

研究室紹介/大前

日本大学 生産工学部
マネジメント工学科
2年生向け

自己紹介

大前佑斗（37歳）

北海道 → 新潟 → 東京 → 千葉 → ヘルシンキ（フィンランド） → 千葉

機械学習：

機械が大量のデータからパターンやルールを自動で学習し、
予測や分類を行う技術の総称（**2024年、ノーベル賞受賞！**）

私の研究テーマ（研究室なので、研究をしています）：

#1 機械学習がなぜうまくいくのか、その理由を解明する

良いモデルを作るための経験則は多数あるものの、なぜうまくいくのか、
解明されていない部分が多い。厳密な理論解析を通して、明らかにする。

#2 応用寄りの研究者・エンジニアが使える新たな機械学習を考案する

- ・ 既存の機械学習を拡張したり、穴があれば埋めたり
- ・ あらゆる応用研究者・エンジニアが真に使える機械学習を提供
→ これまで、10種類ほど新規の手法・理論を提案

#3 いろいろ作る。

機械学習をやっていると、これをやってほしい、あれをやってほしい依頼が
たくさんくるので、それをこなす。

最近やっている研究： 人類がまだ到達していない 機械学習について考える (ハイレベルな研究者には敵いませんが...)

深層学習が うまくいく理由を 明らかにする。

Y. Omae, Wolkowicz-Styan Upper
Bound on the Hessian
Eigenspectrum for Cross-Entropy
Loss in Nonlinear Smooth Neural
Networks

非線形平滑ニューラルネットワーク
における交差エントロピー損失の
ヘッセ行列固有スペクトルに関する
ウォルコヴィッツ-スティアン上界

詳細:

<https://arxiv.org/abs/2604.10202>
<https://arxiv.org/pdf/2604.10202>

Therefore,

$$\begin{aligned} H_l(w, w) &= \frac{\partial}{\partial w} \left(\frac{\partial l}{\partial w} \right)^\top \\ &= \begin{bmatrix} \frac{\partial}{\partial w_{:0}} \\ \vdots \\ \frac{\partial}{\partial w_{:M}} \end{bmatrix} \begin{bmatrix} \left(\frac{\partial l}{\partial w_{:0}} \right)^\top & \cdots & \left(\frac{\partial l}{\partial w_{:M}} \right)^\top \end{bmatrix} \\ &= \begin{bmatrix} H_l(W_{:0}, W_{:0}) & \cdots & H_l(W_{:0}, W_{:M}) \\ \vdots & \ddots & \vdots \\ H_l(W_{:M}, W_{:0}) & \cdots & H_l(W_{:M}, W_{:M}) \end{bmatrix} \\ &= h(x)h(x)^\top \\ &\quad \otimes (s'(z)F'(y)\tilde{V}^\top \tilde{V}F'(y) + \delta \text{diag}(\tilde{V}^\top)F''(y)), \\ H_l(w, w) &\in \mathbb{R}^{(M+1)N \times (M+1)N} \end{aligned} \quad (61)$$

is satisfied.

F. Proof for Eq. (16)

From Eqs. (52) and (55), we obtain

$$\frac{\partial p}{\partial v} = \frac{\partial z}{\partial v} \frac{\partial p}{\partial z} = s'(z)h(r). \quad (62)$$

From this, Eq. (56), and Eq. (37) in [52],

$$\begin{aligned} H_l(v, v) &= \frac{\partial}{\partial v} \left(\frac{\partial l}{\partial v} \right)^\top = \frac{\partial}{\partial v} \delta h(r)^\top \\ &= \left(\frac{\partial \delta}{\partial v} \right) h(r)^\top + \delta \frac{\partial}{\partial v} h(r)^\top = \left(\frac{\partial p}{\partial v} \right) h(r)^\top \\ &= s'(z)h(r)h(r)^\top \in \mathbb{R}^{(N+1) \times (N+1)} \end{aligned} \quad (63)$$

is satisfied.

G. Proofs for Eqs. (17) and (18)

From Eqs. (59), (62), and Eq. (37) in [52], we obtain

$$\begin{aligned} H_l(v, W_{:m}) &= \frac{\partial}{\partial v} \left(\frac{\partial l}{\partial W_{:m}} \right)^\top = x_m \frac{\partial}{\partial v} \delta \tilde{V}F'(y) \\ &= x_m \left(\left(\frac{\partial \delta}{\partial v} \right) \tilde{V}F'(y) + \delta \frac{\partial}{\partial v} \tilde{V}F'(y) \right) \\ &= x_m \left(s'(z)h(r)\tilde{V}F'(y) + \delta \begin{bmatrix} 0_N \\ F'(y) \end{bmatrix} \right) \in \mathbb{R}^{(N+1) \times N}. \end{aligned}$$

Therefore, this yields

$$\begin{aligned} H_l(v, w) &= \frac{\partial}{\partial v} \left(\frac{\partial l}{\partial w} \right)^\top \\ &= \begin{bmatrix} \frac{\partial}{\partial v} \left(\frac{\partial l}{\partial w_{:0}} \right)^\top & \cdots & \frac{\partial}{\partial v} \left(\frac{\partial l}{\partial w_{:M}} \right)^\top \end{bmatrix} \\ &= \begin{bmatrix} H_l(v, W_{:0}) & \cdots & H_l(v, W_{:M}) \end{bmatrix} \\ &= h(x)^\top \otimes \left(s'(z)h(r)\tilde{V}F'(y) + \delta \begin{bmatrix} 0_N \\ F'(y) \end{bmatrix} \right), \\ H_l(v, w) &\in \mathbb{R}^{(N+1) \times (M+1)N}. \end{aligned}$$

From Eq. (57), we have

$$\begin{aligned} H_l(w, v) &= H_l(v, w)^\top \\ &= h(x) \otimes \left(s'(z)F'(y)\tilde{V}^\top h(r)^\top + \delta \begin{bmatrix} 0_N & F'(y) \end{bmatrix} \right), \\ H_l(w, v) &\in \mathbb{R}^{(M+1)N \times (N+1)}, \end{aligned}$$

where Eqs. (4), (5), and (510) in [52] have been applied.

H. Proof for Eqs. (20) and (21)

Based on Eq. (63) and Eq. (14) in [52], we obtain

$$\begin{aligned} \text{tr}(H_l(v, v)) &= s'(z)\text{tr}(h(r)h(r)^\top) = s'(z)\text{tr}(h(r)^\top h(r)) \\ &= s'(z)h(r)^\top h(r) = s'(z)(1 + r^\top r). \end{aligned} \quad (64)$$

Employing Eq. (61) and Eq. (515) in [52] leads to

$$\begin{aligned} \text{tr}(H_l(w, w)) &= \text{tr}(h(x)h(x)^\top) \\ &\quad \otimes (s'(z)F'(y)\tilde{V}^\top \tilde{V}F'(y) + \delta \text{diag}(\tilde{V}^\top)F''(y)) \\ &= (1 + x^\top x)\text{tr}(s'(z)F'(y)\tilde{V}^\top \tilde{V}F'(y) + \delta \text{diag}(\tilde{V}^\top)F''(y)) \\ &= (1 + x^\top x)(s'(z)\|F'(y)\tilde{V}^\top\|^2 + \delta \tilde{V}f''(y)). \end{aligned} \quad (65)$$

Furthermore, from Eq. (15) in [52], the trace for all training data is expressed as

$$\text{tr}(H_L(a, a)) = \sum_{i=1}^I \text{tr}(H_{l_i}(a, a)), \quad a \in \{w, v\}. \quad (66)$$

Substituting

$$\begin{aligned} (E_I + X^\top X \odot E_I)1_I &= [1 + x_i^\top x_i] \in \mathbb{R}^{I \times 1}, \\ (E_I + R^\top R \odot E_I)1_I &= [1 + r_i^\top r_i] \in \mathbb{R}^{I \times 1}, \\ s' \odot (F_y^{\odot 2} \tilde{V}^{\odot 2}) &= s' \odot ((F_y' \odot F_y')(\tilde{V} \odot \tilde{V})^\top) \\ &= [s'(z_i)\|F'(y_i)\tilde{V}^\top\|^2] \in \mathbb{R}^{I \times 1}, \\ \delta \odot (F_y'' \tilde{V}^\top) &= [\delta_i f''(y_i)^\top \tilde{V}^\top] \\ &= [\delta_i \tilde{V}f''(y_i)] \in \mathbb{R}^{I \times 1} \end{aligned}$$

into Eqs. (20) and (21) and simplifying the terms shows that Eq. (66) and Eqs. (20)–(21) are equivalent.

I. Proof for Eq. (22)

From Eq. (64), we obtain $\text{tr}(H_l(v, v)) = s'(z)(1 + r^\top r)$. Since $s(z)$ is a function that outputs the estimated probability in (0, 1) according to Eq. (1), it follows that

$$\max_{z \in \mathbb{R}} s'(z) = \max_{p \in (0,1)} p(1-p) = \frac{1}{4}. \quad (67)$$

It holds from Eqs. (36), (39), (42), (45), and (48) that

$$\begin{aligned} \sup_r (1 + r^\top r) &= \sup_{y \in \mathbb{R}^N} (1 + f(y)^\top f(y)) \\ &= \begin{cases} N+1, f : \text{Sigmoid/Tanh} \\ \infty, f : \text{Linear/SmoothReLU/GELU} \end{cases} \end{aligned}$$


Therefore, we have

$$\text{tr}(H_l(v, v)) < \begin{cases} \frac{1}{4}(N+1), f : \text{Sigmoid/Tanh} \\ \infty, f : \text{Linear/SmoothReLU/GELU} \end{cases}.$$

Substituting this into Eq. (66) yields Eq. (22).

最近やっている研究：
 人類がまだ到達していない
 機械学習について考える
 (ハイレベルな研究者には敵いませんが...)

今まで誰も見れなかった
 深層学習の主軸を
 可視化する。




PCA- and SVM-Grad-CAM for
 Convolutional Neural Networks:
 Closed-form Jacobian Expression

畳み込みニューラルネットワーク
 におけるPCA-SVM-Grad-CAM:
 ヤコビ行列の閉形式表現

詳細:

<https://arxiv.org/abs/2508.11880>
<https://arxiv.org/pdf/2508.11880>



3. Visualized Jacobian computed from a CNN trained on the Dog at dataset, as described in Section VI. The red and blue paths represent ve and negative gradients, respectively. The width of each path represents absolute value of the gradient.

最近やっている研究： 人類がまだ到達していない 機械学習について考える (ハイレベルな研究者には敵いませんが...)

従来よりも良い
ベイズ最適化を作る。

EVI-GPBO: Estimated Variance
Integration-Based Gaussian Process
Bayesian Optimization

推定分散積分に基づく
ガウス過程ベイズ最適化

詳細:

<https://ieeexplore.ieee.org/document/10872956>

Algorithm 1 EVI-GPBO (Proposed Method)

Input: Initial observation set $D_0 = \{(\mathbf{x}_1, y_1), \dots, (\mathbf{x}_N, y_N)\}$, BO iterations T , gradient iterations T' , learning rate r , weight coefficient τ , search space Ψ , integration range X , initial kernel parameters $\mathbf{v}^{(0)}$

Output: Solution $\mathbf{x}^\#$

```

1:  $\mathbf{v}^{(0)} \leftarrow \log \mathbf{v}^{(0)}$ , Eq. 19
2:  $N \leftarrow |D_0|$ 
3: for  $t = 0$  to  $T - 1$  do
4:   for  $t' = 0$  to  $T' - 1$  do
5:      $\mathbf{v}^{(t'+1)} \leftarrow \mathbf{v}^{(t')} + r \frac{\partial L(\mathbf{v}, D_t)}{\partial \mathbf{v}'} \Big|_{\mathbf{v} \leftarrow \exp(\mathbf{v}^{(t')})}$ , Eq. 23
6:   end for
7:    $\mathbf{v}^{(T')} \leftarrow \exp(\mathbf{v}^{(T')})$ , Eq. 20
8:    $\beta_t \leftarrow \frac{\tau}{M} \int_X V_t(\mathbf{x}; \mathbf{v}^{(T')}) d\mathbf{x}$ , Eqs. 26, 40, and 45
9:    $\mathbf{x}_{|D_t|+1} \leftarrow \operatorname{argmax}_{\mathbf{x} \in \Psi} A_t(\mathbf{x}; \beta_t, \mathbf{v}^{(T')})$ , Eq. 10
10:   $y_{|D_t|+1} \leftarrow f(\mathbf{x}_{|D_t|+1}) + \epsilon$ , Eq. 11
11:   $D_{t+1} \leftarrow D_t \cup \{(\mathbf{x}_{|D_t|+1}, y_{|D_t|+1})\}$ , Eq. 13
12:   $\Psi \leftarrow \Psi \setminus \{\mathbf{x}_{|D_t|+1}\}$ 
13: end for
14:  $\mathbf{x}^\# \leftarrow \mathbf{x}_{i^\#}$  s.t.  $i^\# \leftarrow \operatorname{argmax}_{i \in \mathbb{N}_{\leq N+T}} y_i$ , Eq. 14
15: return  $\mathbf{x}^\#$ 

```

$$\mathbf{x}^* = \mathbf{x} - \frac{1}{2}(\mathbf{x}_i + \mathbf{x}_j), \quad (36)$$



Equation 28 can be represented as

$$\begin{aligned}
 k^*(\mathbf{x}, \mathbf{x}_i, \mathbf{x}_j) &= \zeta^2 \left(\exp \left(-\frac{\|\mathbf{x}_i - \mathbf{x}_j\|_2^2}{\eta} \right) \right)^{\frac{1}{2}} \exp \left(-\frac{2}{\eta} (\mathbf{x}^*)^\top (\mathbf{x}^*) \right) \\
 &= \zeta^{\frac{3}{2}} (k(\mathbf{x}_i, \mathbf{x}_j) - \theta \delta_{ij})^{\frac{1}{2}} \exp \left(-\frac{2}{\eta} (\mathbf{x}^*)^\top (\mathbf{x}^*) \right). \quad (37)
 \end{aligned}$$

With this substitution, the integration range changes from X to

$$X_{ij}^* = \prod_{p=1}^d \left[(x_p^*)_{ij}^{\min}, (x_p^*)_{ij}^{\max} \right], \quad \mathbf{x}^* \in X_{ij}^*, \quad (38)$$

where, $(x_p^*)_{ij}^{\min} = x_p^{\min} - \frac{1}{2}(x_{ip} + x_{jp})$ and $(x_p^*)_{ij}^{\max} = x_p^{\max} - \frac{1}{2}(x_{ip} + x_{jp})$. The Jacobian matrix with respect to $\mathbf{x}^*$ can be represented as



$$- \operatorname{erf} \left[\sqrt{\frac{2}{\eta}} \left(x_p^{\min} - \frac{x_{ip} + x_{jp}}{2} \right) \right]. \quad (41)$$

$\operatorname{erf}[z]$ is a Gaussian error function, which is defined as

$$\operatorname{erf}[z] := \frac{2}{\sqrt{\pi}} \int_0^z \exp(-t^2) dt. \quad (42)$$

Note that when transforming Equation 40, we use the following relationship:

$$\begin{aligned}
 & \int_{(x_p^*)_{ij}^{\min}}^{(x_p^*)_{ij}^{\max}} \exp \left(-\frac{2}{\eta} (x_p^*)^2 \right) dx_p^* \\
 &= \sqrt{\frac{\eta}{2}} \int_{\sqrt{\frac{2}{\eta}} (x_p^*)_{ij}^{\min}}^{\sqrt{\frac{2}{\eta}} (x_p^*)_{ij}^{\max}} \exp(-u^2) du \\
 &= \sqrt{\frac{\eta\pi}{8}} \left(\operatorname{erf} \left[\sqrt{\frac{2}{\eta}} (x_p^*)_{ij}^{\max} \right] - \operatorname{erf} \left[\sqrt{\frac{2}{\eta}} (x_p^*)_{ij}^{\min} \right] \right). \quad (43)
 \end{aligned}$$

↑ ここまで自己紹介

↓ ここからゼミ紹介

教育に対する考え方など

比較対象は他人ではなく、過去の自分とする。

- ・ 苦手な人は少しでもできるように。
- ・ 得意な人はもっとできるように。

「できないことができるようになる」というのが大事

→ 目標設定は、一律ではなく（なるべく）個別に設定

何を大事にしたいかは自分で決めること。

- ・ 趣味、アルバイト、スポーツ、大学の勉強、大学以外の勉強 etc.
 - ・ ゼミの活動は少しでもいいし、たくさんやってもいい（最低ラインあり）
-

勉強したい人も、研究したい人も。

- ・ **勉強**：誰かがまとめたもの、明らかにしたことを理解する行為
- ・ **研究**：世界中で誰もやっていないことをやる行為
- ・ 機械学習の理論に精通した専門家になりたい、という人も歓迎

（ただし難易度は高い）

ゼミの勉強

本研究室では、機械学習/深層学習の厳密な理論を学習します。ふんわりではなく、曖昧さもなく、カラフルな図も（あまり）出てきません。

この過程で、数学を利用します。どうしてかという、機械学習/深層学習はすべて数学で成り立っているからです。

数学とは、極めて抽象度の高い言語（ことば）です。自然言語（日本語、英語など）で記述された理論は、人によって解釈が違ふとか、環境で結論が変わるとか、曖昧なものです。そのため、厳密性を重視する分野では、自然言語は理論の記述には不向きとされます。一方、数学により記述された理論とは、（基本的に）曖昧さを含みません。ですから、機械学習に限らず、理系の理論を学ぼうと思ったら、まずは、それを読む・書くための言語として数学を学ぶ必要があります。そのため本研究室では、理論を記述する言語として数学を学んでから、機械学習/深層学習の理論を学んでいきます。

難しそうなのだが？

Q. 数学が苦手だが、良いか？

A. いいです。 前提知識がなくてもわかるように、最初から始めます。数学が得意でも、もちろんいいです。その場合、多分、楽しいと思います。

（おそらく）これまで行ってきたような、問題を解くとか、テストで点を取るというような勉強の仕方とは違ってきますので、数学が苦手でも問題ありません。というか、多分ほとんど苦手だと思っています。前提知識は仮定しませんので、基本的に誰でもウェルカムです。

どうしても難しいようなら、別の課題で対応するなどの処置もとります。何か高いハードルがあって、必ずそれを越えなければ卒業できない、ということはありません。基本的に皆、問題なく卒業していきます。

きちんと学びたい人でも、ささっと単位を取りたい人でも、どちらでも構いません。真面目でもいいし、不真面目でも良いです。定員もあるので全員とはいきませんが、このような人でなければ志望してはいけない、というような条件はありません。

卒業研究テーマ

(応用) 機械学習を用いて、高度なデータ分析を行いたい。

→ 予測、因果、相関、要因分析

→ データサイエンス/コンサルは統計と機械学習の二刀流が必須

(というより、統計と機械学習の学問体系は複雑に絡み合い、区別不能)

例: **XXXを食べると長生きするのか？売れるカバンの条件は？**

(応用) 機械学習を用いて、高度なソフトウェアを作りたい。

→ 何かすごいシステム。例えば...

缶詰工場ラインで、食べ物の画像からネジとか、
髪の毛とか、爪とかを検出する人工知能！

(理論) 新しい機械学習の理論を作り上げてみたい。

→ 機械学習の理論の成熟を目指す。

これまでのブレイクスルー（畳み込みニューラルネットワーク、トランスフォーマー、生成AIとか）は、数学を使いこなす機械学習の理論研究者が作り上げたもの。 **大学院の内部進学希望者はこちらをやってほしい。**

進路関係

就職活動の支援：

- ・ 就活はとても大事なので、集中して取り組んでください。
- ・ その期間に課題などは出しません。
- ・ エントリーシート、履歴書など、添削を希望する方は添削します。
- ・ 企業の人事の方を呼んで、会社説明会などを開いています。

就職先：

- ・ IT系8割、コンサル+金融系1割、その他1割
- ・ IT系は、上流・下流工程の半々くらい。
- ・ 具体名は、興味があれば聞いてください。

大学院の進学先：

- ・ 色々あります。領域は、情報系や、経営系がほとんど。
- ・ 具体名は、興味があれば聞いてください。

配属の案内（学部で卒業する人向け）

どんな人に希望して欲しいか？：

- ・ 基本的には、誰でも良いです。
- ・ 文系でも、理系でも構いません。
- ・ たくさんやりたい人でも、ちょっとだけやりたい人でも。

あえていうならば、以下：

- ・ 音信不通にならない人（これが一番重要）
- ・ 嘘をついたり、不誠実なことをしない人（これも大事）

注意事項：

- ・ 定員がありますので、希望者が全員配属される保証はありません。
- ・ 希望者はメールで事前に連絡する方が無難です。
- ・ もっと詳しく話をしてみたい人は、メールで連絡のこと。

研究室HP <http://int-info.com/>
連絡先 oomae.yuuto@nihon-u.ac.jp