

ガウス・ニュートン法とレーベンバーグ・マーカート法

ほげ

2021年2月7日

1 ニュートン法

ニュートン法は、2階微分可能な関数 $f(\mathbf{x})$ を、 \mathbf{x} に関して最小化するための逐次的な手法である [6]。その派生であるガウス・ニュートン法や、レーベンバーグ・マーカート法は、グラフベース SLAM の基礎となるポーズ調整 [2][4][5] や、スキャンマッチング [1][3] などで用いられている。

関数 $f(\mathbf{x}) : \mathbb{R}^N \rightarrow \mathbb{R}$ の最適化を、初期値 $\check{\mathbf{x}} \in \mathbb{R}^N$ から始めるとする。初期値 $\check{\mathbf{x}}$ からの変位を $\Delta\mathbf{x}$ として、元の関数 $f(\mathbf{x})$ を変位に対する関数 $f(\check{\mathbf{x}} + \Delta\mathbf{x})$ として書き直し、 $\Delta\mathbf{x}$ に関して最小化する。そのような $\Delta\mathbf{x}$ が求まつたら、現在の値を $\check{\mathbf{x}}$ から $\check{\mathbf{x}} + \Delta\mathbf{x}$ に更新する。これがニュートン法の大まかな流れとなる。

変位に対する関数 $f(\check{\mathbf{x}} + \Delta\mathbf{x})$ を、2次の項まで泰勒展開すると

$$f(\check{\mathbf{x}} + \Delta\mathbf{x}) \simeq f(\check{\mathbf{x}}) + \mathbf{g}^\top \Delta\mathbf{x} + \frac{1}{2} \Delta\mathbf{x}^\top \mathbf{H} \Delta\mathbf{x} \quad (1)$$

(1) 式において、 $\mathbf{g} = \nabla f(\check{\mathbf{x}}) \in \mathbb{R}^N$ と $\mathbf{H} = \nabla^2 f(\check{\mathbf{x}}) \in \mathbb{R}^{N \times N}$ は、それぞれ $f(\mathbf{x})$ の勾配およびヘッセ行列であり、次のように書ける。

$$\nabla f(\mathbf{x}) = \frac{\partial}{\partial \mathbf{x}} f(\mathbf{x}) = \left[\frac{\partial}{\partial x_1} f(\mathbf{x}), \dots, \frac{\partial}{\partial x_N} f(\mathbf{x}) \right]^\top \in \mathbb{R}^N \quad (2)$$

$$\nabla^2 f(\mathbf{x}) = \begin{bmatrix} \frac{\partial^2}{\partial x_1^2} f(\mathbf{x}) & \frac{\partial^2}{\partial x_1 \partial x_2} f(\mathbf{x}) & \cdots & \frac{\partial^2}{\partial x_1 \partial x_N} f(\mathbf{x}) \\ \frac{\partial^2}{\partial x_2 \partial x_1} f(\mathbf{x}) & \frac{\partial^2}{\partial x_2^2} f(\mathbf{x}) & \cdots & \frac{\partial^2}{\partial x_2 \partial x_N} f(\mathbf{x}) \\ \vdots & \vdots & \ddots & \vdots \\ \frac{\partial^2}{\partial x_N \partial x_1} f(\mathbf{x}) & \frac{\partial^2}{\partial x_N \partial x_2} f(\mathbf{x}) & \cdots & \frac{\partial^2}{\partial x_N^2} f(\mathbf{x}) \end{bmatrix} \in \mathbb{R}^{N \times N} \quad (3)$$

(1) 式を $\Delta\mathbf{x}$ に関して最小化するために、 $f(\check{\mathbf{x}} + \Delta\mathbf{x})$ を $\Delta\mathbf{x}$ で偏微分すると

$$\frac{\partial}{\partial \Delta\mathbf{x}} f(\check{\mathbf{x}} + \Delta\mathbf{x}) = \frac{\partial}{\partial \Delta\mathbf{x}} \left(f(\check{\mathbf{x}}) + \mathbf{g}^\top \Delta\mathbf{x} + \frac{1}{2} \Delta\mathbf{x}^\top \mathbf{H} \Delta\mathbf{x} \right) = \mathbf{g} + \mathbf{H} \Delta\mathbf{x} \quad (4)$$

ここでベクトルの微分に関する次の関係式を用いた。

$$\frac{\partial}{\partial \mathbf{x}} \mathbf{a}^\top \mathbf{x} = \mathbf{a} \quad (5)$$

$$\frac{\partial}{\partial \mathbf{x}} \mathbf{x}^\top \mathbf{A} \mathbf{x} = (\mathbf{A} + \mathbf{A}^\top) \mathbf{x} \quad (6)$$

$f(\mathbf{x})$ は 2 階微分可能であるので, ヘッセ行列 $\mathbf{H} = \nabla^2 f(\mathbf{x})$ を構成する各要素は, 微分の順序を入れ替えられる. 従って $\partial^2/\partial x_i \partial x_j f(\mathbf{x}) = \partial^2/\partial x_j \partial x_i f(\mathbf{x})$ であるから, ヘッセ行列 \mathbf{H} の (i, j) 要素と (j, i) 要素は等しく, 対称行列になる. (6) 式の結果は, 行列 \mathbf{A} が対称であれば $2\mathbf{A}\mathbf{x}$ とできる ($\mathbf{A} = \mathbf{A}^\top$). (4) 式を 0 とおいて $\Delta\mathbf{x}$ について解けば, (1) 式を最小化する $\Delta\mathbf{x}^*$ は次のようにになる.

$$\Delta\mathbf{x}^* = -\mathbf{H}^{-1}\mathbf{g} \quad (7)$$

以上より, ニュートン法のアルゴリズムは次のようにまとめられる.

アルゴリズム 1 ニュートン法

Input: 初期値 $\check{\mathbf{x}} \in \mathbb{R}^N$, 収束判定に用いる閾値 $\varepsilon \ll 1$

- 1: $\mathbf{x}_1 \leftarrow \check{\mathbf{x}}$ として初期化する
 - 2: **for** $i = 1, 2, \dots$ **do**
 - 3: $\mathbf{x} = \mathbf{x}_i$ における $f(\mathbf{x})$ の勾配 $\mathbf{g} = \nabla f(\mathbf{x}_i)$ とヘッセ行列 $\mathbf{H} = \nabla^2 f(\mathbf{x}_i)$ を求める
 - 4: \mathbf{x}_i に対する変位を $\Delta\mathbf{x}^* \leftarrow -\mathbf{H}^{-1}\mathbf{g}$ として求める
 - 5: $\mathbf{x}_{i+1} \leftarrow \mathbf{x}_i + \Delta\mathbf{x}^*$ として解を更新する
 - 6: $|f(\mathbf{x}_i) - f(\mathbf{x}_{i+1})| < \varepsilon$ であれば終了する
-

2 ガウス・ニュートン法

ガウス・ニュートン (Gauss-Newton) 法は, 関数 $f(\mathbf{x})$ が次のように, M 個の関数 $e_1(\mathbf{x}), \dots, e_M(\mathbf{x})$ の二乗和で表される場合に利用できる.

$$f(\mathbf{x}) = \frac{1}{2} \sum_{i=1}^M e_i(\mathbf{x})^2 \quad (8)$$

例えば, M 個の入力と教師データの組 $\{(\mathbf{a}_1, b_1), \dots, (\mathbf{a}_M, b_M)\}$ があるとして, これらのデータに当てはまるように, モデル $b = \phi(\mathbf{a}; \mathbf{x})$ のパラメータ $\mathbf{x} \in \mathbb{R}^N$ を決めたいとする. このとき (8) 式の $e_i(\mathbf{x})$ を, i 番目の入力データ \mathbf{a}_i に対するモデルの予測値 $\phi(\mathbf{a}_i; \mathbf{x})$ と, 期待される出力値 b_i との残差 $e_i(\mathbf{x}) = b_i - \phi(\mathbf{a}_i; \mathbf{x})$ とする. (8) 式の $f(\mathbf{x})$ は残差の二乗和となるが, これをパラメータ \mathbf{x} に関して最小化すれば, データに最もよく適合するパラメータ \mathbf{x} が得られる. グラフベース SLAM のポーズ調整であれば, $e_i(\mathbf{x})$ は i 番目のポーズグラフのエッジについての残差となる.

先程のニュートン法と同様に, 関数 $f(\mathbf{x})$ を, 初期値 $\check{\mathbf{x}}$ からの変位 $\Delta\mathbf{x}$ についての関数 $f(\check{\mathbf{x}} + \Delta\mathbf{x})$ に置き換えて考える. $f(\check{\mathbf{x}} + \Delta\mathbf{x})$ を最小化するような $\Delta\mathbf{x}$ は, (7) 式のように, $f(\mathbf{x})$ のヘッセ行列の逆行列 \mathbf{H}^{-1} と, 勾配 \mathbf{g} との積で表現される. 残差 $e_i(\mathbf{x})$ の勾配 $\nabla e_i(\mathbf{x}) \in \mathbb{R}^N$ とヘッセ行列 $\nabla^2 e_i(\mathbf{x}) \in \mathbb{R}^{N \times N}$ は, j 番目の要素 $(\nabla e_i(\mathbf{x}))_j$ と, (j, k) 番目の要素 $(\nabla^2 e_i(\mathbf{x}))_{jk}$ がそれぞれ

$$(\nabla e_i(\mathbf{x}))_j = \frac{\partial}{\partial x_j} e_i(\mathbf{x}), \quad (\nabla^2 e_i(\mathbf{x}))_{jk} = \frac{\partial^2}{\partial x_j \partial x_k} e_i(\mathbf{x}) \quad (9)$$

で与えられるので, $f(\mathbf{x})$ の勾配 \mathbf{g} の第 k 要素 g_k と, ヘッセ行列 \mathbf{H} の (j, k) 要素 H_{jk} は

$$g_k = \frac{\partial}{\partial x_k} f(\mathbf{x}) = \sum_{i=1}^M e_i(\mathbf{x}) \frac{\partial}{\partial x_k} e_i(\mathbf{x}) = \sum_{i=1}^M e_i(\mathbf{x}) (\nabla e_i(\mathbf{x}))_k \quad (10)$$

$$\begin{aligned}
H_{jk} &= \frac{\partial^2}{\partial x_j \partial x_k} f(\mathbf{x}) = \frac{\partial}{\partial x_j} \left(\sum_{i=1}^M e_i(\mathbf{x}) \frac{\partial}{\partial x_k} e_i(\mathbf{x}) \right) \\
&= \sum_{i=1}^M \left(\frac{\partial}{\partial x_j} e_i(\mathbf{x}) \frac{\partial}{\partial x_k} e_i(\mathbf{x}) + e_i(\mathbf{x}) \frac{\partial^2}{\partial x_j \partial x_k} e_i(\mathbf{x}) \right) \\
&= \sum_{i=1}^M \frac{\partial}{\partial x_j} e_i(\mathbf{x}) \frac{\partial}{\partial x_k} e_i(\mathbf{x}) + \sum_{i=1}^M e_i(\mathbf{x}) \frac{\partial^2}{\partial x_j \partial x_k} e_i(\mathbf{x}) \\
&= \sum_{i=1}^M (\nabla e_i(\mathbf{x}))_j (\nabla e_i(\mathbf{x}))_k + \sum_{i=1}^M e_i(\mathbf{x}) (\nabla^2 e_i(\mathbf{x}))_{jk}
\end{aligned} \tag{11}$$

これより $f(\check{\mathbf{x}} + \Delta\mathbf{x})$ の勾配 $\mathbf{g} = \nabla f(\check{\mathbf{x}})$ とヘッセ行列 $\mathbf{H} = \nabla^2 f(\check{\mathbf{x}})$ は

$$\mathbf{g} = [g_1, \dots, g_N]^\top = \sum_{i=1}^M e_i(\mathbf{x}) \nabla e_i(\check{\mathbf{x}}) \tag{12}$$

$$\mathbf{H} = [H_{jk}] = \sum_{i=1}^M \nabla e_i(\check{\mathbf{x}}) \nabla e_i(\check{\mathbf{x}})^\top + \sum_{i=1}^M e_i(\check{\mathbf{x}}) \nabla^2 e_i(\check{\mathbf{x}}) \tag{13}$$

のように書ける。ニュートン法では、最適な $\Delta\mathbf{x}$ を $-\mathbf{H}^{-1}\mathbf{g}$ として求める。

ヘッセ行列 \mathbf{H} を得るには、 $e_i(\mathbf{x})$ に関する $N \times N$ ヘッセ行列 $\nabla^2 e_i(\mathbf{x})$ を M 個、即ち $M \cdot N(N+1)/2$ 種類の 2 階微分を計算する必要がある。 N や M が大きければ、ヘッセ行列を求めるのは困難である。そこで、(13) 式の $\nabla^2 e_i(\mathbf{x})$ を省略する。このとき \mathbf{H} は、 $e_i(\mathbf{x})$ に関する勾配 $\nabla e_i(\mathbf{x})$ のみから計算でき、ヘッセ行列 $\nabla^2 e_i(\mathbf{x})$ は不要になる。新たな $\tilde{\mathbf{H}}$ は

$$\tilde{\mathbf{H}} = \sum_{i=1}^M \nabla e_i(\check{\mathbf{x}}) \nabla e_i(\check{\mathbf{x}})^\top \tag{14}$$

であるから、最適な $\Delta\mathbf{x}$ は

$$\Delta\mathbf{x} = - \left(\sum_{i=1}^M \nabla e_i(\check{\mathbf{x}}) \nabla e_i(\check{\mathbf{x}})^\top \right)^{-1} \sum_{i=1}^M e_i(\mathbf{x}) \nabla e_i(\check{\mathbf{x}}) \tag{15}$$

となる。 $N \times M$ 行列 $\mathbf{J}(\check{\mathbf{x}})$ を

$$\mathbf{J}(\check{\mathbf{x}}) = [\nabla e_1(\check{\mathbf{x}}), \nabla e_2(\check{\mathbf{x}}), \dots, \nabla e_M(\check{\mathbf{x}})] \in \mathbb{R}^{N \times M} \tag{16}$$

とおけば $\tilde{\mathbf{H}} = \mathbf{J}(\check{\mathbf{x}})\mathbf{J}(\check{\mathbf{x}})^\top$ であるから、 $\Delta\mathbf{x}$ は

$$\Delta\mathbf{x} = - (\mathbf{J}(\check{\mathbf{x}})\mathbf{J}(\check{\mathbf{x}})^\top)^{-1} \nabla f(\check{\mathbf{x}}) \tag{17}$$

のように書ける。以上より、ガウス・ニュートン法のアルゴリズムが得られる。

アルゴリズム 2 ガウス・ニュートン法

Input: 初期値 $\check{\mathbf{x}} \in \mathbb{R}^N$, 収束判定に用いる閾値 $\varepsilon \ll 1$

- 1: $\mathbf{x}_1 \leftarrow \check{\mathbf{x}}$ として初期化する
 - 2: **for** $i = 1, 2, \dots$ **do**
 - 3: $\mathbf{x} = \mathbf{x}_i$ における勾配 \mathbf{g} とヘッセ行列 $\tilde{\mathbf{H}}$ を, (12) 式と (14) 式から求める
 - 4: \mathbf{x}_i に対する変位を $\Delta\mathbf{x}^* \leftarrow -\tilde{\mathbf{H}}^{-1}\mathbf{g}$ として求める
 - 5: $\mathbf{x}_{i+1} \leftarrow \mathbf{x}_i + \Delta\mathbf{x}^*$ として解を更新する
 - 6: $|f(\mathbf{x}_i) - f(\mathbf{x}_{i+1})| < \varepsilon$ であれば終了する
-

$f(\mathbf{x})$ を構成する各残差 $e_i(\mathbf{x}) = e_i(\check{\mathbf{x}} + \Delta\mathbf{x})$ を, 1 次の項まで泰勒一展開して近似すれば

$$e_i(\check{\mathbf{x}} + \Delta\mathbf{x}) \simeq e_i(\check{\mathbf{x}}) + \nabla e_i(\check{\mathbf{x}})^\top \Delta\mathbf{x} \quad (18)$$

となる. これを元の関数 $f(\mathbf{x}) = f(\check{\mathbf{x}} + \Delta\mathbf{x})$ に代入すれば

$$f(\check{\mathbf{x}} + \Delta\mathbf{x}) \simeq \frac{1}{2} \sum_{i=1}^M (e_i(\check{\mathbf{x}}) + \nabla e_i(\check{\mathbf{x}})^\top \Delta\mathbf{x})^2 \quad (19)$$

$$= \frac{1}{2} \sum_{i=1}^M (e_i(\check{\mathbf{x}})^2 + 2e_i(\check{\mathbf{x}})\nabla e_i(\check{\mathbf{x}})^\top \Delta\mathbf{x} + \Delta\mathbf{x}^\top \nabla e_i(\check{\mathbf{x}})\nabla e_i(\check{\mathbf{x}})^\top \Delta\mathbf{x}) \quad (20)$$

を得る. $f(\check{\mathbf{x}} + \Delta\mathbf{x})$ を $\Delta\mathbf{x}$ で偏微分すれば

$$\frac{\partial}{\partial \Delta\mathbf{x}} f(\check{\mathbf{x}} + \Delta\mathbf{x}) = \sum_{i=1}^M (e_i(\check{\mathbf{x}}) + \nabla e_i(\check{\mathbf{x}})^\top \Delta\mathbf{x}) \nabla e_i(\check{\mathbf{x}}) \quad (21)$$

$$= \sum_{i=1}^M (\nabla e_i(\check{\mathbf{x}})^\top \nabla e_i(\check{\mathbf{x}}) + \nabla e_i(\check{\mathbf{x}}) \nabla e_i(\check{\mathbf{x}})^\top \Delta\mathbf{x}) \quad (22)$$

となるから, 0 において $\Delta\mathbf{x}$ について解けば, $f(\check{\mathbf{x}} + \Delta\mathbf{x})$ を最小化する $\Delta\mathbf{x}$ として

$$\Delta\mathbf{x}^* = - \left(\sum_{i=1}^M \nabla e_i(\check{\mathbf{x}}) \nabla e_i(\check{\mathbf{x}})^\top \right)^{-1} \sum_{i=1}^M e_i(\check{\mathbf{x}}) \nabla e_i(\check{\mathbf{x}}) \quad (23)$$

が得られ, (15) 式と同一になる. 従って, ガウス・ニュートン法では, 残差 $e_i(\mathbf{x})$ を初期値 $\check{\mathbf{x}}$ の周りで線形近似することで, 目的関数 $f(\mathbf{x})$ を近似している. 一方, ニュートン法では, 目的関数 $f(\mathbf{x})$ を初期値 $\check{\mathbf{x}}$ の周りで 2 次近似している.

3 レーベンバーグ・マーカート法

ガウス・ニュートン法では, 目的関数の近似である (19) 式を, (初期値 $\check{\mathbf{x}}$ に加える) 変位 $\Delta\mathbf{x}$ に関して最小化した. (18) 式の残差を, 初期値 $\check{\mathbf{x}}$ のまわりで線形近似しているため, 初期値から離れた点では近似による誤差が大きくなる ($e_i(\mathbf{x})$ が三角関数 \sin や \cos で表現される場合などに相当する). レーベンバーグ・マーカート (Levenberg-Marquardt) 法では, ガウス・ニュートン法の目的関数 (19) 式に, 変位 $\Delta\mathbf{x}$ が大きくなり過ぎないための罰則項 ($\Delta\mathbf{x}$ の各要素の二乗和) を加えた新たな目的関数を, $\Delta\mathbf{x}$ に関して最小化する.

$$f(\check{\mathbf{x}} + \Delta\mathbf{x}) + \frac{\lambda}{2} \|\Delta\mathbf{x}\|^2 = \frac{1}{2} \sum_{i=1}^M (e_i(\check{\mathbf{x}}) + \nabla e_i(\check{\mathbf{x}})^\top \Delta\mathbf{x})^2 + \frac{\lambda}{2} \|\Delta\mathbf{x}\|^2 \quad (24)$$

(24) 式を $\Delta\mathbf{x}$ で偏微分すれば

$$\frac{\partial}{\partial \Delta\mathbf{x}} \left(f(\check{\mathbf{x}} + \Delta\mathbf{x}) + \frac{\lambda}{2} \|\Delta\mathbf{x}\|^2 \right) = \left(\sum_{i=1}^M (e_i(\check{\mathbf{x}}) \nabla e_i(\check{\mathbf{x}}) + \nabla e_i(\check{\mathbf{x}}) \nabla e_i(\check{\mathbf{x}})^\top \Delta\mathbf{x}) \right) + \lambda \Delta\mathbf{x} \quad (25)$$

となるから, 0 とおいて $\Delta\mathbf{x}$ について解けば, (24) 式を最小化する $\Delta\mathbf{x}$ として

$$\Delta\mathbf{x}^* = - \left(\sum_{i=1}^M \nabla e_i(\check{\mathbf{x}}) \nabla e_i(\check{\mathbf{x}})^\top + \lambda \mathbf{I} \right)^{-1} \sum_{i=1}^M e_i(\check{\mathbf{x}}) \nabla e_i(\check{\mathbf{x}}) \quad (26)$$

$$= - (\mathbf{J}(\check{\mathbf{x}}) \mathbf{J}(\check{\mathbf{x}})^\top + \lambda \mathbf{I})^{-1} \nabla f(\check{\mathbf{x}}) \quad (27)$$

が得られる (\mathbf{I} は単位行列). 罰則項に対応する項 $\lambda \mathbf{I}$ を, $\tilde{\mathbf{H}} = \mathbf{J}(\check{\mathbf{x}}) \mathbf{J}(\check{\mathbf{x}})^\top$ の対角要素を使って, $\lambda \operatorname{diag}(\tilde{\mathbf{H}})$ とすることもある ($\operatorname{diag}(\mathbf{A})$ は, 行列 \mathbf{A} の対角要素のみを残し, 他の要素を 0 で置き換えた対角行列).

$$\Delta\mathbf{x}^* = - \left(\mathbf{J}(\check{\mathbf{x}}) \mathbf{J}(\check{\mathbf{x}})^\top + \lambda \operatorname{diag}(\tilde{\mathbf{H}}) \right)^{-1} \nabla f(\check{\mathbf{x}}) \quad (28)$$

(15) 式に示すガウス・ニュートン法の更新量 $\Delta\mathbf{x}$ を求める際は, ヘッセ行列 $\tilde{\mathbf{H}} = \mathbf{J}(\check{\mathbf{x}}) \mathbf{J}(\check{\mathbf{x}})^\top$ の正則性 (逆行列の存在) を仮定している. 数値誤差などによって $\tilde{\mathbf{H}}$ の逆行列の計算が不安定になる場合があるが, $\lambda \mathbf{I}$ を加えることで安定化する. レーベンバーグ・マーカート法では目的関数 $f(\check{\mathbf{x}} + \Delta\mathbf{x})$ が減少するように, λ が自動的に調節される.

$$\lambda \Delta\mathbf{x}^* = - \left(\frac{1}{\lambda} \mathbf{J}(\check{\mathbf{x}}) \mathbf{J}(\check{\mathbf{x}})^\top + \mathbf{I} \right)^{-1} \nabla f(\check{\mathbf{x}}) \quad (29)$$

上式より $\lambda \rightarrow \infty$ とすれば更新量は $\Delta\mathbf{x} \rightarrow -\nabla f(\check{\mathbf{x}})$ となり, 勾配降下法に近づく. また (26) 式から, $\lambda \rightarrow 0$ とすれば $\Delta\mathbf{x}$ は (15) 式に示すガウス・ニュートン法となる. 現在の λ の下で, 解を $\check{\mathbf{x}} + \Delta\mathbf{x}^*$ により更新し, 目的関数の値 $f(\check{\mathbf{x}} + \Delta\mathbf{x}^*)$ が $f(\check{\mathbf{x}})$ よりも増加 (悪化) してしまった場合は, λ を大きくして勾配降下法に近づける (更新量を小さくする). また目的関数の値が改善 (減少) した場合は, λ を小さくしてガウス・ニュートン法に近づける (更新量を大きくする). アルゴリズムは最初, 目的関数の値が改善し続けるので更新量が大きくなり, 最適解の近くに移動するまでは粗い探索を行う. 最適解にある程度近づいたら, 更新量が小さくなり細かな探索を行うようになる (粗く探索すると, 最適解から離れて目的関数の値が悪化してしまう). 以上より, レーベンバーグ・マーカート法のアルゴリズムが得られる.

アルゴリズム 3 レーベンバーグ・マーカート法

Input: 初期値 $\check{\mathbf{x}} \in \mathbb{R}^N$, 収束判定に用いる閾値 $\varepsilon \ll 1$, λ の初期値 (0.001 など), 係数 $\rho > 1$ (2, 10 など)

- 1: $\mathbf{x}_1 \leftarrow \check{\mathbf{x}}$ として初期化する
 - 2: **for** $i = 1, 2, \dots$ **do**
 - 3: $\mathbf{x} = \mathbf{x}_i$ における勾配 \mathbf{g} とヘッセ行列 $\tilde{\mathbf{H}}$ を, (12) 式と (14) 式から求める
 - 4: \mathbf{x}_i に対する変位を $\Delta\mathbf{x}^* \leftarrow -(\tilde{\mathbf{H}} + \lambda \mathbf{I})^{-1} \mathbf{g}$ として求める
 - 5: $\mathbf{x}_{i+1} \leftarrow \mathbf{x}_i + \Delta\mathbf{x}^*$ として解を更新する
 - 6: $|f(\mathbf{x}_i) - f(\mathbf{x}_{i+1})| < \varepsilon$ であれば終了する
 - 7: **if** $f(\mathbf{x}_i) < f(\mathbf{x}_{i+1})$ **then**
 - 8: $\lambda \leftarrow \lambda \rho$ に設定
 - 9: **else**
 - 10: $\lambda \leftarrow \lambda \rho^{-1}$ に設定
-

参考文献

- [1] Peter Biber and Wolfgang Straßer. The Normal Distributions Transform: A New Approach to Laser Scan Matching. In *Proceedings of the IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*, pages 2743–2748, 2003.
- [2] Giorgio Grisetti, Rainer Kuemmerle, Cyrill Stachniss, and Wolfram Burgard. A Tutorial on Graph-Based SLAM. *IEEE Transactions on Intelligent Transportation Systems Magazine*, 2(4):31–43, December 2010.
- [3] Stefan Kohlbrecher, Oskar von Stryk, Johannes Meyer, and Uwe Klingauf. A Flexible and Scalable SLAM System with Full 3D Motion Estimation. In *Proceedings of the IEEE International Symposium on Safety, Security, and Rescue Robotics (SSRR)*, pages 155–160, 2011.
- [4] Kurt Konolige, Giorgio Grisetti, Rainer Kümmeler, Wolfram Burgard, Benson Limketkai, and Regis Vincent. Efficient Sparse Pose Adjustment for 2D Mapping. In *Proceedings of the IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*, pages 22–29, 2010.
- [5] Rainer Kümmeler, Giorgio Grisetti, Hauke Strasdat, Kurt Konolige, and Wolfram Burgard. G2o: A General Framework for Graph Optimization. In *Proceedings of the IEEE International Conference on Robotics and Automation (ICRA)*, pages 3607–3613, 2011.
- [6] 金森 敬文, 鈴木 大慈, 竹内 一郎, and 佐藤 一誠. 機械学習プロフェッショナルシリーズ 機械学習のための連続最適化. 講談社, 2016.