



8. előadás

Kiegyenlítő számítások MSc

2018/19

Áttekintés

- Kálmán szűrés *lineáris* esetben (ismétlés)
- Kálmán szűrés *nem lineáris* esetben
 - Kibővített Kálmán szűrő (EKF)
nem lineáris mérési és állapot egyenlet
példák:
 - odometria
 - kerék gyorsulásmérő
 - Szagtalan Kálmán szűrő (UKF)
szigma pontok és súlyok
példa: odometria

Kálmán szűrő lineáris rendszer modellje (Welch és Bishop jelöléseivel)

- állapot átmeneti mátrix: A
- kezdeti rendszer állapot és annak kovariancia mátrixa: x_0, P_0
- vezérlési mátrix: B
- rendszer zaj kovariancia mátrix: Q
- mérési mátrix: H
- mérési zaj kovariancia mátrix: R

A Kálmán szűrő működése

1) Előző rendszer állapot és kovariancia becslése

$$\hat{\mathbf{x}}_{k-1}, \quad \hat{\mathbf{P}}_{k-1}$$

2) A rendszer állapot és kovariancia előrejelzése

$$\hat{\mathbf{x}}_k^- = \mathbf{A} \hat{\mathbf{x}}_{k-1} + \mathbf{B} \mathbf{u}_{k-1}$$

$$\mathbf{P}_k^- = \mathbf{A} \mathbf{P}_{k-1} \mathbf{A}^T + \mathbf{Q}$$

3) A mérés utáni állapot és kovariancia frissítés

$$\mathbf{K}_k = \mathbf{P}_k^- \mathbf{H}^T (\mathbf{H} \mathbf{P}_k^- \mathbf{H}^T + \mathbf{R})^{-1}$$

$$\hat{\mathbf{x}}_k = \hat{\mathbf{x}}_k^- + \mathbf{K}_k (\mathbf{z}_k - \mathbf{H} \hat{\mathbf{x}}_k^-)$$

$$\mathbf{P}_k = (\mathbf{I} - \mathbf{K}_k \mathbf{H}) \mathbf{P}_k^-$$

Kibővített Kálmán szűrő (EKF)

- A mérési egyenlet, az állapot átviteli egyenlet vagy mindkettő *nem lineáris*

$$z_k = h(\mathbf{x}_k, \mathbf{v}_k),$$

$$\mathbf{x}_k = f(\mathbf{x}_{k-1}, \mathbf{u}_{k-1}, \mathbf{w}_{k-1})$$

\mathbf{v}_k mérési zaj, \mathbf{w}_k rendszer zaj

- A pillanatnyi értékek (átlag, kovariancia) körüli *linearizációra* van szükség – Taylor sorfejtés
- Általában nem ismerjük az egyes zaj komponenseket, ezért közelítőleg nélkülük számítjuk ki a rendszer állapotát és a mérési vektort

Kibővített Kálmán szűrő

- A rendszer állapota és a mérési vektor

$$\tilde{\mathbf{x}}_k = f(\hat{\mathbf{x}}_{k-1}, \mathbf{u}_{k-1}, \mathbf{0})$$

$$\tilde{\mathbf{z}}_k = h(\hat{\mathbf{x}}_k, \mathbf{0})$$

$\hat{\mathbf{x}}_{k-1}$ előző becsült rendszer állapot

- A kibővített Kálmán-szűrő alapvető hiányossága az, hogy különböző valószínűségi változók eloszlása a nem lineáris transzformáció után már nem Gauss-féle, ezért a becslés nem is lehet optimális.

Linearizáció után

- A rendszer állapota és a mérési vektor

$$\mathbf{x}_k \approx \tilde{\mathbf{x}}_k + \mathbf{A} (\mathbf{x}_{k-1} - \hat{\mathbf{x}}_{k-1}) + \mathbf{W} \mathbf{w}_{k-1}$$

$$\mathbf{z}_k \approx \tilde{\mathbf{z}}_k + \mathbf{H} (\mathbf{x}_k - \tilde{\mathbf{x}}_k) + \mathbf{V} \mathbf{v}_k$$

$\mathbf{x}_k, \mathbf{z}_k$ rendszer állapot és mérés
 $\tilde{\mathbf{x}}_k, \tilde{\mathbf{z}}_k$ közelítő rendszer állapot és mérés
 $\hat{\mathbf{x}}_k$ becsült rendszer állapot a k -edik időpontban
 $\mathbf{w}_k, \mathbf{v}_k$ folyamat és mérési zaj

\mathbf{A} az f függvény Jacobi mátrixa \mathbf{x} szerint
 \mathbf{W} az f függvény Jacobi mátrixa \mathbf{w} szerint
 \mathbf{H} a h függvény Jacobi mátrixa \mathbf{x} szerint
 \mathbf{V} a h függvény Jacobi mátrixa \mathbf{v} szerint

A kibővített Kálmán szűrő működése

1) Előző rendszer állapot és kovariancia becslése

$$\hat{\mathbf{x}}_{k-1}, \quad \hat{\mathbf{P}}_{k-1}$$

2) A rendszer állapot és kovariancia előrejelzése

$$\hat{\mathbf{x}}_k^- = f(\hat{\mathbf{x}}_{k-1}, \mathbf{u}_{k-1}, \mathbf{0})$$

$$\mathbf{P}_k^- = \mathbf{A}_k \mathbf{P}_{k-1} \mathbf{A}_k^T + \mathbf{W}_k \mathbf{Q}_{k-1} \mathbf{W}_k^T$$

3) A mérés utáni állapot és kovariancia frissítés

$$\mathbf{K}_k = \mathbf{P}_k^- \mathbf{H}_k^T (\mathbf{H}_k \mathbf{P}_k^- \mathbf{H}_k^T + \mathbf{V}_k \mathbf{R}_k^- \mathbf{V}_k^T)^{-1}$$

$$\hat{\mathbf{x}}_k = \hat{\mathbf{x}}_k^- + \mathbf{K}_k (\mathbf{z}_k - h(\hat{\mathbf{x}}_k^-, \mathbf{0}))$$

$$\mathbf{P}_k = (\mathbf{I} - \mathbf{K}_k \mathbf{H}_k) \mathbf{P}_k^-$$


Odometria kerékre szerelt kéttengelyű gyorsulásmérővel

- Feladat:

Határozzuk meg egy kerékre szerelt kéttengelyű gyorsulásmérő szenzor adatai alapján a kerék által megtett utat. Tegyük fel, hogy a kerék vízszintes talajon csúszás nélkül gördül.


Kerék mozgása

- egyenletes haladás és forgás, a pillanatnyi érintkezési pont zérus sebességű



Kerék mozgása

- kerék sugara: r_w
- az S szenzor az a_1 és a_2 gyorsulásokot méri




g vektor összetevői

$$a_1 = -g \sin(\theta)$$

$$a_2 = -g \cos(\theta)$$

Kerék mozgása

- a \ddot{p} lineáris gyorsulásból adódó összetevők S -ben

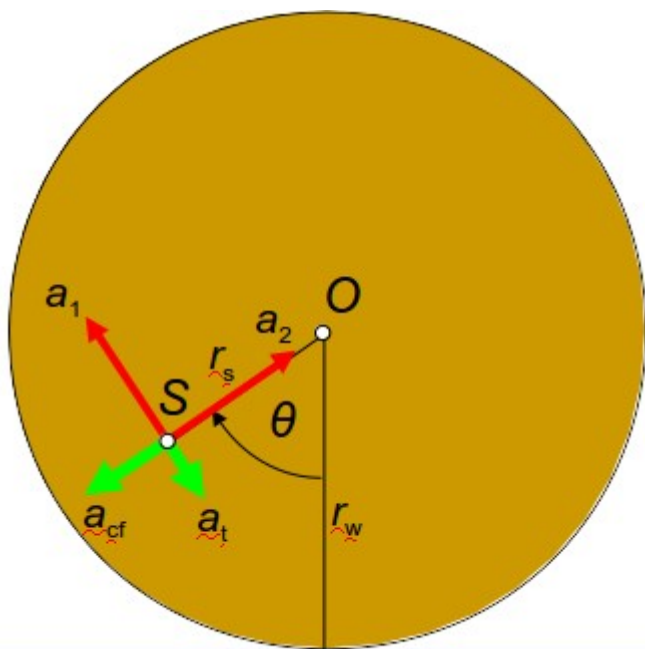


$$a_1 = \ddot{p} \cos(\theta)$$

$$a_2 = -\ddot{p} \sin(\theta)$$

Kerék mozgása

- a kerék csúszásmentesen gördül:



az elfordulási szög,
a szögsebesség és
a szöggyorsulás
kifejezhető a
megtett úttal, a
sebességgel és a
gyorsulással


$$\theta = \frac{p}{r_w}$$

$$\dot{\theta} = \frac{\dot{p}}{r_w}$$

$$\ddot{\theta} = \frac{\ddot{p}}{r_w}$$

Kerék mozgása

- a centripetális és centrifugális gyorsulásból adódó összetevők S -ben




$$a_1 = -r_s \ddot{\theta} = \frac{-r_s}{r_w} \ddot{p}$$

$$a_2 = -r_s \dot{\theta}^2 = \frac{-r_s}{r_w^2} \dot{p}^2$$

Kerék mozgása

- A szenzorra ható teljes gyorsulás komponensei



$$a_1 = -g \sin\left(\frac{p}{r_w}\right) + \ddot{p} \cos\left(\frac{p}{r_w}\right) - \frac{r_s}{r_w} \ddot{p}$$

$$a_2 = -g \cos\left(\frac{p}{r_w}\right) - \ddot{p} \sin\left(\frac{p}{r_w}\right) - \frac{r_s}{r_w^2} \dot{p}^2$$

Állapot és mérési egyenlet

- a rendszer állapotát a kerék helyzete, sebessége és gyorsulása adja

$$\mathbf{x} = \begin{bmatrix} p \\ \dot{p} \\ \ddot{p} \end{bmatrix}$$

- a mérési függvény a mért gyorsulásokot adja meg (ahol a \mathbf{v} mérési zaj Gauss eloszlású v.v.)

$$h(\mathbf{x}, \mathbf{v}) = \begin{bmatrix} -g \sin\left(\frac{p}{r_w}\right) + \ddot{p} \cos\left(\frac{p}{r_w}\right) - \frac{r_s}{r_w} \ddot{p} + v_1 \\ -g \cos\left(\frac{p}{r_w}\right) - \ddot{p} \sin\left(\frac{p}{r_w}\right) - \frac{r_s}{r_w^2} \dot{p}^2 + v_2 \end{bmatrix}$$

Állapot átmenet

- Az állapot átmenet függvénye már lineáris, melynek A mátrixa


$$A = \begin{bmatrix} 1 & \Delta t & \frac{1}{2} \Delta t^2 \\ 0 & 1 & \Delta t \\ 0 & 0 & 1 \end{bmatrix}$$

- az állapot átmeneti egyenlet linearizációjára nincs szükség

Adatok

- A kibővített Kálmán-szűrést Gersdorf B., Frese U. (2013) cikkéből vett gyorsulás adatokkal végezzük

Galaxy S2 szenzor adatok



→ driving direction





Figure 4: A Samsung Galaxy S2 as a wheel sensor at radius $r_s = 9.5 \text{ cm}$ in a bicycle wheel of radius $r_w = 35 \text{ cm}$ for data logging.

Program

- Python program:
https://github.com/gyulat/Korszeru_matek/blob/master/KF2.ipynb
- `def EKFwheel(t, a1, a2, q=0.07, r=5):`

''''''

Kibővített Kálmán-szűrő kéttengelyű gyorsulásmérő szenzoros odometriához

t - mérési időpontok vektora

a1, a2 - mért szenzor centripetális és centrifugális gyorsulások (m/s**2)

q - folyamat zaj varianciá (m/s**2)

r - mérési zaj variancia (m/s**2)


''''''

- a szűrés megvalósítása:


`xe = EKFwheel(t, a1, a2, 0.17, 5.0)`


Eredmények

Kibővített Kálmán-szűrő (EKF) eredmények




Eredmények (cikk)






Kibővített Kálmán-szűrő (EKF) eredmények



Eredmények

Kibővített Kálmán-szűrő (EKF) eredmények



- a sebesség és gyorsulás nem lesz zérus a végén
- linearizáció problémái: EKF → UKF

Szagtalan Kálmán szűrő (UKF)

- A kibővített Kálmán szűrő (EKF) problémái:
 - linearizáció: csak a Taylor-sor elsőrendű tagját veszi figyelembe
 - a Jacobi-mátrix előállítása nehézkes
 - nehezen beállítható a szűrő paraméterezése,
 - némely esetben a szűrő divergáló rendszer állapotot becsül
- A tapasztalatok szerint a szagtalan Kálmán szűrő (Unscented Kalman Filter, UKF) sok esetben jobb eredményeket ad

Szagtalan Kálmán szűrő

- A bizarr név a megalkotójától, Jeffrey Uhlmann-tól ered:

"Miért „szagtalan”? „Kezdetben »új szűrő« volt a neve, de mivel jellegzetesebb névre volt szükség, ezért egyesek »Uhlmann szűrőnek« kezdték hívni, amit nyilván nem használhattam. Egyik este mindenki más a laborból a Royal Opera House-ba ment. Miközben dolgoztam, észrevettem valaki dezodorát az asztalon. A »szagtalan« (»unscented«) felirat szemet szúrt, ami tökéletes név volt. A laborban először abszurdnak találták – ami rendben van, mert az abszurditás a vezérelvem.”

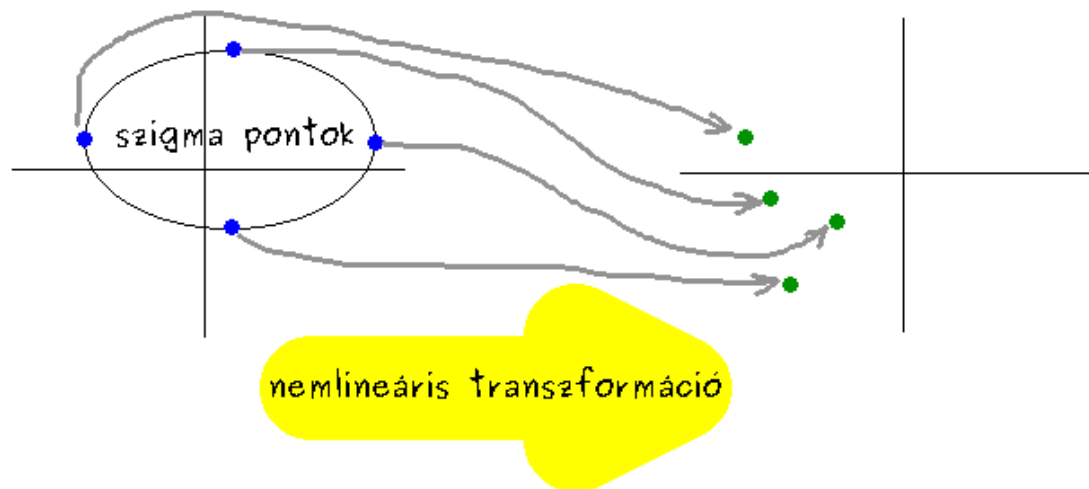


Az UKF alapötlete

- Kálmán szűrés a Gauss eloszlású rendszer állapotának változását és méréseken alapuló frissítését írja le
- A Gauss eloszlást könnyebb közelíteni mint a nem lineáris transzformációt
- Ötlet:
 - megtartjuk a nem lineáris transzformációt
 - a Gauss eloszlás paramétereit (várható érték, szórás) közelítjük diszkrét pontok (ún. *sigma pontok*) segítségével (ez a *szagtalan transzformáció*)


Az UKF alapötlete

- felvesszük a szigma pontokat úgy, hogy pontosan jellemezzék a rendszer állapot átlagát és kovarianciáját
- a szigma pontokat átvisszük a nemlineáris f, h transzformációkkal az állapot- ill. mérési térbe (kovariancia terjedés nemlineáris változata)
- az átvitt pontokból számítjuk közelítőleg a rendszer állapot átlagot és kovarianciát



- Az eljárás rokona a Monte Carlo módszereknek, azzal a különbséggel, hogy jóval kevesebb pontra van szükség a diszkrét pontokat nem véletlenszerűen, hanem determinisztikusan vesszük fel 27 / 43

Szigma pontok



forrás: Roger R Labbe: [Kalman and Bayesian Filters in Python](#)

- n dimenziós állapot térben $2n + 1$ db. X_i szigma pontot választunk ki
- a transzformált szigma pontokat W_i súlyokkal súlyozzuk

Van der Merwe-féle skálázott szigma pontok

- A szigma pontok halmazát a következő összefüggések szolgáltatják:

$$\mathbf{X}_0 = \mu$$


$$\mathbf{X}_i = \mu + [\sqrt{(n+\lambda)\mathbf{P}}]_i \quad i=1, \dots, n$$

$$\mathbf{X}_i = \mu - [\sqrt{(n+\lambda)\mathbf{P}}]_{i-n} \quad i=n+1, \dots, 2n$$

ahol $[A]_i$ a szimmetrikus A mátrix i -edik oszlopát (vagy sorát) jelöli és

$$\lambda = \alpha^2(n+k) - n, \quad k = 3 - n.$$

- A λ és k skálatényezők, az α paraméter határozza meg a szigma pontok távolságát a μ ponttól.



Van der Merwe-féle súlyok

$$W_0^m = \frac{\lambda}{n + \lambda}$$

m : átlaghoz

$$W_0^c = \frac{\lambda}{n + \lambda} + 1 - \alpha^2 + \beta$$

c : kovarianciához

$$W_i^m = W_i^c = \frac{1}{2(n + \lambda)}, \quad i = 1, \dots, 2n$$

- Gauss-eloszlás esetén az alábbi paramétereket célszerű használni:

$$\beta = 2, \quad k = 3 - n, \quad 0 \leq \alpha \leq 1.$$

Szagtalan transzformáció

- A szagtalan transzformáció során a szigma vektorokat transzformáljuk egy nem lineáris

$$Y_i = g(X_i) \quad i = 0, \dots, 2n$$

függvény segítségével, és az eredményül kapott pontokból határozzuk meg súlyozott átlagképzéssel a poszterior eloszlásfüggvény közelítő átlagát és kovarianciáját:

$$\bar{Y} \approx \sum_{i=0}^{2n} W_i^m Y_i$$

$$P_Y \approx \sum_{i=0}^{2n} W_i^c (Y_i - \bar{Y})(Y_i - \bar{Y})^T.$$

UKF szűrés egyenletei

- A szűrés a kezdeti rendszer állapot és kovariancia mátrixa ismeretében a $k - 1$ időpontból a k időpontba lépve a következő egyenletek alapján működik, miután rendelkezésre állnak a szigma pontok.

- **Állapot átmenet**

szigma pontok transzformációja

$$\mathbf{X}_{i,t} = \mathbf{f}(\mathbf{X}_{i,k-1}, \mathbf{u}_{k-1}) \quad i = 0, \dots, 2n$$

rendszer állapot mérések előtti becslése

$$\hat{\mathbf{x}}^- = \sum_{i=0}^{2n} W_i^m \mathbf{X}_{i,t}$$

rendszer állapot kovariancia mátrix becslése

$$\hat{\mathbf{P}}^- = \sum_{j=0}^{2n} W_j^c (\mathbf{X}_{j,t} - \hat{\mathbf{x}}^-) (\mathbf{X}_{j,t} - \hat{\mathbf{x}}^-)^T + \mathbf{Q}_{k-1}$$

UKF szűrés egyenletei

- Az átmenet utáni, de még a mérések előtti rendszer állapot és a kovariancia mátrix becslését a szigma pontok f függvényen (állapot átmeneti függvény) keresztül történő "átvitelével" határozzuk meg.
- **Mérés utáni állapot becslése**

szigma pontok transzformációja a mérések terébe

$$\mathbf{z}_{i,t} = \mathbf{h}(\mathbf{X}_{i,k-1}, \mathbf{v}_{k-1}) \quad i=0, \dots, 2n$$

becslés a szigma pontok alapján

$$\hat{\mathbf{z}}_k = \sum_{i=0}^{2n} W_i^m \mathbf{z}_{i,t}$$

rendszer állapot kovariancia és keresztkovariancia mátrixainak

becslése

$$\mathbf{P}_z = \sum_{j=0}^{2n} W_j^c (\mathbf{z}_{j,t} - \hat{\mathbf{z}}_k) (\mathbf{z}_{j,t} - \hat{\mathbf{z}}_k)^T + \mathbf{R}_{k-1}$$

$$\mathbf{P}_{x,z} = \sum_{j=0}^{2n} W_j^c (\mathbf{X}_{j,t} - \hat{\mathbf{x}}_k^-) (\mathbf{z}_{j,t} - \hat{\mathbf{z}}_k)^T$$

UKF szűrés egyenletei

Kálmán-féle erősítési mátrix számítása

$$\mathbf{K}_k = \mathbf{P}_{x,z} \mathbf{P}_z^{-1}$$

rendszer állapot és kovariancia mátrix mérések utáni becslése

$$\hat{\mathbf{x}}_k = \hat{\mathbf{x}}_k^- + \mathbf{K}_k (\mathbf{z}_k - \hat{\mathbf{z}}_k)$$

$$\mathbf{P}_k = \hat{\mathbf{P}}_k^- - \mathbf{K}_k \mathbf{P}_z \mathbf{K}_k^T$$


- A mérés utáni rendszer állapot, a kovariancia és keresztkovariancia mátrixok becslését a szigma pontok h függvényén (mérési függvény) keresztül történő "átvitelével" határozzuk meg.
- Az UKF szűrési algoritmus számításigénye hasonló az EKF szűréshez, viszont nagy előnye, hogy nincs szükség az átmeneti és mérési függvények Jacobi-mátrixainak az előállítására.

Kerék odometria UKF szűrővel


- A korábbi EKF szűrővel feldolgozott adatok szűrését végezzük el
- Roger R. Labbe FilterPy eljáráskönyvtárában található UKF implementációt használjuk.

Eredmények


Szagtalan Kálmán-szűrő (UKF) eredmények



Kibővített Kálmán-szűrő (EKF) eredmények



Szagtalan Kálmán-szűrő (UKF) eredmények





Irodalom


- Ádám et al.: Műholdas helymeghatározás, 176-178. oldal.
Műegyetemi Kiadó, 2004.
- Kálmán-szűrés 2.
Jupyter munkafüzet és Python kód: (
https://github.com/gyulat/Korszeru_matek/blob/master/KF2.ipynb)
- Szagtalan Kálmán szűrő
Jupyter munkafüzet és Python kód: (
https://github.com/gyulat/Korszeru_matek/blob/master/UKF.ipynb)
- Welch G, Bishop G: An introduction to the Kalman Filter, TR 95-041,
UNC, 2006
- Gersdorf B, Frese U: A Kalman Filter for Odometry using a Wheel
Mounted Inertial Sensor, URL:
<https://pdfs.semanticscholar.org/ab65/2f5c812b580f1c6b154161317b2bb9434655.pdf>

Zárthelyi (8. hét)

- 45 perc, 5 kérdés, 30 pont, megadott témakörökből
- nincs minimum, nem pótolható
- témakörök, kérdések: oktatas.epito.bme.hu

- 
- 1) A minta jellemző értékeinek mérőszámai: mintamedián, számtani átlag, leggyakoribb érték fogalma, jellemzőik és számítási összefüggéseik
 - 2) Az adatrendszer bizonytalansága mint valamely norma értéke a minimumhelyen. L_1 , L_2 és P_1 normák: közepes eltérés, szórás, határozatlanság. Konfidencia intervallumok: interkvartilis és interszeksztilis féleterjedelem.
 - 3) A statisztikai próba feladata. Mi a statisztika? A statisztikai függvény és eloszlásának meghatározása Monte Carlo eljárással. Illeszkedésvizsgálat Kolmogorov próbával. Mi a Kolmogorov próba statisztikai függvénye és a statisztika eloszlásfüggvénye? Eloszlásfüggvények (elméleti-tapasztalati és tapasztalati-tapasztalati) összehasonlításának menete kvantilis-kvantilis ábrával. Mit nevezünk kvantilisnek?

- 
- 4) Mit ad meg az IC-függvény, és mire tudjuk használni az IC görbét? Az aszimptotikus szórásnégyzet definíciója. Mit fejez ki a Cramér-Rao határ?
 - 5) Mi egy becslés abszolút hatásfoka és mi a hatásfok jelentősége a gyakorlati munkában? Definiálja két becslés relatív hatásfokát! Mikor nevezhető egy becslés vagy statisztikai algoritmus robusztusnak?
 - 6) Mi a különbség a klasszikus és a bayesi szemléletű valószínűség felfogás között? Mondja ki Bayes tételét teljes eseményrendszerre! Ismertesse Bayes tételét sűrűségfüggvényekre alkalmazva. Mit fejez ki a likelihood függvény, mi a prior és a poszterior? A prior és a poszterior esélyhányados definíciója.
 - 7) Milyen lépésekből áll egy Monte Carlo eljárással végzett számítás? Hogyan használható egy mérési eljárás esetében a kimeneti értékek legjellemzőbb értékeinek és mérési bizonytalanságainak a számítására?

- 
- 8) Adja meg a mérési bizonytalanság definícióját és meghatározásának alapvető eljárásait a GUM alapján. Mondjon példákat a mérési bizonytalanság megadására. Minek tekinthető a geodéziában használt középhiba a GUM szempontjából? Mi a kiterjesztett bizonytalanság és a megbízhatósági tartomány?
 - 9) Röviden ismertesse a GNSS mérések kiegyenlítésének általános modelljét (funkcionális és sztochasztikus modell). Miért kell linearizálni a közvetítő egyenleteket? Mi a ponthiba és a közepes ponthiba, és hogyan lehet ezeket meghatározni három dimenzióban a ponthoz tartozó kiegyenlítés utáni kovariancia mátrix segítségével?
 - 10) Mi az egész értékű legkisebb négyzetek módszerének a lényege és mit nevezünk leképezési függvénynek? Miért van szükség dekorrelációra a megoldás megtalálásához?
 - 11) Milyen kiegyenlítési eljárás alkalmazható abban az esetben, ha sokkal több a mérés mint ahány paraméter van? Ismertesse röviden ennek az eljárásnak a lényegét.



1. házi feladat (8. hét)

- Kálmán szűrés (10 pont)
- beadás: oktatas.epito.bme.hu
- határidő: félév vége