

# プライバシー保護一人称ビジョン

～安全な画像認識の基盤技術～

米谷 竜

東京大学生産技術研究所



## コンピュータビジョン = 「見え方の科学」

- 計算機に外界を視覚的に理解させたい
- 画像認識: 画像に映る外界の内容を判断できるか?




## 統計的機械学習に基づく画像認識

- 判断のためのモデルを大量の事例 (画像+判断) から学習



## とはいえ撮影・提供しにくいデータも存在する

- 例: ウェアラブルカメラで撮影されたライフログ映像  
-> 人々のプライベートな瞬間が含まれるため




## 解決したい問題

画像認識技術が社会的に受容される将来を切り拓くため、ウェアラブルカメラ映像等センシティブなデータを、安心して扱えるコンピュータビジョンの基盤技術を開発したい。

## 安全な画像認識を目指して: その1

- 画像から抽出された特徴量のみを計算機に提供する?



→ 不十分! 特徴量から元画像をある程度復元可能



## 安全な画像認識を目指して: その2

- 特徴量を暗号化して提供
- 暗号化したまま計算が可能な準同型暗号の利用



## 今回の成果


ある条件下において、データ提供者の持つプライベートな画像データの内容が分からないようにしつつ、計算機がその画像データを用いて統計的機械学習を行える枠組みを提案し、いくつかの実験でその有効性を確認しました。

## Privacy-Preserving Visual Learning with Doubly-Permuted Homomorphic Encryption

Ryo Yonetani, Vishnu Naresh Boddeti, Kris M. Kitani, and Yoichi Sato, International Conference on Computer Vision (ICCV), 2017


### Introduction: Distributed Supervised Learning

1. Aggregator distributes classifier weight  $w$
2. Users update  $w$  using own data and send  $w^{(i)}$  back to the aggregator
3. Aggregator computes  $w_{new} = \frac{1}{N} \sum_i w^{(i)}$  and distributes it again




### Proposed: Doubly-Permuted Homomorphic Encryption (DPHE)

A new homomorphic encryption scheme for sparse high-dimensional data



### Two permutation matrices for encrypting non-zero indices

$P^{(i)}$ : shared between user  $U^{(i)}$  and the aggregator |  $P$ : shared between all users but the aggregator



### Homomorphic Encryption for Distributed Learning

Using Paillier cryptosystem [Paillier, '99] for secure aggregation of classifiers


Encryption (pub-key  $n = pq, g = n + 1$ )

$r$  is a random variable generated for each encryption



Computing sum over encrypted data:

$$E(x)E(y) = g^{x+y} (r_x r_y)^n \bmod n^2 = E(x+y)$$




Decryption (priv-key  $p, q$ )

$E(x)$  cannot be inverted to  $x$  without both  $p$  and  $q$

### Homomorphically-encrypted distributed learning protocol

1. Key generator issues and distributes a pub key to all parties
2. Users encrypt  $w^{(i)}$  and send  $E(w^{(i)})$  to the aggregator
3. Aggregator computes  $E(\sum_i w^{(i)}) = \prod_i E(w^{(i)})$  and sends it to the key generator for decrypting  $E(\sum_i w^{(i)})$  to obtain  $\sum_i w^{(i)}$



Pros:  $w_{new} = \frac{1}{N} \sum_i w^{(i)}$  can be computed without knowing each plain  $w^{(i)}$

Cons: Encryption time (e.g., 10 minutes\* to encrypt 200k weights)

\* Using Python+GMP. More efficient implementations are available at <https://medium.com/@elpa-a/benchmarking-paillier-encryption-15531a0b5a68>

### Experiments

#### Implementation details

- Classifier was updated via SGD with the elastic net regularization
- Feature were extracted from pre-trained deep nets (e.g., ResNet trained on ImageNet)

#### Performance evaluation

- DPHE performed comparably to SoTA methods (HZRS14, ZF13, LLWT15) while preserving privacy and outperformed existing privacy-preserving methods (PRR10, RA12)

Classification accuracy (# users = 5)	Methods	Caltech101	Caltech256	Privacy	Encryption time		
					Sparsity	Accuracy	Time (sec)
HZRS14	93.4 ± 0.5	N/A	NO	0.01	89.7	620	
	85.4 ± 0.4	72.6 ± 0.1	NO	95.6	88.2	62	
	41.6 ± 1.2	55.9 ± 0.5	YES				
	83.8 ± 1.1	68.0 ± 0.3	YES				
DPHE (Ours)	89.3 ± 0.8	74.7 ± 0.4	YES	Number of users			
				# Users	Accuracy		
				10	88.9		
				100	85.6		