

1. Прилог А

Основе теорије вероватноће

Основни појмови теорије вероватноће су *експеримент* и *исходи (резултати)*. Најпознатији пример којим се уводе појмови и концепти теорије вероватноће је бацање новчића и накнадно одређивање (предвиђање) на коју ће страну пасти ("глава" или "писмо").

Један од основних концепата теорије вероватноће је *случајни догађај*. Случајни или *стохастички* догађај је онај догађај који није предвидљив зато што је и сам последица великог броја узрока. Претпоставља се да и узроци случајног догађаја имају случајан карактер.

Скуп свих елементарних догађаја називамо *простор елементарних догађаја*. Простор елементарних догађаја је *дискретан* ако је број његових елемената коначан, а у случају да је број елемената бесконачан онда се такав простор назива *континуалан*.

Квантитативна оцена могућности појаве случајног догађаја представља *вероватноћу* неког догађаја. Нека X буде нека произвољна случајна променљива, и нека је x одређена вредност коју X може да има. У том случају, за исход догађаја можемо написати:

$$p(X=x) \tag{A.1}$$

У стандардном примеру са бацањем новчића важи:

$$p(X=glava)=0.5 \text{ и } p(X=pismo)=0.5 \tag{A.2}$$

Уобичајено је, ради једноставнијег записивања, да се у ознаци за вероватноћу догађаја не узима симбол случајне променљиве већ само њена могућа вредност, симболички, односно:

$$p(x) \tag{A.3}$$

У општем случају, након N извршених бацања новчића, вероватноћа појављивања једнака је лимесу *релативне фреквенције* догађаја, односно:

$$p(x) = \lim_{N \rightarrow \infty} \frac{N(x)}{N} \tag{A.4}$$

Из релације (А.4) није тешко закључити да се вероватноћа неког догађаја креће у границама:

$$0 \leq p(x) \leq 1 \quad (\text{A.5})$$

На основу претходних ставова могу се увести три аксиома теорије вероватноће:

1. Вероватноћа неког догађај је *увек ненегативна* величина:

$$p(x) \geq 0 \quad (\text{A.6})$$

2. Вероватноћа неког догађаја има вредност 1 ако ће се поменути догађај сигурно одиграти:

$$p(x) = 1 \quad (\text{A.7})$$

и вредност 0 ако не постоји вероватноћа одигравања догађаја:

$$p(x) = 0 \quad (\text{A.8})$$

3. За два догађаја који се међусобно искључују важи својство адитивности:

$$p(A \cup B) = p(A + B) = p(A) + p(B) \quad (\text{A.9})$$

односно у општем случају:

$$p(A \cup B) = p(A + B) = p(A) + p(B) - p(A \cap B) \quad (\text{A.10})$$

Концепт вероватноће може бити примењен и на две променљиве X и Y :

$$p(x, y) = p(X = x \text{ и } Y = y) \quad (\text{A.11})$$

Ако су величине X и Y *независне* важи следеће својство:

$$p(x, y) = p(x) p(y) \quad (\text{A.12})$$

Условна вероватноћа неког догађаја је:

$$p(x|y) = p(X = x | Y = y) \quad (\text{A.13})$$

Релација (А.13) нам омогућава да одредимо случајну променљиву X ако је величина Y позната. Условна вероватноћа неког догађаја је тада:

$$p(x|y) = \frac{p(x) p(y)}{p(y)} = p(x) \quad (\text{A.14})$$

што значи да ако су две величине независне онда нам величина Y неће пружити додатну информацију о променљивој X .

Међутим, уколико су две величине зависне, онда сходно Бајесовом правилу можемо одредити променљиву X на следећи начин:

$$p(x|y) = \frac{p(y|x)p(x)}{p(y)} \quad (\text{A.15})$$

Бајесово правило може бити и проширено:

$$\begin{aligned} p(x|y, z) &= \frac{p(x, y, z)}{p(y, z)} = \frac{p(y|x, z)p(x, z)}{p(y|z)p(z)} = \\ &= \frac{p(y|x, z)p(x|z)p(z)}{p(y|z)p(z)} = \frac{p(y|x, z)p(x|z)}{p(y|z)} \end{aligned} \quad (\text{A.16})$$

Бајесово правило може бити изведено и у рекурзивној форми:

$$p(x|z_1, z_2, \dots, z_n) = \frac{p(z_n|x, z_1, z_2, \dots, z_{n-1})p(x|z_1, z_2, \dots, z_{n-1})}{p(z_n|z_1, z_2, \dots, z_{n-1})} \quad (\text{A.17})$$

Одакле се увођењем претпоставке Маркова о независности величине z_n од z_1, z_2, \dots, z_{n-1} ако знамо величину x претходна релација може значајно поједноставити.

Функцијом расподеле вероватноће скаларне континуалне случајне променљиве x у тачки $x = \xi$ називамо следећу граничну вредност:

$$p_\xi(x) = \lim_{d\xi \rightarrow 0} \frac{p(\xi - d\xi < x \leq \xi)}{d\xi} \geq 0 \quad (\text{A.18})$$

Сходно основним теоретским поставкама теорије вероватноће неопозиво следи:

$$p_\xi(+\infty) = 1, \quad p_\xi(-\infty) = 0 \quad (\text{A.19})$$

Важи и:

$$p(x) = \frac{dp_\xi(x)}{d\xi} \quad (\text{A.20})$$

Неке од основних функција расподеле вероватноће, као што су *равномерна*, *експоненцијална*, *Гаусова*, *Студентова* итд. са свим својим основним карактеристикама могу се наћи у литератури.

С обзиром да је већина модела шума (како мерења тако и управљања) апроксимирана Гаусовом (нормалном) расподелом, у наставку ће бити приказана основна математичка формулација поменуте расподеле (функције). За скаларну променљиву Гаусова расподела је дата у следећем облику:

$$p(x) = (2\pi\sigma^2)^{-\frac{1}{2}} \exp\left\{-\frac{1}{2} \frac{(x-\mu)^2}{\sigma^2}\right\} \quad (\text{A.21})$$

где су са μ и σ^2 обележене очекивана вредност и варијанса, респективно. Ове две величине једнозначно одређују функцију расподеле случајне променљиве, односно, $\mathfrak{N}(x; \mu, \sigma^2)$. У случају векторске случајне променљиве, нормална расподела је:

$$p(x) = \det(2\pi\Sigma)^{-\frac{1}{2}} \exp\left\{-\frac{1}{2}(x-\mu)^T \Sigma^{-1}(x-\mu)\right\} \quad (\text{A.22})$$

где су са μ и Σ обележене одговарајуће матрице очекиване вредности величине и матрице коваријанси. Важно је напоменути је μ вектор, а матрица коваријанси Σ позитивно-семидефинитна матрица (увек позитивна). Густина расподеле је на основу претходног једнозначно дефинисана као $\mathfrak{N}(x; \mu, \Sigma)$.

Потребно је и математички дефинисати очекивану вредност μ расподеле и матрицу коваријанси Σ . Очекивана вредност μ се може дефинисати помоћу оператора математичког очекивања:

$$E[x] = \int_{-\infty}^{+\infty} x p(x) dx = \mu \quad (\text{A.23})$$

док је варијанса за скаларну променљиву дата као:

$$\text{var}(x) = E[(x - \bar{x})^2] = \int_{-\infty}^{+\infty} (x - \bar{x})^2 p(x) dx = E[x^2] - E[x]^2 = \sigma^2 \quad (\text{A.24})$$

Основне особине оператора математичког очекивања су:

1. $E[C] = C, C = \text{const.},$
2. $E[Cx] = C E[x],$
3. $E[x+y] = E[x] + E[y],$
4. $E[Cxy] = C E[x] E[y],$
5. $E[x^T y] = 0$, ако су величине x и y независне.

2. Прилог Б

Линеарна алгебра

Б.1 Извод вектора и матричне функције

Нека је $f(x)$ нека функција реалног или комплексног аргумента при чему је аргумент x вектор са N компоненти. Први извод функције $f(x)$ је тада:

$$\text{grad}f = \frac{\partial \mathbf{f}(x)}{\partial x} \quad (\text{Б.1.1})$$

и назива се *градијент*. Елементи градијента дефинисани су на следећи начин:

$$\frac{\partial \mathbf{f}(x)}{\partial x_n}, 1 \leq n \leq N \quad (\text{Б.1.2})$$

Други извод функције $f(x)$ је матрица типа $N \times N$ која се назива *Хесијан*:

$$H(x) = \frac{\partial^2 \mathbf{f}(x)}{\partial x^2} \quad (\text{Б.1.3})$$

са елементима који су дефинисани на следећи начин:

$$h_{nm}(x) = \frac{\partial^2 \mathbf{f}(x)}{\partial x_n \partial x_m} \quad (\text{Б.1.4})$$

Јакобијан матрица N -димензионе векторске функције $\mathbf{f}(\cdot)$ одређује се сходно:

$$J(x) = \frac{\partial \mathbf{f}(x)}{\partial x} \quad (\text{Б.1.5})$$

где су елементи Јакобијан матрице

$$j_{nm}(x) = \frac{\partial \mathbf{f}_n(x)}{\partial x_m} \quad (\text{Б.1.6})$$

Б.2 Квадратна форма и извод квадратне форме

За сваки вектор $x \in \mathfrak{R}^{n \times 1}$ и матрицу $A \in \mathfrak{R}^{n \times n}$ скаларна функција дефинисана на следећи начин:

$$f(x) = x^T A x = \sum_{i=1}^n \sum_{j=1}^n a_{ij} x_i x_j \quad (\text{Б.2.1})$$

назива се *квадратна форма*.

За квадратну форму се каже да је *позитивно дефинитна* када год је матрица A позитивно дефинитна матрица.

Основне особине квадратне форме одређују се помоћу матрице A .

Квадратна форма је:

- ♦ *Позитивно (негативно) дефинитна* ако и само ако је матрица $A > 0$ ($A < 0$) за свако $x \neq 0$,
- ♦ *Позитивно (негативно) семи-дефинитна* ако и само ако је матрица $A \geq 0$ ($A \leq 0$).

Нека је дата квадратна форма:

$$y = x^T A x \quad (\text{Б.2.2})$$

где је матрица A квадратна матрица типа $N \times N$. Први извод квадратне форме је:

$$\frac{\partial y}{\partial x} = A x + A^T x \quad (\text{Б.2.3})$$

а уколико је матрица A симетрична израз се своди на:

$$\frac{\partial y}{\partial x} = 2A x \quad (\text{Б.2.4})$$

Други извод квадратне форме је у општем случају:

$$\frac{\partial^2 y}{\partial x^2} = \frac{\partial}{\partial x} \left(\frac{\partial y}{\partial x} \right) = A + A^T \quad (\text{Б.2.5})$$

Иначе, што у случају симетричне матрице A квадратне форме даје следећи резултат:

$$\frac{\partial^2 y}{\partial x^2} = \frac{\partial}{\partial x} \left(\frac{\partial y}{\partial x} \right) = 2A \quad (\text{Б.2.6})$$

У следећој табели су дата основна правила:

\mathbf{y}	$\frac{\partial y}{\partial x}$
\mathbf{Ax}	\mathbf{A}^T
$\mathbf{x}^T \mathbf{A}$	\mathbf{A}
$\mathbf{x}^T \mathbf{x}$	$\mathbf{2x}$
$\mathbf{x}^T \mathbf{Ax}$	$\mathbf{Ax} + \mathbf{A}^T \mathbf{x}$

Б.3 Извод сложене векторске функције

Потребно је одредити $\frac{\partial z}{\partial x}$ где је \mathbf{z} функција векторског аргумента \mathbf{y} који је даље функција векторског аргумента \mathbf{x} . Развијањем комплетног израза веома лако се доказује следећа једнакост:

$$\frac{\partial z}{\partial x} = \left(\frac{\partial y}{\partial x}\right)^T \left(\frac{\partial z}{\partial y}\right)^T \quad (\text{Б.3.1})$$

Важно је нагласити да уколико је потребно да се одреди извод функције \mathbf{w} , која је функција \mathbf{z} , која је функција \mathbf{y} , која је функција \mathbf{x} , онда следи:

$$\frac{\partial w}{\partial x} = \frac{\partial y}{\partial x} \frac{\partial z}{\partial y} \frac{\partial w}{\partial z} \quad (\text{Б.3.2})$$

Б.4 Инверзна матрична лема – општи и специјални случај

Инверзија производа две или више матрица постоји и потпуно је математички дефинисана. С друге стране, у општем случају инверзија збира двеју или више матрица *не постоји*. Односно, $(\mathbf{A} + \mathbf{B})^{-1}$ може, али у општем случају не мора, да буде једнако збиру инверзија појединачних матрица \mathbf{A} и \mathbf{B} :

$$(\mathbf{A} + \mathbf{B})^{-1} \neq \mathbf{A}^{-1} + \mathbf{B}^{-1} \quad (\text{Б.4.1})$$

Шерман-Морисонова формула, гласи:

$$(\mathbf{A} + \mathbf{CD}^T)^{-1} = \mathbf{A}^{-1} - \mathbf{A}^{-1} \mathbf{C} (\mathbf{I} + \mathbf{D}^T \mathbf{A}^{-1} \mathbf{C})^{-1} \mathbf{D}^T \mathbf{A}^{-1} \quad (\text{Б.4.2})$$

Постоји и специјалан случај инверзне матричне леме који је у употреби у теорији естимације и назива се Шерман-Морисон-Вудбуријева формула:

$$(\mathbf{R} + \mathbf{PQP}^T)^{-1} = \mathbf{R}^{-1} - \mathbf{R}^{-1} \mathbf{P} (\mathbf{Q}^{-1} + \mathbf{P}^T \mathbf{R}^{-1} \mathbf{P})^{-1} \mathbf{P}^T \mathbf{R}^{-1} \quad (\text{Б.4.3})$$

Докази Шерман-Морисонове леме и Шерман-Морисон-Вудбуријеве леме могу се једноставно извести. У том смислу, у наставку овог прилога биће изведен доказ за

Шерман-Морисонову формулу. Применом идентичног поступка може се извести и доказ за Шерман-Морисон-Вудбуријево лему.

Да би се доказала једнакост (Б.4.2) све што је потребно је показати да важи следећа једнакост:

$$(A^{-1} - A^{-1}C(I + D^T A^{-1}C)^{-1}D^T A^{-1})(A + CD^T) = I \quad (\text{Б.4.4})$$

Уведимо следећу смену ради једноставнијег записивања:

$$B = (I + D^T A^{-1}C)^{-1} \quad (\text{Б.4.5})$$

Једнакост (Б.4.4) сада гласи

$$(A^{-1} - A^{-1}CBD^T A^{-1})(A + CD^T) = I \quad (\text{Б.4.6})$$

Множењем чланова израза добијамо:

$$\begin{aligned} \underbrace{A^{-1}A}_I - A^{-1}CBD^T A^{-1}CD^T - A^{-1}CBD^T \underbrace{A^{-1}A}_I + A^{-1}CD^T &= I \\ I + A^{-1}C(D^T - BD^T - BD^T A^{-1}CD^T) &= I \end{aligned} \quad (\text{Б.4.7})$$

Да би претходна једнакост била задовољена потребно је показати да је израз у загради једнак нули:

$$\begin{aligned} I + A^{-1}C(I - B - BD^T A^{-1}C)D^T &= I \\ I + A^{-1}C(I - \underbrace{B(I + D^T A^{-1}C)}_{B^{-1}})D^T &= I \\ I + A^{-1}C(I - \underbrace{BB^{-1}}_I)D^T &= I \\ \underbrace{0} &= 0 \end{aligned} \quad (\text{Б.4.8})$$

чиме је инверзна матрична лема доказана.

Б.5 Развијање функције векторске промењљиве у Тејлоров ред

Аналогно развијању функције скаларне промењљиве у Тејлоров ред у околини неке посматране тачке x_0 , математички је дефинисан и развој векторске функције у околини тачке (вектора) x_0 .

Тејлорова теорема у простору \mathfrak{R}^n каже да ако је $f(x)$ нека функција дефинисана у \mathfrak{R}^n , при чему је аргумент $f(x)$ реална променљива дефинисана у $x \in \mathfrak{R}^{n \times 1}$, онда се вредност $f(x)$ у тачки x може одредити на следећи начин:

$$f(x) = f(x_0) + (x - x_0)^T \nabla f(x_0) + (x - x_0)^T H(x_0)(x - x_0) + O(\|x - x_0\|^2) \quad (\text{Б.5.1})$$

Где су:

x_0 – тачка у којој се функција апроксимира Тејлоровим редом (полиномом),

$\nabla f(x_0)$ - градијент векторске функције $\frac{\partial \mathbf{f}(x)}{\partial x_n}$ дефинисан изразом (Б.1.2) срачунат у тачки апроксимације x_0 , односно $\left(\frac{\partial \mathbf{f}(x)}{\partial x_n} \right)_{x=x_0}$,

$H(x_0)$ - матрица других извода векторске функције (Хесијан) дефинисана изразом (Б.1.3), срачуната у тачки апроксимације x_0 , где су елементи матрице
$$h_{nm}(x) = \left(\frac{\partial^2 \mathbf{f}(x)}{\partial x_n \partial x_m} \right)_{x=x_0}$$

Ако је тачка x_0 критична тачка (екстрем) онда члан реда $(x - x_0)^T H(x_0)(x - x_0)$ одређује понашање функције $f(x)$ у тачки x која је у непосредној близини тачке x_0 :

- ◆ Ако је матрица $H(x)$ позитивно-дефинитна, онда функција $f(x)$ има минимум у тачки x ,
- ◆ Ако је матрица $H(x)$ негативно-дефинитна, онда функција $f(x)$ има максимум у тачки x .

Б.6 Норма Махаланобиса¹

За разлику од еуклидске норме која је дефинисана следећим изразом:

$$\|x\| = \left(\sum_{i=1}^n x_i^2 \right)^{\frac{1}{2}} = \sqrt{x^T x} \quad \forall x \in \mathfrak{R}^{n \times 1} \quad (\text{Б.6.1})$$

норма (метрика) *Махаланобиса* уводи тежинску матрицу која представља корелацију између два скупа. Норма *Махаланобиса* је дата као:

$$\|d\| = \sqrt{(x - x_0)^T P^{-1} (x - x_0)} \quad \forall x \in \mathfrak{R}^{n \times 1} \quad (\text{Б.6.2})$$

На основу (Б.6.2) веома једноставно је закључити да се за јединичну тежинску матрицу норма *Махаланобиса* своди на еуклидску норму. Норма *Махаланобиса* се користи да одреди сличност између два скупа, једног чије вредности су познате и другог чије вредности треба одредити.

¹ Прасанта Шандра Махаланобис (1893-1972), индијски математичар

3. Прилог В

Калманов филтер (основна формулација)

Нека је дат неки сигнал $x_1(t)$ са придруженим шумом $x_2(t)$, и замислимо да само збир ове две величине $y(t) = x_1(t) + x_2(t)$ можемо да одредимо, односно употребом сензора можемо "доћи" до информације о збиру ове две величине при чему не знамо колики део сензорске информације $y(t)$ припада "правом" $x_1(t)$ а колики шуму $x_2(t)$. Такође, замислимо и да нам је доступна информација о претходним мерењима на основу којих можемо да формирамо следећи низ $\{y(t_0), y(t_1), \dots, y(t)\}$. Питање на које треба дати одговор је: *Шта можемо да закључимо о стању система у тренутку t_1 ако t_1 може да буде мање, веће или једнако тренутку t ? Естимација* (оцењивање) представља процес оцењивања параметара стања или пак самог стања система на основу прикупљених информација. Проблем естимације се може разврстати у три категорије.

- ♦ *Филтрација*; $t_1 = t$ - представља процес који за циљ има одређивање удела сигнала $x_1(t)$ и шума $x_2(t)$ у сензорској информацији $y(t)$.
- ♦ *Предикција*; $t_1 > t$ - сврха процеса предикције је да се на основу свих информација прикупљених до тренутка t направи што боље предвиђање стања система, или само једног елемента система, у тренутку t_1 .
- ♦ *Интерполација*; $t_1 < t$ - основни циљ процеса интерполације је прикупљање што више валидних информација о неком процесу или систему.

Калманов филтер претпоставља да се линеарни динамички систем напише у форми једначина које описују простор стања и да се на тим једначинама изведе *рекурзивна естимација*. Под термином рекурзивна естимација подразумева се оцењивање стања система на основу информација о мерењима али се разматрају само најскорије информације о стању система. Другим речима, важи претпоставка Маркова.

Нека је дата једначина система у простору стања:

$$x_{k+1} = F_{k+1,k} x_k + w_k \quad (\text{B.1})$$

где $F_{k+1,k}$ представља матрицу система која дефинише транзицију система из x_k у x_{k+1} , док је w_k шум чије основне карактеристике су:

$$E[w_n w_k^T] = \begin{cases} Q_k, & n = k \\ 0, & n \neq k \end{cases} \quad (\text{B.2})$$

Претпоставља се да шум спада у *беле шуме* и да има нормалну расподелу са нултом очекиваном вредношћу. Такође, претпоставља се да почетно стање x_0 познато одређеном очекиваном вредношћу и познатом матрицом коваријанси.

Излаз система (или једначина мерења) је:

$$y_k = H_k x_k + v_k \quad (\text{B.3})$$

Матрица H_k је матрица излаза система док је v_k шум мерења за кога важе идентичне претпоставке као и код шума система w_k , односно:

$$E[v_n v_k^T] = \begin{cases} R_k, & n = k \\ 0, & n \neq k \end{cases} \quad (\text{B.4})$$

Два шума, шум мерења v_k и шум система w_k који су уведени у анализу у циљу правилног моделовања реалне ситуације су *независни* један од другог али и од почетног стања x_0 . Ова претпоставка се зове *линеарна Гаусова претпоставка*. Након увода у коме је дефинисана суштина проблема и где се уведене основне претпоставке следи извођење Калмановог филтера.

Нека је извршено прикупљање информација (мерење) о стању система у тренутку k на основу чега треба извршити ваљану оцену стања система које је дато вектором стања x_k . Вектор оцене стања система \hat{x}_k може бити представљен као линеарна комбинација предвиђеног стања система на основу претходног понашања и нових информација о стању система:

$$\hat{x}_k = G_k^{(1)} \hat{x}_k^- + G_k y_k \quad (\text{B.5})$$

Вектор \hat{x}_k^- је стање система које је предвиђено на основу претходних стања кроз које је систем прошао и предтсваља *a priori* процену стања (информације о мерењу *нису* узете у обзир). Вектор y_k је вектор чије компоненте су мерења, док матрице $G_k^{(1)}$ и G_k треба одредити.

Грешка оцене је дефинисана на следећи начин:

$$\tilde{x}_k = x_k - \hat{x}_k \quad (\text{B.6})$$

Да би успешно одредили оптимално решење неопходно је увести *критеријум перформансе* J_k , који у овом случају мора да задовољи следеће услове:

- ♦ Критеријум перформансе J_k мора бити *ненегативна* функција,
- ♦ Критеријум перформансе J_k мора бити *функција* грешке оцене стања система.

На основу горњих услова критеријум перформансе J_k своди се на следећи облик:

$$J_k = E[(x_k - \hat{x}_k)^2] = E[(\tilde{x}_k)^2] \quad (\text{B.7})$$

који представља критеријум минимизације грешке у смислу *методе најмањих квадрата*.

С обзиром да је у питању *Марковски процес* грешка коју правимо је потпуно независна од претходних мерења, односно математички исказано:

$$E[\tilde{x}_k y_i^T] = 0 \quad ; \quad i = 1, 2, \dots, k-1 \quad (\text{B.8})$$

Заменом израза за \tilde{x}_k и y_i^T у израз (B.8) који дефинише ортогоналност две величине добијамо:

$$E[(x_k - G_k^{(1)} \hat{x}_k^- - G_k y_k) y_i^T] = 0 \quad ; \quad i = 1, 2, \dots, k-1 \quad (\text{B.9})$$

Даљим развијањем имамо:

$$E[(x_k - G_k^{(1)} \hat{x}_k^- - G_k H_k x_k - G_k w_k) y_i^T] = 0 \quad (\text{B.10})$$

Одакле се након сређивања добија следећа једначина:

$$E[(I - G_k H_k - G_k^{(1)}) x_k y_i^T + G_k^{(1)} (x_k - \hat{x}_k^-) y_i^T] = 0 \quad (\text{B.11})$$

Оператор математичког очекивања E је линеарни оператор па након његове примене на горњи израз уз чињеницу да је грешка која се направи пре мерења (на основу *a priori* информација) независна од мерења y_k ($E[(x_k - \hat{x}_k^-) y_i^T] = 0$) следи:

$$(I - G_k H_k - G_k^{(1)}) E[x_k y_i^T] = 0 \quad (\text{B.12})$$

Израз (B.12) ће бити тачан само у случају ако је члан $(I - G_k H_k - G_k^{(1)})$ једнак нули за потпуно произвољне величине x_k и y_i , па је на основу тога прва непозната величина (матрица) у функцији друге:

$$G_k^{(1)} = I - G_k H_k \quad (\text{B.13})$$

Заменом у полазни израз за \hat{x}_k и након сређивања добијамо:

$$\hat{x}_k = \hat{x}_k^- + G_k (y_k - H_k \hat{x}_k^-) \quad (\text{B.14})$$

Матрица G_k назива се *Калманово појачање (Kalman Gain)* и "физички" представља наш степен поверења у последње мерење које је извршено, односно колико озбиљно схватамо мерење у односу на предвиђену вредност мерења $H_k \hat{x}_k^-$.

Да би целокупно извођење Калмановог филтера било комплетно потребно је одредити матрицу Калмановог појачања у целости. У том циљу можемо увести нову величину у анализу која се назива *иновација мерења*:

$$\tilde{y}_k = y_k - \hat{y}_k \quad (\text{B.15})$$

која дефинише колико нових информација имамо у y_k . Величина \hat{y}_k је *предикција мерења* која је извршена на основу свих претходних мерења y_1, y_2, \dots, y_{k-1} . Вектор иновације мерења може бити написан у следећем, знатно погоднијем облику

$$\begin{aligned}\tilde{y}_k &= y_k - \hat{y}_k \\ &= H_k x_k + v_k - H_k \hat{x}_k^- \\ &= H_k (x_k - \hat{x}_k^-) + v_k \\ &= H_k \tilde{x}_k^- + v_k\end{aligned}\tag{B.16}$$

Однос између грешке оцене \tilde{x}_k и предикције мерења \hat{y}_k је на основу принципа ортогоналности дат следећом релацијом

$$\begin{aligned}E[\tilde{x}_k \hat{y}_k^T] &= 0 \\ E[(x_k - \hat{x}_k^-) \hat{y}_k^T] &= 0\end{aligned}\tag{B.17}$$

одакле следи и

$$E[(x_k - \hat{x}_k^-) \tilde{y}_k^T] = 0\tag{B.18}$$

Принципом ортогоналности се исказује да је коваријанса компонената вектора грешке оцене стања система и компонената вектора мерења нула. Једнакост (B.18) има велики значај с обзиром да се на основу особине ортогоналности грешке оцене \tilde{x}_k и предикције мерења \hat{y}_k изводи израз за Калманово појачање. Наиме, грешка оцене \tilde{x}_k може бити написана и на следећи начин

$$\begin{aligned}\tilde{x}_k &= x_k - \hat{x}_k \\ &= x_k - \hat{x}_k^- - G_k H_k x_k - G_k v_k + G_k H_k \hat{x}_k^- \\ &= (I - G_k H_k) \underbrace{(x_k - \hat{x}_k^-)}_{\tilde{x}_k^-} - G_k v_k\end{aligned}\tag{B.19}$$

где је са \tilde{x}_k^- обележена грешка пре него што је мерење узето у обзир.

Развијањем израза (B.18) добија се:

$$E\{[(I - G_k H_k) \tilde{x}_k^- - G_k v_k] (H_k \tilde{x}_k^- + v_k)^T\} = 0\tag{B.20}$$

уз примену чињенице да су шум мерења v_k и \tilde{x}_k^- ортогонални, имамо

$$(I - G_k H_k) E[\tilde{x}_k^- (\tilde{x}_k^-)^T] H_k^T - G_k \underbrace{E[v_k v_k^T]}_{R_k} = 0\tag{B.21}$$

Величина $E[\tilde{x}_k^- (\tilde{x}_k^-)^T]$ може бити развијена на следећи начин:

$$E[\tilde{x}_k^- (\tilde{x}_k^-)^T] = E[(x_k - \hat{x}_k^-)(x_k - \hat{x}_k^-)^T] = P_k^-\tag{B.22}$$

и представља матрицу коваријанси пре него што су информације о мерењу узете у обзир.

Матрица Калмановог појачања се сада лако одређује:

$$G_k = P_k^- H_k^T [H_k P_k^- H_k^T + R_k]^{-1} \quad (\text{B.23})$$

Као што се може видети, матрица Калмановог појачања зависи од *a priori* матрице коваријанси P_k^- , матрице излаза система H_k , и матрице коваријанси шума мерења R_k . Матрица коваријанси стања система P_k се може написати у следећем облику:

$$P_k = E[\tilde{x}_k (\tilde{x}_k)^T] = E[(x_k - \hat{x}_k)(x_k - \hat{x}_k)^T] \quad (\text{B.24})$$

Заменом израза за грешку вектора стања у претходни израз:

$$P_k = E\{[(I - G_k H_k)(x_k - \hat{x}_k^-) - G_k v_k] \{[(I - G_k H_k)(x_k - \hat{x}_k^-) - G_k v_k]^T\}} \quad (\text{B.25})$$

Одакле се након сређивања уз примену претпоставке о независности грешке стања система и шума мерења v_k добијамо следећи израз:

$$\begin{aligned} P_k &= (I - G_k H_k) E[\tilde{x}_k^- (\tilde{x}_k^-)^T] (I - G_k H_k)^T - G_k E[v_k (v_k)^T] G_k^T \\ &= (I - G_k H_k) P_k^- (I - G_k H_k)^T - G_k R_k G_k^T \end{aligned} \quad (\text{B.26})$$

Заменом матрице Калмановог појачања у претходни израз и након сређивања:

$$P_k = (I - G_k H_k) P_k^- \quad (\text{B.27})$$

Претходна једначина показује зависност *a posteriori* (после мерења) матрице коваријанси од *a priori* (пре мерења) матрице коваријанси. Преостало је само да се покаже како претходно стање система утиче на садашње.

Ако напишемо следећу једнакост:

$$\hat{x}_k^- = F_{k,k-1} \hat{x}_{k-1} \quad (\text{B.28})$$

где матрица $F_{k,k-1}$ представља матрицу система која дефинише транзицију оцене стања система у тренутку $k-1$ у оцену стања система у тренутку k али пре него што је мерење извршено. Грешку оцене \tilde{x}_k^- пре него што је мерење узето у обзир можемо написати на следећи начин:

$$\begin{aligned} \tilde{x}_k^- &= x_k - \hat{x}_k^- \\ &= (F_{k,k-1} x_{k-1} + w_{k-1}) - F_{k,k-1} \hat{x}_{k-1} \\ &= F_{k,k-1} \tilde{x}_{k-1} + w_{k-1} \end{aligned} \quad (\text{B.29})$$

Коваријансна матрица стања система пре мерења је дата у следећем облику:

$$\begin{aligned} P_k^- &= F_{k,k-1} E[\tilde{x}_{k-1} (\tilde{x}_{k-1})^T] F_{k,k-1}^T + E[w_{k-1} w_{k-1}^T] \\ &= F_{k,k-1} P_{k-1} F_{k,k-1}^T + Q_{k-1} \end{aligned} \quad (\text{B.30})$$

који тачно показује како *a priori* матрица P_k^- у тренутку k зависи од *a posteriori* матрице коваријанси P_{k-1} у тренутку $k-1$, али и од коваријансне матрице Q_{k-1} .