

連続最適化のための進化戦略の数理解習課題 (解説)

秋本洋平 (筑波大学 / 理研 AIP / 大阪大学)

2025年8月28–30日 統計数理研究所
連続最適化および関連分野に関する夏期学校 2025

問1 Truncated Additive Drift の証明

講演資料に示した Truncated Additive Drift の定理を証明する。証明したい命題は以下の通りである。

命題 Let $\{(X_t, \mathcal{F}_t) : t \geq 0\}$ be an integrable adapted process in \mathbb{R} and $X_0 = \beta_0$. For $\beta < \beta_0$, let $T_\beta^X = \inf\{t : X_t \leq \beta\}$ be the first hitting time of the set $(-\infty, \beta]$. If there exist $A \geq B > 0$ such that

$$\mathbb{E} \left[\max \{X_{t+1} - X_t, -A\} \mathbb{I}\{T_\beta^X > t\} \mid \mathcal{F}_t \right] \leq -B \mathbb{I}\{T_\beta^X > t\}, \quad (1.1)$$

then the expectation of T_β^X satisfies

$$\mathbb{E} \left[T_\beta^X \right] \leq \frac{A + \beta_0 - \beta}{B}. \quad (1.2)$$

(1) 以下のように確率過程 $\{Y_t : t \geq 0\}$ を定義する： $Y_0 = X_0$ および

$$Y_{t+1} = Y_t + \max \{X_{t+1} - X_t, -A\} \mathbb{I}\{T_\beta^X > t\} - B \mathbb{I}\{T_\beta^X \leq t\}. \quad (1.3)$$

このとき、任意の $t \geq 0$ について $\mathbb{E}[|Y_t|] < \infty$ となることを、 $\mathbb{E}[|X_t|] < \infty$ と数学的帰納法により示せ。

(2) $T_\beta^Y = \inf\{t : Y_t \leq \beta\}$ は $T_\beta^X \leq T_\beta^Y$ を満たすことを示せ。

(3) $\{Y_t\}$ についてのストッププロセスを $\tilde{Y}_t = Y_{\min\{t, T_\beta^Y\}}$ と定義する。このとき、

$$\mathbb{E}[\tilde{Y}_{t+1} \mid \mathcal{F}_t] \leq \tilde{Y}_t - B \mathbb{I}\{T_\beta^Y > t\} \quad (1.4)$$

が任意の t について成立することを示せ。

(4) 下に有界な場合の加法的ドリフト解析の証明を参考に、以下を証明せよ：

$$\mathbb{E} \left[T_\beta^X \right] \leq \frac{A + \beta_0 - \beta}{B}. \quad (1.5)$$

(1) の解説 $t = 0$ のとき、 $\mathbb{E}[|Y_0|] = \mathbb{E}[|X_0|] < \infty$ より成立。 $t \geq 0$ について $\mathbb{E}[|Y_t|] < \infty$ が成立するならば、

$$|Y_{t+1}| = |Y_t + \max \{X_{t+1} - X_t, -A\} \mathbb{I}\{T_\beta^X > t\} - B \mathbb{I}\{T_\beta^X \leq t\}| \quad (1.6)$$

$$\leq |Y_t| + |X_{t+1}| + |X_t| + A + B \quad (1.7)$$

より、期待値をとれば

$$\mathbb{E}[|Y_{t+1}|] \leq \mathbb{E}[|Y_t|] + \mathbb{E}[|X_{t+1}|] + \mathbb{E}[|X_t|] + A + B \quad (1.8)$$

$$< \infty \quad (1.9)$$

が得られ、 $\mathbb{E}[|Y_{t+1}|] < \infty$ についても命題成立。数学的帰納法により題意成立。

(2) の解説 Y_t の定義から、 $t < T_\beta^X$ について、 $X_t \leq Y_t$ が得られる。すなわち、 $t < T_\beta^X \implies \beta < X_t \leq Y_t \implies t < T_\beta^Y$ 。したがって、 $T_\beta^X \leq T_\beta^Y$ 。

(3) の解説 $\mathbb{I}\{T_\beta^Y \leq t\} + \mathbb{I}\{T_\beta^Y > t\} = 1$ であることから,

$$\mathbb{E}[\tilde{Y}_{t+1} | \mathcal{F}_t] = \mathbb{E}[\tilde{Y}_{t+1} \mathbb{I}\{T_\beta^Y \leq t\} | \mathcal{F}_t] + \mathbb{E}[\tilde{Y}_{t+1} \mathbb{I}\{T_\beta^Y > t\} | \mathcal{F}_t] \quad (1.10)$$

が得られる. ここで, \tilde{Y} はストッププロセスであることから,

$$\mathbb{E}[\tilde{Y}_{t+1} \mathbb{I}\{T_\beta^Y \leq t\} | \mathcal{F}_t] = \mathbb{E}[\tilde{Y}_t \mathbb{I}\{T_\beta^Y \leq t\} | \mathcal{F}_t] = \tilde{Y}_t \mathbb{I}\{T_\beta^Y \leq t\} \quad (1.11)$$

が得られる. また, (1.1)と(1.3)より,

$$\mathbb{E}[\tilde{Y}_{t+1} \mathbb{I}\{T_\beta^Y > t\} | \mathcal{F}_t] \quad (1.12)$$

$$= \mathbb{E}[Y_{t+1} \mathbb{I}\{T_\beta^Y > t\} | \mathcal{F}_t] \quad (1.13)$$

$$= \mathbb{E}[Y_t \mathbb{I}\{T_\beta^Y > t\} + \max\{X_{t+1} - X_t, -A\} \mathbb{I}\{T_\beta^X > t\} \mathbb{I}\{T_\beta^Y > t\} - B \mathbb{I}\{T_\beta^X \leq t\} \mathbb{I}\{T_\beta^Y > t\} | \mathcal{F}_t] \quad (1.14)$$

$$= Y_t \mathbb{I}\{T_\beta^Y > t\} + \mathbb{E}[\max\{X_{t+1} - X_t, -A\} \mathbb{I}\{T_\beta^X > t\} | \mathcal{F}_t] \mathbb{I}\{T_\beta^Y > t\} - B \mathbb{I}\{T_\beta^X \leq t\} \mathbb{I}\{T_\beta^Y > t\} \quad (1.15)$$

$$\leq (Y_t - B \mathbb{I}\{T_\beta^X > t\} - B \mathbb{I}\{T_\beta^X \leq t\}) \mathbb{I}\{T_\beta^Y > t\} \quad (1.16)$$

$$= (Y_t - B) \mathbb{I}\{T_\beta^Y > t\} \quad (1.17)$$

$$= (\tilde{Y}_t - B) \mathbb{I}\{T_\beta^Y > t\} . \quad (1.18)$$

以上より,

$$\mathbb{E}[\tilde{Y}_{t+1} | \mathcal{F}_t] \leq \tilde{Y}_t \mathbb{I}\{T_\beta^Y \leq t\} + (\tilde{Y}_t - B) \mathbb{I}\{T_\beta^Y > t\} \quad (1.19)$$

$$= \tilde{Y}_t - B \mathbb{I}\{T_\beta^Y > t\} . \quad (1.20)$$

(4) の解説 (1.4)の両辺について期待値をとれば, $\mathbb{E}[\tilde{Y}_{t+1}] \leq \mathbb{E}[\tilde{Y}_t] - B \Pr[T_\beta^Y > t]$ が得られる. T_β^Y は非負の整数に値をとる確率変数であるため, $\mathbb{E}[T_\beta^Y] = \sum_{t=0}^{+\infty} \Pr[T_\beta^Y > t]$ と表すことができる. このとき,

$$B \mathbb{E}[T_\beta^Y] \stackrel{\text{Fubini}}{\leq} \sum_{t=0}^{\tilde{t}} B \Pr[T_\beta^Y > t] \leq \sum_{t=0}^{\tilde{t}} (\mathbb{E}[\tilde{Y}_t] - \mathbb{E}[\tilde{Y}_{t+1}]) = \mathbb{E}[\tilde{Y}_0] - \mathbb{E}[\tilde{Y}_{\tilde{t}}] \quad (1.21)$$

が得られる. ここで, $Y_{t+1} \geq Y_t - A$ であることから, $Y_{T_\beta^Y} \geq \beta - A$ である. $\tilde{Y}_{\tilde{t}} \geq Y_{T_\beta^Y}$ であることから, $\mathbb{E}[\tilde{Y}_{\tilde{t}}] \geq \beta - A$ が得られる. したがって, $\mathbb{E}[\tilde{Y}_0] = \beta_0$ より,

$$\mathbb{E}[T_\beta^Y] \leq (A/B) + B^{-1}(\beta_0 - \beta) . \quad (1.22)$$

$\mathbb{E}[T_\beta^X] \leq \mathbb{E}[T_\beta^Y]$ であることから, 題意成立.

問 2 Hit-and-Run アルゴリズムのドリフト下限の導出

講義資料では Spherical 関数において, Hit-and-Run アルゴリズムが (1+1)-ES のドリフトの下界を与えることを示した. ここでは, 任意の関数において, Hit-and-Run アルゴリズムがドリフトの下界 (その結果 EFHT の下界) を与えることを確認する.

(1) 確率過程 $X_t = \log\|m_t - x^*\|$ に対して, 確率過程 Y_t を以下のように定義する: $Y_0 = X_0$ かつ

$$Y_{t+1} = Y_t + \min\{X_{t+1} - X_t, 0\} . \quad (2.1)$$

このとき, $\{Y_t\}$ は単調非増加系列であり, $T_\beta^X \geq T_\beta^Y$ となることを示せ.

(2) 確率過程 Y_t のドリフトについて

$$\mathbb{E}[Y_{t+1} - Y_t | \mathcal{F}_t] \geq \mathbb{E} \left[\log \frac{\|x_t - x^*\|}{\|m_t - x^*\|} \mathbb{I}\{\|x_t - x^*\| \leq \|m_t - x^*\|\} | \mathcal{F}_t \right] \quad (2.2)$$

が成立することを示せ.

(3) Hit-and-Run アルゴリズム (各ステップにおいて $z_t \sim \mathcal{N}(0, I)$ をサンプルし, $\sigma_t^* = \operatorname{argmin}_{\sigma \geq 0} \|m_t + \sigma z_t - x^*\|$ を後付けで計算し, $x_t^* = m_t + \sigma_t^* z_t$ とするアルゴリズム) を考えることで,

$$\log \frac{\|x_t - x^*\|}{\|m_t - x^*\|} \mathbb{I}\{\|x_t - x^*\| \leq \|m_t - x^*\|\} \geq \log \frac{\|x_t^* - x^*\|}{\|m_t - x^*\|} = \log(\sin(\theta_t)) \mathbb{I}\{\theta_t \leq \pi/2\} \quad (2.3)$$

となることを示せ. ここで, $\theta_t \in [0, \pi)$ は z_t と $x^* - m_t$ の間の角度を表すものとする.

(4) $d \geq 2$ のとき $\mathbb{E}[\log(\sin(\theta_t)) \mathbb{I}\{\theta_t \leq \pi/2\} \mid \mathcal{F}_t] \geq -1/d$ となる事実を用いて, $d \geq 2$ の場合の $\mathbb{E}[T_\beta^X]$ の下界を求めよ.

(1) **の解説** (単調非増加) 定義より, $Y_{t+1} \leq Y_t$.
 $(T_\beta^X \geq T_\beta^Y)$ $t = 0$ のとき, $Y_0 \leq X_0$ であり, $Y_t \leq X_t$ が成立するならば,

$$Y_{t+1} = Y_t + \min\{X_{t+1} - X_t, 0\} \quad (2.4)$$

$$\leq Y_t + X_{t+1} - X_t \quad (2.5)$$

$$\leq X_t + X_{t+1} - X_t \quad (2.6)$$

$$= X_{t+1} . \quad (2.7)$$

数学的帰納法により, $Y_t \leq X_t$ が任意の t で成立. したがって, $Y_t > \beta \implies X_t > \beta$ なので, $T_\beta^X \geq T_\beta^Y$ が成立.

(2) **の解説** 定義より,

$$\mathbb{E}[Y_{t+1} - Y_t \mid \mathcal{F}_t] = \mathbb{E}[X_{t+1} - X_t, 0 \mid \mathcal{F}_t] \quad (2.8)$$

$$= \mathbb{E} \left[\min \left\{ \log \frac{\|m_{t+1} - x^*\|}{\|m_t - x^*\|}, 0 \right\} \mid \mathcal{F}_t \right] . \quad (2.9)$$

ここで, (1+1)-ES のアルゴリズムより,

$$\log \frac{\|m_{t+1} - x^*\|}{\|m_t - x^*\|} = \log \frac{\|x_t - x^*\|}{\|m_t - x^*\|} \mathbb{I}\{f(x_t) \leq f(m_t)\} \quad (2.10)$$

が成立する. 一般の関数 f のにおいて, $f(x_t) \leq f(m_t)$ は必ずしも $\|x_t - x^*\| \leq \|m_t - x^*\|$ を意味しないため, この値は正になり得る. 正になる値をクリップすることによって下限が得られるが, これは上式の両辺に $\mathbb{I}\{\|x_t - x^*\| \leq \|m_t - x^*\|\}$ を乗することに他ならない. すなわち,

$$\min \left\{ \log \frac{\|m_{t+1} - x^*\|}{\|m_t - x^*\|}, 0 \right\} \quad (2.11)$$

$$= \min \left\{ \log \frac{\|x_t - x^*\|}{\|m_t - x^*\|} \mathbb{I}\{f(x_t) \leq f(m_t)\}, 0 \right\} \quad (2.12)$$

$$= \log \frac{\|x_t - x^*\|}{\|m_t - x^*\|} \mathbb{I}\{f(x_t) \leq f(m_t)\} \mathbb{I}\{\|x_t - x^*\| \leq \|m_t - x^*\|\} \quad (2.13)$$

このとき, 値は非負になるため, 指示関数 $\mathbb{I}\{f(x_t) \leq f(m_t)\}$ を取り除いたとしても, 値は増加しない. すなわち,

$$\geq \log \frac{\|x_t - x^*\|}{\|m_t - x^*\|} \mathbb{I}\{\|x_t - x^*\| \leq \|m_t - x^*\|\} . \quad (2.14)$$

期待値をとれば(2.2)を得る.

(3) **の解説** Hit-and-Run アルゴリズムを考えると,

$$\|x_t - x^*\| = \|m_t - x^* + \sigma_t z_t\| \quad (2.15)$$

$$\geq \min_{\sigma \geq 0} \|m_t - x^* + \sigma z_t\| \quad (2.16)$$

$$= \|m_t - x^* + \sigma_t^* z_t\| \quad (2.17)$$

$$= \|x_t^* - x^*\| \quad (2.18)$$

が得られる. このとき, $\|x_t^* - x^*\| \leq \|m_t - x^*\|$ が常に成立する. したがって,

$$\log \frac{\|x_t - x^*\|}{\|m_t - x^*\|} \mathbb{I}\{\|x_t - x^*\| \leq \|m_t - x^*\|\} \geq \log \frac{\|x_t^* - x^*\|}{\|m_t - x^*\|} . \quad (2.19)$$

続いて, 等式を示す. Hit-and-Run アルゴリズムにおける m_t, x_t^*, x^* の位置関係を幾何学的に考えると, z_t と $x^* - m_t$ のなす角 θ_t が $\theta_t > \pi/2$ となるとき $x_t^* = m_t$ ($\sigma_t^* = 0$) となり, $\theta_t \leq \pi/2$ のとき $x_t^* - m_t = \sigma_t^* z_t$ と $x_t^* - x^*$ は直交することがわかる. すなわち,

$$\|x_t^* - x^*\| = \begin{cases} \|m_t - x^*\| \sin(\theta_t) & \theta_t \leq \pi/2 \\ \|m_t - x^*\| & \theta_t > \pi/2 \end{cases} \quad (2.20)$$

が得られる. $\theta_t > \pi/2$ の場合, $\log \frac{\|x_t^* - x^*\|}{\|m_t - x^*\|} = 0$ となることに注意すれば, (2.3)を得る.

(4) **の解説** 小問 (1) で示したとおり, $T_\beta^Y \leq T_\beta^X$ であることから, $\mathbb{E}[T_\beta^Y]$ の下限を得ることにより, $\mathbb{E}[T_\beta^X]$ を下からバウンドできる. 小問 (2) および (3) と $d \geq 2$ のとき $\mathbb{E}[\log(\sin(\theta_t))\mathbb{I}\{\theta_t \leq \pi/2\} | \mathcal{F}_t] \geq -1/d$ が成立することから Y_t のドリフトの下界として $-1/d$ が得られ, Y_t が単調非増加系列であることから, 講義資料の Negative Drift Analysis を用いることが可能である. これにより,

$$\mathbb{E}[T_\beta^X] \geq \mathbb{E}[T_\beta^Y] \geq -\frac{1}{2} + \frac{d}{4} \log \frac{\|m_0 - x^*\|}{\epsilon} \quad (2.21)$$

を得る.

問 3 強凸かつリプシッツ平滑な関数が Assumption 1 を満たすことの確認

目的関数 $f(x) = g(h(x))$ が以下の性質を満たすとする: $g: \mathbb{R} \rightarrow \mathbb{R}$ は狭義単調増加関数, $h: \mathbb{R}^d \rightarrow \mathbb{R}$ は連続的一階微分可能であり, 任意の $z, \Delta \in \mathbb{R}^d$ について

$$\frac{L_\ell}{2} \|\Delta\|^2 \leq h(z + \Delta) - h(z) - \Delta^\top \nabla h(z) \leq \frac{L_u}{2} \|\Delta\|^2. \quad (3.1)$$

このとき, Assumption 1 を $C_\ell = \frac{1}{V_d} \sqrt{\frac{L_\ell}{L_u}}$, $C_u = \frac{1}{V_d} \sqrt{\frac{L_u}{L_\ell}}$ について満たすことを示せ. ここで, $V_d = \frac{\pi^{1/2}}{\Gamma(1/d)(d/2+1)}$ は d 次元単位超球の体積の d 乗根を表す.

解説 f_μ は g に対して不変であるため, 一般性を失うことなく $f(x) = h(x) - h(x^*)$ と仮定する. ここで, x^* は f のユニークな最適解である. (3.1)を $z = x^*$ について考えると, $f(y) \leq f(x)$ のとき,

$$\frac{L_\ell}{2} \|y - x^*\|^2 \leq f(y) \leq f(x) \quad (3.2)$$

が得られる. すなわち,

$$\{y: f(y) \leq f(x)\} \subseteq \mathcal{B}\left(x^*, \sqrt{\frac{f(x)}{L_\ell/2}}\right) \quad (3.3)$$

が成立する. $f_\mu(x)$ は上式左辺の volume の d 乗根であるから,

$$f_\mu(x) \leq \mu^{1/d} \left(\mathcal{B}\left(x^*, \sqrt{\frac{f(x)}{L_\ell/2}}\right) \right) = V_d \sqrt{\frac{f(x)}{L_\ell/2}} \quad (3.4)$$

が得られる. ここで, μ は Lebesgue 測度である. 同様にして,

$$\mathcal{B}\left(x^*, \sqrt{\frac{f(x)}{L_u/2}}\right) \subseteq \{y: f(y) < f(x)\} \quad (3.5)$$

および

$$f_\mu(x) \geq V_d \sqrt{\frac{f(x)}{L_u/2}} \quad (3.6)$$

が得られる. 以上より,

$$\{y: f(y) \leq f(x)\} \subseteq \mathcal{B}\left(x^*, \sqrt{\frac{L_u}{L_\ell} \frac{f_\mu(x)}{V_d}}\right) \quad \mathcal{B}\left(x^*, \sqrt{\frac{L_\ell}{L_u} \frac{f_\mu(x)}{V_d}}\right) \subseteq \{y: f(y) < f(x)\} \quad (3.7)$$

が得られる.

問 4 Assumption 1 のもとで成功確率がバウンドされることの証明

Assumption 1 を仮定すると成功確率のバウンドが得られ、これが (1+1)-ES の一次収束の証明上重要な役割を果たす。ここでは、Assumption 1 のもとで成功確率のバウンドを導出する。

(1) 成功確率が以下を満たすことを示せ：

$$p_0^{\text{succ}}(\bar{\sigma}; m) \leq \Phi \left(\mathcal{B} \left(0, \frac{C_u}{\bar{\sigma}} \right); 0, \mathbf{I} \right) . \quad (4.1)$$

ここで、 $\Phi(\cdot; 0, \mathbf{I})$ は多変量標準正規分布のもとでの確率測度を表す。

(2) 成功確率が以下を満たすことを示せ：

$$p_0^{\text{succ}}(\bar{\sigma}; m) \geq \Phi \left(\mathcal{B} \left(\left(\frac{(2C_u - C_\ell)}{\bar{\sigma}} \right) e_1, \frac{C_\ell}{\bar{\sigma}} \right); 0, \mathbf{I} \right) . \quad (4.2)$$

(1) の解説 以下、 $\phi(x; m, \sigma^2 \mathbf{I})$ を平均ベクトル $m \in \mathbb{R}^d$ 、共分散行列が $\sigma^2 \mathbf{I}$ の多変量正規分布の確率密度関数を表すものとする。

任意の $m \in \mathbb{R}^d$ について、Assumption 1 のもとでは $S_0(m) = \{x : f(x) \leq f(m)\} \subseteq \bar{B}_u$ となる閉球 \bar{B}_u が存在する。このとき、

$$p_0^{\text{succ}}(\bar{\sigma}; m) = \int_{S_0(m)} \phi(x; m, (f_\mu(m)\bar{\sigma})^2 \mathbf{I}) dx \quad (4.3)$$

$$\leq \int_{\bar{B}_u} \phi(x; m, (f_\mu(m)\bar{\sigma})^2 \mathbf{I}) dx \quad (4.4)$$

この積分は \bar{B}_u の中心が m である場合に最大化されるため、

$$\leq \int_{\|x-m\| \leq C_u f_\mu(m)} \phi(x; m, (f_\mu(m)\bar{\sigma})^2 \mathbf{I}) dx \quad (4.5)$$

$$= \int_{\|x\| \leq C_u f_\mu(m)} \phi(x; 0, (f_\mu(m)\bar{\sigma})^2 \mathbf{I}) dx \quad (4.6)$$

$$= \int_{\|x\| \leq C_u / \bar{\sigma}} \phi(x; 0, \mathbf{I}) dx \quad (4.7)$$

$$= \Phi \left(\mathcal{B} \left(0, \frac{C_u}{\bar{\sigma}} \right); 0, \mathbf{I} \right) . \quad (4.8)$$

(2) の解説 前問と同様、 $B_\ell \subseteq S_0(m) \subseteq \bar{B}_u$ を満たす開球 B_ℓ と閉球 \bar{B}_u が存在する。このとき、

$$p_0^{\text{success}}(\bar{\sigma}; m) = \int_{S_0(m)} \phi(x; m, (f_\mu(m)\bar{\sigma})^2 \mathbf{I}) dx \quad (4.9)$$

$$\geq \int_{B_\ell} \phi(x; m, (f_\mu(m)\bar{\sigma})^2 \mathbf{I}) dx \quad (4.10)$$

この積分は B_ℓ が \bar{B}_u 上において m の反対側に存在する場合（すなわち、 \bar{B}_u が中心 $\left(1 - \frac{C_u f_\mu(m)}{\|m\|}\right) m$ 、 B_ℓ の中心が $\left(1 - \frac{(2C_u - C_\ell) f_\mu(m)}{\|m\|}\right) m$ の状況）に最小となるため、

$$\geq \int_{\|x - \left(1 - \frac{(2C_u - C_\ell) f_\mu(m)}{\|m\|}\right) m\| \leq C_\ell f_\mu(m)} \phi(x; m, (f_\mu(m)\bar{\sigma})^2 \mathbf{I}) dx \quad (4.11)$$

$$= \int_{\|x - (2C_u - C_\ell) f_\mu(m) \frac{m}{\|m\|}\| \leq C_\ell f_\mu(m)} \phi(x; 0, (f_\mu(m)\bar{\sigma})^2 \mathbf{I}) dx \quad (4.12)$$

$$= \int_{\|x - ((2C_u - C_\ell) f_\mu(m)) e_m\| \leq C_\ell f_\mu(m)} \phi(x; 0, (f_\mu(m)\bar{\sigma})^2 \mathbf{I}) dx \quad (4.13)$$

$$= \int_{\|x - ((2C_u - C_\ell) / \bar{\sigma}) e_m\| \leq C_\ell / \bar{\sigma}} \phi(x; 0, \mathbf{I}) dx \quad (4.14)$$

$$= \Phi \left(\mathcal{B} \left(\left(\frac{(2C_u - C_\ell)}{\bar{\sigma}} \right) e_m, \frac{C_\ell}{\bar{\sigma}} \right); 0, \mathbf{I} \right) . \quad (4.15)$$

ここで、 $e_m = \frac{m}{\|m\|}$ とおいた。最右辺の値は e_m が単位ベクトルである限り変化しないので、これを e_1 に置き換えれば題意成立。