

深層学習を用いた画像情報に基づく 潜在状態空間モデルの推定

遠藤 弘史† 小口 俊樹†

† 首都大学東京大学院 理工学研究科 機械工学専攻

1 はじめに

近年、深層学習を制御分野に応用しようとする試みが行われている。本稿では、Rahul らの手法 [1] を拡張し、荒い画像情報より、動的システムの潜在変数空間における状態空間モデル（以下、潜在状態空間モデルと記す）を推定する新しい深層学習手法を提案する。

2 動的システムの潜在状態空間モデルの推定手法

2.1 提案モデル

提案モデルの概略を図 1 に示す。Rahul らの提案したモデルは対象の時系列因果推定のため、Variational Auto-Encoder を状態空間モデルに基づき拡張している。しかし、動的システムを対象とした場合、学習時の潜在変数の時系列制約が少なく局所解に陥り、対象のダイナミクスを学習できない問題が存在する。そこで、提案モデルでは図 1 に示すように、各時刻の潜在変数間に推論遷移モデル q_ϕ^{trans} を導入し、ニューラルネットワークの誤差逆伝播法の経路を形成することで、潜在変数の学習に長期の時系列制約を設ける。さらに、各時刻の潜在変数の推定時と画像の再構成の際に 2 時刻分の画像と入力を用いることで速度情報が学習されるように拘束をかける。これら二つの制約により、対象のダイナミクスを学習されるようにする。

2.2 提案モデルの学習

N 個の時間長 T のデータで構成されるデータセット $D = \{(x_0, u_0, \dots, u_{T-1}, x_T)_0, \dots, (x_0, u_0, \dots, u_{T-1}, x_T)_N\}$ を考える。ただし、 x_t, u_t はそれぞれ対象の画像と入力であるとする。提案モデルは図 1 中に示す、ニューラルネットワークモデル $q_\phi^{enc}, q_\phi^{trans}, p_\theta^{trnas}, p_\theta^{dec}$ に加え、 (x_1, u_0, x_0) より、初期潜在変数 z_1 を推定する推論モデル q_ϕ^{init} で構成する。この時、次の変分下限をデータセット D に対して最大化することで各ニューラルネットワークモデルを学習する。

$$\log p_\theta(\bar{x}|\bar{u}) \geq \mathbb{E}_{z_1 \sim q_\phi^{init}} [\log p_\theta^{dec}] - \text{KL}(q_\phi^{init} \| p(z_1))$$

$$+ \sum_{t=2}^T \left\{ \mathbb{E}_{z_t \sim q_\phi^{infe}} [\log p_\theta^{dec}] - \mathbb{E}_{z_{t-1} \sim q_\phi^{infe}} [\text{KL}(q_\phi^{infe} \| p_\theta^{trans})] \right\}$$

ただし、 $\text{KL}(p\|q)$ は二つの分布間の KL ダイバージェンス、 $p(z_1) = \mathcal{N}(0, I)$ とし、 $q_\phi^{infe} = q_\phi^{trans} q_\phi^{enc}$ と定義する。このとき、次の潜在状態空間モデルが得られる。

$$z_t \sim p_\theta^{trans}(z_t | z_{t-1}, u_{t-1})$$

$$(x_t, x_{t-1}) \sim p_\theta^{dec}(x_t, x_{t-1} | z_t, u_{t-1}) \quad (1)$$




図 1: 提案モデルの概略。黒の矢印が誤差逆伝播法の経路を示している




図 2: 一次元振子




図 3: データセットの画像例




図 4: ランダムな初期値、入力を与えたときの時系列予測結果。上: 対象システムの生成画像、下: 獲得モデルの生成画像

3 結果

図 2 に示す一次元振子を対象とし、図 3 に示すような画像から提案手法によりモデル推定を行う。画像データ作成においては、振子のダイナミクスは次に従うものとする。

$$\ddot{\theta} = \frac{g}{l} \sin \theta + \frac{1}{ml^2} (u - \mu \dot{\theta}) \quad (2)$$

ここで、 $g = 9.81, m = 1, l = 1, \mu = 0.05$ とする。学習の結果獲得されたモデル (1) を用いて、ランダムな初期状態と入力を与え時系列予測を行った結果を図 4 に示す。この結果から、獲得モデルが対象システムと同様の画像を出力しており、対象のダイナミクスを学習できていることがわかる。

4 今後の課題

今後は 3 次元挙動を含むシステムへの拡張を検討する予定である。

参考文献

[1] Rahul G. Krishnan, Uri Shalit and David Sontag. Deep Kalman Filters, arXiv:1511.05121 Preprint of NIPS 2015.