva az eddigi jelöléseket, és a folyamat zaj mátrixot \mathbf{Q} -val jelölve a predikciós lépés:

$$\begin{aligned}\mathbf{x}_{k+1} &= f(\mathbf{x}_k, \mathbf{a}_{m,k}, \boldsymbol{\omega}_{m,k}) \\ \delta\hat{\mathbf{x}}_{k+1} &= \mathbf{F}_{x,k} \delta\hat{\mathbf{x}}_k = \mathbf{0} \\ \mathbf{P}_{k+1} &= \mathbf{F}_{x,k} \mathbf{P}_k \mathbf{F}_{x,k}^T + \mathbf{F}_i \mathbf{Q} \mathbf{F}_i^T,\end{aligned}$$


ahol az első egyenlet a nominális állapot számítása a nemlineáris modell alapján; a második egyenlet formális okokból került feltüntetésre, mivel a hibaállapot Gauss-eloszlású fehérzajjal van modellezve, ezért ennek prediktált (várható) értéke mindig 0; az utolsó egyenlet pedig a hibaállapot kovarianciájának a predikciója.

Kálmán-frissítés

A szűrőszámítások másik része a Kálmán-frissítés, ahol a vizuális információ kerül felhasználásra. A vizuális adatok kinyerése nem triviális művelet, ugyanis a kamera által készített felvételeken valamilyen képfeldolgozó algoritmust kell futtatni, amely képes jellegpontokat detektálni, és azokat képkockákon keresztül követni. A legelőrehaladottabb szimulációs eredményekben már ténylegesen bevonásra került egy képfeldolgozó algoritmus a Kanade-Lucas-Tomasi-, vagyis a KLT-sarokdetektor.

Valós alkalmazásban azonban még egy további előfeldolgozó lépésre szükség van, mielőtt a pixeladatokat fel lehetne használni a frissítésben, és ez a valós kamerák által okozott lencsetorzításból eredő hibák kompenzálása, azonban ebben a munkában egyelőre csak szintetikus generált képek kerültek felhasználásra.

A vizuális információ felhasználásának alapelvét az 5. ábra mutatja, amelynek lényege, hogy a repülőgép egy trajektória mentén halad, és adott jellegpontokról ismert pozícióban és orientációban készül kamerafelvétel, így, ha ismert a jellegpont pozíciója a lokalizációs rendszerben (\mathbf{p}_n^f), akkor ez alkalmas az állapot hibabecslésére.



5. ábra: Vizuális adatok felhasználásának szemléltetése
(Forrás: Ellingson – Brink – McLain 2020. 7. oldal 4. ábra)

Az előfeldolgozó eljárásokat követően a frissítésben a mérési egyenlet a lyukkamera-vetítés modellje, azonban a frissítés végrehajtása egy komplex művelet. Először is az állapot szerinti megfigyelési mátrixot (\mathbf{H}_x) a hibaállapot szerint kell meghatározni, amelyhez többlépcsős deriválási láncszabály alkalmazására van szükség:

$$\mathbf{H}_x = \frac{\partial h(\mathbf{p}_c^f)}{\partial \delta \mathbf{x}} = \frac{\partial \bar{\mathbf{u}}}{\partial \mathbf{p}_c^f} \frac{\partial \mathbf{p}_c^f}{\partial \mathbf{x}_t} \frac{\partial \mathbf{x}_t}{\partial \delta \mathbf{x}}$$

azaz a fenti egyenletből látható, hogy három Jacobi-mátrix számítása szükséges: a pixelmérés jellegpont szerinti, a jellegpont valódi állapot szerinti és a valós állapot hibaállapot szerinti deriváltja.

Már az előző lépésben is látható, hogy a számításokhoz szükséges a jellegpont kamerarendszerbeli vektorának ismerete, és erre a reziduál képzésénél is szükség van.

Ez a vektor:

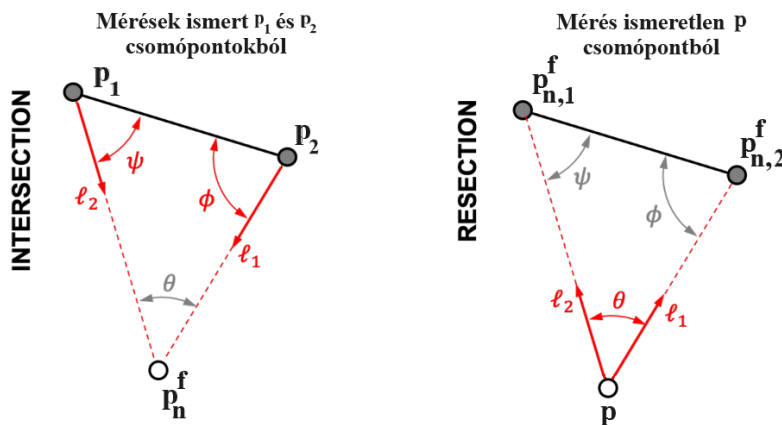
$$\mathbf{p}_c^f = \mathbf{R}_{CB}(\mathbf{R}_{BN}(\mathbf{p}_n^f - \mathbf{p}_n^b) - \mathbf{p}_b^c)$$

A fenti egyenletben a kamera állapota ismert konstans a testrendszerhez képest ($\mathbf{R}_{CB}, \mathbf{p}_b^c$), a testrendszer pozíciója és orientációja pedig a szűrő által becsült, azonban a jellegpont lokalizációs koordináta-rendszerbeli vektornak (\mathbf{p}_n^f) a priori ismerete nem feltételezhető. Meghatározásához háromszögelési eljárásra van szükség, amely a kamerafelvételek alapján képes értékét becsülni, viszont bármilyen eljárás pontossága véges, ezért a becsült jellegpont-pozíció bizonytalanságát is figyelembe kell venni a számítások során, például a reziduál kovarianciájának és a Kálmán-erősítés meghatározásánál is. Egy további nehézséget okoz, hogy a Kálmán-szűrő és a háromszögelő eljárás egymás becsléseit felhasználja, így azok közt korreláció lép fel, amelyet egy pontos rendszer esetén modellezni kell. A nehézségek miatt az ezekre a problémákra alkalmazott megoldások egy későbbi fejezetben kerülnek bemutatásra.

Végül érdemes megemlíteni, hogy az ESKF-ben a Kálmán-erősítés (\mathbf{K}_g) és a reziduál (\mathbf{r}) felhasználásával a hibaállapotot ($\delta\hat{\mathbf{x}} = \mathbf{K}_g\mathbf{r}$) lehet meghatározni, amelyet a nominális állapotba kell injektálni. Az injekciós lépés során az 1. táblázatban látható kompozíciókat kell képezni, majd a hibaállapotot nullvektorra kell visszaállítani ($\delta\hat{\mathbf{x}} = \mathbf{0}$).

A háromszögelési eljárás

A háromszögelési eljárásoknak két különböző megfogalmazása is lehetséges: *intersection* és *resection*, amelyek a 6. ábrán láthatóak.



6. ábra: *Intersection* és *resection*
(Forrás: HENRY – CHRISTIAN 2022. 3. oldal)

Az *intersection* esetében az ismert pozícióból és orientációval készült kamerafelvételek alapján a látott jellegpont-pozíció meghatározása a feladat, gyakorlati alkalmazásokra példa a műhold pálya meghatározás és a 3-D rekonstrukció eljárás, amelyet *Structure from Motion*nek (SfM) is szokás nevezni. A *resection* probléma esetében fordított a feladat, a látott jellegpontok pozíciója ismert és a feladat a kamera pozíciójának meghatározása, ez tipikusan a járműlokalizációs probléma.

A kutatásban a LOST (Linear Optimal Sine Triangulation) eljárást alkalmazzuk (HENRY – CHRISTIAN 2022.), mégpedig annak is az *intersection* változatát, hisz a cél a jellegpont-pozíciók meghatározása. Az algoritmus bemutatása előtt fontos tisztázni a LOS (Line of Sight) mérés fogalmát, amely a közvetlen optikai útvonalra vonatkozó mérés két pont között. A 4. ábrán látható, hogy a képi mérésekben a principális pont általi eltolás, azaz a kamera origója és a képsík origója közti eltérés kompenzálása után, a LOS-mérés (\mathbf{u}) és a jellegpont-pozíció (\mathbf{p}_c^f) egy egyenes mentén helyezkedik el.

Az algoritmus alapötlete, hogy a jellegpont-pozíció (\mathbf{p}_c^f) és a LOS-mérés kollinearitását használja ki, vagyis, hogy azok párhuzamosak, amelyet matematikailag úgy lehet megfogalmazni, hogy:

$$[\mathbf{u}]_{\times} \mathbf{p}_c^f = [\mathbf{u}]_{\times} \mathbf{R}_{CB} (\mathbf{R}_{BN} (\mathbf{p}_n^f - \mathbf{p}_n^b) - \mathbf{p}_b^c) = \boldsymbol{\epsilon},$$

vagyis a két vektor keresztszorzatát veszi, amely ideális esetben $\boldsymbol{\epsilon} = \mathbf{0}$ lenne, azonban a képi mérések zajjal terheltek, illetve a kamera pozíciója és orientációja is valamilyen bizonytalansággal számolható, így $\boldsymbol{\epsilon}$ kicsi, de nem $\mathbf{0}$ értékű lesz és a LOST algoritmust ezt minimalizálja.

A minimális megoldás egy MLE (Maximum Likelihood Estimation) optimalizációs problémára vezet, amely végeredményben egy súlyozott legkisebb négyzetes (Weighted Least Squares, WLS) értelemben vett optimális becslőt ad eredményül. A szakirodalomban az algoritmus direkt megoldása található meg, azonban számításgépi szempontból sokkal célszerűbb volt a tanulmányban az algoritmus rekurzív változatának használata, amely saját továbbfejlesztés.

Szimulációs eredmények

A szimulációk két kategóriába sorolhatóak be:

1. A képi mérések ismert jellegpont koordinátákból lettek generálva. Ebben az esetben valódi képfeldolgozó algoritmus nincs bevonva, és a pixel értékek a lyukkamera-vetítés alapján lettek előállítva.
2. A képi mérések valódi képfeldolgozó algoritmus által kerültek meghatározásra szintetikus generált képek alapján.

Az 1. esetben három különböző pálya mellett is teszteltük az algoritmust: egyenes és magasságtartó, egyenes és süllyedő, illetve cikk-cakk és magasságtartó pályán. A szimulációkban alkalmazott zaj és bias paraméterek a 2. táblázatban láthatóak.


Név	Zaj kovariancia érték	Mértékegység
Gyorsulás mérési zaj	1	m/s ²
Szögsebesség mérési zaj	0.1	°/s
Gyorsulásmérő bias változás	10 ⁻⁶	m/s ² VHz
Giroszkóp bias változás	10 ⁻⁷	°/sVHz
Képi mérési zaj	0.7	px
Gyorsulásmérő bias	[0.5 -0.4 0.4]	m/s ²
Giroszkóp bias	[0.04 -0.05 -0.05]	rad/s

2. táblázat: Zaj és bias értékek
(saját szerkesztés)

Fontos megjegyezni, hogy az 1. esetben alkalmazott szimulációk során kezdetben ismert pozíciót és orientációt alkalmaztunk, amely a szűrő konvergálásához szükséges. Azonban a 2. esetben a rendelkezésre álló adathalmaz rövidege miatt ez nem volt lehetséges, és ugyanebből kifolyólag biasok se kerültek alkalmazásra.

Az eredmények bemutatásához két „mérce” alkalmazunk: a becült és a valós 2-D pálya² közti eltérést, és a 2-D pozíció hibáját %-osan kifejezve a megtett távolság függvényében.

Egyenes, magasságtartó pálya




7. ábra: Egyenes, magasságtartó pálya eredmények
(saját szerkesztés)

² X-Y síkbeli pálya, azaz az északi és a keleti koordináták által meghatározott trajektória

Az eredményekből az látható, hogy kezdetben amíg a LOST-becslések és a bias értékek nem konvergáltak, a becsült pálya és a relatív hiba nagy, azonban ez hamar eltűnik, mert a 30. másodpercig elérhető a valós pozíció. A továbbiakban egy folyamatosan, de lassan növekvő hiba figyelhető meg, amely a szimuláció végére 1% alatt maradt, amely kielégítő eredménynek tekinthető.

Egyenes, süllyedő pálya

A süllyedő pálya úgy volt beállítva, hogy a repülőgép minden megtett 200 m után süllyedt 10 m-t.




8. ábra: Egyenes, süllyedő pálya eredmények
(saját szerkesztés)

Az eredményekben némi romlás tapasztalható az előző esethez képest, amelynek legvalószínűbb oka, hogy a földfelszínhez közeledve a jellegpontok hamarabb kikerülnek a kamera látóteréből, ami rontja a háromszögelő eljárás pontosságát, így az állapotbecslést is. Azonban az eredmények így is jónak tekinthetők, mert a halmozott hiba 1.5% alatt maradt a szimuláció végére.

Cikk-cakk, magasságtartó pálya

A cikk-cakk pálya beállítása úgy történt, hogy keleti irányban a repülőgép -50 m és +50 m között cikázott minden északi irányban megtett 300 m-t követően.



9. ábra: Cikk-cakk, magasságtartó pálya eredmények
(saját szerkesztés)

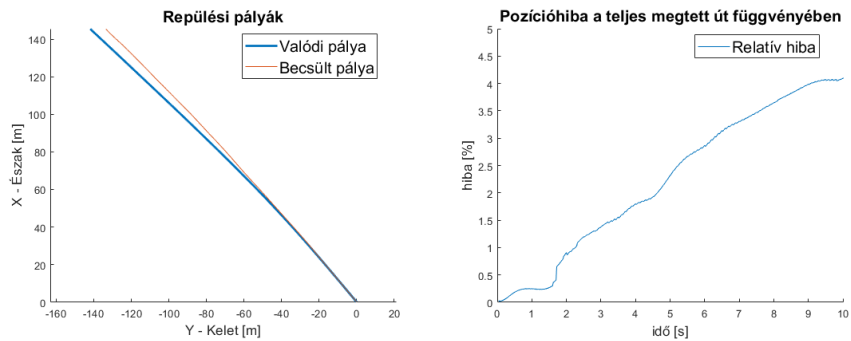
A három azonos típusú szimuláció közül ezen a pályán látható a legrosszabb eredmény, amelynek oka ugyanaz, mint az előző esetben, csak még hangsúlyosabban, azaz a fordulásoknál a kameraképről hamar eltűnnek a követett jellegpontok, így azok becslése kevésbé pontos. A teljes szimuláció alatt kumulált hiba azonban biztatónak mondható, mert 2.5% alatt maradt.

Szintetikus kép alapú, egyenes, magasságtartó pálya

A szintetikus képalapú szimulációban egy észak-nyugati egyenes, magasságtartó repülés lett modellezve egy városi környezet felett. Egy példa a város felett készült felvételre és a detektált jellegpontokra (piros pontokkal jelölve) a 10. ábrán látható.



10. ábra: Szintetikus kép és a detektált jellegpontok
(saját szerkesztés)



11. ábra: Szintetikus kép alapú, egyenes, magasságtartó pálya eredmények
(saját szerkesztés)

Az eredményekből az látható, hogy a relatív hiba ebben az esetben a legnagyobb, viszont ennek okai nemcsak a képfeldolgozó algoritmusból eredő további bizonytalanságok lehetnek, hanem az is, hogy a rendelkezésre álló 10 másodperces adathalmaz miatt a szűrőt nem volt lehetőség az elején ismert pozícióinformációkkal konvergáltatni. A felhalmozott hiba 4% körül maradt a szimuláció végére.

Felhasználási lehetőségek

Zárszóként az algoritmus felhasználhatóságáról ejtünk néhány szót biztonságtechnikai szempontból. Az UAV-k, vagyis drónok használata egyre elterjedtebb mind a katonai, mind a civil szektorokban. Az alkalmazások körétől a megfigyelésen és felderítésen át a teherszállításig, mezőgazdasági felhasználásig és kritikus infrastruktúrák ellenőrzéséig terjed. Azonban a gyors növekedés és a SWaP-C (size, weight, power, and cost) csökkentésének nyomása gyakran a biztonsági szempontok figyelmen kívül hagyásához vezet, komoly biztonsági kockázatokat eredményezve.

Az egyik fő fenyegetés, amivel a UAV-k szembesülnek, a GPS jel hamisítás. Mivel a UAV-k nagymértékben támaszkodnak a GPS-re a pozícionáláshoz és navigáláshoz, ezért érzékenyek annak zavarására és hamisítására. Ezek a támadások félrevezethetik vagy akár teljesen eltéríthetik a drónokat rosszindulatú célokból. Ez a sebezhetőség nemcsak a UAV-kra korlátozódik, hanem kiterjed más GPS-függő platformokra is, beleértve a személyzettel rendelkező repülőgépeket, földi járműveket és mobil rendszereket. Ennek eredményeként már számos módszert javasoltak a GPS hamisítási támadások észlelésére (KHAN – MOHSIN – IQBAL 2021.; QIAO – YUXING – XIAO 2017.).

Összefoglalás

Ebben a tanulmányban bemutatásra került egy GPS-mentes módszer az UAV pozíciójának becslésére, kizárólag egy IMU és egy kamera méréseinek felhasználásával. Az algoritmus GPS-mérések nélkül is futtatható, ami ellenállóvá teszi a GPS kiesésekkel vagy hamisítási támadásokkal szemben.

Az algoritmus használatával, amely független a GPS-mérésektől, az UAV képes becsleni a pozícióját, és összevetni azt a GPS-mérésekkel. Ha a két pozíció közötti különbség rövid idő alatt jelentős, akkor az UAV GPS hamisítási támadás alatt állhat. Ha csak GPS kiesés történik rövid időtartamra, akkor ezzel a navigációs eljárással zavartalanul lehet tovább haladni.

Röviítések

DOA	- Direction-of-Arrival
ESKF	- Error-State Kalman Filter
EKF	- Extended Kalman filter
FOA	- Frequency-of-Arrival
GNSS	- Global Navigation Satellite System
GPS	- Global Positioning System
IMU	- Inertial Measurement Unit
INS	- Inertial Navigation System
KLT	- Kanade-Lucas-Tomasi
LOS	- Line of Sight
LOST	- Linear Optimal Sine Triangulation
LEO	- Low Earth Orbit
MLE	- Maximum Likelihood Estimation
NED	- North-East-Down
SOP	- Signals of Opportunity
SLAM	- Simultaneous Localization and Mapping
SWaP-C	- Size Weight Power and Cost
SfM	- Structure from Motion
TOA	- Time-of-Arrival
UAV	- Unmanned Aerial Vehicle
WLS	- Weighted Least Squares

Felhasznált irodalom:

AL-KAFF, A. – MORENO, F. M. – SAN JOSÉ, L. J. – GARCÍA, F. – MARTÍN, D. – DE LA ESCALERA, A. – NIEVA, A. M. – GARCÍA, J. L.: VBII-UAV: Vision-Based Infrastructure Inspection-UAV. Springer International Publishing, 2017.

ANGELINO, C. V. – BARANIELLO, V. R. – CICALA, L.: High altitude UAV navigation using IMU, GPS and camera. Institute of Electrical and Electronics Engineers, 2013.

BEARD, R. W. – MCLAIN, T. W.: Small Unmanned Aircraft: Theory and Practice. Princeton University Press, 2012.

DE MARCO, A.: FlightMechanics4Pilots. Università degli Studi di Napoli Federico II, 2020. május 24.
<https://agodemar.github.io/FlightMechanics4Pilots/mypages/external-actions/> (Letöltés ideje: 2024. 02. 15.)

ELLINGSON, G. – BRINK, K. – MCLAIN, T.: Relative navigation of fixed-wing aircraft in GPS-denied environments. Journal of the INstitute of Navigation, 2020. június, pp. 255-273.

ERDOS, D. – ERDOS, A. – Watkins, S. E.: An experimental UAV system for search and rescue challenge. IEEE Aerospace and Electronic Systems Magazine, 2013. pp. 32-37.

FRAUNDORFER, F. – HENG, L. – HONEGGER, D. – LEE, G. H. – MEIER, L. – TANSKANEN, P. – POLLEFEYS, M.: Vision-based autonomous mapping and exploration using a quadrotor MAV. Institute of Electrical and Electronics Engineers, 2012.

GRISSETTI, G. – KÜMMERLE, R. – STACHNISS, C. – BURGARD, W.: A Tutorial on Graph-Based SLAM. IEEE Intelligent Transportation Systems Magazine, 2010. pp. 31-43.

HAMILTON, W. R. : On a New Species of Imaginary Quantities, Connected with the Theory of Quaternions. Proceedings of the Royal Irish Academy (1836-1869), 1840. pp. 424-434.

HENRY, S. – CHRISTIAN, J. A.: Absolute triangulation algorithms for space exploration. Journal of Guidance, Control, and Dynamics, 2022. pp. 21-46.

KHAN, S. Z. – MOHSIN, M. – IQBAL, W.: On GPS spoofing of aerial platforms: a review of threats, challenges, methodologies, and future research directions. PeerJ. Computer science, 2021. pp. 2167-9843.

KITANI, K.: Carnegie Mellon University edu. 2017. március 8.
https://www.cs.cmu.edu/~16385/s17/Slides/11.1_Camera_matrix.pdf.
Letöltés ideje: 2024. 02. 15.)

LEISHMAN, R. C. – MCLAIN, T. W. – BEARD, R. W.: Relative navigation approach for vision-based aerial GPS-denied navigation. *Journal of Intelligent & Robotic Systems*, 2014. április 1. pp. 97-111.

LEUTENEGGER, S. – SIEGWART, R. Y.: A low-cost and fail-safe Inertial Navigation System for airplanes. *Institute of Electrical and Electronics Engineers*, 2012.

NEINAVAIE, M. – KASSAS, Z. M.: Unveiling Starlink LEO Satellite OFDM-Like Signal Structure Enabling Precise Positioning. *IEEE Transactions on Aerospace and Electronic Systems*, 2023. pp. 1-4.

NEINAVAIE, M. – KHALIFE, J. – KASSAS, Z. M.: Cognitive Detection of Unknown Beacons of Terrestrial Signals of Opportunity for Localization. *IEEE Transactions on Wireless Communications*, 2023. augusztus, pp. 5613-5627.

NGUYEN, A. A. – KASSAS, Z. M.: Efficient Transmitter Selection Strategies for Improved Information Gathering of Aerial Vehicle Navigation in GNSS-Denied Environments. *IEEE Transactions on Aerospace and Electronic Systems*, 2023. pp. 26-39.

QIAO, Y. – YUXING, Z. – XIAO, D.: A Vision-Based GPS-Spoofing Detection Method for Small UAVs. in *International Conference on Computational Intelligence and Security (CIS)*, 2017.

SALO, H. – TIRRONEN, V. – NERI, F.: *Evolutionary Regression Machines for Precision Agriculture*. Springer Berlin Heidelberg, 2012.

SOLÀ, J.: Quaternion kinematics for the error-state Kalman filter. *arXiv*, 2017.

THRUN, S. – BURGARD, W. – FOX, D.: *Probabilistic Robotics*. MIT Press, Cambridge, 2010.

WEISS, S. – ACHELIK, M. W. – LYNEN, S. – CHLI, M. – SIEGWART, R.: Real-time onboard visual-inertial state estimation and self-calibration of MAVs in unknown environments. *Institute of Electrical and Electronics Engineers*, 2012.

WHEELER, D. O. – NYHOLM, P. W. – KOCH, D. P. – ELLINGSON, G. J. – MCLAIN, T. W. – BEARD, R. W.: Relative navigation in GPS-degraded environments. *Encyclopedia of Aerospace Engineering*, 2016. pp. 1-10.