

УДК 681.51

Минимаксное оценивание движения летательного аппарата в условиях априорной стохастической неопределённости

А.Р. Панков, А.С. Попов.

Рассмотрена задача параметрической идентификации кинематической модели движения летательного аппарата (ЛА) в условиях неполной информации о характеристиках параметров модели и ошибок наблюдений. Исследуются методы борьбы с систематическими ошибками наблюдений. Получены явные выражения для некоторых минимаксных оценивателей движения ЛА. Рассмотрены результаты численных экспериментов.

Введение

Проблемы и методы оценивания параметров движения летательного аппарата (ЛА) по результатам траекторных измерений изучены достаточно хорошо в случае точно известных характеристик случайных ошибок наблюдений и при отсутствии систематических ошибок [1-4]. На практике указанная информация зачастую отсутствует или имеет весьма приблизительный характер. В частности, ковариационные матрицы случайных ошибок измерений обычно известны лишь с точностью до принадлежности некоторому априорно заданному множеству допустимых ковариационных матриц, которое может быть довольно широким. Что же касается систематических погрешностей наблюдений, то их адекватная математическая модель обычно отсутствует [1].

Указанные проблемы вызвали необходимость разработки методов гарантирующего оценивания параметров движения ЛА [6], обладающих устойчивостью к возможным отклонениям реальных характеристик ошибок наблюдений от их расчётных значений.

В данной работе рассматривается метод оценивания параметров движения ЛА в условиях неполной априорной информации о характеристиках ошибок наблюдения (неопределённо-стохастическая модель).

Для построения соответствующих алгоритмов оценивания использован минимаксный подход и теория двойственности экстремальных задач [6,7,8].

1. Модель наблюдений

1.1 Кинематическая модель движения ЛА

Рассмотрим кинематическую модель движения ЛА в некоторой декартовой системе координат. Пусть $Z_t = \{z_{1t}, z_{2t}, z_{3t}\}^*$ - вектор декартовых координат ЛА в момент $t \in [0, T]$, где T - момент времени окончания наблюдения за движением ЛА. Здесь и далее $*$ - операция транспонирования. Пусть также $\{\psi_k(t)\}_{k=1}^{\infty}$ - полная система функций в пространстве $L_2[0, T]$.

Представим зависимость координат ЛА от времени в виде $z_{it} = \sum_{k=1}^{n_i} a_{ik} \psi_k(t)$, где $\{n_i\}$ - определяют порядок модели движения по каждой координате, а $i=1,2,3$,

$$\text{Пусть } \theta = \{a_{11}, \dots, a_{1n_1}, a_{21}, \dots, a_{2n_2}, a_{31}, \dots, a_{3n_3}\}^*,$$

$$\Psi(t) = \begin{bmatrix} \psi_1(t) & \dots & \psi_{n_1}(t) & 0 & \dots & 0 & 0 & \dots & 0 \\ 0 & \dots & 0 & \psi_1(t) & \dots & \psi_{n_2}(t) & 0 & \dots & 0 \\ 0 & \dots & 0 & 0 & \dots & 0 & \psi_1(t) & \dots & \psi_{n_3}(t) \end{bmatrix}$$

Теперь модель движения ЛА можно представить в окончательном виде

$$Z_t = \Psi(t)\theta, \quad t \in [0, T].$$

1.2 Модель траекторных наблюдений

Рассмотрим связь декартовых координат Z_t с измеряемыми координатами Q_t :

$$Q_t = \varphi(Z_t),$$

где $\varphi(\cdot)$ задаёт связь декартовых координат с измеряемыми. При проведении траекторных наблюдений имеют место два случая [1, 2]:

1) $Q_t = \{r_t, \beta_t, \varepsilon_t\}^*$, где r_t - наклонная дальность, β_t - азимут, ε_t - угол места.

$$\begin{cases} r_t = [(z_{1t})^2 + (z_{2t})^2 + (z_{3t})^2]^{1/2} \\ \beta_t = \begin{cases} \arccos(z_{1t} [(z_{1t})^2 + (z_{2t})^2]^{-1/2}), & \text{если } z_{2t} \geq 0 \\ \pi + \arccos(z_{1t} [(z_{1t})^2 + (z_{2t})^2]^{-1/2}), & \text{если } z_{2t} < 0 \end{cases} \\ \varepsilon_t = \arcsin(z_{3t} / r_t) \end{cases}$$

2) $Q_t = \{r_t, \cos(\varphi_{1t}), \cos(\varphi_{2t})\}^*$, где $\cos(\varphi_{kt}) = z_{kt} / r_t$, $k=1,2$ - направляющие косинусы.

Модель реальных наблюдений имеет вид

$$\tilde{Q}_t = Q_t + \Delta Q_t,$$

где \tilde{Q}_t - результат измерения вектора Q_t , ΔQ_t - ошибка наблюдения. Далее предполагается:

$\Delta Q_t = \rho_t + v_t$, где $\{v_t\}$ - векторный белый шум (случайные ошибки наблюдений), $M[v_t] = 0$, $\{\rho_t\}$ - неслучайная функция времени (систематическая погрешность).

Объединяя модели для \tilde{Q}_t и Z_t , получаем

$$\tilde{Q}_t = H_t(\theta) + \Delta Q_t, t = 1, \dots, T,$$

где $H_t(\theta) = \varphi(\Psi(t)\theta)$ - параметрическая модель точных наблюдений (нелинейная). Существует множество эффективных способов оценки параметров нелинейной модели, в данной статье применяется линеаризация модели с последующей оценкой параметров модели.

2. Линеаризация параметрической модели

Для упрощения дальнейших исследований проведём линеаризацию модели наблюдения, т.е. представим её в линейном по θ виде:

$$Y_t = X_t\theta + \Delta Q_t, t = 1, \dots, T \quad (1)$$

1. Пусть имеется некоторое опорное значение θ_0 для вектора параметров θ , тогда

$$\tilde{Q}_t = H_t(\theta_0) + G_t(\theta - \theta_0) + \Delta Q_t, \text{ где } G_t = \left. \frac{\partial H_t(\theta)}{\partial \theta} \right|_{\theta = \theta_0}$$

Теперь, обозначая

$$X_t = G_t, \quad Y_t = \tilde{Q}_t + G_t\theta_0 - H_t(\theta_0), \quad (2)$$

приходим к модели (1).

2. Если ошибки ΔQ_t малы по сравнению с Q_t , то можно воспользоваться следующим способом линеаризации: из $Z_t = \varphi^{-1}(\tilde{Q}_t - \Delta Q_t)$ следует $Z_t = \varphi^{-1}(\tilde{Q}_t) - C_t\Delta Q_t$, где

$$C_t = \left. \frac{\partial \varphi^{-1}(Q_t)}{\partial Q_t} \right|_{Q_t = \tilde{Q}_t}. \text{ Опять приходим к уравнению (1), если положить}$$

$$X_t = C_t^{-1}\Psi(t), \quad Y_t = C_t^{-1}\varphi^{-1}(\tilde{Q}_t) \quad (3)$$

Далее считаем, что соответствующие преобразования уже проведены, и мы в качестве исходной модели наблюдения используем (1).

3. Постановка задачи минимаксного оценивания

3.1 Описание множеств неопределённости

Опишем теперь множества неопределённости ковариационных матриц и систематических ошибок модели (1), записанной в матричном виде:

$$Y = X\theta + \Delta Q,$$

где $Y = (Y_1, \dots, Y_T)^*$, $X = (X_1^*, \dots, X_T^*)^*$, $\Delta Q = (\Delta Q_1, \dots, \Delta Q_T)^*$.

При сделанных выше предположениях $\Delta Q = \rho + v$. Вектор наблюдений $Y \in H$, а белый шум $v \in L$, $\rho \in M \subseteq K$, где H , L , K – конечномерные евклидовы пространства с соответствующими скалярными произведениями и нормами, M – выпуклый центрально-симметричный компакт. Тогда множество неопределённости W ковариационной матрицы R_v случайных погрешностей v имеет вид:

$$W = \left\{ R_v \in L^+(L \times H) : R_v \in \tilde{W} \right\}, \quad (4)$$

где $L^+(L \times H)$ – семейство неотрицательно определённых самосопряжённых операторов в $L \times H$, \tilde{W} – выпуклое компактное подмножество операторов из $L^+(L \times H)$.

Конкретизируем предположение о множестве неопределённости систематических ошибок измерения:

$$M = \left\{ \rho \in K : \rho^* \Sigma \rho \leq 1 \right\}, \quad (5)$$

где $\Sigma \in L^+(K)$ – некоторая весовая матрица, задаваемая априорно.

Обозначим через P_ε обобщённое распределение неопределённо-стохастического вектора $\varepsilon = \text{col}[\rho, v]$. Далее, суммируя всё вышесказанное, предположим, что

$P_\varepsilon \in \Xi$, где

$$\Xi = \left\{ P_\varepsilon : \rho \in M, R_v \in W, M[v] = 0 \right\} \quad (6)$$

Таким образом, Ξ – множество допустимых распределений вектора ε . Если Ξ не является одноточечным, то оно задаёт класс неопределённостей модели наблюдения (1), которую мы называем, следуя [6, 7], *обобщённой неопределённо-стохастической линейной моделью* наблюдения.

3.2 Критерий

Пусть $\tilde{\theta} = F(Y)$ - оценка параметра Θ по наблюдениям Y в модели (1), где F – оператор оценивания. Предполагается, что F принадлежит классу \mathfrak{F} линейных операторов оценивания. Далее через $\Delta\tilde{\theta} = \tilde{\theta} - \theta$ будем обозначать ошибку оценки $\tilde{\theta}$. В данной работе будем использовать следующий критерий качества оценки:

$$J(F, P_\varepsilon) = E_{P_\varepsilon} \left\{ \|\Delta\tilde{\theta}\|^2 \right\}, \quad (7)$$

где E_{P_ε} - оператор усреднения по распределению P_ε .

Заметим, что при одном и том же алгоритме оценивания F критерий (7) будет принимать различные значения при изменении распределения P_ε параметров ε модели (1).

Очевидно, что оценка $\tilde{\theta}$ тем точнее, чем меньше значение критерия $J(F, P_\varepsilon)$. В силу того, что распределение $P_\varepsilon \in \Xi$ и, следовательно, в общем случае точно неизвестно, оптимизацию оценки $\tilde{\theta}$ по критерию (7) на заданном выше классе операторов оценивания мы будем проводить с использованием минимаксного подхода.

3.3 Минимаксная оценка и её характеристики

Определение 1 [6]. Оценка $\hat{\theta} = F(Y)$ в модели (1) называется минимаксной на классе

неопределённости Ξ , если $\hat{F} \in \mathfrak{F}$ и

$$\sup_{P_\varepsilon \in \Xi} J(\hat{F}, P_\varepsilon) \leq \sup_{P_\varepsilon \in \Xi} J(F, P_\varepsilon) \quad \forall F \in \mathfrak{F} \quad (8)$$

Если существует хотя бы один оператор \hat{F} , удовлетворяющий (8), то будем писать:

$$\hat{F} \in \operatorname{argmin}_{F \in \mathfrak{F}} \sup_{P_\varepsilon \in \Xi} J(F, P_\varepsilon)$$

Далее полагаем, что вектор Θ идентифицируем, т.е.

$$\exists \bar{F} \in \mathfrak{F}: \sup_{P_\varepsilon \in \Xi} J(\bar{F}, P_\varepsilon) < \infty \quad (9)$$

Подводя итог вышесказанному, запишем критерий (7) в следующем эквивалентном виде:

$$J(F, P_\varepsilon) = J(F, W, M)$$

Введём следующие обозначения:

$$I(F) = \sup_{R_v \in W, \rho \in M} J(F, W, M) \quad (10)$$

$$\underline{I}(W, M) = \inf_{F \in \mathfrak{F}} J(F, W, M) \quad (11)$$

Функционал (11) называется двойственным функционалом. Таким образом, задача минимаксной идентификации в условиях априорной стохастической неопределённости имеет следующую постановку:

$$\hat{F} = \arg \min_{F \in \mathfrak{F}} J(F) \quad (12)$$

Задача (12) называется прямой задачей минимаксной оптимизации. При различных упрощающих предположениях о множествах W и M задача (12) может быть сведена к специальным задачам нелинейного программирования [4,9]. В данной работе используется

другой подход к построению \hat{F} , основанный на численном или аналитическом решении двойственной задачи

$$(\hat{R}_v, \hat{\rho}) \in \arg \max_{R_v \in W, \rho \in M} \underline{I}(W, M) \quad (13)$$

и использовании её решения $(\hat{R}_v, \hat{\rho})$ для аналитического построения минимаксного оператора \hat{F} .

4. Решение задачи минимаксного оценивания

В данном разделе сформулированы основные результаты построения минимаксного оценителя \hat{F} .

Теорема 1. Пусть выполнены все ограничения, наложенные на множества неопределённости ковариационной матрицы случайного вектора и систематическую погрешность. Пусть также выполнено условие (9), тогда

$$1. \max_{R_v \in W} \max_{\rho \in M} \underline{I}(W, M) = \max_{\rho \in M} \max_{R_v \in W} \underline{I}(W, M) \quad (14)$$

$$2. \Sigma^+ = \arg \max_{\rho \in M} I(W, M) \quad (15)$$

3. справедливо соотношение двойственности

$$\min_{F \in \Xi} \sup_{P_\varepsilon \in \Xi} J(F, P_\varepsilon) = \max_{P_\varepsilon \in \Xi} \inf_{F \in \Xi} J(F, P_\varepsilon) \quad (16)$$

Доказательство. Введём в рассмотрение следующий критерий, по которому и будем идентифицировать параметры модели:

$$J^\circ(F, P_\varepsilon) = E_{P_\varepsilon} \left\{ \left(\Delta \tilde{\theta} \right) \left(\Delta \tilde{\theta} \right)^* \right\} \quad (17)$$

Запишем модель (1) следующим образом (следуя [6,7]) с точностью до обозначений:

$$\begin{cases} Y = X\theta + \rho + D\xi + v \\ u = A\theta + B\xi \end{cases} \quad (18)$$

Матрицы D и B нулевые в рассматриваемой модели (однако в отличие от моделей, рассмотренных в [6,7], здесь присутствует систематическая ошибка в наблюдениях - ρ). Оценитель параметров движения по наблюдениям из заданного класса линейных оценок:

$$\hat{\theta} = F(Y) = FY$$

Общее выражение для значения критерия выглядит следующим образом:

$$J^\circ = (F\tilde{W} - \tilde{I})\rho\rho^* (F\tilde{W} - \tilde{I})^* + FR_\nu F^*, \text{ где}$$

$$\tilde{W} = [0 \ I_H]; \quad \tilde{I} = [0 \ 0].$$

$$\text{Тогда } J^\circ = F\rho\rho^* F + FR_\nu F^*$$

Заменим $\rho = (\Sigma^+)^{1/2} \mu$, где $\mu \in \mathbb{R}^{m \times 1}$, $\|\mu\| \leq 1$ (m – размерность одного наблюдения), тогда

$$\max_{Rv \in W, \rho \in M} J^\circ = \max_{Rv \in W, \rho \in M} (F\rho\rho^* F + FR_\nu F^*) \Rightarrow$$

$$\begin{aligned} \max_{Rv \in W, \rho \in M} J^\circ &= \max_{\rho \in M} F\rho\rho^* F + \max_{Rv \in W} FR_\nu F^* = \\ &= F\Sigma^+ F + \max_{Rv \in W} FR_\nu F^* \end{aligned}$$

$$\begin{aligned} \text{Поскольку } \max_{Rv \in W, \rho \in M} J(F, P_\varepsilon) &= \max_{Rv \in W, \rho \in M} \text{tr} [J^\circ(F, P_\varepsilon)] \geq \\ &\geq \text{tr} \left[\max_{Rv \in W, \rho \in M} J^\circ(F, P_\varepsilon) \right], \end{aligned}$$

то пункт 2 в теореме 1 доказан. Пункт 1 следует непосредственно из последнего равенства в силу коммутативности операции сложения.

Существование седловой точки следует также непосредственно из пункта 1 и доказательства существования седловой точки для модели (18) [6]. Теорема доказана.

В качестве отдельного утверждения сформулируем следующий важный результат, доказательство которого вытекает непосредственно из предыдущей теоремы.

Теорема 2. В условиях теоремы 1 минимаксная оценка параметров модели (1) имеет вид:

$$\hat{\theta} = F(\hat{V})Y \quad (19)$$

где

$$F(\hat{V}) = (\hat{X}^* \hat{V}^{-1} \hat{X})^{-1} \hat{X}^* \hat{V}^{-1}, \quad \hat{V} = \hat{R}_v + \hat{\Sigma}^+, \quad (20)$$

$$\hat{R}_v = \arg \max_{R_v \in W} \left\{ \text{tr} \left(F^*(R_v + \Sigma^+) (R_v + \Sigma^+) F(R_v + \Sigma^+) \right) \right\} \quad (21)$$

5. Алгоритм вычисления минимаксных оценок

5.1 Общий случай (решение двойственной задачи)

Процедура нахождения “наихудшей” матрицы в общем случае решается только численно. Опишем итерационный алгоритм решения двойственной задачи (13), позволяющий найти матрицу наихудших ковариаций \hat{V} , определённую по формуле (20).

Алгоритм.1) выбрать произвольную матрицу $R_v^{(0)} \in W$, определить $V^{(0)} = R_v^{(0)} + \Sigma^+$ (см. (20)) и положить $S=0$;

2) определить $F^{(S)} = \arg \min_{F \in \tilde{S}} J(F, R_v^{(S)}, \Sigma^+)$ по формуле:

$$F^{(S)} = (X^* (V^{(S)})^{-1} X)^+ X^* (V^{(S)})^{-1}$$

3) решить задачу обобщённого линейного программирования:

$$\tilde{R}_v^{(S)} \in \arg \max_{R_v \in W} J(F^{(S)}, W, \Sigma^+)$$

4) вычислить $\delta_s = J(F^{(S)}, \tilde{R}_v^{(S)}, \Sigma^+) - J(F^{(S)}, R_v^{(S)}, \Sigma^+) \geq 0$

если $\delta_s = 0$, то положить $\hat{V} = \tilde{R}_v^{(S)} + \Sigma^+$ и закончить итерационный процесс;

если $\delta_s \geq 0$, то перейти к следующему шагу;

5) определить число $\gamma_s \in [0, \tilde{\gamma}_s]$ из условия

$$\gamma_s \in \arg \max_{\gamma_s \in [0, \tilde{\gamma}_s]} J(F, R_{v\gamma}^{(s)}, \Sigma^+), \text{ где}$$

$$R_{v\gamma}^{(s)} = (1-\gamma)R_v^{(s)} + \gamma \tilde{R}_v^{(s)}, \quad \tilde{\gamma}_s = \max \{\gamma \geq 0 : R_{v\gamma}^{(s)} \in W\};$$

6) положить $R_v^{(s+1)} = R_{v\gamma}^{(s)}$, увеличить s на 1 и перейти к шагу 2) алгоритма.

Докажем сходимость описанного итерационного процесса. Пусть $\Omega = \arg \max_{R_v \in W} I(R_v, \Sigma^+)$ -

множество всех точек глобального максимума двойственного функционала $I(R_v, \Sigma^+)$.

$d(R_v, \Omega) = \inf_{\tilde{R}_v \in W} \|R_v - \tilde{R}_v\|$ - расстояние от R_v до множества Ω .

Теорема 3. Пусть множество W - выпукло и компактно. Тогда $d(R_v^{(s)}, \Omega) \rightarrow 0$ при $S \rightarrow \infty$,

если $\{R_v^{(s)}\}$ - бесконечная последовательность. Если же $\hat{R}_v = R_v^{(s)}$ при $S < \infty$, то $\hat{R}_v \in \Omega$.

Доказательство. Рассмотрим многозначное алгоритмическое отображение $\ell : W \rightarrow W$, где $R_v^{(s+1)} = \ell(R_v^{(s)})$, $R_v^{(0)} \in W$ определённое алгоритмом. В условиях теоремы

$I(R_v, \Sigma^+) = \inf_{F \in \mathfrak{F}} J(F, R_v, \Sigma^+)$, где F - оператор оценивания обобщённым методом наименьших квадратов, определённый формулой (19), который даёт оценку параметров Θ по Y в модели (1),

т.е. $\hat{\theta} = FY$

В силу компактности W , условия $R_v > 0$, заключаем, что F - непрерывно зависит от R_v , а множество $\mathfrak{F}^0 = \{F : R_v \in W\}$ - компактно. Следовательно по теореме 7.2 из [11] заключаем, что функционал

$$I(R_v, \Sigma^+) = \inf_{F \in \mathfrak{F}} J(F, R_v, \Sigma^+) \quad (22)$$

непрерывен по R_v на W .

Покажем, что $\hat{R}_v \in \Omega$ тогда и только тогда, когда $\delta_s = 0$. Функционал $\underline{I}(R_v, \Sigma^+)$ есть точная

нижняя грань на \mathfrak{Z}^0 линейных по R_v функций $J(F, R_v, \Sigma^+)$, поэтому $\underline{I}(R_v, \Sigma^+)$ вогнут на W . В

силу этого условие $\hat{R}_v \in \Omega$ равносильно:

$$\sup_{R_v \in W} \underline{I}^{(s)}(R_v^{(s)}, \Sigma^+)(R_v - R_v^{(s)}) = 0 \quad (23)$$

- производная $\underline{I}(R_v, \Sigma^+)$ в точке $R_v^{(s)}$ по направлению ΔR_v .

В силу (22), компактности W и теоремы 3.5 из [10] заключаем, что

$$\begin{aligned} \underline{I}^{(s)}(R_v^{(s)}, \Sigma^+)(R_v - R_v^{(s)}) &= \inf_{F^{(s)} \in \mathfrak{Z}} J(F^{(s)}, R_v, \Sigma^+) - \inf_{F^{(s)} \in \mathfrak{Z}} J(F^{(s)}, R_v^{(s)}, \Sigma^+) = \\ &= \inf_{F^{(s)} \in \mathfrak{Z}} J(F^{(s)}, R_v, \Sigma^+) - \underline{I}(R_v^{(s)}, \Sigma^+) = \underline{I}(R_v, \Sigma^+) - \underline{I}(R_v^{(s)}, \Sigma^+), \end{aligned}$$

поэтому условие (23) равносильно $\delta_s = 0$, т.е. $\hat{R}_v \in \Omega$.

Если же $\hat{R}_v \notin \Omega$, то $\delta_s > 0$ в силу вогнутости и линейности функционала $\underline{I}(R_v, \Sigma^+)$ на

компакте.

Из определения $R_v^{(s+1)}$ следует, что

$$\underline{I}(R_v^{(s+1)}, \Sigma^+) = \sup_{0 \leq \tau \leq \tau_s} \underline{I}((1-\tau)R_v^{(s)} + \tau \tilde{R}_v^{(s)}, \Sigma^+) \geq \underline{I}(R_v^{(s)}, \Sigma^+) \quad (24)$$

причём, в силу вогнутости $\underline{I}(R_v, \Sigma^+)$ на W , равенство (24) возможно лишь при $\delta_s = 0$, что

следует из (23). Поэтому $\underline{I}(R_v^{(s+1)}, \Sigma^+) > \underline{I}(R_v^{(s)}, \Sigma^+)$, если $\delta_s > 0$ (т.е., если $R_v \notin \Omega$).

Представим теперь отображение ℓ в виде композиции алгоритмических отображений:

$\ell = \ell_1 \circ \ell_2 \circ \ell_3$, где

1) $\ell_1 : W \rightarrow \mathfrak{Z}^0 \times W$, где $(F^{(s)}, R_v^{(s)}) = \ell_1(R_v^{(s)})$

2) $\ell_2 : \mathfrak{Z}^0 \times W \rightarrow W \times W$, где паре $(F^{(s)}, R_v^{(s)})$ ставится в соответствие $(R_v^{(s)}, \tilde{R}_v^{(s)})$, т.е. ℓ_2

задаёт направление для максимизации $\underline{I}(R_v, \Sigma^+)$, а $\tilde{R}_v^{(s)}$ определено в п. 3) алгоритма.

3) $\ell_3 : W \times W \rightarrow W$ и переводит пару $(R_v^{(s)}, \tilde{R}_v^{(s)})$ в $R_v^{(s+1)}$ по правилу $R_v^{(s+1)} = (1-\gamma)R_v^{(s)} + \gamma \tilde{R}_v^{(s)}$, а

$\tilde{\gamma}_s$ находится из решения

$\tilde{\gamma}_s = \max \{ \gamma \geq 0 : (1 - \gamma)R_v^{(s)} + \gamma \tilde{R}_v^{(s)} \in W \}$, являющегося частью действий п. 5) алгоритма.

В силу вышесказанного, можно видеть, что каждое из отображений ℓ_1, ℓ_2, ℓ_3 определяется с помощью решения соответствующей задачи оптимизации на компактах. Таким образом, в силу теоремы 3.7 из [11] заключаем, что ℓ_1, ℓ_2, ℓ_3 - замкнутые отображения, а ℓ - замкнуто на W , как композиция замкнутых отображений на компактных множествах (следствие 4.2.1 из [11]).

Таким образом, отображение ℓ обладает следующими свойствами:

- 1) $\ell : W \rightarrow W$, где W - компакт.
- 2) если $\ell(R_v^{(s)}) = R_v^{(s)}$, то $R_v^{(s)} \in \Omega$, если $R_v^{(s+1)} = \ell(R_v^{(s)}) \neq R_v^{(s)}$, то $\underline{I}(R_v^{(s+1)}, \Sigma^+) > \underline{I}(R_v^{(s)}, \Sigma^+)$.
- 3) ℓ замкнуто в каждой точке $R_v \in W$.

В силу теоремы А и леммы 11.2 из [11] заключаем, что для последовательности $\{R_v^{(s)}\}$ вида $R_v^{(s)} = \ell(R_v^{(s-1)}) \forall R_v^{(0)} \in W$ справедливо $d(R_v^{(s)}, \Omega) \rightarrow 0$ при $s \rightarrow \infty$, причём, если $R_v^{(s)} = \ell(R_v^{(s)})$, то $R_v^{(s)} \in \Omega$. Теорема 3 доказана.

Замечание. Теорема 3 устанавливает возможность следующих случаев:

- 1) алгоритм сходится за конечное число шагов;
- 2) если подпоследовательность $R_v^{(s_n)}$ сходится, то $\lim_{n \rightarrow \infty} R_v^{(s_n)} \in \Omega$, при этом хотя бы одна такая подпоследовательность существует. Если же такая подпоследовательность единственна, то $\lim_{s \rightarrow \infty} R_v^{(s)} \in \Omega$;
- 3) Если $\hat{\Omega} = \hat{R}_v$ - одноточечное множество, то $R_v^{(s)} \rightarrow \hat{R}_v$ при $s \rightarrow \infty$.
- 4) Задаче обобщённого линейного программирования посвящены многие эффективные методы [12, 13], и её решение не должно вызывать затруднений.

5.2 Специальные виды множеств неопределённости

В большинстве приложений ограничения на ковариационную матрицу ошибок наблюдений имеют такой вид, который позволяет решать задачу нахождения «наихудшей» ковариационной матрицы аналитически. Приведём некоторые примеры специальных множеств неопределённости.

1) $W = \left\{ R : R_{-ij} \leq R_{ij} \leq \bar{R}_{ij} \right\} \Leftrightarrow W = \left\{ R : R_{-} \leq R \leq \bar{R} \right\}$, где неравенство понимается покомпонентно.

2) $W = \{ R : \|R - R^0\| \leq \varepsilon \} = \{ r_{ij} : \sqrt{\sum_{i,j} |r_{ij} - r_{ij}^0|^2} \leq \varepsilon \}$

3) $W = \{R : \|R - R^0\|_s \leq \varepsilon\}$, где $\|A\|_s = \lambda_{\max}(A)$ - спектральная норма (\cdot, \cdot)

скалярное произведение, $\lambda_{\max}(A)$ - максимальное собственное значение матрицы W .

Заметим, что множества в случаях 1)-3) являются выпуклыми компактами. Случаи 2) и 3) интересны тем, что наилучшие матрицы в них ищутся аналитически. Более того в случаях 2), 3)

аналитически ищется также минимаксный оператор оценивания \hat{F} .

Сформулируем следующие результаты.

Утверждение 1. Если множество неопределённости ковариационной матрицы описывается в виде ограничения по евклидовой норме около некоторой опорной матрицы R^0 :

$$W = \{R : \|R - R^0\| \leq \varepsilon\} = \{r_{ij} : \sqrt{\sum_{i,j} |r_{ij} - r_{ij}^0|^2} \leq \varepsilon\}, \text{ то}$$

$$\exists R : R = \arg \max_{R \in W} J(F, W, M), \text{ где } \hat{R} = R^0 + \frac{\varepsilon}{\|FF^*\|} FF^*$$

Доказательство. Рассматриваемая оптимизационная задача имеет следующий вид:

$$\begin{cases} \operatorname{tr} F^* R F \rightarrow \max_R \\ \|R - R^0\| \leq \varepsilon \end{cases}$$

Пусть $F = \{f_1, \dots, f_p\}$, тогда $\operatorname{tr} F^* R F = \sum_{k=1}^p f_k^* R f_k$, где f_k - вектор-столбец матрицы F . Подводя

итог сказанному, видим, что оптимизационная задача примет вид:

$$\begin{cases} \sum_{k=1}^p f_k^* R f_k \rightarrow \max_R \\ \sum_{i,j} (r_{ij} - r_{ij}^0)^2 \leq \varepsilon^2 \end{cases}$$

Обозначая теперь $f_k = \{a_{k1}, \dots, a_{kp}\}^*$, в окончательном виде запишем:

$$\begin{cases} \sum_{i,j} \left(\sum_k a_{ki} a_{kj} \right) r_{ij} \rightarrow \max_{r_{ij}} \\ \sum_{i,j} (r_{ij} - r_{ij}^0)^2 \leq \varepsilon^2 \end{cases}$$

Решая данную задачу максимизации линейной функции на выпуклом множестве [14],

получим, что максимум доставляется при $r_{ij} = r_{ij}^0 + \frac{\sum_k a_{ki} a_{kj}}{\sqrt{\sum_{i,j} \left(\sum_k a_{ki} a_{kj} \right)^2}} \varepsilon$, или в матричном виде:

$$\hat{R} = R^0 + \frac{FF^*}{\|FF^*\|} \varepsilon. \text{ Утверждение доказано.}$$

Утверждение 2. В случае задания множества неопределённости ковариационной матрицы описывается в виде ограничения по спектральной норме около некоторой опорной матрицы R_0 :

$$W = \{R : \|R - R_0\|_{sp} \leq \varepsilon\}, \text{ где } \|A\|_{sp} = \lambda_{\max}(A) \text{ или } \|A\|_{sp} = \max_{|x|=1} (Ax, x). \text{ Тогда}$$

$$R^0 + \varepsilon I = \arg \max_{R_v \in W} J(F, W, M)$$

Пример

Рассмотрим пример, в котором движение ЛА в декартовой системе координат описывается кинематической моделью вида:

$$Z_t = \begin{pmatrix} 1 & t & 0 & 0 & 0 \\ 0 & 0 & 1 & t & 0 \\ 0 & 0 & 0 & 0 & 1 \end{pmatrix} \cdot \begin{bmatrix} 35000 \\ 250 \\ 30000 \\ 250 \\ 10000 \end{bmatrix}$$

Реально данные измерения движения ЛА - Q_t , содержат случайную и регулярную составляющие ошибки наблюдения. Проводить минимаксную идентификацию будем для линеаризованной системы следующего вида:

$$Y_t = C_t^{-1} \begin{pmatrix} 1 & t & 0 & 0 & 0 \\ 0 & 0 & 1 & t & 0 \\ 0 & 0 & 0 & 0 & 1 \end{pmatrix} \cdot \theta + v_t + \rho_t$$

При моделировании случайная величина: $v_t \sim N \left(\begin{bmatrix} 0 \\ 0 \\ 0 \end{bmatrix}, \begin{bmatrix} 625 & 2 \cdot 10^{-5} & 2 \cdot 10^{-5} \\ 2 \cdot 10^{-5} & 10^{-8} & 0 \\ 2 \cdot 10^{-5} & 0 & 10^{-8} \end{bmatrix} \right)$

Систематические ошибки в данном примере равнялись трём средним квадратическим отклонениям случайных ошибок в каждом из каналов измерения: $\rho_t = 3 \times [25 \ 10^{-4} \ 10^{-4}]^*$.

Известно, что ковариационная матрица случайного вектора V принадлежит следующему множеству неопределённости:

$$\begin{pmatrix} 600 & 10^{-7} & 2 \cdot 10^{-6} \\ 10^{-7} & 10^{-10} & 0 \\ 2 \cdot 10^{-6} & 0 & 10^{-10} \end{pmatrix} \leq R_v \leq \begin{pmatrix} 1000 & 2 \cdot 10^{-4} & 2 \cdot 10^{-4} \\ 2 \cdot 10^{-4} & 10^{-6} & 0 \\ 2 \cdot 10^{-4} & 0 & 10^{-6} \end{pmatrix}$$

Проведя численное решение задачи нахождения “наихудшей” ковариационной матрицы, получим следующую оценку минимаксной ковариационной матрицы:

$$\hat{R}_v = \begin{pmatrix} 1000 & 10^{-7} & 2 \cdot 10^{-4} \\ 10^{-7} & 10^{-6} & 0 \\ 2 \cdot 10^{-4} & 0 & 10^{-6} \end{pmatrix}$$

Учитывая результаты предыдущих разделов видно, что ковариационная матрица \hat{V} , которая будет являться матрицей весов в обобщённом методе наименьших квадратов выглядит (с сохранением всех предыдущих обозначений):

$$\hat{V} = \hat{R}_v + \hat{\Sigma}^+ = \begin{pmatrix} 1000 & 10^{-7} & 2 \cdot 10^{-4} \\ 10^{-7} & 10^{-6} & 0 \\ 2 \cdot 10^{-4} & 0 & 10^{-6} \end{pmatrix} + \begin{pmatrix} 625 \cdot 9 \cdot S & 0 & 0 \\ 0 & 10^{-8} \cdot 9 \cdot S & 0 \\ 0 & 0 & 10^{-8} \cdot 9 \cdot S \end{pmatrix}$$

Матрица C_t^{-1} в формуле (3) выглядит в данном случае:

$$C_t^{-1} = \begin{bmatrix} \cos(\varphi_2) & \cos(\varphi_1) & \sqrt{1 - (\cos(\varphi_1))^2 - (\cos(\varphi_2))^2} \\ -\frac{\cos(\varphi_1) \cdot \cos(\varphi_2)}{r} & \frac{1 - (\cos(\varphi_1))^2}{r} & -\frac{\cos(\varphi_1) \cdot \sqrt{1 - (\cos(\varphi_1))^2 - (\cos(\varphi_2))^2}}{r} \\ \frac{1 - (\cos(\varphi_2))^2}{r} & -\frac{\cos(\varphi_1) \cdot \cos(\varphi_2)}{r} & -\frac{\cos(\varphi_2) \cdot \sqrt{1 - (\cos(\varphi_1))^2 - (\cos(\varphi_2))^2}}{r} \end{bmatrix}$$

Проводя оценку параметров модели (теорема 2), получим: $\theta = (35067,6 \ 250,09 \ 30065,49 \ 250,111 \ 9954,04)^*$. Гарантированное значение критерия $\inf_{F \in \mathfrak{F}} I(F) = 812,3$.

Список литературы

1. Жданюк Б.Ф. Основы статистической обработки траекторных наблюдений.-М.: Сов. радио, 1978.- 384с.
2. Брандин В.Н., Разоренов Г.Н. Определение траектории космических аппаратов.-М.: Машиностроение, 1978.-216с.
3. Малышев В.В., Красильщиков М.Н., Карлов В.И. Оптимизация наблюдения и управления летательных аппаратов.-М.: Машиностроение, 1989.-312с.
4. Бахшиян Б.Ц., Назтров Р.Р., Эльясберг П.Е. Определение и коррекция движения.-М.: Наука, 1981.-360с.
5. Дмитриевский А.А и др. Баллистика и навигация ракет.-М.: Машиностроение, 1985.-312с.

6. Панков А.Р., Семенихин К.В. Минимаксная идентификация обобщённой неопределённо-стохастической линейной модели.// Автоматика и телемеханика.-1998, №11.-с.158-171.
 7. Панков А.Р., Семенихин К.В. Методы параметрической идентификации многомерных линейных моделей в условиях априорной неопределённости. // Автоматика и телемеханика.- 2000, №5.-с.76-92.
 8. Панков А.Р., Миллер Г.Б. Минимаксная линейная рекуррентная фильтрация.// Информационные процессы.- 2001, том 1, №2.-с.150-166.
 9. Матасов А.И. Введение в теорию гарантирующего оценивания.-М.: МАИ, 1999.-78с.
 10. Пшеничный Б.Н. Необходимые условия экстремума.-М.: Наука, 1982.-144с.
 11. Зангвилл У.И. Нелинейное программирование.-М.: Советское радио, 1973.-312с.
 12. Реклейтис Г., Рейвиндран А., Рэгсдел К. Оптимизация в технике. Том 1.-М.:Мир, 1986.-349с.
 13. Eaves B.C., Zangwill W.I. Generalized Cutting Plane Algorithms. // SIAM. J. Control.- 1971,№ 9.- р.529-542.
 14. Летова А.Т., Пантелеев А.В. Экстремум функций в примерах и задачах.-М.: МАИ, 1998.-374с.
-

Сведения об авторах

Панков Алексей Ростиславович, профессор кафедры теории вероятностей и математической статистики Московского государственного авиационного института (технического университета), д.ф.-м.н.

Попов Алексей Сергеевич, студент 6-ого курса факультета «Прикладной математики и физики» Московского государственного авиационного института (технического университета).

SSS 1

kljklkj
 RRR 2
 jhgig
 WWW 3
 jhhkjh