



安全な AIこそ効率的： ロバスト学習による汎化性能向上の研究

マシュー・ホーランド（大阪大学）

「任せて安心！機械学習の性能保証」

本研究の目的

関心の対象は汎用的学習アルゴリズム。

- (1) 統計的な性能保証の高度化
- (2) 安易な実装
- (3) 限りなく小さなオーバーヘッド

↓（同時に満たせば）

試行錯誤が少なく、
信頼保証付きの AI 基盤技術の刷新

（関連業績）

- AISTATS 2019、採録決定 x 2件
- ICML 2019 投稿中
- ECML 2019 投稿中


既存手法とコア技法

拙速型：速いが、性能保証がきわめて弱い（脆弱性）


（例）従来の SGD 系からの Adam, Adagrad, Dropout や Clipping 等のワザも。

机上の空論型：理論上は担保されるが、コストが高すぎる

（例）geometric median による勾配統合、次元ごとの M 推定量の導入など。




$$\hat{w}_{(t+1)} = \hat{w}_{(t)} - \alpha_{(t)} \hat{g}_{(t)}(\hat{w}_{(t)})$$



頑健性と計算効率の両立について

巧みな truncation 関数と
ノイズ分布の設計がポイント。




あらゆるデータ分布

高い確率 $(1 - \delta)$ で、
高水準の誤差を担保する
領域を左図に明示

期待値を解析的に求める

$$\mathbf{E}_{\nu} \psi \left(a + b\sqrt{\beta}\epsilon \right) = a \left(a - \frac{b^2}{2} \right) - \frac{a^3}{6} + C(a, b)$$



$$\|\hat{g}(w) - g(w)\| \leq \frac{\tilde{\epsilon}}{\sqrt{n}} \quad (\text{一様上界})$$

$$R(\hat{w}_{(T)}) - R^* \leq (1 - \alpha)^T \lambda \|\hat{w}_{(0)} - w^*\|^2 + \frac{4\lambda\tilde{\epsilon}}{\kappa^2 n}$$
$$= O\left((1 - \alpha)^T\right) + O\left(\frac{d(\log(d\delta^{-1}) + d\log(\Delta n))}{n}\right)$$

この保証は、2 次モーメントの有限性だけで十分。
従来手法と比べると、大幅な仮定の緩和。

深層学習向けの実装

逆走部分を書き換えるだけ済む。
既成 backprop はそのまま。

（Chainer での実装例）

（FunctionNode）

LinearFunction_Robust

def forward(...):

use fn as-is

def backward(...):

core grad step


...

ソース+デモ
公開中


GitHub --> feedbackward
--> softgrad

種々の実験結果


シミュレーション上の振る舞いは理論通り



微調整なしでも多様なノイズに頑健



深層学習への拡張も



今後に向けて

冒頭の (1) ~ (3) を満たす新手法。
取り口は新しく、有効性も入念な
検証を経て確認できている。

次なる課題：CNN や RNN への
拡張，検証，および実用化。

【問】アーキテクチャー
とデータ分布に応じて、
いつ、どこをロバスト化
すべきか？

【問】モデルとデータに
見合ったノイズ分布の設
計を盛り込む利点とコス
トとは？

