

第6章 正則化とカーネル法

6.1 導入

訓練データの実現値を $t_n = \{(\mathbf{x}_j, y_j); j = 1, 2, \dots, n\}$ とする. ただし $\mathbf{x}_j \in \mathbb{R}^d, y_j \in \mathbb{R}$ である. 予測関数 g_t をみつけるために探索する関数族 $\mathcal{G} = \{g: \mathbb{R}^d \mapsto \mathbb{R}\}$ を定めて, $g \in \mathcal{G}$ に関して

$$\widehat{\text{Err}}_t(g) := \frac{1}{n} \sum_{j=1}^n (y_j - g(\mathbf{x}_j))^2$$

を最小にする関数 $g_t \in \mathcal{G}$ をみつきたい. 関数族 \mathcal{G} をすべての \mathbb{R}^d 上の実数値関数全体がなす集合とすると

$$g(\mathbf{x}_j) = y_j \quad (j = 1, 2, \dots, n)$$

をみたく任意の関数 g は $\widehat{\text{Err}}_t(g) = 0$ をみたく. しかしこの g の汎化誤差はよいことが期待できない. いわゆる過学習が起きていることになる.

予測の観点から問題を考える. (X, Y) は (\mathbf{x}_j, y_j) を発生させて確率分布と同じ分布に従う確率ベクトルとする. 任意の関数 $g: \mathbb{R}^d \rightarrow \mathbb{R}$ に対して, 2乗誤差

$$E[\{Y - g(X)\}^2]$$

を考える. このとき 2乗誤差を最小にする g は

$$g^*(\mathbf{x}) = E[Y | X = \mathbf{x}]$$

で与えられた. 関数族 \mathcal{G} は解釈が容易であるような簡単なもので, かつ最適の g^* を含むような豊かなものが望ましい.

関数族 \mathcal{G} をよりよく理解するために \mathcal{G} を Hilbert 空間 (完備な内積空間) とみなす. たとえば \mathcal{G} を \mathbb{R}^d 上の線型関数すべてのなす集合とすれば, これは Hilbert 空間とみなすことができる. $\mathcal{G} = \{g_\beta(\mathbf{x}) = \mathbf{x}^\top \beta; \beta \in \mathbb{R}^d\}$ の元 g_β と $\beta \in \mathbb{R}^d$ を同一視し, \mathcal{G} 上の内積を

$$\langle g_{\beta_1}, g_{\beta_2} \rangle = \beta_1^\top \beta_2,$$

で定義する. ただし $g_{\beta_1}(\mathbf{x}) = \mathbf{x}^\top \beta_1, g_{\beta_2}(\mathbf{x}) = \mathbf{x}^\top \beta_2, \beta_1, \beta_2 \in \mathbb{R}^d$ である. すなわち $\langle \cdot, \cdot \rangle$ は \mathbb{R}^d 上の Euclid 内積である. するとこの内積 $\langle \cdot, \cdot \rangle$ をもつ \mathcal{G} は Hilbert 空間になること¹がわかる.

¹これは実数の完備性より直ちに確認できる.

ex:6-1

例 6.1. () 多項式回帰訓練データの実現値を

$$\mathbf{t}_n = \{(u_1, y_1), (u_2, y_2), \dots, (u_n, y_n)\}$$

とする. ただし $u_j, y_j \in \mathbb{R}$ ($j = 1, 2, \dots, n$) である. $d \in \mathbb{N}$, $d \geq 2$ とし, 変換

$$\phi(u) := \begin{pmatrix} 1 \\ u \\ u^2 \\ \vdots \\ u^{d-1} \end{pmatrix}, \mathbb{R} \longrightarrow \mathbb{R}^d$$

を考える. すると $\beta \in \mathbb{R}^d$ としたとき, 関数

$$g_\beta : u \mapsto \phi(u)^\top \beta$$

全体のなす集合を \mathcal{G} としたとき, 対応

$$h_\beta \longleftrightarrow \beta$$

と \mathbb{R}^d 上の Euclid 内積により \mathcal{G} は Hilbert 空間となる. \square

回帰問題において線型空間では単純すぎるが, 複雑すぎる関数の利用は避けたいところである. そのために, 問題そのものを「代入が内積で表現される空間 (再生核 Hilbert 空間)」に変換しその変換先での線型関数を考える方法がカーネル法である. カーネル法では, 半正定値行列を一般化したカーネル関数とよばれる 2 変数関数 k を考え, データ \mathbf{x}_j を $k\mathbf{x}_j = k(\cdot, \mathbf{x}_j)$ に変換することをカーネルトリックとよぶ. 特に写像

$$\phi : \mathbf{x}_j \mapsto k\mathbf{x}_j$$

は特徴写像とよばれる. データを \mathbb{R}^d とは曲り具合の異なる高次元空間に埋め込むことに相当する. この高次元空間のことを特徴空間とよぶ.

6.2 正則化

sec:6-2

$d \in \mathbb{N}$, $d \geq 2$ とする. 訓練データの実現値を $\mathbf{t}_n = \{(\mathbf{x}_j, y_j); j = 1, 2, \dots, n\}$ とする. ただし $\mathbf{x}_j \in \mathbb{R}^d$, $y_j \in \mathbb{R}$ とする. \mathbb{R}^d 上の実数値関数の族 \mathcal{G} に関してある損失関数 $\text{Loss} : \mathbb{R}^2 \longrightarrow \mathbb{R}$ を用いた訓練誤差

$$\widehat{\text{Err}}_{\mathbf{t}}(g) := \frac{1}{n} \sum_{j=1}^n \text{Loss}(g(\mathbf{x}_j), y_j) \quad (g \in \mathcal{G})$$

を最小にする $g_t \in \mathcal{G}$ をみつきたい. 関数族 \mathcal{G} はある内積に関して Hilbert 空間になっているとする. \mathcal{G} が豊かすぎると訓練誤差は零または零に近くなり, 過学習を起こす. 過学習をさけるためのひとつの方法はモデルの複雑さに罰則

$$J: \mathcal{G} \longrightarrow [0, \infty) \cup \{+\infty\}$$

を導入し, 罰則付きの訓練誤差の最小化問題を考えることである. すなわち

$$\min_{g \in \mathcal{G}} \{ \widehat{\text{Err}}_t(g) + J(g) : g \in \mathcal{G} \}$$

である.

ex:6-2

例 6.2. (リッジ回帰) リッジ回帰は 2 上ノルムの罰則項をもった線型回帰である. $d, n \in \mathbb{N}$ とする. 訓練データの実現値を $t_n = \{(\mathbf{x}_j, y_j); j = 1, 2, \dots, n\}$ とする. ただし $\mathbf{x}_j \in \mathbb{R}^d, y_j \in \mathbb{R}$ である. 関数族

$$\mathcal{G} = \{g(\mathbf{x}) = \mathbf{x}^\top \boldsymbol{\beta} : \boldsymbol{\beta} \in \mathbb{R}^d\}$$

を考え, $\gamma > 0$ に対して

$$\min_{g \in \mathcal{G}} \left\{ \frac{1}{n} \sum_{j=1}^n (y_j - g(\mathbf{x}_j))^2 + \gamma \|g\|^2 \right\} \quad (6.1) \quad \text{eq:6-1}$$

を考える. ただし $\|\cdot\|$ は \mathcal{G} の内積から定義される \mathcal{G} 上のノルムである. $g \in \mathcal{G}$ に対して $\boldsymbol{\beta} \in \mathbb{R}^d$ を対応させると

$$\|g\|^2 = \langle \boldsymbol{\beta}, \boldsymbol{\beta} \rangle = |\boldsymbol{\beta}|_{2,d}^2$$

となる. ただし, $|\cdot|_{2,d}$ は Euclid \mathbb{R}^d のノルムである. したがって, 問題は

$$\min_{\boldsymbol{\beta} \in \mathbb{R}^d} \left\{ \frac{1}{n} |\mathbf{y} - \mathbf{X}\boldsymbol{\beta}|_{2,n}^2 + \gamma |\boldsymbol{\beta}|_{2,d}^2 \right\} = \min_{\boldsymbol{\beta} \in \mathbb{R}^d} \left\{ \frac{1}{n} \sum_{j=1}^n (y_j - \mathbf{x}_j^\top \boldsymbol{\beta})^2 + \gamma |\boldsymbol{\beta}|_{2,d}^2 \right\} \quad (6.2) \quad \text{eq:6-2}$$

と書きなおすことができる. ただし

$$\mathbf{X} = \begin{pmatrix} \mathbf{x}_1^\top \\ \mathbf{x}_2^\top \\ \vdots \\ \mathbf{x}_n^\top \end{pmatrix}, \quad \mathbf{y} = \begin{pmatrix} y_1 \\ y_2 \\ \vdots \\ y_n \end{pmatrix}$$

とした. 最小化問題 (6.1) の解は

$$\mathbf{x} \mapsto \mathbf{x}^\top \boldsymbol{\beta}$$

という形となり β^* は最小化問題 (6.1) の解である. $\gamma \rightarrow \infty$ のとき罰則項が支配的になり $g \equiv 0$ となる.

問題 (6.2) は凸問題 (対象の関数が凸関数) なので勾配を零とおく.

$$h(\beta) := \frac{1}{n} \|\mathbf{y} - \mathbf{X}\beta\|_2^2 + \gamma \|\beta\|_{2,d}^2$$

とおいたとき

$$\frac{\partial h}{\partial \beta} = \frac{1}{n} \mathbf{X}^\top (\mathbf{X}\beta - \mathbf{y}) + \gamma \beta = 0 \quad (6.3) \quad \text{eq:6-3}$$

とおく. $\gamma = 0$ のとき上の方程式は正規方程式になる. $\mathbf{X}^\top \mathbf{X} + \mathbf{I}_d$ が正則のとき

$$\hat{\beta}_\gamma := (\mathbf{X}^\top \mathbf{X} + \gamma \mathbf{I}_d)^{-1} \mathbf{X}^\top \mathbf{y}$$

が方程式 (6.3) の解となる. $\hat{\beta}_\gamma$ のことをリッジ回帰推定量という. \square

ある Hilbert 空間 \mathcal{G} に対して罰則項を用いるとき \mathcal{G} を 2 つの直交部分空間 \mathcal{H} と \mathcal{C} に分解するとよい. すなわち $\forall g \in \mathcal{G}$ に対して, ある $h \in \mathcal{H}$ と $c \in \mathcal{C}$ が一意的に存在して

$$g = h + c, \quad \langle h, c \rangle_{\mathcal{G}} = 0$$

となる. ただし $\langle \cdot, \cdot \rangle_{\mathcal{G}}$ は Hilbert 空間 \mathcal{G} の内積である. Hilbert 空間 \mathcal{G} の任意の元がこのような分解をもつとき, \mathcal{G} は \mathcal{H} と \mathcal{C} の直和であるといひ, $\mathcal{G} = \mathcal{H} \oplus \mathcal{C}$ と書く.

ex:6-3

例 6.3. (例 6.2 の続き)

$$\tilde{\mathbf{x}}_j = (1, \mathbf{x}_j^\top)^\top \quad (j = 1, 2, \dots, n)$$

とする. 第 1 成分に対応する回帰係数 (切片) には罰則を加えない. $\tilde{\mathbf{x}} = (1, \mathbf{x}^\top)^\top$ とおいたとき

$$\mathcal{G} := \{g(\tilde{\mathbf{x}}) = \beta_0 + \mathbf{x}^\top \beta; \beta_0 \in \mathbb{R}, \beta \in \mathbb{R}^d\}$$

とし

$$\widehat{\text{Err}}(g) = \frac{1}{n} \|\mathbf{y} - \tilde{\mathbf{X}}\tilde{\beta}\|_{2,n}^2 + \gamma \|\beta\|_{2,d}^2$$

の最小化問題を考える. ただし $\gamma > 0$ で

$$\tilde{\mathbf{X}} = (\mathbf{1}, \mathbf{X}), \quad \tilde{\beta} = \begin{pmatrix} \beta_0 \\ \beta \end{pmatrix}, \quad \mathbf{1} = \underbrace{(1, 1, \dots, 1)}_n^\top$$

である. すると $\gamma \rightarrow \infty$ のとき $g(\tilde{\mathbf{x}}) = \beta_0$ となる. $g \in \mathcal{G}$ は

$$\tilde{\mathbf{x}} \mapsto \beta_0 + \mathbf{x}^\top \beta$$

である. さらに関数族 \mathcal{C} を

$$c: \tilde{\mathbf{x}} \mapsto \beta_0$$

とし, \mathcal{H} を

$$h: \tilde{\mathbf{x}} \mapsto \mathbf{x}^\top \boldsymbol{\beta}$$

とする. このとき \mathcal{G} の内積を $(1, \boldsymbol{\beta}^\top)^\top$ に対する \mathbb{R}^{d+1} 上の Euclid 内積とすれば

$$\mathcal{G} = \mathcal{C} \oplus \mathcal{H}$$

となる.

よって

$$\min_{g \in \mathcal{H} \oplus \mathcal{C}} \left\{ \frac{1}{n} \sum_{j=1}^n (y_j - g(\tilde{\mathbf{x}}))^2 + \gamma \|g\|_{\mathcal{H}} \right\} \quad (6.4) \quad \boxed{\text{eq:6-4}}$$

となる. ただし $\|\cdot\|_{\mathcal{H}}$ は \mathcal{H} のノルムである. 問題 ^{eq:6-4}(6.4) は

$$\min_{\beta_0, \boldsymbol{\beta}} \left\{ \frac{1}{n} \|\mathbf{y} - \beta_0 \mathbf{1} - \mathbf{X}\boldsymbol{\beta}\|_{2,n}^2 + \gamma \|\boldsymbol{\beta}\|_{2,d}^2 \right\} =: \min_{\beta_0, \boldsymbol{\beta}} h(\beta_0, \boldsymbol{\beta}) \quad (6.5) \quad \boxed{\text{eq:6-5}}$$

と書きなおすことができる. $\gamma \rightarrow \infty$ のとき

$$g(\tilde{\mathbf{x}}) \longrightarrow \bar{y}_n = \frac{1}{n} \sum_{j=1}^n y_j$$

となる. 問題 ^{eq:6-5}(6.5) も凸なので

$$\frac{\partial h}{\partial \boldsymbol{\beta}}(\beta_0, \boldsymbol{\beta}) = \mathbf{X}^\top (\beta_0 \mathbf{1} + \mathbf{X}\boldsymbol{\beta} - \mathbf{y}) + n\gamma \boldsymbol{\beta} = \mathbf{0} \quad (6.6) \quad \boxed{\text{eq:6-6}}$$

$$\frac{\partial h}{\partial \beta_0}(\beta_0, \boldsymbol{\beta}) = n\beta_0 - \mathbf{1}^\top (\mathbf{y} - \mathbf{X}\boldsymbol{\beta}) = 0 \quad (6.7) \quad \boxed{\text{eq:6-7}}$$

を解けばよい. ^{eq:6-7}(6.7) の解を ^{eq:6-6}(6.6) に代入すれば $\boldsymbol{\beta}$ をみつけるためには方程式

$$(\mathbf{X}^\top \mathbf{X} - n^{-1} \mathbf{X}^\top \mathbf{1} \mathbf{1}^\top \mathbf{X} + n\gamma \mathbf{I}_d) \boldsymbol{\beta} = (\mathbf{X}^\top - n^{-1} \mathbf{X}^\top \mathbf{1} \mathbf{1}^\top) \mathbf{y} \quad (6.8) \quad \boxed{\text{eq:6-8a}}$$

を解けばよい.

議論を簡単にするために $n \geq d$ かつ $\text{rank } \mathbf{X} = d$ ($\iff \mathbf{X}^\top \mathbf{X}$ は正則) を仮定する. すると

$$\begin{aligned} \text{(6.6)} \quad & \iff \beta_0 \mathbf{X}^\top \mathbf{1} + \mathbf{X}^\top \mathbf{X} \boldsymbol{\beta} - \mathbf{X}^\top \mathbf{y} + n\gamma \boldsymbol{\beta} = \mathbf{0} \\ & \iff (\mathbf{X}^\top \mathbf{X} + n\gamma \mathbf{I}_d) \boldsymbol{\beta} = \mathbf{X}^\top (\mathbf{y} - \beta_0 \mathbf{1}) \end{aligned}$$

なので β は $\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_n$ の一次結合で書ける. よって

$$\beta = \mathbf{X}^\top \alpha, \quad \alpha = (\alpha_1, \alpha_2, \dots, \alpha_n)^\top \in \mathbb{R}^n$$

とおく. これを (6.8) に代入すれば

$$(\mathbf{X}\mathbf{X}^\top - n^{-1}\mathbf{1}\mathbf{1}^\top\mathbf{X}\mathbf{X}^\top + n\gamma\mathbf{I}_n)\alpha = (\mathbf{I}_n - n^{-1}\mathbf{1}\mathbf{1}^\top)\mathbf{y}$$

を得る. $\mathbf{X}\mathbf{X}^\top - n^{-1}\mathbf{1}\mathbf{1}^\top\mathbf{X}\mathbf{X}^\top + n\gamma\mathbf{I}_n$ は正則と仮定すると

$$\hat{\alpha} = (\mathbf{X}\mathbf{X}^\top - n^{-1}\mathbf{1}\mathbf{1}^\top\mathbf{X}\mathbf{X}^\top + n\gamma\mathbf{I}_n)^{-1}(\mathbf{I}_n - n^{-1}\mathbf{1}\mathbf{1}^\top)\mathbf{y} \quad (6.9)$$

eq:6-8

となる. ここで

$$\mathbf{X}\mathbf{X}^\top = \begin{pmatrix} \langle \mathbf{x}_1, \mathbf{x}_1 \rangle_{2,d} & \langle \mathbf{x}_1, \mathbf{x}_2 \rangle_{2,d} & \cdots & \langle \mathbf{x}_1, \mathbf{x}_n \rangle_{2,d} \\ \langle \mathbf{x}_2, \mathbf{x}_1 \rangle_{2,d} & \langle \mathbf{x}_2, \mathbf{x}_2 \rangle_{2,d} & \cdots & \langle \mathbf{x}_2, \mathbf{x}_n \rangle_{2,d} \\ \vdots & \vdots & \ddots & \vdots \\ \langle \mathbf{x}_n, \mathbf{x}_1 \rangle_{2,d} & \langle \mathbf{x}_n, \mathbf{x}_2 \rangle_{2,d} & \cdots & \langle \mathbf{x}_n, \mathbf{x}_n \rangle_{2,d} \end{pmatrix}$$

となることに注意すると $\hat{\alpha}$ は $\{\langle \mathbf{x}_i, \mathbf{x}_j \rangle_{2,d}; (i, j = 1, 2, \dots, n)\}$ のみを通して $\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_n$ に依存することがわかる. すなわち 各 \mathbf{x}_j ($j = 1, 2, \dots, n$) の値がわからなくとも $\{\langle \mathbf{x}_i, \mathbf{x}_j \rangle_{2,d}; (i, j = 1, 2, \dots, n)\}$ の値がわかれば $\hat{\alpha}$ の値は計算できる. さらに (6.9) を (6.7) に代入すれば

$$\hat{\beta}_0 = \frac{1}{n}\mathbf{1}^\top(\mathbf{y} - \mathbf{X}\mathbf{X}^\top\hat{\alpha})$$

となる. よって

$$g_t(\tilde{\mathbf{x}}) = \hat{\beta}_0 + \mathbf{x}^\top\mathbf{X}^\top\hat{\alpha} = \hat{\beta}_0 + \sum_{j=1}^n \hat{\alpha}_j \langle \mathbf{x}, \mathbf{x}_j \rangle_{2,d}, \quad \hat{\alpha} = (\hat{\alpha}_1, \hat{\alpha}_2, \dots, \hat{\alpha}_n)^\top$$

となる. $\hat{\beta}_0$ と $\hat{\alpha}_j$ ($j = 1, 2, \dots, n$) は内積 $\{\langle \mathbf{x}_i, \mathbf{x}_j \rangle_{2,d}; i, j = 1, 2, \dots, n\}$ の値がわかればよい. さらに $g_t(\tilde{\mathbf{x}})$ の値を求めるためには, $\{\langle \mathbf{x}_j, \mathbf{x} \rangle_{2,d}; j = 1, 2, \dots, n\}$ の値がわかればよい. 内積だけの計算になっていることが肝である.

6.3 カーネル関数

sec:6-3

df:6-4

定義 6.4. \mathbb{X} を空でない集合とし k を \mathbb{X} 上の 2 変数関数とする. k が次の 2 条件をみたすとき, k は \mathbb{X} 上のカーネル関数とよばれる.

(i) $\forall x, y \in \mathbb{X}$ に対し

$$k(x, y) = k(y, x). \quad (\text{対称性})$$

(ii) $\forall n \in \mathbb{N}, \{x_j\}_{j=1}^n \subset \mathbb{X}, \{c_j\}_{j=1}^n \subset \mathbb{R}$ に対し

$$\sum_{j, \ell=1}^n c_j c_\ell k(x_j, x_\ell) \geq 0. \quad (\text{半正定値性})$$

定義 ^{df:6-4}6.4(ii) は, $\forall n \in \mathbb{N}$ と $\{x_j\}_{j=1}^n \subset \mathbb{X}$ に対し

$$\begin{pmatrix} k(x_1, x_1) & k(x_1, x_2) & \cdots & k(x_1, x_n) \\ k(x_2, x_1) & k(x_2, x_2) & \cdots & k(x_2, x_n) \\ \vdots & \vdots & \ddots & \vdots \\ k(x_n, x_1) & k(x_n, x_2) & \cdots & k(x_n, x_n) \end{pmatrix} \text{は半正定値}$$

となる.

重要なカーネル関数の例をあげておく.

ex:6-5

例 6.5. f を \mathbb{X} 上の関数とする. このとき

$$k(x, y) = f(x)f(y) \quad (x, y \in \mathbb{X})$$

はカーネル関数となる. 実際, $\forall n \in \mathbb{N}, \{x_j\}_{j=1}^n \subset \mathbb{X}, \{c_j\}_{j=1}^n \subset \mathbb{R}$ に対し

$$\sum_{j, \ell=1}^n c_j c_\ell k(x_j, x_\ell) = \sum_{j, \ell=1}^n c_j c_\ell f(x_j)f(x_\ell) = \left(\sum_{j=1}^n c_j f(x_j) \right)^2 \geq 0$$

より半正定値性はわかる. 対称性は定義より明らか. □

ex:6-6

例 6.6. k_1, k_2 を \mathbb{X} 上のカーネル関数とする. このとき

$$(k_1 + k_2)(x, y) := k_1(x, y) + k_2(x, y) \quad (x, y \in \mathbb{X})$$

はカーネル関数. □

pro:6-1

問 6.1. 例 ^{ex:6-6}6.6 の k の対称性と半正定値性を確認せよ.

ex:6-7

例 6.7. $d \in \mathbb{N}, \mathbb{X}$ を空でない集合とし

$$\phi: \mathbb{X} \rightarrow \mathbb{R}^d$$

を \mathbb{X} から \mathbb{R}^d への写像とする. \mathbb{R}^d 上の任意の内積 $\langle \cdot, \cdot \rangle$ を考える. このとき

$$k(x, y) = \langle \phi(x), \phi(y) \rangle \quad (x, y \in \mathbb{X})$$

はカーネル関数である. 上式の右辺の ϕ のことを特徴写像, \mathbb{R}^d を特徴空間という.

pro:6-1

問 6.2. 内積の性質を用いて例 ^{ex:6-7}6.7 の k の対称性と半正定値性を確認せよ.

sec:6-4

6.4 カーネル関数から内積空間の構成

\mathbb{X} を空でない集合とし k を \mathbb{X} 上のカーネル関数とする. カーネル関数 k と $x \in \mathbb{X}$ に対し, \mathbb{X} 上の関数 k_x を

$$k_x : \mathbb{X} \longrightarrow \mathbb{R}, \quad y \mapsto k(x, y)$$

で定める. $\{k_x\}_{x \in \mathbb{X}}$ で張られる部分ベクトル空間 \mathcal{V} を

$$\mathcal{V} := \left\{ \sum_{j=1}^n c_j k_{x_j}; \text{ある } n \in \mathbb{N} \text{ があって, } \{x_j\}_{j=1}^n \subset \mathbb{X}, \{c_j\}_{j=1}^n \subset \mathbb{R} \right\}$$

で定める. $f = \sum_{j=1}^n a_j x_j, g = \sum_{j=1}^m b_j y_j \in \mathcal{V}$ ($a_j, b_j \in \mathbb{R}, x_j, y_j \in \mathbb{X}, m, n \in \mathbb{N}$) に対し, 写像 $\langle \cdot, \cdot \rangle_{\mathcal{V}} : \mathcal{V} \times \mathcal{V} \longrightarrow \mathbb{R}$ を

$$\langle f, g \rangle_{\mathcal{V}} := \left\langle \sum_{j=1}^n a_j k_{x_j}, \sum_{j=1}^m b_j k_{y_j} \right\rangle_{\mathcal{V}} = \sum_{j=1}^n \sum_{\ell=1}^m a_j b_{\ell} k(y_{\ell}, x_j)$$

と定める. するとカーネル関数 k の半正定値性より $\langle \cdot, \cdot \rangle_{\mathcal{V}} \geq 0$ となる. さらに $f, g \in \mathcal{V}$ の表し方に依らず $\langle f, g \rangle_{\mathcal{V}}$ は一意的に定まる. 実際, $x \in \mathbb{X}$ に対し

$$\sum_{j=1}^n a_j k_{x_j}(x) = \sum_{j=1}^{m'} a'_j k_{x'_j}(x), \quad \sum_{j=1}^n b_j k_{y_j}(x) = \sum_{j=1}^{m'} b'_j k_{y'_j}(x)$$

とする. このとき $k(x, y) = k_y(x)$ と $k(x, y) = k(y, x)$ より

$$\begin{aligned} \sum_{j, \ell} a_j b_{\ell} k(y_{\ell}, x_j) &= \sum_j a_j \sum_{\ell} b_{\ell} k(x_j, y_{\ell}) = \sum_j a_j \sum_{\ell} b_{\ell} k_{y_{\ell}}(x_j) \\ &= \sum_j a_j \sum_{\ell} b'_{\ell} k_{y'_{\ell}}(x_j) = \sum_j a_j \sum_{\ell} b'_{\ell} k(x_j, y'_{\ell}) \\ &= \sum_j a_j \sum_{\ell} b'_{\ell} k(y'_{\ell}, x_j) = \sum_{\ell} b'_{\ell} \sum_j a_j k(y'_{\ell}, x_j) \\ &= \sum_{\ell} b'_{\ell} \sum_j a_j k_{x_j}(y'_{\ell}) = \sum_{\ell} b'_{\ell} \sum_j a'_j k_{x'_j}(y'_{\ell}) \\ &= \sum_{j, \ell} b'_{\ell} a'_j k(y'_{\ell}, x'_j) \end{aligned}$$

が成り立つ. よって $\langle \cdot, \cdot \rangle_{\mathcal{V}}$ は f, g の表現の仕方によらず f, g で一意的に定まる.

次に, $f, g, h \in \mathcal{V}$ と $\forall \alpha \in \mathbb{R}$ に対し,

$$(1) \langle f, g + h \rangle_{\mathcal{V}} = \langle f, g \rangle_{\mathcal{V}} + \langle f, h \rangle_{\mathcal{V}},$$

$$(2) \langle f, g \rangle_{\mathcal{V}} = \langle g, f \rangle_{\mathcal{V}},$$

$$(3) \langle \alpha f, g \rangle_{\mathcal{V}} = \alpha \langle f, g \rangle_{\mathcal{V}}$$

が成り立つ.

(2), (3) は明らか. (1) だけを示す.

(1) の証明: $f = \sum_{j=1}^n a_j k_{x_j}$, $g = \sum_{j=1}^m b_j k_{y_j}$, $\gamma k_z (a_j, b_j, z \in \mathbb{R}, x_j, y_j, z \in \mathbb{X})$ に対し, $b_{m+1} = \gamma$, $y_{m+1} = z$ とおく. すると

$$\begin{aligned} \langle f, g + h \rangle_{\mathcal{V}} &= \sum_{j=1}^n \sum_{\ell=1}^m a_j b_{\ell} k(y_{\ell}, x_j) + \sum_{j=1}^n a_j b_{m+1} k(y_{m+1}, x_j) \\ &= \sum_{j=1}^n \sum_{\ell=1}^m a_j b_{\ell} k(y_{\ell}, x_j) + \sum_{j=1}^n a_j \gamma k(z, x_j) \\ &= \langle f, g \rangle_{\mathcal{V}} + \langle f, \gamma k_z \rangle_{\mathcal{V}} \end{aligned}$$

が成り立つ. ここで示した等式を繰り返し用いれば, (1) が得られる.

(4) \mathcal{V} に対し

$$f(x) = \langle f, k_x \rangle_{\mathcal{V}} \quad (x \in \mathcal{V})$$

が成り立つ.

証明: $f = \sum_{j=1}^m a_j k_{x_j}$ とおく. このとき

$$\begin{aligned} \langle f, k_x \rangle_{\mathcal{V}} &= \left\langle \sum_{j=1}^m a_j k_{x_j}, k_x \right\rangle_{\mathcal{V}} = \sum_{j=1}^m a_j \langle k_{x_j}, k_x \rangle_{\mathcal{V}} = \sum_{j=1}^m a_j k(x, x_j) \\ &= \sum_{j=1}^m a_j k(x_j, x) = \sum_{j=1}^m a_j k_{x_j}(x) = f(x). \end{aligned}$$

(5) (Cauchy-Schwarz の不等式) $\forall f, g \in \mathcal{V}$ に対し

$$|\langle f, g \rangle_{\mathcal{V}}| \leq \langle f, f \rangle_{\mathcal{V}} \langle g, g \rangle_{\mathcal{V}}. \quad (6.10) \quad \boxed{\text{eq:6-9}}$$

等号成立は $f = cg$ ($c \in \mathbb{R}$) のとき.

証明: $\forall t \in \mathbb{R}$ に対し

$$\langle tf + g, tf + g \rangle_{\mathcal{V}} = t^2 \langle f, f \rangle_{\mathcal{V}} + 2t \langle f, g \rangle_{\mathcal{V}} + \langle g, g \rangle_{\mathcal{V}} \geq 0$$

である. $\langle f, f \rangle_{\mathcal{V}} = 0$ のとき,

$$2t \langle f, g \rangle_{\mathcal{V}} + \langle g, g \rangle_{\mathcal{V}} \geq 0$$

となる. t は任意であったので, $\langle f, g \rangle_{\mathcal{V}} = 0$. よって, (6.10) は成立.

$\langle f, f \rangle_{\mathcal{V}} \neq 0$ のとき,

$$\langle f, f \rangle_{\mathcal{V}} \left\{ t + \frac{\langle f, g \rangle_{\mathcal{V}}}{\langle f, f \rangle_{\mathcal{V}}} \right\}^2 + \frac{\langle f, f \rangle_{\mathcal{V}} \langle g, g \rangle_{\mathcal{V}} - \langle f, g \rangle_{\mathcal{V}}^2}{\langle f, f \rangle_{\mathcal{V}}} \geq 0$$

より

$$\frac{\langle f, f \rangle_{\mathcal{V}} \langle g, g \rangle_{\mathcal{V}} - \langle f, g \rangle_{\mathcal{V}}^2}{\langle f, f \rangle_{\mathcal{V}}} \geq 0 \iff |\langle f, g \rangle_{\mathcal{V}}|^2 \leq \langle f, f \rangle_{\mathcal{V}} \langle g, g \rangle_{\mathcal{V}}$$

がわかる.

以上の議論により, k によって構成された, \mathcal{V} は $\langle \cdot, \cdot \rangle_{\mathcal{V}}$ を内積としてもつ内積空間となることがわかった. あとは, \mathcal{V} を完備化することになる. 完備化された空間を $(\mathcal{H}, \langle \cdot, \cdot \rangle_{\mathcal{H}})$ と書くことにする.

定理 6.8. (Moore-Aronszajn の定理) \mathbb{X} 上のカーネル関数 k に対し, \mathbb{X} の再生核 Hilbert 空間 $(\mathcal{H}, \langle \cdot, \cdot \rangle_{\mathcal{H}})$ で以下の 3 条件をみたすものが一意的に存在する.

- (1) $\forall x \in \mathbb{X}$ に対し, $k(\cdot, x) \in \mathcal{H}_k$.
- (2) $\text{span}\{k(\cdot, x) \in x \in \mathbb{X}\}$ は \mathcal{H}_k の稠密な部分集合. すなわち, $\forall \epsilon > 0$ と $\forall h \in \mathcal{H}$ に対し, ある $v \in \mathcal{V}$ が存在して,

$$\|f - v\|_{\mathcal{H}} < \epsilon$$

となる. ただし, $\|f\|_{\mathcal{H}} = \sqrt{\langle f, f \rangle_{\mathcal{H}}}$.

- (3) k は \mathcal{H}_k の再生核. すなわち,

$$\langle f, k(\cdot, x) \rangle_{\mathcal{H}} = f(x) \quad (\forall x \in \mathbb{X}, \forall f \in \mathcal{H}).$$

Proof. 福水 (2010, pp.18-19). □

命題 6.9. k を空ではない位相空間 \mathbb{X} 上の半正定値カーネル. \mathcal{H} を対応する再生核 Hilbert 空間とする. 関数 $x \mapsto k(x, x)$ は連続で, 任意の $y \in \mathbb{X}$ に対し, $x \mapsto k(x, y)$ が $x = y$ において連続であれば, \mathcal{H} に属するすべての関数は \mathbb{X} 上で連続である. とくに $\mathbb{X} \times \mathbb{X}$ 上で連続な半正定値カーネルにより定まる再生核 Hilbert 空間は連続関数からなる.

Proof. 福水 (2010, p.19). □

定理 6.10. (リプリゼンタ定理) k を \mathbb{X} 上のカーネル関数とし, \mathcal{H} を k に対応する再生核 Hilbert 空間とする. $\mathcal{T} = \{x_1, x_2, \dots, x_n\} \subset \mathbb{X}$ をデータとする. Loss を n 変数の関数で, pen は \mathbb{R} 上の非減少関数, $b \in \mathbb{R}$ とする. この設定で

$$\text{Loss}(f(x_1) + b, f(x_2) + b, \dots, f(x_n) + b) + \text{pen}(\|f\|_{\mathcal{H}}^2)$$

を \mathcal{H} の中で最小にするものは

$$f = \sum_{j=1}^n \xi_j k_{x_j} \quad (\xi_j \in \mathbb{R}, j = 1, 2, \dots, n)$$

と仮定してよい.

Proof. \mathbf{P} を $\text{span}\{k_{x_1}, k_{x_2}, \dots, k_{x_n}\} =: \mathcal{V}$ への直交射影とする. \mathbf{P} は, $\langle \mathbf{P}f, g \rangle_{\mathcal{H}} = \langle f, \mathbf{P}g \rangle_{\mathcal{H}} (\forall f, g \in \mathcal{H})$ かつ $\mathbf{P}f = f (\forall f \in \mathcal{V})$ である. $f \in \mathcal{H}$ に対し

$$f(x_j) = \langle f, k_{x_j} \rangle_{\mathcal{H}} = \langle f, \mathbf{P}k_{x_j} \rangle_{\mathcal{H}} = \langle \mathbf{P}f, k_{x_j} \rangle_{\mathcal{H}} = (\mathbf{P}f)(x_j)$$

となる. したがって,

$$\begin{aligned} & \text{Loss}(f(x_1) + b, f(x_2) + b, \dots, f(x_n) + b) + \text{pen}(\|f\|_{\mathcal{H}}^2) \\ &= \text{Loss}((\mathbf{P}f)(x_1) + b, (\mathbf{P}f)(x_2) + b, \dots, (\mathbf{P}f)(x_n) + b) + \text{pen}(\|f\|_{\mathcal{H}}^2) \end{aligned}$$

を得る. $\mathcal{V}^\perp := \{f \in \mathcal{H}; \langle f, g \rangle = 0 (\forall g \in \mathcal{V})\}$ とする. このとき, $\forall f \in \mathcal{H}$ に対し,

$$f = \mathbf{P}f + f^\perp \quad (f^\perp \in \mathcal{V}^\perp)$$

と一意的に分解できるので,

$$\|\mathbf{P}f\|_{\mathcal{H}}^2 \leq \|f\|_{\mathcal{H}}^2 \implies \text{pen}(\|\mathbf{P}f\|_{\mathcal{H}}^2) \leq \text{pen}(\|f\|_{\mathcal{H}}^2).$$

よって,

$$\begin{aligned} & \text{Loss}(f(x_1) + b, f(x_2) + b, \dots, f(x_n) + b) + \text{pen}(\|f\|_{\mathcal{H}}^2) + \text{pen}(\|f\|_{\mathcal{H}}^2) \\ & \geq \text{Loss}((\mathbf{P}f)(x_1) + b, (\mathbf{P}f)(x_2) + b, \dots, (\mathbf{P}f)(x_n) + b) \\ & \quad + \text{pen}(\|f\|_{\mathcal{H}}^2) + \text{pen}(\|\mathbf{P}f\|_{\mathcal{H}}^2) \end{aligned}$$

が成り立つので,

$$f = \mathbf{P}f = \sum_{j=1}^n \xi_j k_{x_j} \quad (\xi_j \in \mathbb{R}, j = 1, 2, \dots, n)$$

としてよい. □

6.5 例

6.5.1 連立方程式

連立方程式

$$\begin{cases} x_1 + x_3 = 0 \\ x_2 = 1 \end{cases} \quad (6.11) \quad \boxed{\text{eq:6-10}}$$

を考える. 行列とベクトルで表現すると

$$\begin{pmatrix} 1 & 0 & 1 \\ 0 & 1 & 0 \end{pmatrix} \begin{pmatrix} x_1 \\ x_2 \\ x_3 \end{pmatrix} = \begin{pmatrix} 0 \\ 1 \end{pmatrix} \iff \mathbf{R}^\top \mathbf{x} = \boldsymbol{\eta},$$

$$\mathbf{R} = (\mathbf{r}_1, \mathbf{r}_2), \mathbf{r}_1 = \begin{pmatrix} 1 \\ 0 \\ 1 \end{pmatrix}, \mathbf{r}_2 = \begin{pmatrix} 0 \\ 1 \\ 0 \end{pmatrix}, \mathbf{x} = \begin{pmatrix} x_1 \\ x_2 \\ x_3 \end{pmatrix}, \boldsymbol{\eta} = \begin{pmatrix} 0 \\ 1 \end{pmatrix}$$

は $\mathbf{R}\mathbf{x} = \boldsymbol{\eta}$ とし
がよい.
である.
すると

$$\mathbf{x}_* = a \begin{pmatrix} -1 \\ 0 \\ 1 \end{pmatrix} + \begin{pmatrix} 0 \\ 1 \\ 0 \end{pmatrix} =: a \begin{pmatrix} -1 \\ 0 \\ 1 \end{pmatrix} + \mathbf{x}_0 \quad (a \in \mathbb{R})$$

は方程式 ^{eq:6-10}6.11 の解となる.

$$\begin{pmatrix} 0 \\ 1 \\ 0 \end{pmatrix} \in \text{span}(\mathbf{R}) = \{a\mathbf{r}_1 + b\mathbf{r}_2; a, b \in \mathbb{R}\},$$

$$\begin{pmatrix} -1 \\ 0 \\ 1 \end{pmatrix} \in \text{span}(\mathbf{R})^\perp := \{\mathbf{x} \in \mathbb{R}^3; \langle \mathbf{x}, \mathbf{y} \rangle = 0 (\forall \mathbf{y} \in \text{span}(\mathbf{R}))\}$$

であることに注意せよ. ベクトル $\mathbf{x}_0 = (0, 1, 0)^\top$ は

$$\|\mathbf{x}\|^2 := \langle \mathbf{x}, \mathbf{x} \rangle = x_1^2 + x_2^2 + x_3^2$$

を最小にする解である. すなわち, $(0, 1, 0)^\top$ はノルムが最小となる解 (唯一存在) で, 任意の解 \mathbf{x}_* に対して

$$\mathbf{x}_0^\top \mathbf{x}_0 \leq \mathbf{x}_*^\top \mathbf{x}_*$$

をみたしている.

以上の考察より一般的に考える. $d, n \in \mathbb{N}$, $n \geq d$ とし, \mathbf{R} を $n \times d$ 実行列, $\boldsymbol{\eta}$ を $d \times 1$ の縦ベクトルで, 方程式

$$\mathbf{R}^\top \boldsymbol{x} = \boldsymbol{\eta} \quad (6.12) \quad \boxed{\text{eq:6-11}}$$

を解くことを考える.

$$\boldsymbol{\eta} \in \text{span}(\mathbf{R}^\top) \in \mathbb{R}^d$$

ならば, 解 \boldsymbol{x}_* は存在する. ただし, $\text{span}(\mathbf{R}^\top)$ は \mathbf{R}^\top の列ベクトルで張られた \mathbb{R}^d の部分空間である. 1 つの解 \boldsymbol{x}_* が与えられたとき, 他の解を \boldsymbol{x} と書けば

$$\mathbf{R}^\top \boldsymbol{x}_* = \mathbf{R}^\top \boldsymbol{x} \iff \mathbf{R}^\top (\boldsymbol{x}_* - \boldsymbol{x}) = \mathbf{0} \iff \boldsymbol{x}_* - \boldsymbol{x} \in \text{span}(\mathbf{R})^\perp$$

となる. $\boldsymbol{x}_1 := \boldsymbol{x}_* - \boldsymbol{x} \in \text{span}(\mathbf{R})^\perp$ とおけば,

$$\mathbb{R}^n = \text{span}(\mathbf{R}) \oplus \text{span}(\mathbf{R})^\perp$$

なので, 解 \boldsymbol{x}_* は

$$\boldsymbol{x}_* = \boldsymbol{x}_0 + \boldsymbol{x}_1 \quad (\boldsymbol{x}_0 \in \text{span}(\mathbf{R}), \boldsymbol{x}_1 \in \text{span}(\mathbf{R})^\perp)$$

と一意的に書ける. さらに,

$$\boldsymbol{x}_0^\top \boldsymbol{x}_0 \leq \boldsymbol{x}_0^\top \boldsymbol{x}_0 + \boldsymbol{x}_1^\top \boldsymbol{x}_1$$

なので, \boldsymbol{x}_0 は最ノルム小解である. よって, 最小ノルム解は

$$\boldsymbol{x}_0 = \mathbf{R}\boldsymbol{\xi} \quad (\boldsymbol{\xi} \in \mathbb{R}^d)$$

と書ける. $\boldsymbol{x}_0 = \mathbf{R}\boldsymbol{\xi}$ を方程式 (6.12) に代入すると

$$\mathbf{R}^\top \mathbf{R}\boldsymbol{\xi} = \boldsymbol{\eta}$$

となる. $\boldsymbol{\xi}$ とは異なるベクトル $\tilde{\boldsymbol{\xi}} \in \mathbb{R}^d$ が

$$\mathbf{R}^\top \mathbf{R}\tilde{\boldsymbol{\xi}} = \boldsymbol{\eta}$$

をみたすとする

$$\mathbf{R}\boldsymbol{\xi} = \mathbf{R}\tilde{\boldsymbol{\xi}}$$

となる. なぜならば, $\mathbf{R}^\top \boldsymbol{x} = \boldsymbol{\eta}$ をみたし, $\boldsymbol{x} \in \text{span}(\mathbf{R})$ となるものは唯一だからである.

例にもどれば

$$\mathbf{R}^\top \mathbf{R} = \begin{pmatrix} 1 & 0 & 1 \\ 0 & 1 & 0 \end{pmatrix} \begin{pmatrix} 1 & 0 \\ 0 & 1 \\ 1 & 0 \end{pmatrix} = \begin{pmatrix} 2 & 0 \\ 0 & 1 \end{pmatrix}$$

より

$$\mathbf{R}^\top \mathbf{R} \boldsymbol{\xi} = \boldsymbol{\eta} \iff \begin{cases} 2\xi_1 = 0 \\ \xi_2 = 1 \end{cases}$$

より, $(\xi_1, \xi_2) = (0, 1)$ となる. よって,

$$\mathbf{x}_0 = \begin{pmatrix} 1 & 0 \\ 0 & 1 \\ 1 & 0 \end{pmatrix} \begin{pmatrix} 0 \\ 1 \end{pmatrix} = \begin{pmatrix} 0 \\ 1 \\ 0 \end{pmatrix}$$

となる.

以上をまとめると,

$$\mathbf{r}_k \in \mathbb{R}^d (k = 1, 2, \dots, d), \quad \boldsymbol{\eta} = (\eta_1, \eta_2, \dots, \eta_n)^\top \in \mathbb{R}^n$$

とする. 方程式

$$\langle \mathbf{r}_k, \mathbf{x} \rangle = \eta_k \quad (k = 1, 2, \dots, n)$$

をみたす, $\mathbf{x} \in \mathbb{R}^d$ でノルム

$$\|\mathbf{x}\| = \sqrt{\mathbf{x}^\top \mathbf{x}}$$

を最小とするものをみつける問題の解は

$$\mathbf{x}_s = \sum_{k=1}^n \xi_k \mathbf{r}_k$$

で $(\xi_1, \xi_2, \dots, \xi_n)$ は

$$\sum_{k=1}^n \langle \mathbf{r}_i, \mathbf{r}_k \rangle \xi_k = \eta_i \quad (i = 1, 2, \dots, n)$$

をみたすものである.

この点は関数解析の観点からまとめなおすこと. 参考文献は, 堤正義『逆問題』(2012) の 6 章. 小川英光『工学系の関数解析』(2010) の 7 章. Saitoh, S. and Sawano, Y (2016) の 3 章.

6.5.2 補間スプライン

点 (t_j, y_j) , $j = 0, \dots, n$, $y_0 = 0$, $0 = t_0 < t_1 < \dots < t_n = 1$ が与えられたとする. 関数族

$$W_0^1 := \left\{ f \in L^2[0, 1]; f(0) = 0, \int_0^1 \{\dot{f}(t)\}^2 dt < \infty \right\}, \quad \dot{f}(t) = \frac{df}{dt}$$

の中で,

$$f(t_j) = y_j \quad (j = 1, 2, \dots, n)$$

をみたしたものの中で

$$\int_0^1 \{\dot{f}(t)\}^2 dt$$

を最小とするものを見つけたい.

W_0^1 の内積として, $f, g \in W_0^1$ に対し

$$\langle f, g \rangle := \int_0^1 \dot{f}(t)\dot{g}(t) dt, \quad \|f\| = \sqrt{\langle f, f \rangle}$$

とおく. $t \in [0, 1]$ に対し

$$k_j(t) = \min\{t, t_j\} \quad (j = 1, 2, \dots, n)$$

とおく. このとき, $k_j(t) \in W_0^1$ であり,

$$\langle f, k_j \rangle = \int_0^1 \dot{f}(s)\dot{k}_j(s) ds = \int_0^{t_j} \dot{f}(s) ds = f(t_j) - f(0) = f(t_j).$$

したがって, $y_j = f(t_j)$ をみたす関数は

$$f(t_j) = \langle k_j, f \rangle = y_j \quad (j = 1, 2, \dots, n) \quad (6.13) \quad \text{eq:6-12}$$

条件 (6.13) をみたす最小ノルムの関数は, リプリゼンタ定理から

$$\hat{f}(s) = \sum_{j=1}^n \xi_j k_j(s), \quad s \in [0, 1], \xi_1, \xi_2, \dots, \xi_n \in \mathbb{R} \quad (6.14) \quad \text{eq:6-13}$$

の形でかける. (6.14) を (6.13) に代入すれば

$$\langle k_j, \sum_{\ell=1}^n \xi_\ell k_\ell \rangle = \sum_{\ell=1}^n \langle k_j, k_\ell \rangle \xi_\ell = y_j \quad (j = 1, 2, \dots, n)$$

となる.

$$\mathbf{K} := \begin{pmatrix} \langle k_1, k_1 \rangle & \langle k_1, k_2 \rangle & \cdots & \langle k_1, k_n \rangle \\ \langle k_2, k_1 \rangle & \langle k_2, k_2 \rangle & \cdots & \langle k_2, k_n \rangle \\ \vdots & \vdots & \ddots & \vdots \\ \langle k_n, k_1 \rangle & \langle k_n, k_2 \rangle & \cdots & \langle k_n, k_n \rangle \end{pmatrix}, \quad \mathbf{y} = \begin{pmatrix} y_1 \\ y_2 \\ \vdots \\ y_n \end{pmatrix}, \quad \boldsymbol{\xi} = \begin{pmatrix} \xi_1 \\ \xi_2 \\ \vdots \\ \xi_n \end{pmatrix}$$

とおけば,

$$\mathbf{K}\boldsymbol{\xi} = \mathbf{y}$$

となる. したがって, $0 < t_1 < t_2 < \dots < t_n = 1$ なので, \mathbf{K} は正定値になる. 実際

$$\text{Det}(\mathbf{K}) = t_1 \prod_{j=2}^n (t_j - t_1)$$

と書けること²からわかる. さらに, \mathbf{K}_i を 1 行目から j 行目に対する小行列式とすると, すべての $i = 1, 2, \dots, n$ に対し $\text{Det} \mathbf{K}_i \gtrsim 0$ なので, $\mathbf{K} \gtrsim 0$ がわかる.

たとえば, $n = 5$ とし,

$$f(0) = 0, f(0.1) = 0.1, f(0.25) = 1, f(0.5) = 2, f(0.75) = 1.5, f(1) = 1.75$$

とすれば,

$$\begin{pmatrix} 0.1 & 0.1 & 0.1 & 0.1 & 0.1 \\ 0.1 & 0.25 & 0.25 & 0.25 & 0.25 \\ 0.1 & 0.25 & 0.5 & 0.5 & 0.5 \\ 0.1 & 0.25 & 0.5 & 0.75 & 0.75 \\ 0.1 & 0.25 & 0.5 & 0.75 & 1 \end{pmatrix} \begin{pmatrix} \xi_1 \\ \xi_2 \\ \xi_3 \\ \xi_4 \\ \xi_5 \end{pmatrix} = \begin{pmatrix} 0.1 \\ 1 \\ 2 \\ 1.5 \\ 1.75 \end{pmatrix}$$

の解は

$$\begin{pmatrix} \xi_1 \\ \xi_2 \\ \xi_3 \\ \xi_4 \\ \xi_5 \end{pmatrix} = \begin{pmatrix} -5 \\ -2 \\ 6 \\ -3 \\ 1 \end{pmatrix}$$

より

$$\hat{f}(t) = -5k_1(t) + 2k_2(t) + 6k_3(t) - 3k_4(t) + k_5(t) = \begin{cases} t & (0 \leq t \leq 0.1) \\ 6t - 0.5 & (0.1 \leq t \leq 0.25) \\ 4t & (0.25 \leq t \leq 0.5) \\ -2t + 3 & (0.5 \leq t \leq 0.75) \\ t + 0.75 & (0.75 \leq t \leq 1) \end{cases}$$

となる.

² $g(t_2, t_3, \dots, t_n) = \text{Det}(\mathbf{K})$ とおく. $t_j = t_1 (j = 2, 3, \dots, n)$ とおけば, 1 行目と j 行目が等しくなるので, 行列式の性質より $g(t_2, t_3, \dots, t_n) = 0$. よって, g は $(t_j - t_1) (j = 2, \dots, n)$ という因子をもつことからわかる.