

通信理論に特化した深層学習 第1回ゼミ資料 はじめに

豊橋技術科学大学
電気・電子情報工学系
准教授 竹内啓悟

目標

通信の復調方式として利用されている**メッセージ伝播法**に基づく深層ニューラルネットワークの**最先端の学習方法**を学ぶ。

原理に関する方針

- 核心部分をおおまかに理解することを目指す。

Q 深層学習の本質は何か？


A 大自由度な損失関数の確率的局所最小化である。

ポイント:

- ・良い解を見つけやすい関数の構造(畳み込みニューラルネットワーク)
- ・良い解を見つけやすい初期値(メッセージ伝播法)
- ・良い解を見つけやすいアルゴリズム(Adam)

このような簡潔な回答をできるようになるのが目標

学習のイメージ図(等高線図)



関数の構造は地形(谷の個数)に影響を与える。

プログラミングに関する方針

TensorFlow 2を利用したPython 3によるコードを作成する。

方針

Pythonの分厚い教科書を読むところからは始めない。

- 何を作りたいのかをまず明確にする。
- 作りたいものを作るのに必要最低限の知識を明確にする。
- 必要になって初めて知らないことを調べる。

対象外の内容

- 実データを使った学習
- 畳み込みニューラルネットワーク
- Python 3の基礎

最初からTensorFlow 2のコードを書いて、動かして、理解する。

TensorFlow 2について

Googleが開発した(主に)Pythonの機械学習用のライブラリ

できること

- 任意の計算グラフの作成
- 学習する変数と学習しない変数の設定
- 誤差逆伝播法による学習
- Kerasという高水準Application Programming Interface (API)を使った簡潔なソースコード記述

TensorFlow 2.0

Define-by-run方式による数学的に自然なソースコード記述

以前のバージョンは、Define-and-runという評判の悪い方式であった。

Webを参考にする際は、バージョンをよく確認すること。

インストールと実行方法

Python 3全般

Debianにログイン後、root権限で以下のコマンドを実行する。

```
apt install python3-pip
```

TensorFlow 2.0

仮想環境を使わないオプション

```
pip3 install --upgrade pip --break-system-packages
```

pipの最新版をインストール

```
pip install tensorflow --break-system-packages
```

インストールしたpipを使用

実行方法

後述するソースコード`***.py`を作成した上で

```
python3 ***.py
```

デフォルトがPython 2なので、「3」を忘れないこと。

加法的白色ガウス雑音通信路

$$y = x + w, \quad w \sim \mathcal{N}(0, \sigma^2).$$

二位相偏移変調 (Binary phase-shift keying, BPSK)

$$\mathbb{P}(x = \pm 1) = \frac{1}{2}.$$

加法的白色ガウス雑音 (Additive white Gaussian noise, AWGN)

w は x と独立な平均0分散 σ^2 のガウス分布に従う。

平均 $\mu = \mathbb{E}[z]$ 分散 $\sigma^2 = \mathbb{E}[(z - \mu)^2]$ のガウス確率変数 z の確率密度関数

$$p(z) = \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{(z-\mu)^2}{2\sigma^2}}, \quad z \in \mathbb{R}.$$

推定量と性能の評価基準

推定量 (Estimator)

受信信号 $y \in \mathbb{R}$ の任意の関数 $\hat{x}(y)$

平均二乗誤差 (Mean square error, MSE)

$$\mathbb{E}[\{x - \hat{x}(y)\}^2] = \mathbb{E}_x \left[\int \{x - \hat{x}(y)\}^2 p(y|x) dy \right].$$

条件付き確率密度関数

$$p(y|x) = \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{(y-x)^2}{2\sigma^2}}.$$

- ∴ ガウス性はノイズのガウス性から従う。条件付き平均と分散を計算すると、
定義 $y = x + w$ 、期待値の線形性、 x と w の独立性、 w の定義から、

$$\mathbb{E}[y|x] = \mathbb{E}[x + w|x] = x + \mathbb{E}[w|x] = x + \mathbb{E}[w] = x,$$

$$\mathbb{E}[(y - \mathbb{E}[y|x])^2|x] = \mathbb{E}[w^2|x] = \mathbb{E}[w^2] = \sigma^2.$$

最適な推定量

事後平均推定量 (Posterior mean estimator, PME)

$$\hat{x}_{\text{PME}}(y) = \mathbb{E}[x|y].$$

定理 1.1: 事後平均推定量は平均二乗誤差を最小にする。

証明: \hat{x} を x の任意の推定量とする。

$$\mathbb{E}[(x - \hat{x})^2] = \mathbb{E}_y \left\{ \mathbb{E}_{x|y} \left[\{(x - \hat{x}_{\text{PME}}) + (\hat{x}_{\text{PME}} - \hat{x})\}^2 \right] \right\}$$

推定量 \hat{x} は y の関数なので、条件付き平均 $\mathbb{E}_{x|y}$ の計算では定数とみなせる。

$\hat{x}_{\text{PME}} = \mathbb{E}[x | y]$ なので、平方を展開すると、 $2(x - \hat{x}_{\text{PME}})(\hat{x}_{\text{PME}} - \hat{x})$ は消える。

$$\mathbb{E}[(x - \hat{x})^2] = \mathbb{E}[(x - \hat{x}_{\text{PME}})^2] + \mathbb{E}[(\hat{x}_{\text{PME}} - \hat{x})^2] \geq \mathbb{E}[(x - \hat{x}_{\text{PME}})^2]$$

等号は $\hat{x} = \hat{x}_{\text{PME}}$ のときに限る。 ■

事後平均推定量の計算

ベイズの公式

$$\mathbb{P}(x|y) = \frac{p(y|x)\mathbb{P}(x)}{p(y)}$$

$$\because p(x, y) = p(y|x)\mathbb{P}(x) = \mathbb{P}(x|y)p(y).$$

$p(y)$ の定義

$$p(y) = \sum_{x=\pm 1} p(y|x)\mathbb{P}(x).$$

事後平均推定量の計算

$$\begin{aligned}\mathbb{E}[x|y] &= \sum_{x=\pm 1} x\mathbb{P}(x|y) = \frac{\sum_{x=\pm 1} xp(y|x)\mathbb{P}(x)}{\sum_{x=\pm 1} p(y|x)\mathbb{P}(x)} \\ &= \frac{\sum_{x=\pm 1} x \exp\left\{-\frac{(y-x)^2}{2\sigma^2}\right\}}{\sum_{x=\pm 1} \exp\left\{-\frac{(y-x)^2}{2\sigma^2}\right\}} = \frac{e^{\frac{y}{\sigma^2}} - e^{-\frac{y}{\sigma^2}}}{e^{\frac{y}{\sigma^2}} + e^{-\frac{y}{\sigma^2}}} = \tanh\left(\frac{y}{\sigma^2}\right).\end{aligned}$$