一般社団法人　電子情報通信学会
THE INSTITUTE OF ELECTRONICS,
INFORMATION AND COMMUNICATION ENGINEERS

信学技報
IEICE Technical Report

AIモデルの説明可能性LIMEとShapley値からの属性推定リスクの評価

當麻僚太郎†　菊池　浩明†

† 明治大学総合数理学部
東京都中野区中野 4-21-1
E-mail: †{ev200598,kikn}@meiji.ac.jp

あらまし　機械学習モデルの公平性や学習の透明性を保証し，ユーザに納得感を与えるために機械学習モデルの出力を説明する説明可能性技術が注目されている．Amazon Web Services や Google Cloud Platform，Microsoft Azure などの主要なサービスの多くは Machine Learning as a Service（以下，MLaaS）と呼ばれるプラットフォーム上で提供されており，モデルの出力を説明するための手法をいくつか提供している．しかし，2022 年に Luo らが Shapley 値による説明からモデルへのプライベートな入力を推論出来ることを示した．ただし，Shapley 値以外の説明手法について同様の属性推定リスクが存在するかは明らかでない．そこで，Shapley 値と同じ局所的な説明手法である LIME に対して属性推論攻撃を行い，Shapley 値と LIME の属性推定リスクの違いについて評価する．

キーワード　Shapley 値，LIME，説明可能性，XAI，特徴推論

Evaluation of Feature Inference Risk from Explainable AI metrics LIME and Shapley Values

Ryotaro TOMA† and Hiroaki KIKUCHI†

† School of Interdisciplinary Mathematical Sciences, Meiji University
4-21-1 Nakano, Nakano-ku, Tokyo
E-mail: †{ev200598,kikn}@meiji.ac.jp

Abstract　Explainability has gained attention to ensure fairness and transparency in machine learning models, providing users with a sense of understanding. Many services such as Amazon Web Services, Google Cloud Platform, and Microsoft Azure running Machine Learning as a Service (MLaaS) platforms, which provide several methods to explain model. However, in 2022, Luo et al. demonstrated that Shapley value-based explanations could lead to inference of private attribute, posing privacy risks of information leakage from models. Nevertheless, it remains unclear whether the attribute inference risk on the alternative explainability exist or not. Therefore, this study evaluates the attribute inference risk on LIME and compare the vulnerability with the explanability Shapley values.

Key words　Shapley values, LIME, Explainability, XAI, Feature Inference

1. はじめに

近年，機械学習モデルは金融や雇用などの重要な領域で活用されることが増えている [1], [3], [4]．多くのモデルはニューラルネットワークやアンサンブルモデルなどの複雑な構造を持つため，入力に対する挙動がブラックボックスである．そのため，モデルの公平性や透明性を保証し，モデルの出力に対して説明を与えるための説明可能性技術 eXplainable AI（XAI）が注目されている [1], [2].

機械学習モデルを用いた商品サービスを提供する基盤である Machine Learning as a Service（以下，MLaaS）プラットフォームでは，様々な説明可能性技術を用いた特徴量の効果説明を提供している．特に Shapley 値 [13] を基にした説明は，Amazon Web Services [5] や Microsoft Azure [6] などの主要な MLaaS プラットフォームで提供されている．例えば，Amazon SageMaker Studio [7] では，図 1 に示すように各入力ベクトルに対する Shapley 値ベクトルと特徴量ごとの Shapley 値の平均絶対値による説明を与えている．

しかし，2022 年に Luo ら [8] は Shapley 値に基づく説明から本来秘匿されているモデルへの入力属性を推論出来ることを示した．Luo ら [8] は，最小勾配法による属性推定アルゴリズム ψ を提案している．しかしながら，説明可能性技術には Shapley

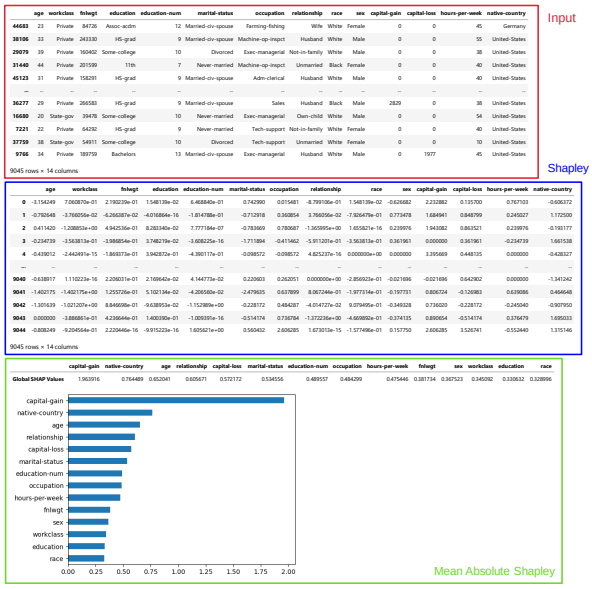

図 1: Amazon SageMaker を用いた Shapley 値の計算例

表 1: Shapley 値の計算に用いられる入力とモデル f の出力

	x_1	x_2	x_3	$f(x)$
$\boldsymbol{x}$	1.5	True	A	0.8
$\boldsymbol{x}^0$	−0.4	False	B	0.6
$\boldsymbol{x}_{[\{1\}]}$	1.5	False	B	0.9
$\boldsymbol{x}_{[\{2\}]}$	−0.4	True	B	0.8
$\boldsymbol{x}_{[\{3\}]}$	−0.4	False	A	0.2
$\boldsymbol{x}_{[\{1,2\}]}$	1.5	True	B	1.0
$\boldsymbol{x}_{[\{1,3\}]}$	1.5	False	A	0.6
$\boldsymbol{x}_{[\{2,3\}]}$	−0.4	True	A	0.4

表 2: Shapley 値の計算に用いるデータ

	x_1	x_2	x_3	$f(\boldsymbol{x})$
$\boldsymbol{x}$	1.5	True	A	0.8
$\boldsymbol{x}^1$	−0.4	False	B	0.6
$\boldsymbol{x}^2$	0.1	False	A	0.3
$\boldsymbol{x}^3$	0.8	True	C	0.9
$\boldsymbol{x}^4$	−1.1	True	A	0.2

値以外にも LIME [14] などの多くの提案があり，それらの中には Luo らの属性推定に対して脆弱なものがないか懸念される．

そこで，本研究では，Luo ら [8] の手法を基にして，Shapley 値と同様の局所的な説明手法である LIME [14] のプライバシーリスクを調査する．加えて，各説明変数と目的変数間の相関や攻撃者が採用するアルゴリズム ψ の違いに対する属性推定リスクの変化を明らかにする．本研究の主要な結論は，f と ψ が線形回帰モデルのときには，Shapley 値から正確にプライベートな特徴ベクトルの推定が可能であり，Luo らの攻撃に対して脆弱であることを理論的，実験的に示したことである．この提案方式を，3 つのデータセット Adult [10]，Bank Marketing [11]，Credit Card Client [12] について適用した結果を報告する．

2. 基本定義

2.1 Shapley 値

Shapley 値 [13] は協力ゲーム理論において連携プレイヤー間で利益を分配するための協調作業を定量化するために，1953 年に Shapley によって提案された指標である．本研究では，n 特徴量の入力 $\boldsymbol{x} = (x_1, \ldots, x_n)$ に対するモデルの出力 $f(\boldsymbol{x})$ の局所的な説明として Shapley 値ベクトル $\boldsymbol{s} = (s_1, \ldots, s_n)$ を与える．

特徴量のインデックス集合を $N = \{1, 2, \ldots, n\}$，N の部分集合を S，Shapley 値を計算するために参照するデータのサンプルを $\boldsymbol{x}^0$ とする．S に対応する入力を $\boldsymbol{x}_{[S]} = ((x_{[S]})_1, \ldots, (x_{[S]})_n)$ とする．ここで，$i = 1, \ldots, n$ について，

$$(x_{[S]})_i = \begin{cases} x_i & \text{if } i \in S, \\ x_i^0 & \text{otherwise.} \end{cases} \tag{1}$$

例えば，$\boldsymbol{x} = (\mathbf{2}, \mathbf{5}, \mathbf{1}, \mathbf{3})$，$\boldsymbol{x}^0 = (0, 3, 2, 1)$，$S = \{2, 3\}$ としたとき，$\boldsymbol{x}_{[S]} = (0, \mathbf{5}, \mathbf{1}, 1)$ である．このとき，Shapley 値 s_i は，

$$s_i = \sum_{S \subseteq N \setminus \{i\}} \frac{|S|!(n - |S| - 1)!}{n!} \Big(f(\boldsymbol{x}_{[S \cup \{i\}]}) - f(\boldsymbol{x}_{[S]}) \Big) \tag{2}$$

で定められる．$\boldsymbol{s} = \phi(\boldsymbol{x}; \boldsymbol{x}^0, f) = (s_1, \ldots, s_n)$ を Shapley 値を与える写像とする．

2.2 Shapley 値の計算例

入力 $\boldsymbol{x} = (1.5, \text{True}, A)$ に対し，参照サンプル $\boldsymbol{x}^0 = (-0.4, \text{False}, B)$ を用いて Shapley 値を計算する例を示す．ここで，攻撃対象のモデル f は表 1 の通りに出力する．

このとき，Shapley 値 $\boldsymbol{s} = (s_1, s_2, s_3)$ は式 (2) により次のように計算される．

$$\begin{aligned} s_1 = {} & \frac{0!(3-0-1)!}{3!}(f(\boldsymbol{x}_{[\{1\}]}) - f(\boldsymbol{x}_{[\{\}]})) \\ & + \frac{1!(3-1-1)!}{3!}(f(\boldsymbol{x}_{[\{1,2\}]}) - f(\boldsymbol{x}_{[\{2\}]})) \\ & + \frac{1!(3-1-1)!}{3!}(f(\boldsymbol{x}_{[\{1,3\}]}) - f(\boldsymbol{x}_{[\{3\}]})) \\ & + \frac{2!(3-2-1)!}{3!}(f(\boldsymbol{x}_{[\{1,2,3\}]}) - f(\boldsymbol{x}_{[\{2,3\}]})) \\ = {} & \frac{1}{3}(0.9 - 0.6) + \frac{1}{6}(1.0 - 0.8) \\ & + \frac{1}{6}(0.6 - 0.2) + \frac{1}{3}(0.8 - 0.4) \\ = {} & \frac{2}{6} \approx 0.33 \end{aligned} \tag{3}$$

s_2, s_3 も式 (3) と同様にして計算される．ここで，実際の Shapley 値の計算は複数の参照サンプルを用いる．そこで表 2 の $\boldsymbol{x}^1$，$\boldsymbol{x}^2$，$\boldsymbol{x}^3$，$\boldsymbol{x}^4$ を参照サンプルとし，それぞれ求めた Shapley 値を平均すると，結果として $\boldsymbol{s} = (0.32, 0.10, -0.12)$ が得られる．正の Shapley 値 s_1，s_2 に対応する属性 x_1，x_2 はモデル f の出力を増加させるように働き，負の Shapley 値 s_3 に対応する属性 x_3 はモデル f の出力を減少させるように働くことを示す．

2.3 LIME

Local Interpretable Model-agnostic Explanations (LIME) は，Ribeiro ら [14] によって提案された，入力ごとに説明を生成する手法である．n 特徴量の入力 $\boldsymbol{x} = (x_1, \ldots, x_n)$ が与えられたとき，その周辺のデータに対するモデル f のふるまいを，線形モ

表 3: 説明モデル g の学習に用いるデータ $\boldsymbol{z}$

	z_1	z_2	z_3	z'_1	z'_2	z'_3	$f(\boldsymbol{z})$
$\boldsymbol{x}$	1.5	True	A	1.5	1	1	0.8
$\boldsymbol{z}^1$	−0.4	False	B	−0.4	0	0	0.6
$\boldsymbol{z}^2$	0.1	False	A	0.1	0	1	0.3
$\boldsymbol{z}^3$	0.8	True	C	0.8	1	0	0.9
$\boldsymbol{z}^4$	−1.1	True	A	−1.1	1	1	0.2

デルや決定木，ルールベースなどの解釈が容易なモデル g で近似する．本研究では説明モデル g に線形モデル $g(\boldsymbol{x}) = \boldsymbol{w}^T\boldsymbol{x} + b$ を採用しているものとし，その係数ベクトル $\boldsymbol{w}$ が説明ベクトルとして与えられるものとする．

説明モデル g を学習するための損失関数 $\mathcal{L}$ は

$$\mathcal{L}(f, g, \pi_{\boldsymbol{x}}) = \sum_{\boldsymbol{z}, \boldsymbol{z}' \in Z} \pi_{\boldsymbol{x}}(\boldsymbol{z})(f(\boldsymbol{z}) - g(\boldsymbol{z}'))^2$$

と定義される．ここで，$\pi_{\boldsymbol{x}}(\boldsymbol{z}) = e^{-D(\boldsymbol{x},\boldsymbol{z})^2/\sigma^2}$ は距離 $D(\boldsymbol{x}, \boldsymbol{z})$ に応じた重みであり，σ はそのパラメタである．$\boldsymbol{z}$ は $\boldsymbol{x}$ と同じ n 次元ベクトルであり，$\boldsymbol{z}'$ は $\boldsymbol{z}$ の一部の特徴量を抜き出したベクトルである．Z は $\boldsymbol{z}$ と $\boldsymbol{z}'$ の組の集合である．

モデル g の取りうる集合を G，$\boldsymbol{w}$ の非ゼロ要素の数を $\Omega(g)$ としたとき，説明モデル g は目的関数 $\xi(\boldsymbol{x}) = \arg\min_{g \in G} \mathcal{L}(f, g, \pi_{\boldsymbol{x}}) + \Omega(g)$ を最小化する g^* で学習される．

2.4 LIME の計算例

Shapley 値の計算例と同様に，入力サンプル $\boldsymbol{x} = (1.5, \text{True}, A)$ に対して LIME を計算する例を示す．表 3 は，説明モデル g を学習するために用いるデータ $\boldsymbol{z}$，$\boldsymbol{z}'$ である．

ここで，距離を求める関数を

$$D(\boldsymbol{x}, \boldsymbol{z}) = \sqrt{(x_1 - z_1)^2 + (x_2 - z_2)^2 + (x_3 - z_3)^2}$$

とし，$\pi_{\boldsymbol{x}}(\boldsymbol{z})$ のパラメタ $\sigma = 2$ とする．説明モデル g を線形モデル $g(\boldsymbol{z}') = w_1 z'_1 + w_2 z'_2 + w_3 z'_3 + b$ とすると，損失関数は

$$\begin{aligned}\mathcal{L}(f, g, \pi_{\boldsymbol{x}}) = {} & (1.5w_1 + w_2 + w_3 + b - 0.8)^2 \\ & + 0.2(-0.4w_1 + b - 0.6)^2 \\ & + 0.5(0.1w_1 + w_3 + b - 0.3)^2 \\ & + 0.7(0.8w_1 + w_2 + b - 0.9)^2 \\ & + 0.2(-1.1w_1 + w_2 + w_3 + b - 0.2)^2\end{aligned} \tag{4}$$

である．ここで，w_1，w_2，w_3，b で $\mathcal{L}(f, g, \pi_{\boldsymbol{x}})$ を偏微分して，

$$\frac{\partial}{\partial w_1}\mathcal{L}(f, g, \pi_{\boldsymbol{x}}) = 5.94w_1 + 3.66w_2 + 2.66w_3 + 3.6b - 3.24 = 0,$$

$$\frac{\partial}{\partial w_2}\mathcal{L}(f, g, \pi_{\boldsymbol{x}}) = 3.68w_1 + 3.8w_2 + 2.4w_3 + 3.8b - 2.94 = 0,$$

$$\frac{\partial}{\partial w_3}\mathcal{L}(f, g, \pi_{\boldsymbol{x}}) = 2.66w_1 + 2.4w_2 + 3.4w_3 + 3.4b - 1.98 = 0,$$

$$\frac{\partial}{\partial b}\mathcal{L}(f, g, \pi_{\boldsymbol{x}}) = 3.62w_1 + 3.8w_2 + 3.4w_3 + 5.2b - 3.48 = 0$$

で与えられる線形式を解いて，$w_1 = 0.23$, $w_2 = 0.13$, $w_3 = -0.30$, $b = 0.61$ であり，説明ベクトルとして $\boldsymbol{w} = (0.23, 0.13, -0.30)$ が得られる．

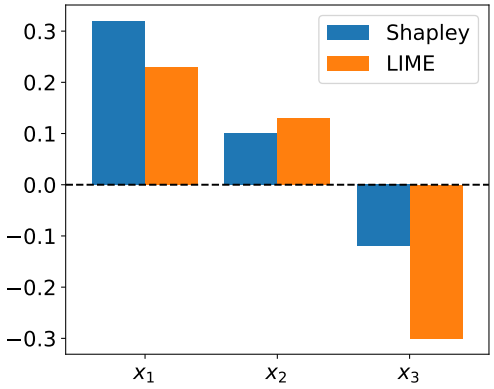

図 2: 入力サンプル $\boldsymbol{x} = (1.5, \text{True}, A)$ に対する Shapley 値と LIME による説明ベクトル

2.5 Shapley 値と LIME の説明可能性

Shapley 値と LIME の計算例において説明ベクトルはそれぞれ $\boldsymbol{s} = (s_1, s_2, s_3) = (0.32, 0.10, -0.12)$，$\boldsymbol{w} = (w_1, w_2, w_3) = (0.23, 0.13, -0.30)$ であった．それぞれを図 2 に示す．$s_1 > s_2 > 0 > s_3$，$w_1 > w_2 > 0 > w_3$ であり，各特徴量の順序が整合した説明が得られた．

しかし，Shapley 値の絶対値 $|s_1| > |s_3|$ に関しては，特徴量 x_1 は特徴量 x_3 よりモデル f の出力に大きい影響を与えているが，LIME による説明ベクトルでは $|w_1| < |w_3|$ であり，特徴量 x_3 の方がより重要であると説明される．Shapley 値と LIME の計算例におけるモデルは $f = \frac{1}{1+\exp(-x_1-x_2-x_3)}$ としている．ここで，True，False を 1，0 に，A，B，C を −1，1，0 にエンコードしている．入力サンプルは $\boldsymbol{x} = (1.5, \text{True}, A) = (1.5, 1, -1)$ であるため，$|x_1| > |x_2| = |x_3|$ の順に重要度が並ぶような説明が最も理想的である．従って，この計算例においては，LIME より Shapley 値の方がより良い説明を与えている．

3. 基本原理

3.1 Feature Inference Attack on Shapley Values [8]

3.1.1 システムモデル

Luo ら [8] は，サービス事業者が機密の学習データセット $\mathcal{X}_{train}$ に基づいてブラックボックスモデル f を訓練し，MLaaS プラットフォーム上に展開するシステムモデルを仮定している．その実験概要図を図 3 に示す．

ユーザはプライベートな入力 $\boldsymbol{x}$ を送信し，モデルの出力 $\hat{\boldsymbol{y}} = (y_1, \ldots, y_c)$ と n 個の説明値のベクトル $\boldsymbol{s} = (s_1, \ldots, s_n)$ を得る．ただし，c は正解ラベルの数である．$c > 2$ のとき対応する説明ベクトルは本来 c 個分得られるが，ここでは $c = 1$ とする．

3.1.2 攻撃者

攻撃者は $\mathcal{X}_{train}$ と同じ分布に従う補助データセット $\mathcal{X}_{aux}$ を持っていると仮定する．全ての $\boldsymbol{x}_{aux} \in \mathcal{X}_{aux}$ をモデル f に送信し，対応する説明データ $\mathcal{S}_{aux}$ を得る．そして，$\psi : \mathcal{S}_{aux} \to \mathcal{X}_{aux}$

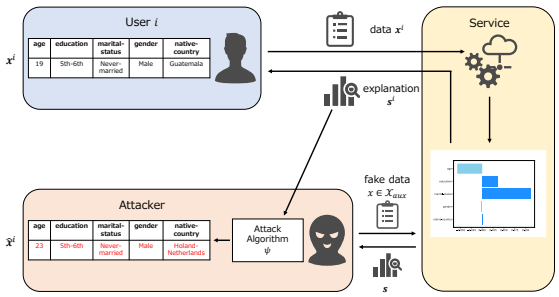

図 3: 全体概要図

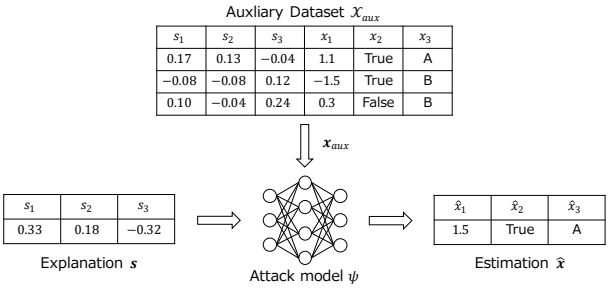

図 4: 属性推論攻撃の概要図

Algorithm 1 補助データセットを用いた推定 [8]

Input: ブラックボックスモデル f，補助データセット $\mathcal{X}_{aux}$，学習率 α，攻撃対象の Shapley 値ベクトル $\boldsymbol{s}$

Output: 推論されたプライベートな入力 $\hat{\boldsymbol{x}}$

$\mathcal{S}_{aux} \leftarrow \phi(\mathcal{X}_{aux}; f)$
$\theta_\psi \leftarrow \mathcal{N}(0, 1)$
for each epoch **do**
  for each batch **do**
    $loss \leftarrow 0$
    $B \leftarrow$ randomly select a batch of samples
    for $j \in 1, \ldots, |B|$ **do**
      $(\hat{\boldsymbol{x}}_{aux})^j \leftarrow \psi((\boldsymbol{s}_{aux})^j; \theta_\psi)$
      $loss \leftarrow loss + L((\hat{\boldsymbol{x}}_{aux})^j, (\boldsymbol{x}_{aux})^j)$
    end for
    $\theta_\psi' \leftarrow \theta_\psi - \alpha \nabla_{\theta_\psi} loss$
  end for
end for
$\hat{\boldsymbol{x}} \leftarrow \psi(\boldsymbol{s}; \theta_\psi)$
return $\hat{\boldsymbol{x}}$

が誤差 $L(\psi(\mathcal{S}_{aux}), \mathcal{X}_{aux})$ を最小化するように訓練する．プライベートな入力 $\boldsymbol{x}$ の推測値は，与えられた Shapley 値 $\boldsymbol{s}$ を用いて $\hat{\boldsymbol{x}} = \psi(\boldsymbol{s})$ とする．攻撃者の属性推論を図 4 に示す．このアルゴリズムを Algorithm 1 に示す．

3.1.3 属性推論攻撃の例

10 行 5 列のサンプルデータに対して属性推論攻撃を行う例を示す．データの生成は，標準正規分布に従う独立な 3 つの乱数列 n_1，n_2，n_3 を用いて，$x_1 = n_1$，$x_2 = n_2$，$x_3 = n_1 n_2$，$x_4 = n_2 n_3$，$y = x_1 - x_3 x_4$ とする．生成したデータを表 4 に示す．

表 4: サンプルデータ

	x_1	x_2	x_3	x_4	y
$\mathcal{X}_{test}$	1.8	0.1	0.3	−0.4	1.9
	0.4	1.5	0.6	1.0	−0.2
	1.0	0.8	0.7	0.7	0.5
	2.2	0.1	0.3	−0.1	2.2
	1.9	0.4	0.8	1.0	1.1
$\mathcal{X}_{train}$（$\mathcal{X}_{aux}$）	−1.0	0.3	−0.3	−0.5	−1.2
	1.0	1.5	1.4	0.1	0.9
	−0.2	−0.2	0.0	0.0	−0.2
	−0.1	0.3	0.0	0.5	−0.1
	0.4	−0.9	−0.4	−1.3	−0.1

表 5: Shapley 値 $\mathcal{S}_{test}$

	s_1	s_2	s_3	s_4
$\boldsymbol{x}^1$	1.30	0.02	0.06	−0.04
$\boldsymbol{x}^2$	0.28	−0.29	0.18	0.34
$\boldsymbol{x}^3$	0.72	−0.13	0.21	0.26
$\boldsymbol{x}^4$	1.59	0.02	0.06	0.04
$\boldsymbol{x}^5$	1.37	−0.04	0.25	0.34

表 6: モデル f と推定アルゴリズム ψ の組み合わせに対する攻撃者の MAE

f	ψ	攻撃者の MAE				
		x_1	x_2	x_3	x_4	平均
線形回帰	線形回帰	0.00	0.00	0.00	0.00	0.00
線形回帰	決定木	0.82	1.24	0.74	1.18	1.00
決定木	線形回帰	0.69	0.52	0.41	0.53	0.54
決定木	決定木	0.68	1.16	0.82	0.54	0.80
平均		0.55	0.73	0.49	0.59	

データの 1〜5 行目を $\mathcal{X}_{test}$，6〜10 行目を $\mathcal{X}_{train}$ とする．Shapley 値は $\mathcal{X}_{train}$ の各行を参照サンプルとし，それぞれ求めた Shapley 値の平均，すなわち $\boldsymbol{s} = \frac{1}{5}\sum_{j=6}^{10} \phi(\boldsymbol{x}, \boldsymbol{x}^j)$ とする．

例として，$\mathcal{X}_{train}$ をフィッティングした線形回帰モデル f について，$\mathcal{X}_{test}$ に対する Shapley 値 $\mathcal{S}_{test}$ を表 5 に示す．モデル f と推定アルゴリズム ψ の組み合わせに対する攻撃者の MAE を表 6 に示す．f と ψ がどちらも線形モデルのとき，誤差 0 で正確に入力特徴を推論されていることに注意せよ．

3.2 線形モデルに対する説明可能性と属性推定リスク

[補題 1] f を線形回帰による説明モデルとする．任意の $i \in N$，$S \subseteq N \setminus \{i\}$，参照ベクトル $(x_1^0, x_2^0, \ldots, x_n^0)$ について，

$$f(\boldsymbol{x}_{[S\cup\{i\}]}) - f(\boldsymbol{x}_{[S]}) = \beta_i(x_i - x_i^0) \tag{5}$$

である．

証明) 説明モデル f を $f(\boldsymbol{x}) = \beta_0 + \beta_1 x_1 + \cdots + \beta_n x_n$ と表すと，線形モデルのため，

$$\begin{aligned} f(\boldsymbol{x}_{[S\cup\{i\}]}) - f(\boldsymbol{x}_{[S]}) &= \beta_0 + \sum_{k\in S\cup\{i\}} \beta_k x_k + \sum_{k\in N\setminus(S\cup\{i\})} \beta_k x_k^0 \\ &\quad - \beta_0 + \sum_{k\in S} \beta_k x_k + \sum_{k\in N\setminus S} \beta_k x_k^0 \\ &= \beta_i(x_i - x_i^0) \end{aligned}$$

表 7: 使用データセット

データセット	レコード数	クラス	特徴量
Adult [10]	48, 842	2	14
Bank Marketing [11]	45, 211	2	16
Credit Card [12]	30, 000	2	24

□

[命題 2] f を線形モデルによる説明モデル，ψ を線形モデルによる推定アルゴリズムとする．$n < |\mathcal{X}_{aux}|$ のとき，ψ による Shapley 値からの攻撃者の MAE = 0 である．

証明) 補題 1 より，s_i について

$$\begin{aligned} s_i &= \sum_{S \subseteq N \setminus \{i\}} \frac{|S|!(n-|S|-1)!}{n!} f(\boldsymbol{x}_{[S\cup\{i\}]}) - f(\boldsymbol{x}_{[S]}) \\ &= \sum_{S \subseteq N \setminus \{i\}} \frac{|S|!(n-|S|-1)!}{n!} \beta_i (x_i - x_i^0) \\ &= \lambda_i (x_i - x_i^0) \end{aligned}$$

ここで，$\lambda_i = \sum_{S \subseteq N \setminus \{i\}} \frac{|S|!(n-|S|-1)!}{n!} \beta_i$ をまとめた項である．したがって，ψ による推定モデルは，

$$\begin{aligned} \hat{x}_i &= \alpha_0 + \alpha_1 s_1 + \cdots + \alpha_n s_n \\ &= \alpha_0 + \alpha_1(\lambda_1(x_1 - x_1^0)) + \cdots + \alpha_n(\lambda_n(x_n - x_n^0)) \\ &= \alpha_0 - \sum_{k=1}^{n} \alpha_k \lambda_k x_k^0 + \alpha_1 \lambda_1 x_1 + \cdots + \alpha_n \lambda_n x_n \\ &= \gamma_0 + \gamma_1 x_1 + \cdots + \gamma_n x_n \end{aligned}$$

と，$x_1, \ldots, x_n$ の線形式で与えられる．ただし，ここで $\gamma_i = \alpha_i \lambda_i$，$\gamma_0 = \alpha_0 - \sum_{k=1}^{n} \alpha_k \lambda_k x_k^0$ をまとめた項である．

$\mathcal{X}_{aux}$ が十分に大きく，$n+1$ 以上の行数があるならば，最小二乗法により，誤差なく $\gamma_1, \ldots, \gamma_n$ が算出される． □

このとき，$\alpha_0 = x_i^0$，$\alpha_i = 1/\lambda_i$ と算出され，$j = 1, ..., i-1, i+1, ..., n$ については $\alpha_j = 0$ となる．結果のところ，線形式によるモデルの Shapley 値を提供すると，属性推定リスクが上がることを意味している．

4. 提 案 方 式

想定する攻撃は先行研究と同様に，図 3 とする．実験に用いるデータセットを表 7 に示す．

この設定下において，LIME を含む説明モデル f や攻撃者が採用する最適化アルゴリズム，各説明変数と目的変数間の相関などに対する属性推定リスクを明らかにすることを目的とする．

4.1 評 価 指 標

属性推定リスクの評価に用いる指標は，攻撃者の MAE と攻撃成功率 SR の 2 つである．

4.1.1 攻撃者の MAE

MAE（Mean Absolute Error）は誤差の絶対値の平均を取る．m 行 n 列のデータセット $\boldsymbol{x}$ に対する推定データ $\hat{\boldsymbol{x}}$ の攻撃者の MAE は

$$MAE(\hat{\boldsymbol{x}}, \boldsymbol{x}) = \frac{1}{mn} \sum_{j=1}^{m} \sum_{i=1}^{n} |\hat{x}_i^j - x_i^j| \tag{6}$$

で与えられる．

4.1.2 攻撃成功率 SR

SR（Success Rate）は攻撃によって正しく推定された入力特徴量の割合を表す．質的変数に対しては推定カテゴリが一致している時，量的変数に対しては推定値と真の値との誤差の絶対値が閾値以下である時成功と判定する．$\boldsymbol{x}$ と推定 $\hat{\boldsymbol{x}}$ の SR は

$$SR(\hat{\boldsymbol{x}}, \boldsymbol{x}) = \frac{success(\hat{\boldsymbol{x}}, \boldsymbol{x})}{mn} \tag{7}$$

で与えられる．ここで，$success(\hat{\boldsymbol{x}}, \boldsymbol{x})$ を推定に成功した入力特徴量の個数とする．

4.2 実 験 方 法

4.2.1 実験 1：説明可能性の推定リスク

Shapley 値と LIME 値のブラックボックスモデル f に対する属性推定リスクを調べる．攻撃対象となるブラックボックスモデル f はニューラルネットワーク（NN），ランダムフォレスト（RF），勾配ブースティング木（GBDT），カーネル SVM（SVM）に線形回帰モデル（LR）を加えた 5 種類である．

NN は Pytorch [9] で実装し，n 次元の入力層と c 次元の出力層を持ち，ニューロン数 $2n$ の隠れ層を 2 つ持つ．活性化関数は出力層のみ softmax でそれ以外は ReLU を用いる．RF，SVM，GBDT は sklearn で実装した．RF と GBDT の木の数と最大の深さは，それぞれ $(100, 5)$，$(100, 3)$ とする．その他のパラメータは全てデフォルトの値とする．RG-E は $\mathcal{X}_{aux}$ に基づく経験分布からのランダム予測である．

4.2.2 実験 2：最適化アルゴリズムの推定リスク

攻撃者が採用する最適化アルゴリズムを変化させたときの属性推定リスクを調査する．攻撃者の採用する推定アルゴリズムは，攻撃者が Algorithm 1 において攻撃モデル ψ のパラメータ θ_ψ を更新する

$$\theta_\psi \leftarrow \theta_\psi - \alpha \nabla_{\theta_\psi} loss \tag{8}$$

の変種を意味する．本研究では，勾配降下法ベースの最適化アルゴリズムとして，SGD [15]，Momentum [16]，RMSprop [17]，Adam [18] の 4 種類を調べる．推定モデル ψ は先行研究と同じく，特徴量の数 n に対して隠れ層のニューロン数 $4n$，出力層のニューロン数 n のニューラルネットワークとし，活性化関数は全てで sigmoid 関数を用いる．実装は Pytorch で行い，SGD の学習率 $\eta = 0.01$，Momentum（すなわち SGD のうち $momentum \neq 0$ のもの）の学習率 $\eta = 0.01$，$momentum = 0.9$ と指定したもの以外は全てデフォルトのパラメータを用いる．

4.3 実験結果と考察

4.3.1 結　果　1

攻撃者が持つデータセット $\mathcal{X}_{aux}$ の行数を変化させたときの，Shapley 値に対する属性推論の結果を図 5，6 に，LIME に対する属性推論の結果を図 7，8 に示す．

Shapley 値と LIME の双方において，データセットの行数 $|\mathcal{X}_{aux}|$ が増えるにしたがって攻撃者の MAE が下がり SR が上がった．特に，モデル f が線形のとき Shapley 値からの推定リ

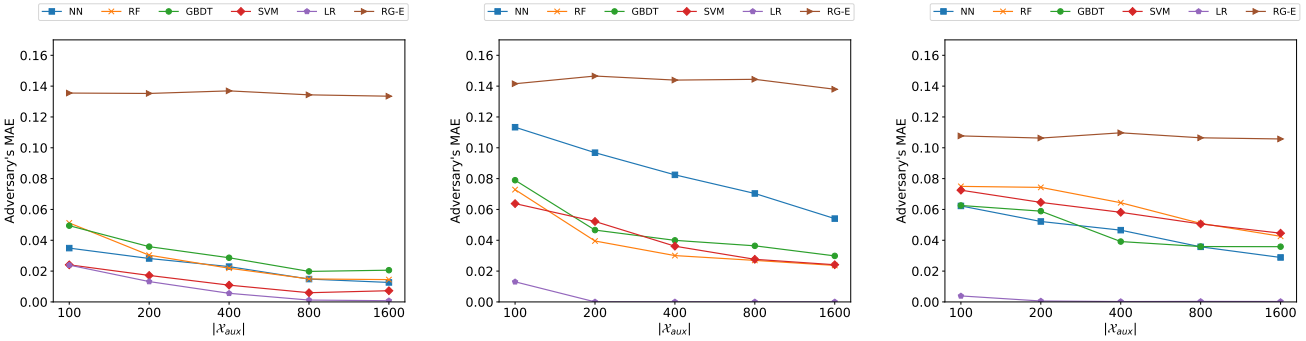

(a) Adult **(b)** Bank Marketing **(c)** Credit Card

図 5: 補助データセットの大きさ $|\mathcal{X}_{aux}|$ と f についての Shapley 値からの属性推論攻撃の MAE

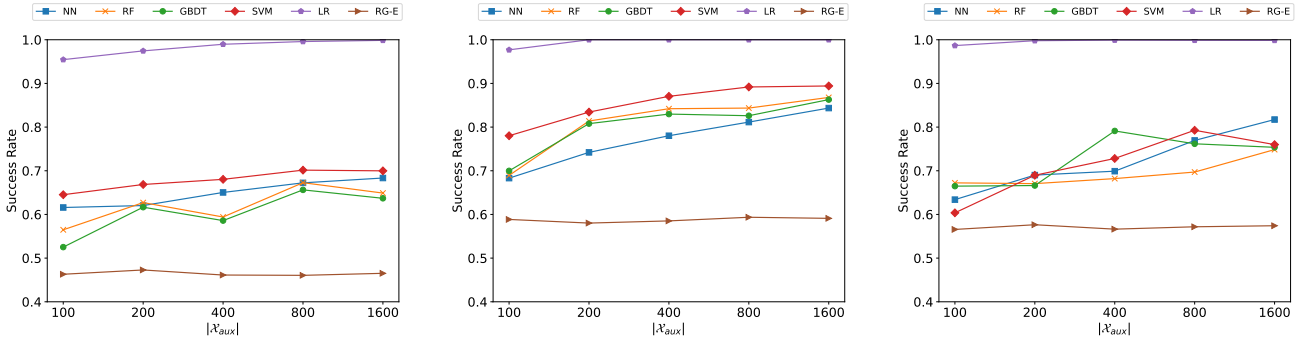

(a) Adult **(b)** Bank Marketing **(c)** Credit Card

図 6: 補助データセットの大きさ $|\mathcal{X}_{aux}|$ と f についての Shapley 値からの属性推論攻撃の SR

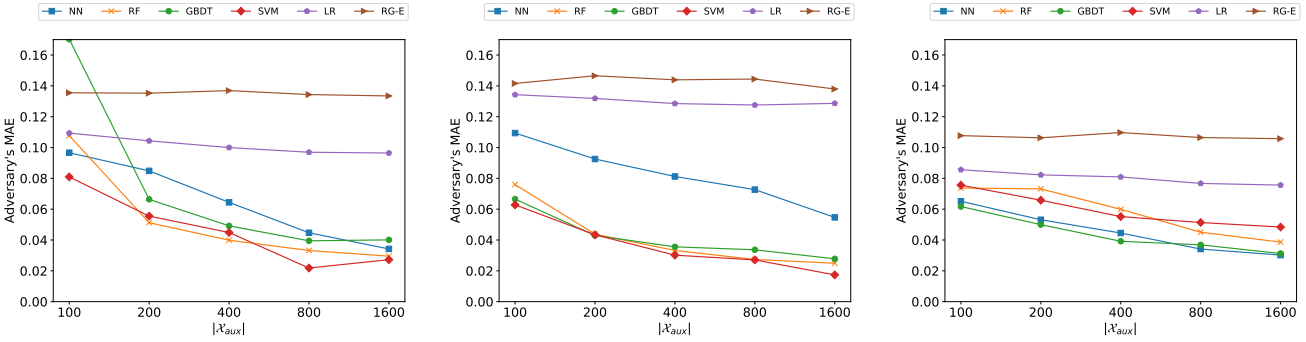

(a) Adult **(b)** Bank Marketing **(c)** Credit Card

図 7: 補助データセットの大きさ $|\mathcal{X}_{aux}|$ と f についての LIME からの属性推論攻撃の MAE

スクが増加した．

Shapley 値と LIME それぞれについて，補助データセットの行数 $|\mathcal{X}_{aux}|$ による攻撃者の MAE と SR のモデルの平均値をそれぞれ図 9，10 に示す．全ての $|\mathcal{X}_{aux}|$ について，LIME より Shapley 値の方が属性推定リスクが高い．

また，Shapley 値に対する攻撃について，モデル f の構造ごとに攻撃者の MAE と SR の全 $|\mathcal{X}_{aux}|$ の平均値を図 11，12 に示す．攻撃者の MAE と SR の双方で最も属性推定リスクが高いのは線形モデルである．線形モデルの脆弱性は命題 3.2 で証明しているが，補助データの行数 $|\mathcal{X}_{aux}|$ が少ない場合には属性推論に誤差が生じている．これは Shapley 値の計算が実際にはサンプリング手法を用いているため，真の Shapley 値ではなく近似値であることが影響している．

4.3.2 結　果　2

最適化アルゴリズムの MAE と SR の違いを図 13 に示す．

図 13 の攻撃者の MAE と SR に共通して，SGD が最も属性推定の精度が低く，RMSprop が最も高い．全ての最適化アルゴリズムで，$|\mathcal{X}_{aux}|$ が増加するにつれて攻撃者の MAE は減少し SR は増加した．また，Adam と RMSprop は攻撃者の MAE が小さく，SGD と Momentum は攻撃者の MAE が大きい傾向が見られた．Adam と RMSprop は SGD，Momentum と異なり，モデルの訓練中に学習率の調整を行う手法である．したがって，学習率の調整を行うことで属性推定の精度が向上している．

5. おわりに

Luo ら [8] の手法に基づき，Shapley 値と LIME の属性推定リ

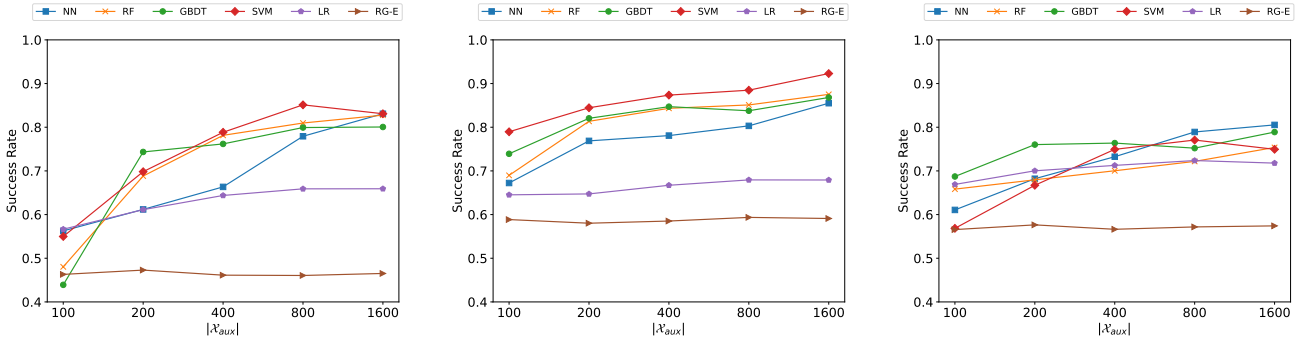

(a) Adult (b) Bank Marketing (c) Credit Card

図 8: 補助データセットの大きさ $|\mathcal{X}_{aux}|$ と f についての LIME からの属性推論攻撃の SR

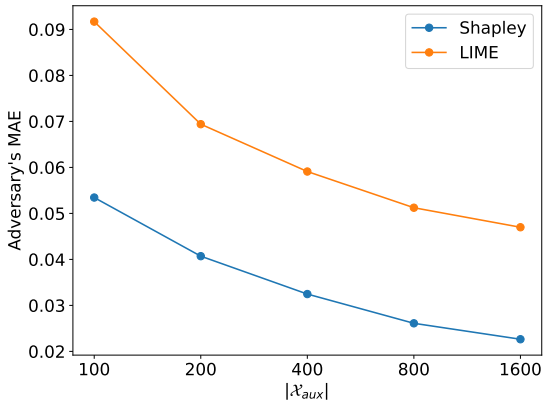

図 9: 補助データセットの大きさ $|\mathcal{X}_{aux}|$ についての攻撃者の平均 MAE

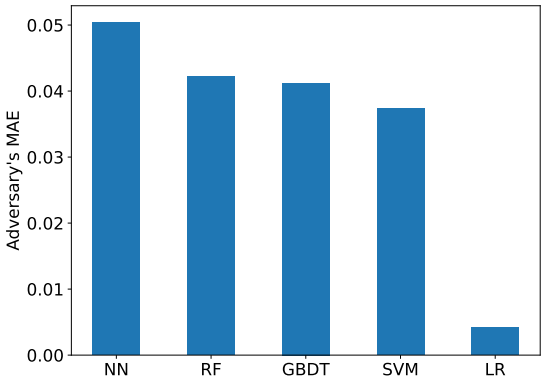

図 11: モデル f の攻撃者の MAE の平均

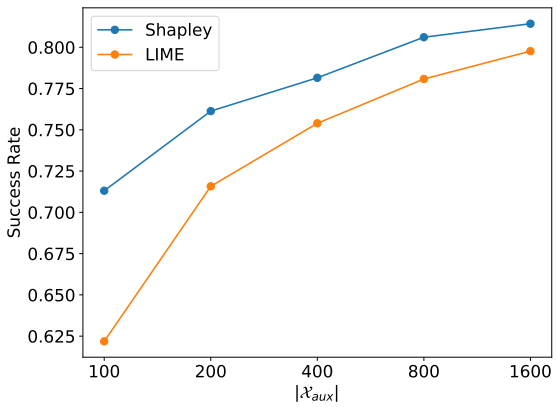

図 10: 補助データセットの大きさ $|\mathcal{X}_{aux}|$ についての平均 SR

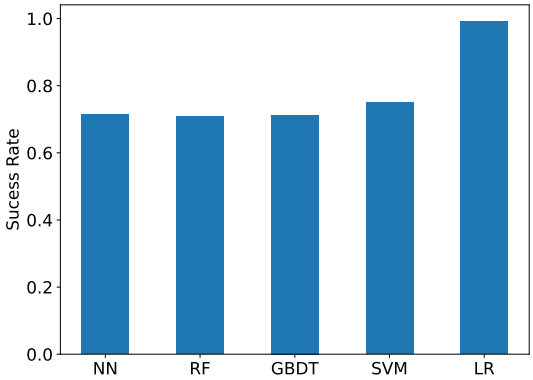

図 12: モデル f の SR の平均

スクを調べた．オープンデータを用いた実験結果より，全ての説明モデル f に対して，どちらもランダムな予測よりも高い精度で属性推定された．また，Shapley 値と LIME の双方で，補助データセットの大きさが増えるにつれて攻撃精度が増加する傾向が見られた．さらに，f と ψ が線形モデルのとき，Shapley 値から正確にプライベートな入力特徴量の推定が可能であることを証明した．

属性推定のリスクを抑えるために，公開する Shapley 値や LIME の値にノイズを加えることが考えられる．2022 年に Bozorgpanah ら [19] はデータそのものを匿名加工や差分プライバシーによって保護しても，ある程度であれば Shapley 値の有用性を損なわないことを報告している．そのため，データと説明ベクトルに対する加工によって属性推定リスクを下げられることが期待される．また，MLaaS プラットフォームのリクエスト数制限やアクセス制御によって守る手法も有効である．

今後の課題として，推定リスクを低減した XAI 手法の提案や説明ベクトルにノイズを加えたときの属性推定リスクの調査などが挙げられる．

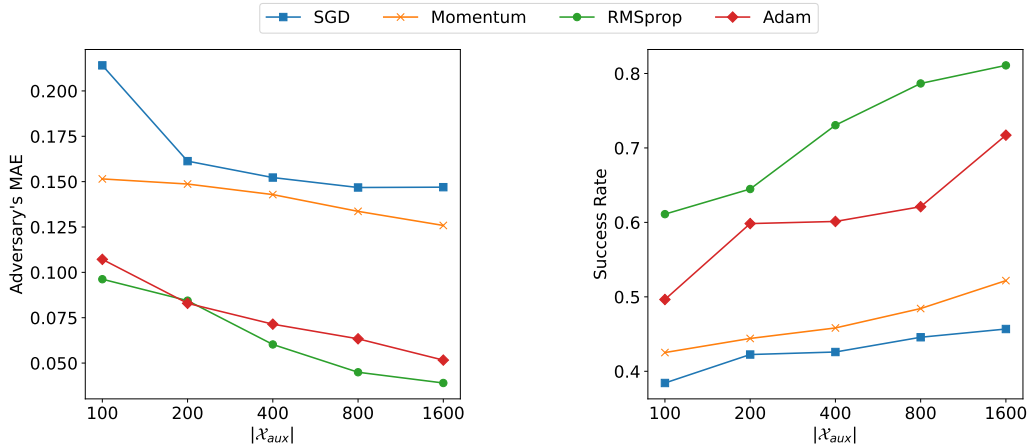

図 13: 攻撃者が採用する最適化アルゴリズムに対する，補助データセットの大きさを変化させたときの攻撃者の MAE と SR

文　　献

[1] Cynthia Rudin, "Stop explaining black box machine learning models forhigh stakes decisions and use interpretable models instead," *Nature Machine Intelligence* 1, 5, pp.206-215, 2019.

[2] Jianbo Chen, et al. "Learning to Explain: An Information-Theoretic Perspective on Model Interpretation", In *Proceedings of the 35th International Conference on Machine Learning, ICML 2018, Stockholmsmässan, Stockholm, Sweden, July*, Vol. 80. PMLR, pp.882-891, 2018.

[3] Akira Sakai, et al. "Medical Professional Enhancement Using Explainable Artificial Intelligence in Fetal Cardiac Ultrasound Screening", Biomedicines 10, no.3, p.551, 2022.

[4] Zest AI, "Why picking the right AI-credit decisioning partner matters", Zest AI Insights. https://www.zest.ai/insights/why-zaml-makes-your-ml-platform-better, November 2023.

[5] Amazon Web Services, Inc, "Amazon SageMaker Clarify Model Explainability", Amazon SageMaker Documentation. https://docs.aws.amazon.com/sagemaker/latest/dg/clarify-model-explainability.html, November 2023.

[6] Microsoft, "Model interpretability", Azure Machine Learning Documentation. https://learn.microsoft.com/en-us/azure/machine-learning/how-to-machine-learning-interpretability, November 2023.

[7] Amazon Web Services, Inc. "Amazon SageMaker Studio", Amazon SageMaker Documentation. https://docs.aws.amazon.com/sagemaker/latest/dg/studio-updated.html, November 2023.

[8] Xinjian Luo, Yangfan Jiang, and Xiaokui Xiao, "Feature Inference Attack on Shapley Values", In *Proceedings of the 2022 ACM SIGSAC Conference on Computer and Communications Security (CCS '22), November, Los Angeles, CA, USA*, pp.1-15, 2022.

[9] Adam Paszke, et al. "PyTorch: An Imperative Style, High-Performance Deep Learning Library", In Advances in Neural Information Processing Systems 32 (pp. 8024–8035). Curran Associates, Inc. 2019.

[10] Becker Barry, and Kohavi Ronny, "Adult", UCI Machine Learning Repository, DOI:10.24432/C5XW20.

[11] Sérgio Moro, Paulo Cortez, and Paulo Rita, "A data-driven approach to predict the success of bank telemarketing", Decision Support Systems 62, pp.22–31, 2014.

[12] I-Cheng Yeh and Che-hui Lien, "The comparisons of data mining techniques for the predictive accuracy of probability of default of credit card clients", Expert systems with applications 36, 2, pp.2473–2480, 2009.

[13] Lloyd S Shapley, "A value for n-person games", Vol. 2. Princeton UniversityPress, pp.303-317, 1953.

[14] Marco Ribeiro, Sameer Singh, and Carlos Guestrin, ""Why Should I Trust You?": Explaining the Predictions of Any Classifier", In Proceedings of the 2016 Conference of the North American Chapter of the Association for Computational Linguistics: Demonstrations, pp.97–101, San Diego, California. Association for Computational Linguistics, 2016.

[15] Bottou, Léon, "Online Algorithms and Stochastic Approximations"., Cambridge University Press, ISBN 978-0-521-65263-6, 1998.

[16] Ilya Sutskever, James Martens, George Dahl, Geoffrey Hinton, "On the importance of initialization and momentum in deep learning", In Proceedings of the 30th international conference on machine learning (ICML-13). Vol. 28. Atlanta, GA. pp. 1139-1147, 2013.

[17] Geoffrey Hinton, "Coursera Neural Networks for Machine Learning Lecture 6", https://www.cs.toronto.edu/~tijmen/csc321/slides/lecture_slides_lec6.pdf.

[18] Diederik P. Kingma, Jimmy Ba, "Adam: A Method for Stochastic Optimization", ICLR 2015, 2015.

[19] Bozorgpanah, A., Torra, V., and Aliahmadipour, L, "Privacy and Explainability: The Effects of Data Protection on Shapley Values", Technologies 10, 6, p.125, 2022.