

# 平滑化フィルタを用いた 画像ベース深層能動推論制御器の性能向上

## Improving the performance of Pixel-Based Deep Active Inference Controllers using Smoothing Filters

○長塚一真\*, 沓澤京\*, 大脇大\*, 林部充宏\*

○Kazuma Nagatsuka\*, Kyo Kutsuzawa\*, Dai Owaki\*, Mitsuhiro Hayashibe\*

\*東北大学

\*Tohoku University

**キーワード** : 能動的推論 (Active Inference), 自由エネルギー原理 (Free Energy Principle), 平滑化フィルタ (Smoothing Filter), ガウシアンフィルタ (Gaussian Filter),

**連絡先** : 〒 980-8579 宮城県仙台市青葉区荒巻字青葉 6-6-01 東北大学 青葉山キャンパス 機械系共同棟  
503 長塚一真, Tel.: 022-795-6970, Fax.: 022-795-6971, E-mail:  
nagatsuka.kazuma.s8@dc.tohoku.ac.jp

### 1. 緒言

能動的推論は神経科学の分野で広く知られている脳のモデルについての数学的なフレームワークである<sup>1)</sup>。能動的推論では、内部モデルによる予測と観測情報との誤差を表す、変分自由エネルギーというただ一つの目的関数の最小化で生物の状態推定及び行動を説明する。能動的推論を用いることで脳のメカニズムを幅広く説明できることがわかっており<sup>2)</sup>、ここ数年、能動的推論はロボット工学においてその適応性やノイズに対する頑健性などから注目されてきている。Pezzato ら<sup>3)</sup>の提案した能動推論制御器 (Active Inference Controller, AIC) は能動的推論をロボット制御に適用したものであり、状態と制御入力を変分自由エネルギーを目的関数とした勾配降下法で更新する。AIC は観測ノイズ、予期し

ない観測情報の変化に対し優れた頑健性を示すことがわかっている。また、AIC を画像のみが観測である場合に拡張した画像ベース深層能動推論制御器 (Pixel-Based Deep Active Inference) が Sancaktar ら<sup>4)</sup>により提案されている他、マルチモーダル変分オートエンコーダを用いてマルチモーダルな情報を観測として受け取ることができるようになったマルチモーダル能動推論制御器 (MAIC) も Meo ら<sup>6)</sup>により提案されている。さらに、離散的な時間における行動計画に能動的推論を適用した研究も多数存在する。離散的な時間においては通常、自由エネルギーの期待和である期待自由エネルギーが最小となるような方策を選択する<sup>8)</sup>が、自由エネルギーを目的関数とした勾配降下法により方策モデルを直接最適化する手法も提案されている<sup>8)</sup>。

しかし、能動推論制御器は自由エネルギーを

目的関数とした勾配降下法を用いるため、最適解への収束が保証されず局所解に陥る可能性がある<sup>2)</sup>。特に画像ベース深層能動推論制御器では目標姿勢に近い初期姿勢からでなければ局所解に陥ってしまうことが報告されている<sup>4)</sup>。他、MAICではマルチモーダルなデータを使えば適応性や頑健性が向上するものの、画像情報を除いた方がより制御動作が滑らかになることがわかっている<sup>6)</sup>。従来の次元関節角度情報のみを観測として用いるAICでは局所解は少ないため、この問題の解決策はあまり議論されてこなかった。しかし、センサの故障により関節角度情報を取得できなくなった場合やMAICで関節角度以外にも様々な観測情報を用いたい場合などが想定でき、これらの場合には画像情報を用いることは重要である。また、視覚センサは環境を非接触で測定できるため、ロボットのセンサとして有用である<sup>11)</sup>。

よって、画像ベース深層能動推論は様々な状況に適用可能であるが、局所解に陥ってしまいやすいことは無視できない問題となる。そこで、本研究では画像を平滑化して特徴を減らしエッジをなだらかにすることで、局所的にしか生じない目標値への勾配の範囲を広げ、局所解を回避する手法を提案する。さらに、平滑化は局所解回避の利点をもたらす一方で細かな特徴量の消失による発散のリスクも生むことから、両者のバランスをとるために適応的に平滑化強度を調整する手法も提案する。

## 2. 手法

提案手法のモデルアーキテクチャをFig.1に示す。画像ベース深層能動推論制御器のアーキテクチャに則しており、基本的には画像平滑化層を追加するのみなので実装は容易である。まずは土台となっている既存のAIC、画像ベース深層能動推論制御器について説明した後、提案手法で新たに追加した画像平滑化層の部分につ

いて説明する。

### 2.1 能動推論制御器

まず、Lanillosら<sup>2)</sup>、Pezzatoら<sup>3)</sup>の定式化に基づき、一般的な能動的推論の定式化及びロボットシステムの制御のために構成された定式化を示す。前提として、ロボットは真の状態がわからず、ノイズを含む観測値から真の状態を推定する必要がある。例えばロータリエンコーダで関節角度を測定してもノイズが乗ってしまうため、真の関節角度を推定しなければならない。また、ロボットは観測値が推定値と合わないときに、自ら能動的に行動して観測値の方を変化させ、推定値に合わせに行くこともできる。このように状態推定と制御を行うわけだが、これらは能動的推論の定式化において自由エネルギーという単一の目的関数の最適化の形で書くことができる。

ロボットの推定したい状態を $z$ 、観測として受け取るデータを $o$ としたとき、観測から状態を推定するモデル $p(z|o)$ を求めたい。 $p(z|o) = p(o|z)p(z)/p(o)$ と計算でき、ここで $p(o|z)p(z) = p(o, z)$ は内部モデルであり既知であるが、 $p(o)$ を計算するためには全ての取りうる状態について $p(o|z)p(z)$ の和を取らなければならないため、計算は困難である。そこで、変分ベイズ推定で状態推定モデルを近似的に求めるためにKLダイバージェンスを下げることを考える。近似モデルを $q(z)$ とし、KLダイバージェンスは

$$KL[q(z)||p(z|o)] = \int_z q(z) \ln \frac{q(z)}{p(z|o)} - \ln p(o) \quad (1)$$

のように書ける。 $\int_z q(z) \ln \frac{q(z)}{p(z|o)}$ の項は自由エネルギー $F$ と呼ばれ、 $-\ln p(o)$ の項はサプライズと呼ばれる。KLダイバージェンスは非負であるため、サプライズの上界は自由エネルギーである。よって、自由エネルギーを下げるのが目的となり、自由エネルギーを下げる方向に状

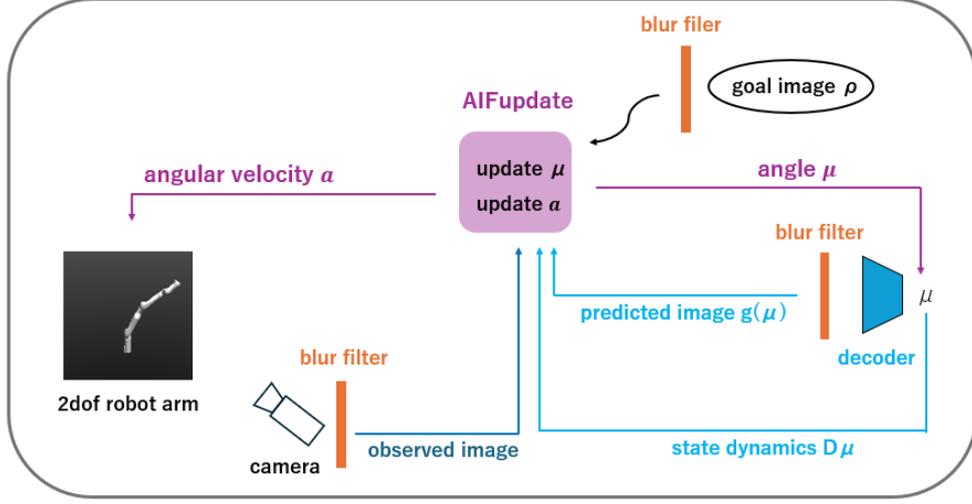


Fig. 1: Active inference architecture.

態変数, 行動変数を更新するのが能動的推論制御器である.

$$z = \underset{z}{\operatorname{argmin}} F(o, z) \quad (2)$$

$$a = \underset{a}{\operatorname{argmin}} F(o, z) \quad (3)$$

## 2.2 画像ベース深層能動推論制御器

画像ベース深層能動推論制御器は前の項で述べた能動推論制御器を, Sancaktar ら<sup>4)</sup> が画像観測の場合に拡張したものである. 内部モデル  $p(o|z)$ ,  $p(z)$  はガウス分布に従うノイズを  $r, w$ ,  $Dz$  は  $z$  の時間微分としてそれぞれ

$$o = g(z) + r \quad (4)$$

$$Dz = f(z) + w \quad (5)$$

のように書け, AIC では関節角度を  $\mu$  としてこれらをそれぞれ

$$\mu = g(\mu) + r \quad (6)$$

$$D\mu = \mu_d - \mu + w \quad (7)$$

のように関節角度を観測とするため恒等関数にノイズが乗る形で定式化している.  $\mu$  のダイナミクス  $D\mu$  は目標関節角度  $\mu_d$  に向かうことを内部モデルが既知情報として持っているとして定式化している. 一方, 画像を観測とする画像

ベース深層能動推論制御器では予測画像を  $x_v$ , 目標画像を  $\rho$  として

$$x_v = g(\mu) + r \quad (8)$$

$$D\mu = T(\mu)\beta(\rho - g(\mu)) + w \quad (9)$$

となり, ここで  $T(\mu) = \partial g(\mu)^T / \partial \mu$  は画像から関節角度へのマッピング,  $\beta$  はゲインパラメータである. 関節角度から画像を生成する形となるため, Sancaktar ら<sup>4)</sup> の実装では変分オートエンコーダ (Variational Auto Encoder, VAE) のデコーダ部分を用いている. 本研究でも同様に, 関節角度からの画像生成はデコーダモデルを用いた.

また, 本研究では Sancaktar ら<sup>4)</sup>, Oliver ら<sup>5)</sup> の実装と同様に制御入力を関節の角速度とし, 同様の近似を行った. 結果として状態変数, 制御入力の更新式はそれぞれ

$$\begin{aligned} \dot{\mu} = & k_v \frac{\partial g(\mu)^T}{\partial \mu} \Sigma_v^{-1} (x_v - g(\mu)) \\ & + \frac{\partial f(\mu, \rho)^T}{\partial \mu} \Sigma_\mu^{-1} (-f(\mu, \rho)) \end{aligned} \quad (10)$$

$$\dot{a} = -\frac{\partial g(\mu)^T}{\partial \mu} \Delta_t \Sigma_v^{-1} (x_v - g(\mu)) \quad (11)$$

のようになる. ここで,  $\Sigma_v^{-1}$ ,  $\Sigma_\mu^{-1}$  はそれぞれガウス分布  $r, w$  の分散であり,  $k_v$  は状態推定と制

御の更新バランスを調節するためのパラメータである。

## 2.3 デコーダモデル

次に、本手法で用いたデコーダモデルの構造を Table.1 に示す。最初の入力は関節角度なので 2次元である。

Table 1: Decoder model architecture.

Layer	output
FC1	512
FC2	1024
FC3	4096
upConv1	64x32x32
Conv1	128x32x32
upConv2	64x64x64
Conv2	64x64x64
Dropout(p=0.15)	64x64x64
upConv3	1x128x128

デコーダモデルの学習には画像に対応した関節角度を教師データとして用い、10000 のデータで学習させた。学習のためにデータを集めた環境は本研究における実験の際に使ったものと同じであるが、時間ステップを 0.0001 秒に設定した AIC を制御器として用いた。1000 ループごとにランダムな目標値に設定されるように制御したシミュレーション環境で、100 ループごとに画像とそれに対応した関節角度を記録したものをデータとした。ただ、目標値は -2.2 rad から 2.2 rad までの範囲を超えないようにした。

## 2.4 画像の平滑化

ここまでは既存の画像ベース深層能動推論制御器の理論、及び実装について説明した。しかし既に述べた通り、画像ベース深層能動推論制御器では目標姿勢に近い初期姿勢からでなければ局所解に陥ってしまうため、本研究では画像の平滑化層を追加することを提案する。画像を平滑化すると画像がぼやけることで、エッジが

なだらかになり、局所解の問題を解決することができる。この項では、新たに追加した画像平滑化層について説明する。

### 2.4.1 平滑化フィルタ

平滑化フィルタには様々なものがあるが、より画像を自然に平滑化するため、本手法ではガウシアンフィルタを用いた。ガウシアンフィルタは広く画像の平滑化に用いられている平滑化フィルタである<sup>10)</sup>。重みがガウス分布に従うフィルタであり、画像との畳み込み計算を行うことで画像を平滑化することができる。ガウシアンフィルタは画像内におけるピクセル位置を  $x, y$ 、ガウス分布の標準偏差を  $\sigma$  として

$$G(x, y) = \frac{1}{2\pi\sigma^2} \exp\left(-\frac{x^2 + y^2}{2\sigma^2}\right) \quad (12)$$

と書け<sup>10)</sup>、フィルタサイズかガウス分布の標準偏差を変更することで画像の平滑化強度を変更することができる。

### 2.4.2 平滑化強度の更新

画像の平滑化強度はガウシアンフィルタの標準偏差を変えることで調節可能である。後述する通り、画像を平滑化しすぎると特徴が減り、逆に勾配が消えてしまう。そこで、本手法では平滑化強度を動的に調整することを提案する。

$$\dot{\sigma} = -\frac{1}{m((x_v - g(\mu))^2 + (\rho - g(\mu))^2)} \quad (13)$$

ここで、 $m$  は更新速度の時定数である。予測が観測から離れている間及び目標値から離れている間は局所解に落ちないように強く平滑化しておく必要があり、誤差が小さくなるにつれ平滑化強度を弱めていくことになる。結果的に平滑化強度の更新式は (13) のように、近似的な自由エネルギーの逆数の形で書くことができる。

### 3. 実験方法

まず、画像を平滑化することで実際に局所解にはまりにくくなることを示すために平滑化の有無で統計的比較を行う。次に、平滑化すると発散しやすくなることを示すために異なる平滑化強度での統計的比較を行う。最後に、平滑化強度を自由エネルギーに基づいて動的に調整することで発散を比較的抑えつつ、収束性能を改善できることを示す。

#### 3.1 実験環境

本実験では MuJoCo<sup>9)</sup> をシミュレータとして使い、制御対象は 2 自由度ロボットアームとした。タスクとしては目標姿勢に到達するリーチングを想定した。シミュレーションのタイムステップは 0.005 秒とし、目標値との L2 ノルム 0.1 以下が 1 秒、すなわち 200 ステップ続いた場合にシミュレーションを終了させたが、最長でも 150 秒、すなわち 30000 ステップまでとした。学習に用いたデータは -2.2 rad から 2.2 rad の範囲で動かしたものをを用いているため、ロボットアームの関節の動く範囲は -2.2 rad から 2.2 rad に制限した。観測として受け取るものはロボットアーム全体が写る  $128 \times 128$  のグレースケール画像である。予測モデルの学習を容易にするため、画像の背景は黒一色のシンプルなものとした。また、本研究では平滑化フィルタのサイズは  $41 \times 41$  に固定しており、各画像は平滑化した後に 0 から 1 の範囲に正規化している。画像を平滑化すると背景が暗いために画像全体が暗くなり、画像の誤差も全体的に低下してしまうためである。また、シミュレーションは平滑化しない場合には CPU 環境で実行し、平滑化する場合には畳み込み処理の計算を高速化すべく GPU 環境で実行した。

#### 3.2 実験 1：平滑化の有無における比較

ガウス分布に従いランダムに用意した 12 の目標値について、シミュレーション終了時の L2 ノルムを統計的に比較した。ここでは目標値からの初期角度のずれが 0.6 rad, 0.8 rad, 1.0 rad, 1.2 rad, 1.4 rad, 1.6 rad の場合を用意し、それぞれの角度の場合について比較を行った。ここではガウシアンフィルタのフィルタサイズは 41、標準偏差は 21 に設定した。このときに用いた能動推論制御器の各パラメータを Table.2 に示す。より収束性能を高めるため、パラメータは第一関節と第二関節で別々のものを用いた。

Table 2: Active inference parameters.

関節	$\Sigma_v^{-1}$	$\Sigma_\mu^{-1}\beta$	$k_v$
1	150	0.001	$2 \times 10^{-3}$
2	100	0.005	$5 \times 10^{-3}$

#### 3.3 実験 2：異なる平滑化強度同士の比較

次に、同じくランダムに用意した 12 の目標値について、ガウシアンフィルタの標準偏差が 3, 7, 19 のときの異なる平滑化強度を 3 つ用意し、それぞれの場合でシミュレーション終了時の L2 ノルムを統計的に比較した。ここで、フィルタサイズは 101 とした。このときは目標値からの角度は 1.4 rad で固定し、ガウシアンフィルタの標準偏差、フィルタサイズ以外のパラメータは全て実験 1 のときと同様である。

#### 3.4 実験 3：平滑化強度を動的に調整した際の比較

最後に、実験 1 で用意したのと同じ 12 の目標値について、平滑化フィルタの標準偏差を (13) に基づき 21 から 3 まで更新した際について実験 1 と同様の比較を行った。ここでは時定数  $m$  は 0.005 のときと 0.05 のときの二つのパターンで実験した。また、この際も平滑化強度以外のパラメータは全て Table.2 と同様とした。

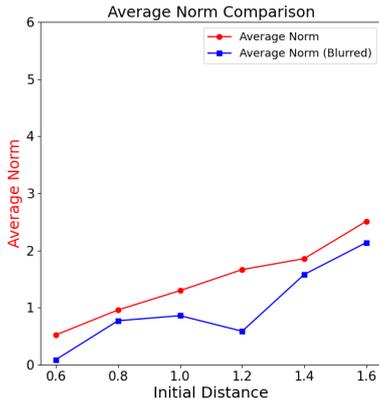


Fig. 2: Mean L2norm comparison.

## 4. 結果

### 4.1 実験 1：平滑化の有無での比較結果

平滑化の有無でシミュレーション終了時の L2 ノルムの平均値を目標値からの角度に対してプロットしたものを Fig.2 に示す。また、平滑化なしの場合における目標値からの角度毎の統計的結果を Fig.3a に、平滑化ありの場合における結果を Fig.3b に示す。

さらに、平滑化していない場合の予測画像とある目標画像の MSE 誤差を、第一関節角度、第二関節角度を  $-2.2 \text{ rad}$  から  $2.2 \text{ rad}$  の範囲で動かしたものに對しヒートマップでプロットしたものを Fig.4a に、標準偏差 7 で平滑化した場合のものを Fig.4b に示す。

### 4.2 実験 2：異なる平滑化強度での比較

目標値からの角度を  $1.4 \text{ rad}$  に固定した際における、異なる平滑化強度毎の統計的比較結果を Fig.5 に示す。

さらに、それぞれの平滑化強度のときについて予測画像と目標画像の MSE 誤差を第一関節角度、第二関節角度を  $-2.2 \text{ rad}$  から  $2.2 \text{ rad}$  の範囲で動かしたものに對しヒートマップでプロットしたものをそれぞれ Fig.6a, Fig.6b, Fig.6c に示す。

### 4.3 実験 3：平滑化強度を動的に調整した際の比較

$m = 0.005$  における更新ありでの目標値からの角度毎の統計的結果を Fig.7 に示す。さらに、 $m = 0.05$  における結果を Fig.8 に示す。

## 5. 考察

実験 1 では、L2 ノルムの平均値や中央値を比較すると、提案手法により局所解を回避できる結果となっていた。特に目標値から離れるにつれて既存手法は収束しにくくなるが、提案手法は多くの場合で収束している。Fig.4a や Fig.4b を見ると確かに解への勾配が生じる範囲が拡大していることがわかる。また、誤差の最大値もわずかに上昇しており、このことも収束性能に影響している可能性がある。しかしながら提案手法では発散してしまうデータも多く、平均値と分散が大きくなっていった。一方、Fig.5 を見ると平滑化強度を強める方が局所解には陥りにくくなるものの、画像の平滑化強度を強めるほど発散するデータが多くなり、データの分散が大きくなることがわかる。また、Fig.6a, 6b, 6c を見ると、平滑化強度が強まるにつれ第二関節方向の勾配がほとんどなくなってしまうことがわかる。この性質はここで用いた画像以外の画像についても同様であった。これは、同じ平滑化強度でもより細かい特徴である第二関節の方が勾配が消えやすいためであると考えられる。よって、発散してしまうデータが多くなるのは、第二関節の勾配が消えて第二関節が上手く収束しなくなることが原因であると考えられる。そこで、実験 3 で平滑化強度を自由エネルギーに基づき動的に更新したところ、Fig.7 のように局所解の回避を実現しつつも発散を抑制することができた。しかし多少発散するデータは依然存在し、平滑化しても消えない局所解は存在するため、これらは平滑化強度が減少し始めないうちに発散してしまったものであると考えられる。また、更

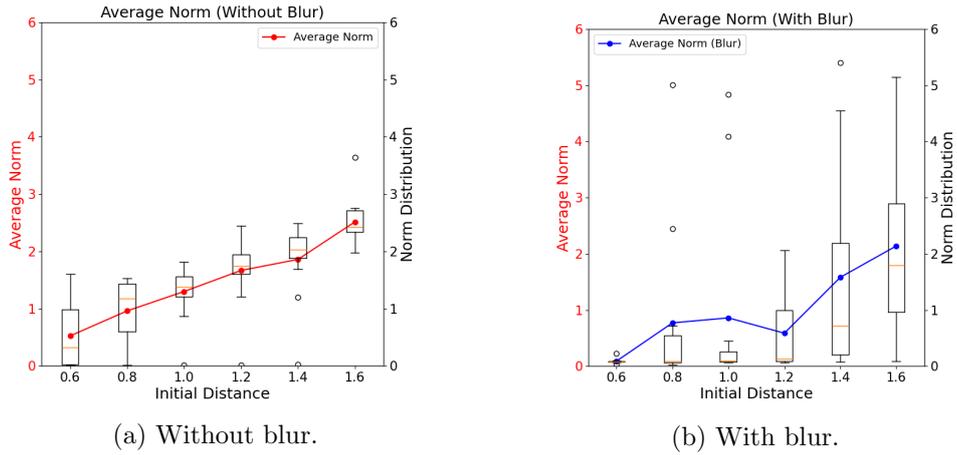


Fig. 3: Statistical result.

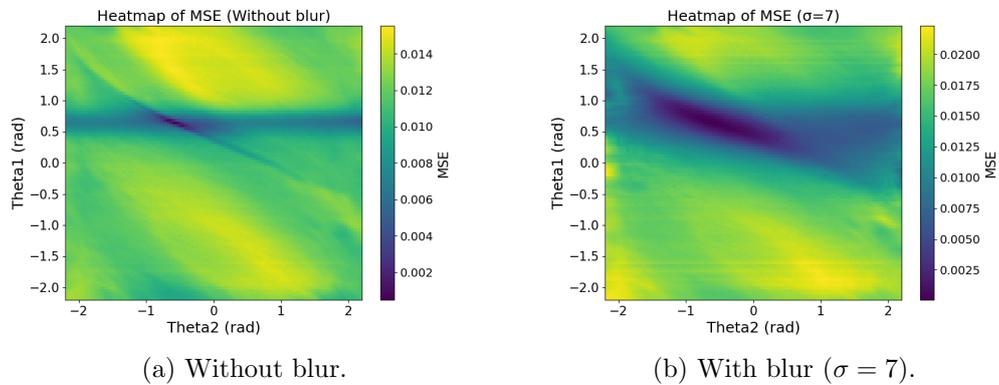


Fig. 4: heatmap comparison.

新速度を小さく設定した際には平滑化時間が長くなるため, Fig.8 に示す通り発散するデータは多くなるが, 収束するデータもより多くなった. 今回用いた更新式 13 の時定数は細かい調整をしておらず, 時定数や平滑化強度の更新式を調整することでさらに性能が改善する可能性がある.

また, 本手法で提案した平滑化強度の更新式は自由エネルギーに近い形となったが逆数を取っており, 本来の自由エネルギー原理における勾配更新式とは異なる形である. この点で生物学的妥当性については議論の余地があるが, 人間の視界も周辺視野はぼやけており, 中心視野を能動的に動かす, つまり視野をぼやけた状態からはっきりとした状態に更新するというものを行っていることは注目すべき点である.

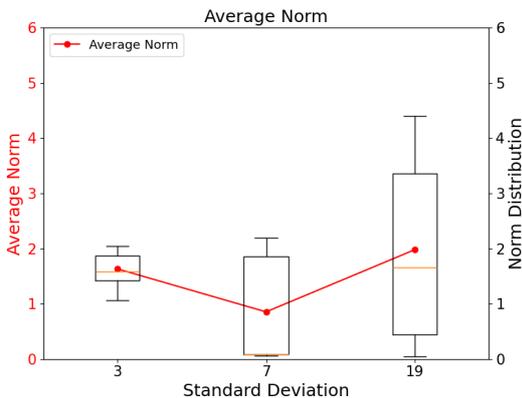


Fig. 5: std comparison.

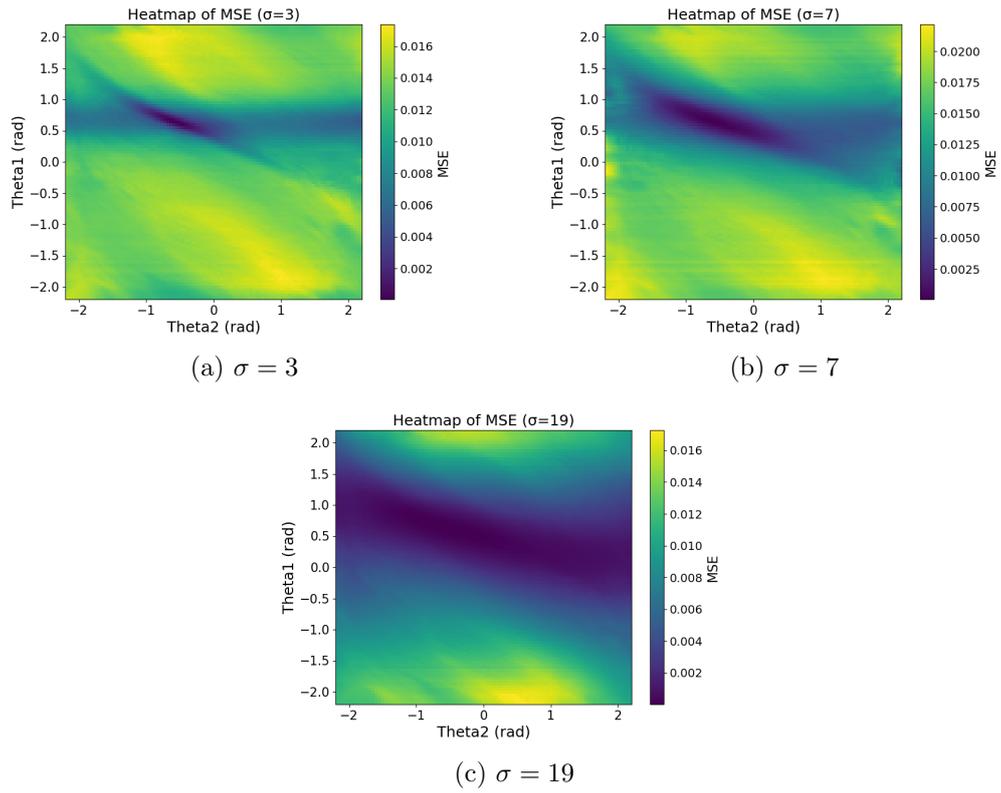


Fig. 6: heatmap plot comparison for different standard deviation.

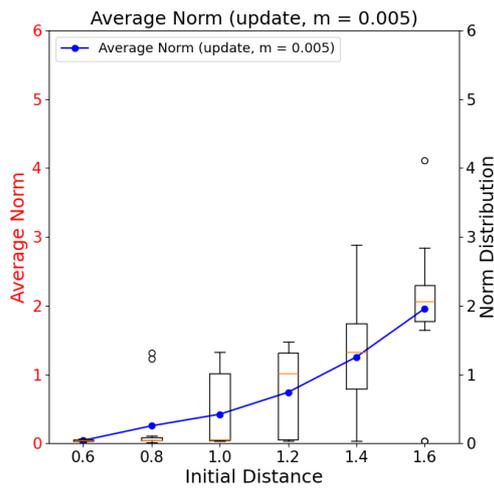


Fig. 7: With update ( $m=0.005$ ).

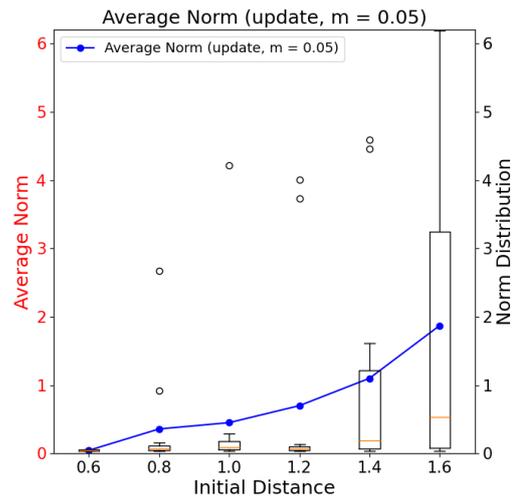


Fig. 8: With update ( $m=0.05$ ).

## 6. 結言

本研究では、画像を平滑化することで能動的推論制御器における局所解を回避する手法を提案し、画像ベース深層能動推論制御器の性能向上を試みた。その結果、提案手法は画像の平滑化がないときに比べ高い局所解回避性能を示した。また、平滑化強度を自由エネルギーに基づき動的に調整することで、平滑化に伴う発散の問題を軽減させつつ高い局所解回避性能を実現した。今後の展望としては、平滑化強度の時定数や更新式を調節することでさらに性能を向上させることができると考えられる。平滑化しても完全には消えない局所解が存在することは今後の課題である。また、本研究では画像ベースの能動的推論に適用したが、本手法は画像以外の次元センサ情報にも原理的には適用可能であり、能動的推論のフレームワーク全体に貢献するものである可能性がある。

## 参考文献

- 1) 乾敏郎, 坂口豊 (編): 自由エネルギー原理入門, 岩波書店, 18/19 (2021)
- 2) P. Lanillos, C. Meo, C. Pezzato, A. Anil Meera, M. Baioumy, W. Ohata, A. Tschantz, B. Millidge, M. Wisse, C. L. Buckley and J. Tani: Active Inference in Robotics and Artificial Agents: Survey and Challenges, CoRR, abs/2112.01871, (2021)
- 3) C. Pezzato, R. Ferrari and C. H. Corbato: A Novel Adaptive Controller for Robot Manipulators Based on Active Inference, IEEE Robotics and Automation Letters, **5-2**, 2973/2980 (2020)
- 4) C. Sancaktar and P. Lanillos: End-to-End Pixel-Based Deep Active Inference for Body Perception and Action, 2020 Joint IEEE 10th International Conference on Development and Learning and Epigenetic Robotics (ICDL-EpiRob), 1-8 (2019)
- 5) G. Oliver, P. Lanillos and G. Cheng: An Empirical Study of Active Inference on a Humanoid Robot, IEEE Transactions on Cognitive and Developmental Systems, **14-2**, 462/471 (2022)
- 6) C. Meo, G. Franzese, C. Pezzato, M. Spahn and P. Lanillos: Adaptation Through Prediction: Multisensory Active Inference Torque Control, IEEE Transactions on Cognitive and Developmental Systems, **15-1**, 32/41 (2023)
- 7) M. Baioumy, P. Duckworth, B. Lacerda and N. Hawes: Active Inference for Integrated State-Estimation, Control, and Learning, 2021 IEEE International Conference on Robotics and Automation (ICRA), 4665/4671 (2021)
- 8) Beren Millidge: Deep active inference as variational policy gradients, Journal of Mathematical Psychology, Volume 96, (2020)
- 9) E. Todorov, T. Erez and Y. Tassa: MuJoCo: A physics engine for model-based control, 2012 IEEE/RSJ International Conference on Intelligent Robots and Systems, 5026/5033 (2012)
- 10) M. Basu: Gaussian-based edge-detection methods-a survey, IEEE Transactions on Systems, Man, and Cybernetics, Part C (Applications and Reviews), **32-3**, 252/260 (2002)
- 11) S. Hutchinson, G. D. Hager and P. I. Corke: A tutorial on visual servo control, IEEE Transactions on Robotics and Automation, **12-5**, 651/670 (1996)