

第11章 正規分布の確率集中不 等式

11.1 正規分布の部分積分公式と補間公式

$X \sim N(0, \sigma^2)$ ($0 < \sigma < \infty$) とする. すると X の p.d.f.

$$p(x) = \frac{1}{\sqrt{2\pi\sigma^2}} \exp\left(-\frac{x^2}{2\sigma^2}\right) \quad (x \in \mathbb{R})$$

をもち

$$xp(x) = -\sigma^2 \dot{p}(x), \quad \dot{p}(x) = \frac{dp}{dx}(x)$$

なる関係式が成立することがわかる. このことをから, 以下の部分積分の公式が得られる.

定理 11.1. $h: \mathbb{R} \rightarrow \mathbb{R}$ は連続微分可能な関数で, $E[|Xh(X)|] < \infty$ と $E[|\dot{h}(X)|] < \infty$ をみたすとする. このとき

$$E[Xh(X)] = E[X^2]E[\dot{h}(X)] \quad (11.1)$$

が成立する.

注意 11.2 ([24] から借用). $X \sim N(0, 1)$ とし, $h: \mathbb{R} \rightarrow \mathbb{R}$ は 1 回連続微分¹ とする. . . このとき, $E[|\dot{h}(X)|] < \infty$ ならば, $E[|Xh(X)|] < \infty$ かつ $E[|h(X)|] < \infty$ となることがわかる. 実際, Fubini の定理を用いると

$$\begin{aligned} \int_0^\infty |xh(x)|e^{-x^2/2} dx &= \int_0^\infty \left| x \int_0^x \dot{h}(y) dy \right| e^{-x^2/2} dx \\ &\leq \int_0^\infty x \left\{ \int_0^x |\dot{h}(y)| dy \right\} e^{-x^2/2} dx \\ &= \int_0^\infty |\dot{h}(y)| \underbrace{\left\{ \int_y^\infty xe^{-x^2/2} dx \right\}}_{=e^{-y^2/2}} dy \quad (\because \text{Fubini}) \\ &= \int_0^\infty |\dot{h}(y)|e^{-y^2/2} dy \end{aligned}$$

¹実は, 絶対連続を仮定するだけでよい.

より

$$\mathbb{E}[|Xh(X)|] \leq \mathbb{E}[|\dot{h}(X)|] < \infty$$

がわかる. さらに

$$\begin{aligned} |h(x)| &= |h(x)\mathbb{1}_{[0,1]}(x)| + |h(x)\mathbb{1}_{(1,\infty)}(x)| \\ &\leq \sup_{|x|\leq 1} |h(x)| + |xh(x)\mathbb{1}_{(1,\infty)}(x)| \\ &\leq \sup_{|x|\leq 1} |h(x)| + |xh(x)| =: C + |xh(x)| \end{aligned}$$

となる. ただし, C はある定数である. よって

$$\mathbb{E}[|h(X)|] \leq C + \mathbb{E}[|Xh(X)|] < \infty$$

がわかる.

また, $\mathbb{E}[|\dot{h}(X)|] < \infty$ もわかるので

$$\lim_{|x|\rightarrow\infty} h(x)e^{-x^2/2} dx = 0$$

が成立することを証明できる. 詳しくは, [32, pp.284-285] を参照のこと.

□

定理 11.1 は多変量正規分布に対する拡張はできる.

$$\mathbf{X} = (X_1, X_2, \dots, X_d)^\top \sim \mathbf{N}_d(\mathbf{0}_d, \Sigma)$$

とする. ただし, $\mathbf{0}_d = \underbrace{(0, 0, \dots, 0)^\top}_{d \text{ 個}}$ で, Σ は $d \times d$ の正定値対称行列で

ある. すなわち, $\Sigma = \Sigma^\top$ で, 任意の $\mathbf{a} \neq \mathbf{0}_d$ に対して, $\mathbf{a}^\top \Sigma \mathbf{a} > 0$ が成立する. さらに, $h_j: \mathbb{R}^n \rightarrow \mathbb{R}$ ($j = 1, 2, \dots, d$) は連続微分可能な関数とし, $\mathbf{h} = (h_1, h_2, \dots, h_d)^\top$ と書くことにする.

定理 11.3. \mathbf{h} はゆるい成長条件をみたすと仮定する. このとき

$$\mathbb{E}[X_1 \mathbf{h}(\mathbf{X})] = \sum_{j=1}^d \mathbb{E}[X_1 X_j] \mathbb{E}\left[\frac{\partial \mathbf{h}}{\partial x_j}(\mathbf{X})\right] \quad (11.2)$$

が成立する. ただし

$$\begin{aligned} \mathbb{E}[X_1 \mathbf{h}(\mathbf{X})] &= (\mathbb{E}[Xh_1(\mathbf{X})], \mathbb{E}[Xh_2(\mathbf{X})], \dots, \mathbb{E}[Xh_d(\mathbf{X})])^\top, \\ \mathbb{E}\left[\frac{\partial \mathbf{h}}{\partial x_j}(\mathbf{X})\right] &= \left(\mathbb{E}\left[\frac{\partial h_1}{\partial x_j}(\mathbf{X})\right], \mathbb{E}\left[\frac{\partial h_2}{\partial x_j}(\mathbf{X})\right], \dots, \mathbb{E}\left[\frac{\partial h_3}{\partial x_j}(\mathbf{X})\right]\right)^\top \end{aligned}$$

である. 等式 (11.2) を多変量正規分布の部分積分公式という.

Proof. $\sigma_1^2 = E[X_1^2]$ とする. このとき, 確率ベクトル $\mathbf{Y} = (Y_1, Y_2, \dots, Y_d)^\top$ の各成分を

$$Y_j = X_j - \lambda_j X_1, \quad \lambda_j = \frac{E[X_j X_1]}{\sigma_1^2},$$

で定まる. すると \mathbf{Y} と X_1 は独立となる. 実際, $j = 1, 2, \dots, d$ に対して

$$\begin{aligned} \text{Cov}[Y_j, X_1] &= \text{Cov}[X_j, X_1] - \lambda_j \text{Cov}[X_1, X_1] \\ &= E[X_j X_1] - \frac{E[X_j X_1]}{\sigma_1^2} \times \underbrace{E[X_1^2]}_{=\sigma_1^2} = 0 \end{aligned}$$

からわかる. よって, 正規分布の性質から \mathbf{Y} と X_1 は独立である.

$\boldsymbol{\lambda} = (\lambda_1, \lambda_2, \dots, \lambda_d)^\top$ とおくと

$$\mathbf{X} = \mathbf{Y} + X_1 \boldsymbol{\lambda}$$

と書ける. $E_1[\cdot] := E[\cdot | \mathbf{Y}]$ と表記する. (11.1) から

$$E_1[X_1 h_j(\mathbf{X})] = E_1[X_1 h_j(\mathbf{Y} + X_1 \boldsymbol{\lambda})] \quad (11.3)$$

$$= \sigma_1^2 E \left[\left. \frac{\partial h_j}{\partial t}(\mathbf{Y} + t \boldsymbol{\lambda}) \right|_{t=X_1} \right] \quad (j = 1, 2, \dots, d) \quad (11.4)$$

となる. ただし, すべての \mathbf{Y} に対して

$$\lim_{t \rightarrow \pm\infty} h(\mathbf{Y} + t \boldsymbol{\lambda}) = 0$$

をみだし, (11.4) の両辺の期待値は有限の値を持つと仮定する. よって

$$E_1[X_1 \mathbf{h}(\mathbf{X})] = \sigma_1^2 E \left[\left. \frac{\partial \mathbf{h}}{\partial t}(\mathbf{Y} + t \boldsymbol{\lambda}) \right|_{t=X_1} \right] \quad (11.5)$$

である. さらに

$$X_1 \mathbf{h}(\mathbf{X}) \quad \text{と} \quad \left. \frac{\partial \mathbf{h}}{\partial t}(\mathbf{Y} + t \boldsymbol{\lambda}) \right|_{t=X_1}$$

は絶対可積分としたとき, (11.5) の両辺の期待値を \mathbf{Y} に関して取り, Fubini の定理を用いると

$$E[X_1 \mathbf{h}(\mathbf{X})] = \sigma_1^2 E \left[\left. \frac{\partial \mathbf{h}}{\partial t}(\mathbf{Y} + t \boldsymbol{\lambda}) \right|_{t=X_1} \right] \quad (11.6)$$

を得る. ここで, $k = 1, 2, \dots, d$ に対して

$$\left. \frac{\partial h_k}{\partial t}(\mathbf{Y} + t \boldsymbol{\lambda}) \right|_{t=X_1} = \sum_{j=1}^d \lambda_j \frac{\partial h_k}{\partial x_j}(\mathbf{Y} + X_1 \boldsymbol{\lambda}) = \sum_{j=1}^d \lambda_j \frac{\partial h_k}{\partial x_j}(\mathbf{X})$$

となることに注意すると

$$E[X_1 \mathbf{h}(\mathbf{X})] = \sum_{j=1}^d E[X_1 X_j] E\left[\frac{\partial \mathbf{h}}{\partial x_j}(\mathbf{X})\right]$$

を得る. □

注意 11.4. 成長条件についてのコメントを加筆すること. □

次に、中心化された多変量正規分布に従う独立な 2 つの確率ベクトルの線型補間を考えるために、確率ベクトルを

$$\mathbf{X} = (X_1, X_2, \dots, X_d)^\top, \quad \mathbf{Y} = (Y_1, Y_2, \dots, Y_d)^\top, \quad \mathbf{X} \text{ と } \mathbf{Y} \text{ は独立}$$

と書こう. さらに

$$\sigma_{ij} := E[X_i X_j], \quad \psi_{ij} := E[Y_i Y_j] \quad (i, j = 1, 2, \dots, d)$$

とする. このとき, $0 \leq t \leq 1$ に対して

$$\mathbf{Z}(t) := \sqrt{t}\mathbf{X} + \sqrt{1-t}\mathbf{Y} \quad (11.7)$$

と定める. $\Sigma := (\sigma_{ij})$, $\Psi = (\psi_{ij})$ とおくと

$$\mathbf{Z}(t) \sim N_d(\mathbf{0}_d, t\Sigma + (1-t)\Psi) \quad (0 \leq t \leq 1)$$

となる. $\mathbf{Z}(t)$ を \mathbf{X} と \mathbf{Y} の線型補間という.

$j = 1, 2, \dots, d$ に対して, $h_j : \mathbb{R}^d \rightarrow \mathbb{R}$ を 2 回連続微分可能な関数とし, $\mathbf{h} = (h_1, h_2, \dots, h_d)^\top$ とおく. \mathbf{h} の期待値を

$$\mathbf{g}(t) := E[\mathbf{h}(\mathbf{Z}(t))] \quad (0 \leq t \leq 1)$$

と書くことにする. 定め方から

$$\mathbf{g}(1) = E[\mathbf{h}(\mathbf{Y})], \quad \mathbf{g}(0) = E[\mathbf{h}(\mathbf{X})]$$

となる. \mathbf{h} の各成分 h_k ($k = 1, 2, \dots, d$) の 1 次導関数は指数成長条件をみたすとき、微分記号と積分記号の交換ができることに注意する.

$\mathbf{g} = (g_1, g_2, \dots, g_d)^\top$ と書いたとき, $k = 1, 2, \dots, d$ に対して

$$\begin{aligned} \dot{g}_k(t) &:= \frac{d}{dt} g_k(t) = \frac{d}{dt} E[h_k(\mathbf{Z}(t))] = E\left[\frac{d}{dt} h_k(\mathbf{Z}(t))\right] \\ &= E\left[\sum_{j=1}^d \frac{dh_k}{dx_j}(\mathbf{Z}(t)) \frac{d}{dt} Z_j(t)\right] =: E\left[\sum_{j=1}^d \frac{dh_k}{dx_j}(\mathbf{Z}(t)) \dot{Z}_j(t)\right] \end{aligned}$$

となる. ただし

$$\dot{Z}_j(t) = \frac{d}{dt}Z_j(t) = \frac{1}{2\sqrt{t}}X_j - \frac{1}{2\sqrt{1-t}}Y_j$$

である. $\dot{Z}_j(t)$ と $Z_i(t)$ ($i = 1, 2, \dots, d$) の共分散は

$$\begin{aligned} \mathbb{E}[\dot{Z}_j(t)Z_i(t)] &= \mathbb{E}\left[\left(\frac{1}{2\sqrt{t}}X_j - \frac{1}{2\sqrt{1-t}}Y_j\right)(\sqrt{t}X_i + \sqrt{1-t}Y_i)\right] \\ &= \mathbb{E}\left[\frac{1}{2}X_iX_j - \frac{\sqrt{t}}{2\sqrt{1-t}}X_jY_j + \frac{\sqrt{1-t}}{2\sqrt{t}}X_jY_i - \frac{1}{2}Y_iY_j\right] \\ &= \frac{1}{2}\left\{\mathbb{E}[X_iX_j] - \mathbb{E}[Y_iY_j]\right\} \\ &= \frac{1}{2}(\sigma_{ij} - \psi_{ij}) \end{aligned}$$

となる. $\forall 1 \leq i, j \leq d$ に対して, ある $c_1 > 0, c_2 > 0$ が存在して

$$\left|\frac{\partial \mathbf{h}}{\partial x_i}(\mathbf{x})\right| \leq c_1 e^{c_2|\mathbf{x}|_{2,d}} \quad (11.8)$$

と

$$\left|\frac{\partial^2 \mathbf{h}}{\partial x_i \partial x_j}(\mathbf{x})\right| \leq c_1 e^{c_2|\mathbf{x}|_{2,d}} \quad \text{または} \quad \sigma_{i,j} = \psi_{i,j} \quad (11.9)$$

のいずれかが成立すると仮定すると, 正規分布の部分積分公式 (定理 11.3) を用いると $k = 1, 2, \dots, d$ に対して

$$\begin{aligned} \mathbb{E}\left[\frac{\partial h_k}{\partial x_j}(\mathbf{Z}(t)) \dot{Z}_j(t)\right] &= \sum_{i=1}^d \mathbb{E}[Z_i(t) \dot{Z}_j(t)] \mathbb{E}\left[\frac{\partial^2 h_k}{\partial x_i \partial x_j}(\mathbf{Z}(t))\right] \\ &= \frac{1}{2} \sum_{i=1}^d (\sigma_{ij} - \psi_{ij}) \mathbb{E}\left[\frac{\partial^2 h_k}{\partial x_i \partial x_j}(\mathbf{Z}(t))\right] \end{aligned}$$

を得る. 1 から d まで j をたし合わせると

$$\dot{g}_k(t) = \frac{d}{dt} \mathbb{E}[h_k(\mathbf{Z}(t))] = \frac{1}{2} \sum_{i=1}^d \sum_{j=1}^d (\sigma_{ij} - \psi_{ij}) \mathbb{E}\left[\frac{\partial^2 h_k}{\partial x_i \partial x_j}(\mathbf{Z}(t))\right] \quad (11.10)$$

を得る. これをベクトルで表現すると

$$\dot{\mathbf{g}}(t) = \frac{1}{2} \sum_{i=1}^d \sum_{j=1}^d (\sigma_{ij} - \psi_{ij}) \mathbb{E}\left[\frac{\partial^2 \mathbf{h}}{\partial x_i \partial x_j}(\mathbf{Z}(t))\right]$$

となる.

関数 $h : \mathbb{R} \rightarrow \mathbb{R}$ は 2 回連続微分可能で、ある種の成長条件をみたすとする. $Z \sim N(0, 1)$ のとき

$$g(t, x) := \mathbf{E}[h(x + \sqrt{t}Z)]$$

とおくと

$$\begin{aligned} \frac{\partial g}{\partial t} &= \mathbf{E}\left[\frac{\partial}{\partial t}h(x + \sqrt{t}X)\right] \\ &= \mathbf{E}\left[\frac{Z}{2\sqrt{t}}\dot{h}(x + \sqrt{t}Z)\right] \\ &= \frac{1}{2\sqrt{t}}\int_{-\infty}^{\infty} z\dot{h}(x + \sqrt{t}z)\frac{1}{\sqrt{2\pi}}e^{-z^2/2}dz \\ &= \frac{1}{2\sqrt{t}}\left[-\dot{h}(x + \sqrt{t}z)\frac{1}{\sqrt{2\pi}}e^{-z^2/2}\right]_{-\infty}^{\infty} \\ &\quad + \frac{1}{2\sqrt{t}}\int_{-\infty}^{\infty}\frac{\partial}{\partial z}\dot{h}(x + \sqrt{t}z)\frac{1}{\sqrt{2\pi}}e^{-z^2/2}dz \\ &= \frac{1}{2}\mathbf{E}[\ddot{h}(x + \sqrt{t}Z)] \end{aligned} \tag{11.11}$$

となる. 一方

$$\begin{aligned} \frac{\partial g}{\partial x^2} &= \frac{\partial^2}{\partial x^2}\mathbf{E}[h(x + \sqrt{t}Z)] = \mathbf{E}\left[\frac{\partial^2}{\partial x^2}h(x + \sqrt{t}Z)\right] \\ &= \mathbf{E}[\ddot{h}(x + \sqrt{t}Z)] \end{aligned} \tag{11.12}$$

となる. (11.11) と (11.12) を合わせると

$$\frac{\partial g}{\partial t}(t, x) = \frac{1}{2}\frac{\partial g}{\partial x^2}(t, x) \tag{11.13}$$

を得る. 境界条件 $g(0, x) = h(x)$ を与えると熱方程式 (11.13) を解くことができる.

11.2 ガウス確率集中不等式

Lipschitz 関数 $h : \mathbb{R}^d \rightarrow \mathbb{R}$ を考える. すなわち、ある $L > 0$ に対して

$$|h(\mathbf{x}) - h(\mathbf{y})| \leq L|\mathbf{x} - \mathbf{y}|_{2,d} \quad (\forall \mathbf{x}, \mathbf{y} \in \mathbb{R}^d) \tag{11.14}$$

をみたす. このような L のうちの最小のものを関数 h の Lipschitz 半ノルム $\|h\|_{\text{Lip}}$ と呼ぶことにする.

定理 11.5. $Z_1, Z_2, \dots, Z_d \stackrel{\text{i.i.d.}}{\sim} \mathbf{N}(0, 1)$ とし, $\mathbf{Z} = (Z_1, Z_2, \dots, Z_d)^\top$ とおく. h を \mathbb{R}^d の Lipschitz 関数とする. このとき, 任意の $t \geq 0$ に対して

$$\Pr\left(h(\mathbf{Z}) - \mathbb{E}[h(\mathbf{Z})] \geq t\right) \leq \exp\left(-\frac{t^2}{4\|h\|_{\text{Lip}}^2}\right)$$

が成り立つ.

Proof. h は微分可能で勾配が有限の場合の証明. h は微分可能で, その勾配が $L > 0$ なる上限を持つと仮定する. すなわち

$$|\nabla h|_{2,d} \leq L, \quad \nabla = \left(\frac{\partial}{\partial x_1}, \frac{\partial}{\partial x_2}, \dots, \frac{\partial}{\partial x_d}\right)^\top, \quad \mathbf{x} = (x_1, x_2, \dots, x_d)^\top$$

である. $\lambda \geq 0$ を取り, $\mathbf{Z}_1, \mathbf{Z}_2$ を \mathbf{Z} の独立複製とし, Gauss 補間

$$g(t) = \mathbb{E}\left[\exp\left\{\lambda\left(h(\sqrt{t}\mathbf{Z}_1 + \sqrt{1-t}\mathbf{Z}) - h(\sqrt{t}\mathbf{Z}_2 + \sqrt{1-t}\mathbf{Z})\right)\right\}\right] \quad (11.15)$$

を考える.

① $g(1) \leq e^{\lambda^2 L^2}$ の証明. 上の $g(t)$ を (11.7) の形に直す. 関数 $G : \mathbb{R}^{2d} \rightarrow \mathbb{R}$ を

$$\begin{aligned} G(x_1, x_2, \dots, x_d, x_{d+1}, \dots, x_{2d}) \\ = \exp\left\{\lambda\left(h(x_1, x_2, \dots, x_d) - h(x_{d+1}, x_{d+2}, \dots, x_{2d})\right)\right\} \end{aligned}$$

と定め

$$\mathbf{X} = \begin{pmatrix} \mathbf{Z}_1 \\ \mathbf{Z}_2 \end{pmatrix}, \quad \mathbf{Y} = \begin{pmatrix} \mathbf{Z} \\ \mathbf{Z} \end{pmatrix}$$

とおく. このとき, (11.7) の形の Gauss 補間は

$$g(t) = \mathbb{E}[G(\sqrt{t}\mathbf{X} + \sqrt{1-t}\mathbf{Y})]$$

と書き直すことができる. さらに

$$\Sigma := \text{Cov}[\mathbf{X}] = \begin{bmatrix} \mathbf{I}_d & \mathbf{0} \\ \mathbf{0} & \mathbf{I}_d \end{bmatrix}, \quad \Psi := \text{Cov}[\mathbf{Y}] = \begin{bmatrix} \mathbf{I}_d & \mathbf{I}_d \\ \mathbf{I}_d & \mathbf{I}_d \end{bmatrix}$$

となることに注意する. したがって

$$\Sigma - \Psi = \begin{bmatrix} \mathbf{0} & -\mathbf{I}_d \\ -\mathbf{I}_d & \mathbf{0} \end{bmatrix} = (\sigma_{i,j} - \psi_{i,j}) \quad (11.16)$$

となる. また, $h_j = \frac{\partial h}{\partial x_j}$ ($j = 1, 2, \dots$) と置いたとき, 簡単な計算² から, $j = 1, 2, \dots, d$ に対して

$$\frac{\partial G^2}{\partial x_j \partial x_{j+d}} = -\lambda^2 G h_j(x_1, x_2, \dots, x_d) h_j(x_{d+1}, x_{d+2}, \dots, x_{2d})$$

を得る. 仮定から, $|\nabla h|_{2,d} \leq L$ なので, h_j ($j = 1, 2, \dots, d$) はすべて有界となる. したがって, $c_1, c_2 \in \mathbb{R}$ が存在して

$$|h(\mathbf{x})| \leq c_1 + c_2 |\mathbf{x}|_{2,d}$$

と評価³できる. よって, G に対して, 成長条件 (11.9) が満たされるので, (11.10) と (11.16) から

$$\begin{aligned} \dot{g}(t) &= \frac{1}{2} \sum_{i,j=1}^d (\sigma_{i,j} - \psi_{i,j}) \mathbb{E} \left[\frac{\partial^2 G}{\partial x_i \partial x_j} \right] \\ &= \lambda^2 \mathbb{E} \left[G(\sqrt{t}\mathbf{X} + \sqrt{1-t}\mathbf{Y}) \sum_{j=1}^d h_j(\sqrt{t}\mathbf{Z}_1 + \sqrt{1-t}\mathbf{Z}) h_j(\sqrt{t}\mathbf{Z}_1 + \sqrt{1-t}\mathbf{Z}) \right] \end{aligned}$$

²実際

$$\begin{aligned} \frac{\partial G^2}{\partial x_j \partial x_{j+d}} &= \frac{\partial}{\partial x_{j+d}} \left\{ \frac{\partial}{\partial x_j} \exp \left(\lambda (h(x_1, x_2, \dots, x_n) - h(x_{d+1}, x_{d+2}, \dots, x_{2d})) \right) \right\} \\ &= \frac{\partial}{\partial x_{j+d}} \left\{ \lambda h_j(x_1, x_2, \dots, x_n) \exp \left(\lambda (h(x_1, x_2, \dots, x_n) - h(x_{d+1}, x_{d+2}, \dots, x_{2d})) \right) \right\} \\ &= -\lambda h_j(x_{d+1}, x_{d+2}, \dots, x_{2d}) \lambda h_j(x_1, x_2, \dots, x_n) \\ &\quad \times \exp \left(\lambda (h(x_1, x_2, \dots, x_n) - h(x_{d+1}, x_{d+2}, \dots, x_{2d})) \right) \\ &= -\lambda^2 h_j(x_{d+1}, x_{d+2}, \dots, x_{2d}) \lambda h_j(x_1, x_2, \dots, x_n) \end{aligned}$$

からわかる.

³実際, $|h_j| \leq c_3$ とすると

$$\begin{aligned} |h(\mathbf{y}) - h(\mathbf{x})| &= \left| \int_0^1 \frac{d}{dt} h(\mathbf{x} + t(\mathbf{y} - \mathbf{x})) dt \right| = \left| \int_0^1 \sum_{j=1}^d (y_j - x_j) h_j dt \right| \\ &\leq \int_0^1 \sum_{j=1}^d |y_j - x_j| \times |h_j| dt \leq c_3 \sum_{j=1}^d |y_j - x_j| \leq \sqrt{dc_3} \sqrt{\sum_{j=1}^d (y_j - x_j)^2} \\ &= \sqrt{dc_3} |\mathbf{y} - \mathbf{x}|_{2,d} \end{aligned}$$

となる. ここで, $\mathbf{y} = \mathbf{0}$ とおくと

$$|h(\mathbf{x})| - \underbrace{|h(\mathbf{0})|}_{=:c_1} \leq \underbrace{\sqrt{dc_3}}_{=:c_2} |\mathbf{x}|_{2,d}$$

よりわかる.

がわかる. Cauchy-Schwarz の不等式から

$$\begin{aligned} & \sum_{j=1}^d h_j(\sqrt{t}\mathbf{Z}_1 + \sqrt{1-t}\mathbf{Z})h_j(\sqrt{t}\mathbf{Z}_1 + \sqrt{1-t}\mathbf{Z}) \\ & \leq |\nabla h(\sqrt{t}\mathbf{Z}_1 + \sqrt{1-t}\mathbf{Z})|_{2,d} \times |\nabla h(\sqrt{t}\mathbf{Z}_2 + \sqrt{1-t}\mathbf{Z})|_{2,d} \\ & \leq L^2 \end{aligned}$$

となる. よって

$$\dot{g}(t) \leq \lambda^2 L^2 \mathbb{E}[G(\sqrt{t}\mathbf{X} + \sqrt{1-t}\mathbf{Y})] = \lambda^2 L^2 g(t)$$

を得る. これより

$$\frac{d}{dt} \left\{ g(t)e^{-\lambda^2 L^2 t} \right\} = e^{-\lambda^2 L^2 t} \left(\dot{g}(t) - \lambda^2 L^2 g(t) \right) \leq 0$$

となるので, 関数 $t \mapsto g(t)e^{-\lambda^2 L^2 t}$ は非増加である. よって, $g(1) \leq e^{\lambda^2 L^2} g(0)$ となる. さらに, (11.15) から $g(0) = 1$ がわかるので

$$g(1) = \mathbb{E}[\exp\{\lambda(h(\mathbf{Z}_1) - h(\mathbf{Z}_2))\}] \leq e^{\lambda^2 L^2} \quad (11.17)$$

がわかる.

② $\Pr(h(\mathbf{Z}) - \mathbb{E}[h(\mathbf{Z})] \geq t) \leq e^{-\lambda^2/L^2}$ の証明. 関数 $x \mapsto \exp(-\lambda x)$ は凸なので, Jensen の不等式 (\mathbf{Z}_2 の期待値に関するもの) から

$$\exp\left\{\lambda\left(h(\mathbf{Z}_1) - \mathbb{E}_2[h(\mathbf{Z}_2)]\right)\right\} \leq \mathbb{E}_2\left[\exp\left\{\lambda\left(h(\mathbf{Z}_1) - h(\mathbf{Z}_2)\right)\right\}\right]$$

を得る. ただし, $\mathbb{E}_j[\cdot]$ は \mathbf{Z}_j ($j = 1, 2$) に関する期待値を表す. さらに, 上記の不等式を \mathbf{Z}_1 に関して積分をし, $\mathbf{Z}_1, \mathbf{Z}_2$ は \mathbf{Z} と同じ分布を持つことと (11.17) から

$$\begin{aligned} \mathbb{E}\left[\exp\left\{\lambda\left(h(\mathbf{Z}) - \mathbb{E}[h(\mathbf{Z})]\right)\right\}\right] &= \mathbb{E}_1\left[\exp\left\{\lambda\left(h(\mathbf{Z}_1) - \mathbb{E}_2[h(\mathbf{Z}_2)]\right)\right\}\right] \\ &\leq \mathbb{E}_1\left[\mathbb{E}_2\left[\exp\left\{\lambda\left(h(\mathbf{Z}_1) - [h(\mathbf{Z}_2)]\right)\right\}\right]\right] \\ &= \mathbb{E}\left[\exp\left\{\lambda\left(h(\mathbf{Z}_1) - [h(\mathbf{Z}_2)]\right)\right\}\right] \\ &\leq e^{\lambda^2 L^2} \end{aligned}$$

を得る. さらに, $\lambda > 0, t > 0$ とし, Markov の不等式を用いると

$$\begin{aligned} \Pr\left(h(\mathbf{Z}) - \mathbb{E}[h(\mathbf{Z})] \geq t\right) &= \Pr\left(\exp\left(\lambda(h(\mathbf{Z}) - \mathbb{E}[h(\mathbf{Z})])\right) \geq e^{\lambda t}\right) \\ &\leq e^{-\lambda t} \mathbb{E}\left[\exp\left(\lambda(h(\mathbf{Z}) - \mathbb{E}[h(\mathbf{Z})])\right)\right] \\ &\leq \exp\left(-\lambda t + \lambda^2 L^2\right) \\ &= \exp\left(L^2\left(\lambda - t/(2L^2)\right)^2 - \frac{t^2}{4L^2}\right) \end{aligned}$$

を得る. $\lambda > 0$ は任意だったので, $\lambda = t/(2L^2)$ とおくと

$$\Pr\left(h(\mathbf{Z}) - \mathbb{E}[h(\mathbf{Z})] \geq t\right) \leq \exp\left(-\frac{t^2}{4L^2}\right)$$

を得る.

II h は Lipschitz の場合の証明. 標準的な smoothing technique を用いる. すなわち, $\epsilon > 0$ に対して

$$h_\epsilon(\mathbf{x}) := \mathbb{E}[h(\mathbf{x} + \epsilon\tilde{\mathbf{Z}})] \quad (11.18)$$

と定める. ただし, $\tilde{\mathbf{Z}} \sim \mathbf{N}_d(\mathbf{0}_d, \mathbf{I}_d)$ である. すると関数 h_ϵ も Lipschitz とこと⁴がわかる. しかし, 微分可能⁵である. 関数 h_ϵ に I の結果を適用すると, $\forall t > 0$ に対して

$$\Pr(h_\epsilon(\mathbf{Z}) - \mathbb{E}[h_\epsilon(\mathbf{Z})] \geq t) \leq \exp\left(-\frac{t^2}{4\|h_\epsilon\|_{\text{Lip}}^2}\right) \quad (11.19)$$

⁴実際

$$|h_\epsilon(\mathbf{x}) - h_\epsilon(\mathbf{y})| \leq \mathbb{E}[|h(\mathbf{x} + \epsilon\mathbf{Z}) - h(\mathbf{y} + \epsilon\mathbf{Z})|] \leq L\|\mathbf{x} - \mathbf{y}\|_{2,d}$$

よりわかる.

⁵なぜならば

$$\begin{aligned} \mathbb{E}[h(\mathbf{x} + \epsilon\mathbf{Z})] &= \frac{1}{(\sqrt{2\pi})^d} \int_{\mathbb{R}^d} h(\mathbf{x} + \epsilon\mathbf{y}) e^{-|\mathbf{y}|_{2,d}^2/2} d\mathbf{y} \\ &= \frac{1}{(\epsilon\sqrt{2\pi})^d} \int_{\mathbb{R}^d} h(\mathbf{t}) e^{-|\mathbf{t} - \mathbf{x}|_{2,d}^2/(2\epsilon^2)} d\mathbf{t} \\ &\quad (\because \mathbf{y} = (\mathbf{t} - \mathbf{x})/\epsilon \text{ と変換}) \end{aligned}$$

とかけることからわかる.

となる. 十分小さな $\epsilon > 0$ に対して

$$\begin{aligned} |h(\mathbf{x}) - h_\epsilon(\mathbf{x})| &= \left| \mathbb{E} \left[h(\mathbf{x}) - h(\mathbf{x} + \epsilon \tilde{\mathbf{Z}}) \right] \right| \\ &\leq \mathbb{E} \left[|h(\mathbf{x}) - h(\mathbf{x} + \epsilon \tilde{\mathbf{Z}})| \right] \\ &\leq \mathbb{E} \left[L\epsilon |\tilde{\mathbf{Z}}|_{2,d} \right] \quad (\because (11.14)) \\ &\leq L\epsilon |\tilde{\mathbf{Z}}|_{2,d} \xrightarrow{\epsilon \rightarrow 0} 0 \end{aligned}$$

から, h_ϵ は h を一様に近似することがわかる. よって

$$\begin{aligned} &\Pr \left(h(\mathbf{Z}) - \mathbb{E}[h(\mathbf{Z})] \geq t \right) \\ &= \Pr \left(h_\epsilon(\mathbf{Z}) - \mathbb{E}[h_\epsilon(\mathbf{Z})] \geq t - \{h(\mathbf{Z}) - h_\epsilon(\mathbf{Z})\} - \mathbb{E}[h(\mathbf{Z}) - h_\epsilon(\mathbf{Z})] \right) \\ &\leq \Pr \left(h_\epsilon(\mathbf{Z}) - \mathbb{E}[h_\epsilon(\mathbf{Z})] \geq t - 2L\epsilon \mathbb{E}[|\tilde{\mathbf{Z}}|_{2,d}] \right) \\ &\leq \exp \left(-\frac{(t - 2L\epsilon \mathbb{E}[|\tilde{\mathbf{Z}}|_{2,d}])^2}{4\|h_\epsilon\|_{\text{Lip}}} \right) \\ &\xrightarrow{\epsilon \rightarrow 0} \exp \left(-\frac{t^2}{4\|h\|_{\text{Lip}}} \right) \end{aligned}$$

がわかる. よって, 定理は証明された. □

以下では, Gauss 確率集中不等式の適用例を述べる.

例 11.6. □

例 11.7. □

例 11.8. □

例 11.9. □

11.3 Gauss 分布比較

定理 11.10 (Slepian の不等式). $\mathbf{X} = (X_1, X_2, \dots, X_d)^\top$, $\mathbf{Y} = (Y_1, Y_2, \dots, Y_d)^\top$ は \mathbb{R}^d 上の中心化された正規分布に従う確率ベクトル⁶で

$$1. \mathbb{E}[X_j^2] = \mathbb{E}[Y_j^2] \quad (j = 1, 2, \dots, d),$$

⁶ \mathbf{X} と \mathbf{Y} は独立でなくともよい.

$$2. \mathbb{E}[X_j X_k] \leq \mathbb{E}[Y_j Y_k] \quad (j, k = 1, 2, \dots, d)$$

をみたすとする. このとき, $\forall t_j (j = 1, 2, \dots, d)$ に対して

$$\Pr\left(\bigcap_{j=1}^d \{X_j \leq t_j\}\right) \leq \Pr\left(\bigcap_{j=1}^d \{Y_j \leq t_j\}\right) \quad (11.20)$$

が成り立つ. さらに

$$\mathbb{E}\left[\max_{j=1,2,\dots,d} X_j\right] \geq \mathbb{E}\left[\max_{j=1,2,\dots,d} Y_j\right] \quad (11.21)$$

が成立する.

Proof. I (11.20) の証明. まず

$$\mathbb{1}\left(\bigcap_{j=1}^d \{x_j \leq t_j\}\right) = \prod_{j=1}^d \mathbb{1}\{x_j \leq t_j\}$$

に注意する. 滑らかな非負値非増加関数 $\varphi_j(\cdot) (j = 1, 2, \dots, d)$ で $\mathbb{1}_{(-\infty, t_j]}(\cdot)$ を近似する. ここで

$$\varphi(\mathbf{x}) = \prod_{j=1}^d \varphi_j(x_j), \quad \mathbf{x} = (x_1, x_2, \dots, d)$$

とおき, Gauss 補間

$$g(t) := \mathbb{E}[\varphi(\sqrt{t}\mathbf{X} + \sqrt{1-t}\mathbf{Y})] \mathbb{E}[\varphi(\sqrt{t}\mathbf{Z}(t))]$$

を考える. すると (11.10) から

$$\dot{g}(t) = \frac{1}{2} \sum_{i,j=1}^d \underbrace{(\mathbb{E}[X_i X_j] - \mathbb{E}[Y_i Y_j])}_{\leq 0} \mathbb{E}\left[\frac{\partial^2 \varphi}{\partial x_i \partial x_j}(\mathbf{Z}(t))\right] \leq 0$$

となる. 実際, $\dot{\varphi}_i(x_i) \leq 0$ かつ $\dot{\varphi}_j(x_j) \leq 0 (i \neq j)$ なので

$$\frac{\partial^2}{\partial x_i \partial x_j} \prod_{\ell=1}^d \varphi_\ell(x_\ell) = \underbrace{\dot{\varphi}_i(x_i) \dot{\varphi}_j(x_j)}_{\geq 0} \prod_{\ell \neq i, j} \underbrace{\varphi_\ell(x_\ell)}_{\geq 0} \geq 0$$

となることからわかる. よって, g は非増加となるので

$$g(1) = \mathbb{E}[\varphi(\mathbf{X})] \leq g(0) = \mathbb{E}[\varphi(\mathbf{Y})]$$

がわかる. φ_j は指示関数 $\mathbb{1}_{(-\infty, t_j]}$ に収束するので

$$\begin{aligned} \Pr\left(\bigcap_{j=1}^d \{X_j \leq t_j\}\right) &= \mathbb{E}\left[\bigcap_{j=1}^d \{X_j \leq t_j\}\right] \leq \mathbb{E}\left[\bigcap_{j=1}^d \{Y_j \leq t_j\}\right] \\ &= \Pr\left(\bigcap_{j=1}^d \{Y_j \leq t_j\}\right) \end{aligned}$$

がわかる.

II (11.23) の証明. (11.20) から (11.23) を証明する. (11.20) において $t_j = t$ ($j = 1, 2, \dots, d$) とおくと

$$\begin{aligned} \Pr\left(\max_{j=1,2,\dots,d} X_j \leq t\right) &= \Pr\left(\bigcap_{j=1}^d \{X_j \leq t\}\right) \leq \Pr\left(\bigcap_{j=1}^d \{Y_j \leq t\}\right) \\ &= \Pr\left(\max_{j=1,2,\dots,d} Y_j \leq t\right) \end{aligned} \quad (11.22)$$

となる. ここで

$$\begin{aligned} X &:= \max_{j=1,2,\dots,d} X_j, & X^+ &:= \max\{X, 0\}, & X^- &:= \max\{-X, 0\}, \\ Y &:= \max_{j=1,2,\dots,d} Y_j, & Y^+ &:= \max\{Y, 0\}, & Y^- &:= \max\{-Y, 0\} \end{aligned}$$

とおく. すると X^+, X^-, Y^+, Y^- は非負値確率変数で

$$X = X^+ - X^-, \quad Y = Y^+ - Y^-$$

となる. すると $t \geq 0$ に対して, $\{X^+ \geq 0\} \cap \{X^- \geq 0\} = \emptyset$ となること注意して, (11.22) を用いると

$$\Pr(X^+ - X^- > t) \geq \Pr(Y^+ - Y^- > t) \Rightarrow \Pr(X^+ > t) \geq \Pr(Y^+ > t)$$

となる. さらに

$$\begin{aligned} \Pr(X^+ - X^- > -t) &\geq \Pr(Y^+ - Y^- > -t) \\ &\Rightarrow \Pr(X^- - X^+ < t) \geq \Pr(Y^- - Y^+ < t) \\ &\Rightarrow \Pr(X^- - X^+ \geq t) \leq \Pr(Y^- - Y^+ \geq t) \\ &\Rightarrow \Pr(X^- \geq t) \leq \Pr(Y^- \geq t) \end{aligned}$$

がわかる. よって, 命題 1.32 から

$$\begin{aligned}
 E[X] &= E[X^+] - E[X^-] \\
 &= \int_0^t \Pr(X^+ > t) dt - \int_0^t \Pr(X^- > t) dt \\
 &= \int_0^t \Pr(X^+ > t) dt - \int_0^t \Pr(X^- \geq t) dt \\
 &\geq \int_0^t \Pr(Y^+ > t) dt - \int_0^t \Pr(Y^- \geq t) dt \\
 &\geq \int_0^t \Pr(Y^+ > t) dt - \int_0^t \Pr(Y^- > t) dt \\
 &= E[Y^+] - E[Y^-] = E[Y]
 \end{aligned}$$

となる. よって, 定理は証明された. \square

次に, (11.23) をより制限のすくない条件のもとで証明しよう. $i, j \in \{1, 2, \dots, d\}$, $i \neq j$ に対して

$$\begin{aligned}
 E[(X_i - X_j)^2] &= E[X_i^2] + E[X_j^2] - E[X_i X_j], \\
 E[(Y_i - Y_j)^2] &= E[Y_i^2] + E[Y_j^2] - E[Y_i Y_j]
 \end{aligned}$$

となるので, 定理 11.10 の最初の条件のもと

$$\begin{aligned}
 E[X_i X_j] &\leq E[Y_i Y_j] \quad (\forall 1 \leq i, j \leq d) \\
 &\Leftrightarrow E[(X_i - X_j)^2] \geq E[(Y_i - Y_j)^2] \quad (\forall 1 \leq i, j \leq d)
 \end{aligned}$$

となる. 2 番目の条件を置き換えることにより, 自動的に 1 番目の条件が成立することを示す.

定理 11.11. $\mathbf{X} = (X_1, X_2, \dots, X_d)^\top$, $\mathbf{Y} = (Y_1, Y_2, \dots, Y_d)^\top$ は \mathbb{R}^d 上の中心化された正規分布に従う確率ベクトルで

$$E[(X_i - X_j)^2] \geq E[(Y_i - Y_j)^2] \quad (\forall 1 \leq i, j \leq d)$$

をみたすとする. このとき

$$E\left[\max_{j=1,2,\dots,d} X_j\right] \geq E\left[\max_{j=1,2,\dots,d} Y_j\right] \quad (11.23)$$

が成立する.

Proof. ① $\max_{j=1,2,\dots,d} x_j$ の平滑化. 補間法を用いて証明する. しかし, 最大値関数 $\mathbf{x} = (x_1, x_2, \dots, x_d) \mapsto \max_{j=1,2,\dots,d} x_j$ に対する特別な平滑化関数

$$F(\mathbf{x}) = \frac{1}{\beta} \log \sum_{j=1}^d e^{\beta x_j}$$

を用いる. ただし, $\beta > 0$ である. 関数 F を最大値の平滑化関数とみる理由は以下である.

$$\max_{j=1,2,\dots,d} x_j \leq \frac{1}{\beta} \log \left(\sum_{j=1}^d e^{\beta x_j} \right) \leq \max_{j=1,2,\dots,d} x_j + \frac{\log n}{\beta} \quad (11.24)$$

が成り立つこと⁷からわかる. すると

$$\mathbb{E}[F(\mathbf{X})] \xrightarrow{\beta \rightarrow \infty} \mathbb{E} \left[\max_{j=1,2,\dots,d} X_j \right]; \quad \mathbb{E}[F(\mathbf{Y})] \xrightarrow{\beta \rightarrow \infty} \mathbb{E} \left[\max_{j=1,2,\dots,d} Y_j \right]$$

から

$$\mathbb{E}[F(\mathbf{X})] \geq \mathbb{E}[F(\mathbf{Y})] \Rightarrow \mathbb{E} \left[\max_{j=1,2,\dots,d} X_j \right] \geq \mathbb{E} \left[\max_{j=1,2,\dots,d} Y_j \right]$$

がわかる.

② $\mathbb{E}[F(\mathbf{X})] \geq \mathbb{E}[F(\mathbf{Y})]$ の証明. Gauss 補間 (11.10) を用いるために, F の導関数を求める. まず, $j = 1, 2, \dots, d$ に対して

$$F_j(\mathbf{x}) := \frac{\partial F}{\partial x_j} = \frac{e^{\beta x_j}}{\sum_{\ell=1}^n e^{\beta x_\ell}}$$

となることに注意する. さらに

$$F_{jj}(\mathbf{x}) := \frac{\partial^2 F}{\partial x_j^2} = \beta \left(F_j(\mathbf{x}) - \{F_j(\mathbf{x})\}^2 \right), \quad (11.25)$$

$$F_{ij}(\mathbf{x}) := \frac{\partial^2 F}{\partial x_i \partial x_j} = -\beta F_i(\mathbf{x}) F_j(\mathbf{x}) \quad (i \neq j) \quad (11.26)$$

となる. よって, Gauss 補間 (11.10) は以下のようになる. $\mathbf{Z}(t) = \sqrt{t}\mathbf{X} +$

⁷実際

$$\begin{aligned} \max_{j=1,2,\dots,d} x_j &= \frac{1}{\beta} \sum_{j=1}^d \beta x_j = \frac{1}{\beta} \log \exp \left(\sum_{j=1}^d \beta x_j \right) \leq \frac{1}{\beta} \log \left(\sum_{j=1}^d e^{\beta x_j} \right) \\ &\leq \frac{1}{\beta} \log \left(n \exp \{ \beta \max_{j=1,2,\dots,d} x_j \} \right) = \frac{1}{\beta} \left(\log n + \beta \max_{j=1,2,\dots,d} x_j \right) \\ &= \max_{j=1,2,\dots,d} x_j + \frac{\log n}{\beta} \end{aligned}$$

からわかる.

$\sqrt{1-t}\mathbf{Y}$ とおくと

$$\begin{aligned} \dot{g}(t) &= \frac{d}{dt} \mathbf{E}[F(\mathbf{Z}(t))] \\ &= \frac{1}{2} \sum_{i,j=1}^d \{ \mathbf{E}[X_i X_j] - \mathbf{E}[Y_i Y_j] \} \mathbf{E} \left[\frac{\partial^2 F}{\partial x_i \partial x_j}(\mathbf{Z}(t)) \right] \\ &= \frac{\beta}{2} \sum_{j=1}^d \{ \mathbf{E}[X_j^2] - \mathbf{E}[Y_j^2] \} \mathbf{E}[F_j(\mathbf{Z}(t)) - F_j^2(\mathbf{Z}(t))] \\ &\quad - \frac{\beta}{2} \sum_{i \neq j} \{ \mathbf{E}[X_i X_j] - \mathbf{E}[Y_i Y_j] \} \mathbf{E} \left[F_i(\mathbf{Z}(t)) F_j(\mathbf{Z}(t)) \right] \quad (11.27) \end{aligned}$$

を得る. F をうまく選んで

$$\sum_{j=1}^d F_j(\mathbf{x}) = \sum_{j=1}^d \frac{e^{\beta x_j}}{\sum_{k=1}^d e^{\beta x_k}} = 1$$

とする. すると

$$F_j(\mathbf{x}) - F_j^2(\mathbf{x}) = F_j(\mathbf{x}) \{ 1 - F_j(\mathbf{x}) \} = F_j(\mathbf{x}) \sum_{i \neq j} F_i(\mathbf{x}) = \sum_{j \neq i} F_i(\mathbf{x}) F_j(\mathbf{x})$$

がわかる. これから

$$\begin{aligned} &\sum_{j=1}^d \{ \mathbf{E}[X_j^2] - \mathbf{E}[Y_j^2] \} \mathbf{E}[F_j(\mathbf{Z}(t)) - F_j^2(\mathbf{Z}(t))] \\ &= \sum_{j=1}^d \{ \mathbf{E}[X_j^2] - \mathbf{E}[Y_j^2] \} \sum_{i \neq j} \mathbf{E}[F_i(\mathbf{Z}(t)) F_j(\mathbf{Z}(t))] \\ &= \sum_{i=1}^d \sum_{j \neq i} \{ \mathbf{E}[X_j^2] - \mathbf{E}[Y_j^2] \} \mathbf{E}[F_i(\mathbf{Z}(t)) F_j(\mathbf{Z}(t))] \end{aligned}$$

となる. 上式の右辺の i と j を入れ替えると

$$\begin{aligned} &\sum_{j=1}^d \{ \mathbf{E}[X_j^2] - \mathbf{E}[Y_j^2] \} \mathbf{E}[F_j(\mathbf{Z}(t)) - F_j^2(\mathbf{Z}(t))] \\ &= \sum_{i=1}^d \sum_{j \neq i} \{ \mathbf{E}[X_i^2] - \mathbf{E}[Y_i^2] \} \mathbf{E}[F_i(\mathbf{Z}(t)) F_j(\mathbf{Z}(t))] \end{aligned}$$

となる. 上の 2 つの式の辺々を加えると

$$\begin{aligned} &\sum_{j=1}^d \{ \mathbf{E}[X_j^2] - \mathbf{E}[Y_j^2] \} \mathbf{E}[F_j(\mathbf{Z}(t)) - F_j^2(\mathbf{Z}(t))] \\ &= \frac{1}{2} \sum_{i=1}^d \sum_{j \neq i} \left(\mathbf{E}[X_i^2] + \mathbf{E}[X_j^2] - \mathbf{E}[Y_i^2] - \mathbf{E}[Y_j^2] \right) \mathbf{E}[F_i(\mathbf{Z}(t)) F_j(\mathbf{Z}(t))] \end{aligned}$$

を得る. この式を (11.27) の最右辺の 1 項目に入れると

$$\begin{aligned}
 \dot{g}(t) &= \frac{\beta}{4} \sum_{i=1}^d \sum_{j \neq i} \left(\mathbb{E}[X_i^2] + \mathbb{E}[X_j^2] - \mathbb{E}[Y_i^2] - \mathbb{E}[Y_j^2] \right) \mathbb{E}[F_i(\mathbf{Z}(t))F_j(\mathbf{Z}(t))] \\
 &\quad - \frac{\beta}{2} \sum_{i=1}^d \sum_{j \neq i} \{ \mathbb{E}[X_i X_j] - \mathbb{E}[Y_i Y_j] \} \mathbb{E}[F_i(\mathbf{Z}(t))F_j(\mathbf{Z}(t))] \\
 &= \frac{\beta}{4} \sum_{i=1}^d \sum_{j \neq i} \left(\mathbb{E}[(X_i - X_j)^2] - \mathbb{E}[(Y_i - Y_j)^2] \right) \mathbb{E}[F_i(\mathbf{Z}(t))F_j(\mathbf{Z}(t))] \\
 &\geq 0
 \end{aligned} \tag{11.28}$$

を得る. これから

$$\mathbb{E}[F(\mathbf{X})] = \mathbb{E}[F(\mathbf{Z}(1))] = g(1) \geq g(0) = \mathbb{E}[F(\mathbf{Z}(0))] = \mathbb{E}[F(\mathbf{Y})]$$

がわかる. □

例 11.12. □

系 11.13. $\mathbf{X} = (X_1, X_2, \dots, X_d)^\top$, $\mathbf{Y} = (Y_1, Y_2, \dots, Y_d)^\top$ は \mathbb{R}^d 上の中心化された正規分布に従う確率ベクトルで, ある $\epsilon > 0$ に対して

$$\left| \mathbb{E}[(X_i - X_j)^2] - \mathbb{E}[(Y_i - Y_j)^2] \right| \leq \frac{\epsilon}{d} \quad (\forall i, j = 1, 2, \dots, d) \tag{11.29}$$

をみたすとき

$$\left| \mathbb{E} \left[\max_{j=1,2,\dots,d} X_j \right] - \mathbb{E} \left[\max_{j=1,2,\dots,d} Y_j \right] \right| \leq \sqrt{\epsilon \log d}$$

が成り立つ.

Proof. $\beta > 0$ に対して

$$F(\mathbf{x}) = \frac{1}{\beta} \log \left(\sum_{j=1}^d e^{\beta x_j} \right)$$

おく. すると, $i \neq j$ に対して

$$\begin{aligned}
 \frac{\partial F}{\partial x_j}(\mathbf{x}) &=: F_j(\mathbf{x}) = \frac{e^{\beta x_i}}{\sum_{k=1}^d e^{\beta x_k}}, \\
 \frac{\partial^2 F}{\partial x_i \partial x_j}(\mathbf{x}) &= \frac{1}{\beta} \frac{\partial}{\partial x_j} \left\{ \frac{\beta e^{\beta x_i}}{\sum_{k=1}^d e^{\beta x_k}} \right\} = -\frac{1}{\beta} \underbrace{\left\{ \frac{\beta e^{\beta x_i}}{\sum_{k=1}^d e^{\beta x_k}} \right\}}_{\beta F_i(\mathbf{x})} \left\{ \frac{\beta e^{\beta x_j}}{\sum_{k=1}^d e^{\beta x_k}} \right\} \\
 &= -\beta F_i(\mathbf{x}) F_j(\mathbf{x}) =: F_{i,j}(\mathbf{x})
 \end{aligned}$$

となる. $\sum_{j=1}^d F_j(\mathbf{X}) = 1$, $0 \leq F_i(\mathbf{x}) \leq 1$ ($j = 1, 2, \dots, d$) から

$$\left| \frac{\partial^2 F}{\partial x_i \partial x_j}(\mathbf{x}) \right| \leq \beta, \quad F_{i,i}(\mathbf{x}) = - \sum_{j \neq i} F_{i,j}(\mathbf{x})$$

がわかる. さらに

$$\begin{aligned} \dot{g}(t) &= \mathbb{E} \left[\frac{d}{dt} F(\mathbf{Z}(t)) \right] \\ &= \mathbb{E} \left[\sum_{j=1}^d F_j(\mathbf{Z}(t)) \left(\frac{1}{2\sqrt{t}} X_j - \frac{1}{2\sqrt{1-t}} Y_j \right) \right] \end{aligned} \quad (11.30)$$

となる. 定理 11.3 から

$$\begin{aligned} \mathbb{E} \left[F_j(\mathbf{Z}(t)) X_j \right] &= \sqrt{t} \sum_{i=1}^d \mathbb{E}[X_j X_i] \mathbb{E} \left[\frac{\partial F^2}{\partial x_i \partial x_j}(\mathbf{Z}(t)) \right], \\ \mathbb{E} \left[F_j(\mathbf{Z}(t)) Y_j \right] &= \sqrt{1-t} \sum_{i=1}^d \mathbb{E}[Y_j Y_i] \mathbb{E} \left[\frac{\partial F^2}{\partial x_i \partial x_j}(\mathbf{Z}(t)) \right] \end{aligned}$$

となる. 上の 2 式を (11.30) に入れると

$$\begin{aligned} \dot{g}(t) &= \frac{1}{2} \sum_{j=1}^d \sum_{i=1}^d \{ \mathbb{E}[X_i X_j] - \mathbb{E}[Y_i Y_j] \} \mathbb{E} \left[\frac{\partial F^2}{\partial x_i \partial x_j}(\mathbf{Z}(t)) \right] \\ &= \frac{1}{2} \sum_{j=1}^d \left\{ \{ \mathbb{E}[X_j^2] - \mathbb{E}[Y_j^2] \} \mathbb{E} \left[\frac{\partial F^2}{\partial x_j \partial x_j}(\mathbf{Z}(t)) \right] \right. \\ &\quad \left. + \sum_{i \neq j} \{ \mathbb{E}[X_i X_j] - \mathbb{E}[Y_i Y_j] \} \mathbb{E} \left[\frac{\partial F^2}{\partial x_i \partial x_j}(\mathbf{Z}(t)) \right] \right\} \end{aligned} \quad (11.31)$$

となる. さらに, (11.26) と $\sum_{k=1}^d F_k(\mathbf{Z}(t)) = 1$ から

$$\begin{aligned} &\sum_{j=1}^d \{ \mathbb{E}[X_j^2] - \mathbb{E}[Y_j^2] \} \mathbb{E} \left[\frac{\partial F^2}{\partial x_j \partial x_j}(\mathbf{Z}(t)) \right] \\ &= \beta \sum_{j=1}^d \{ \mathbb{E}[X_j^2] - \mathbb{E}[Y_j^2] \} \mathbb{E} \left[F_i(\mathbf{Z}(t)) \underbrace{\{ 1 - F_i(\mathbf{Z}(t)) \}}_{= - \sum_{j \neq i} F_j(\mathbf{Z}(t))} \right] \\ &= -\beta \sum_{j=1}^d \sum_{j \neq i} \{ \mathbb{E}[X_j^2] - \mathbb{E}[Y_j^2] \} \mathbb{E} [F_i(\mathbf{Z}(t)) F_j(\mathbf{Z}(t))] \end{aligned}$$

となる. 上の式の右辺で i と j を入れ替えると

$$\begin{aligned} & \sum_{j=1}^d \{E[X_j^2] - E[Y_j^2]\} E\left[\frac{\partial F^2}{\partial x_j \partial x_j}(\mathbf{Z}(t))\right] \\ &= -\beta \sum_{i=1}^d \sum_{i \neq j} \{E[X_i^2] - E[Y_i^2]\} E[F_i(\mathbf{Z}(t))F_j(\mathbf{Z}(t))] \end{aligned}$$

となる. これらのふたつの式を合わせると

$$\begin{aligned} & \sum_{j=1}^d \{E[X_j^2] - E[Y_j^2]\} E\left[\frac{\partial F^2}{\partial x_j \partial x_j}(\mathbf{Z}(t))\right] \\ &= -\frac{\beta}{2} \sum_{j=1}^d \sum_{i \neq j} \{E[X_i^2] + E[X_j^2] - E[Y_i^2] + E[Y_j^2]\} E[F_i(\mathbf{Z}(t))F_j(\mathbf{Z}(t))] \end{aligned}$$

を得る. この式を (11.31) に代入すると

$$\begin{aligned} \dot{g}(t) &= -\frac{\beta}{4} \sum_{j=1}^d \sum_{i \neq j} \left\{ E[X_i^2] + E[X_j^2] - E[Y_i^2] - E[Y_j^2] - 2E[X_i X_j] + 2E[Y_i Y_j] \right\} \\ & \quad \times E[F_i(\mathbf{Z}(t))F_j(\mathbf{Z}(t))] \\ &= -\frac{\beta}{4} \sum_{j=1}^d \sum_{i \neq j} \left\{ E[(X_i - X_j)^2] - E[(Y_i - Y_j)^2] \right\} E[F_i(\mathbf{Z}(t))F_j(\mathbf{Z}(t))] \end{aligned}$$

を得る. したがって, (11.29) から

$$\begin{aligned} |\dot{g}(t)| &\leq \frac{\epsilon\beta}{4d} \left| \sum_{j=1}^d \sum_{i \neq j} E[F_i(\mathbf{Z}(t))F_j(\mathbf{Z}(t))] \right| \\ &= \frac{\epsilon\beta}{4d} \left| \sum_{j=1}^d E\left[\underbrace{\sum_{i \neq j} F_i(\mathbf{Z}(t)) F_j(\mathbf{Z}(t))}_{=1-F_j(\mathbf{Z}(t))} \right] \right| \\ &\leq \frac{\epsilon\beta}{4d} \sum_{j=1}^d E[|F_j(\mathbf{Z}(t))|] \\ &\leq \frac{\epsilon\beta}{4} \end{aligned}$$

を得る. 以上から

$$\begin{aligned} \left| E[F(\mathbf{X})] - E[F(\mathbf{Y})] \right| &= |g(1) - g(0)| = \left| \int_0^1 \dot{g}(t) dt \right| \\ &\leq E[|\dot{g}(t)|] \leq \frac{\beta\epsilon}{4} \end{aligned} \quad (11.32)$$

となる. (11.27) から (11.28) から

$$F(\mathbf{X}) \leq \max_{j=1,2,\dots,d} X_j + \frac{\log d}{\beta},$$

$$F(\mathbf{Y}) \geq \max_{j=1,2,\dots,d} Y_j$$

となるので

$$F(\mathbf{X}) - \max_{j=1,2,\dots,d} X_j - \{F(\mathbf{Y}) - \max_{j=1,2,\dots,d} Y_j\} \leq \frac{\log d}{\beta}$$

となる. 同様に

$$F(\mathbf{Y}) - \max_{j=1,2,\dots,d} Y_j - \{F(\mathbf{X}) - \max_{j=1,2,\dots,d} X_j\} \leq \frac{\log d}{\beta}$$

となるので

$$\left| F(\mathbf{X}) - \max_{j=1,2,\dots,d} X_j - \{F(\mathbf{Y}) - \max_{j=1,2,\dots,d} Y_j\} \right| \leq \frac{\log d}{\beta} \quad (11.33)$$

となる. したがって, (11.32) と (11.33) から

$$\begin{aligned} & \left| \mathbb{E} \left[\max_{j=1,2,\dots,d} X_j \right] - \mathbb{E} \left[\max_{j=1,2,\dots,d} X_j \right] \right| \\ & \leq \left| \mathbb{E}[F(\mathbf{Z})] - \mathbb{E}[F(\mathbf{Y})] \right| \\ & \quad + \mathbb{E} \left[\left| F(\mathbf{X}) - \max_{j=1,2,\dots,d} X_j - \{F(\mathbf{Y}) - \max_{j=1,2,\dots,d} Y_j\} \right| \right] \\ & \leq \frac{\beta\epsilon}{4} + \frac{\log d}{\beta} \end{aligned}$$

を得る. ここで, $\beta = 2\sqrt{\frac{\log d}{\epsilon}}$ とおくと

$$\left| \mathbb{E} \left[\max_{j=1,2,\dots,d} X_j \right] - \mathbb{E} \left[\max_{j=1,2,\dots,d} X_j \right] \right| \leq \sqrt{\epsilon \log d}$$

を得る. よって, 系は証明された. \square

定理 11.14 (Sudakov minoration). X_1, X_2, \dots, X_d を中心かされた正規分布に従う確率変数列とする. このとき

$$\mathbb{E} \left[\max_{j=1,2,\dots,d} X_j \right] \geq \frac{1}{2} \min_{i \neq j} \sqrt{\mathbb{E}[(X_i - X_j)^2] \log d}$$

が成立する.

Proof.

□

注意 11.15. Sudakov minoration の不等式の驚くべき結果は, Gauss 過程の最大値に対する下限を与えることである. 実際, \mathcal{T} で添え字づけられた中心化された Gauss 過程 $\{X_t : t \in \mathcal{T}\}$ を考える. \mathcal{T} 上の疑似距離 $d(t, s)^2 = E[(X_t - X_s)^2]$ で定める. このとき, $0 < \forall \epsilon \leq D := \sup_{s, t \in \mathcal{T}} d(s, t)$ に対して

$$E \left[\sup_{t \in \mathcal{T}} X_t \right] \geq \frac{\epsilon}{2} \sqrt{H(\epsilon, \mathcal{T}, d)}$$

をもつことである.