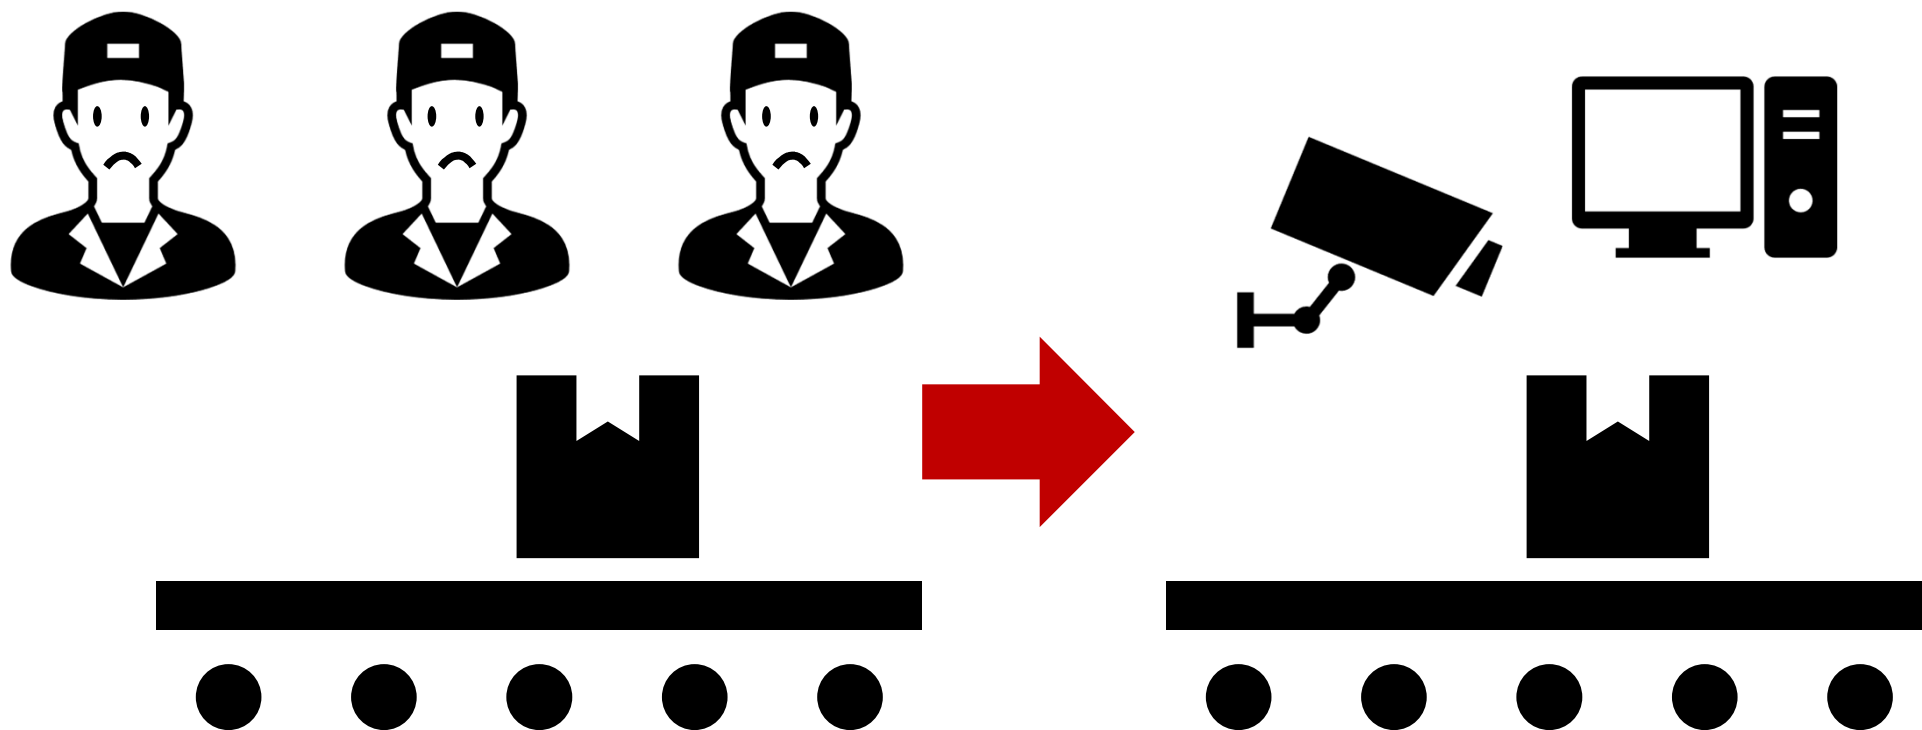


# 少数不良品サンプル下における深層学習による 正常モデル生成と異常品検出

岐阜大学 工学部 電気電子・情報工学科  
准教授 加藤 邦人

2019年7月11日

# 外観検査の現状




● ● ● ● ●  
たくさんの検査員が必要

- 人手不足
- 単純作業で重労働  
→見落とし増

● ● ● ● ●  
画像による自動化

↓  
AI（深層学習）による高精度化が期待されている。


# 深層学習による外観検査の問題



通常のアプローチ  
入力画像を正常か不良かを  
判定させる。

## 大問題に直面！


正常と不良を学習するには  
正常と不良の学習サンプルが  
同数程度必要。



不良率0.01%の製造ラインでは  
不良サンプルがなかなか  
手に入らない！

サンプルを集めるには数年かかる！

# 新技術の特徴



大量の  
良品サンプル

## 特徴1

大量に手に入る良品サンプルと  
ごく少量の不良品サンプルから  
正常を学習可能！



ごく少量の  
不良品サンプル


## 特徴2

学習された特徴は正規分布に  
従うため、不良とするしきい値  
決定が容易！

# 新技術の概要


## Adversarial AutoEncoder (AAE) + 正規分布

### オートエンコーダ



# オートエンコーダの概要

大量の学習サンプルを非常によく表す低次元特徴が得られる



画像特徴を抽出しながら  
低次元に圧縮する

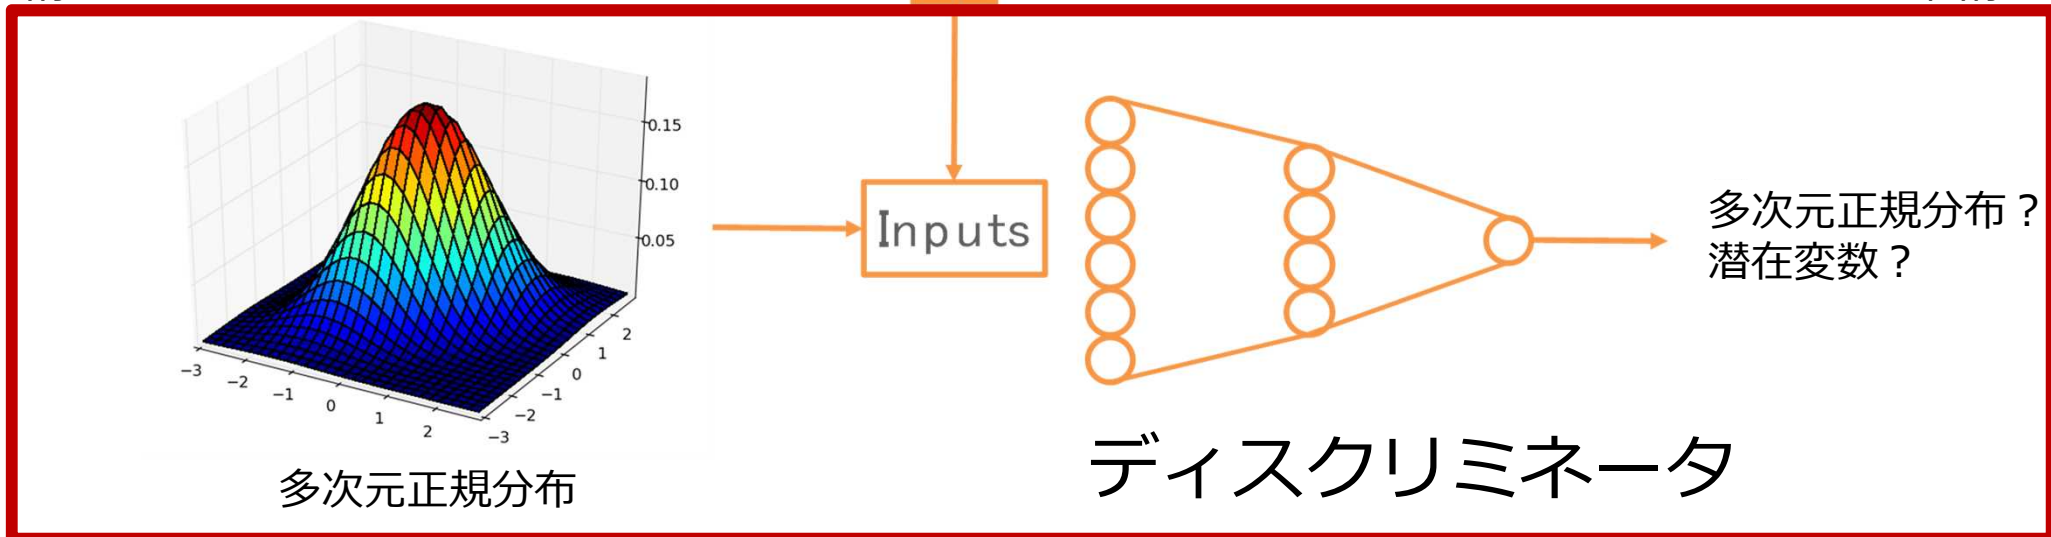
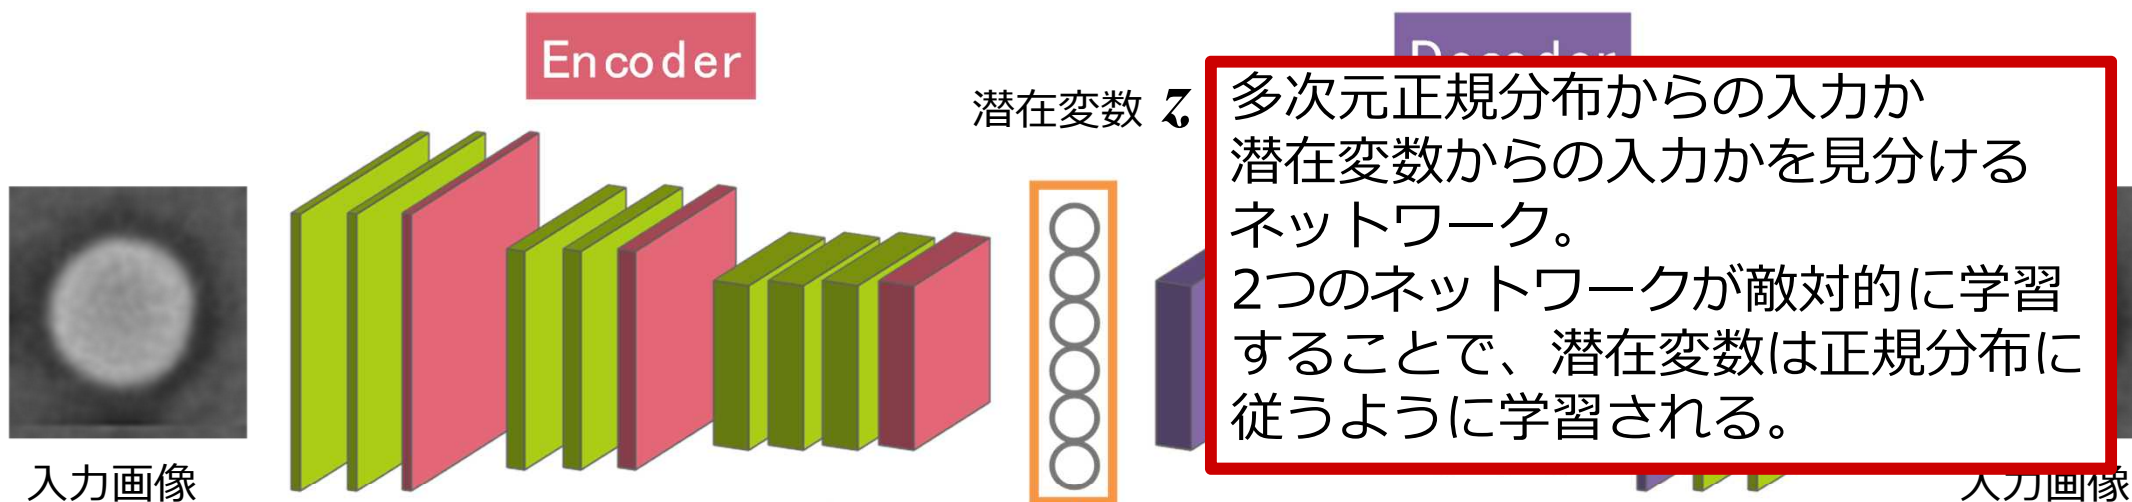
低次元に圧縮された特徴  
から元の画像を復元する

入力画像を復元するネットワーク

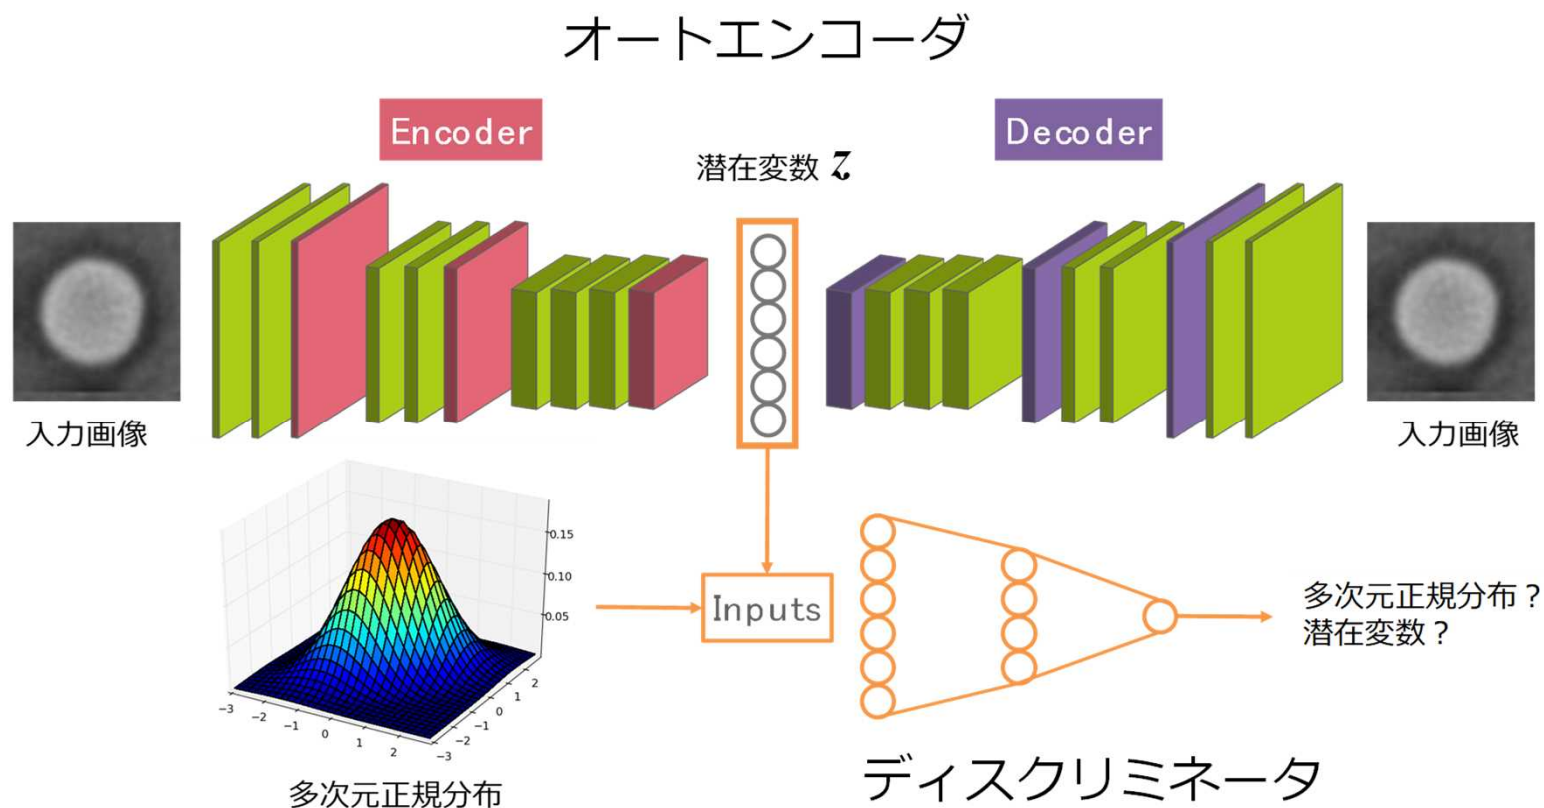
# 新技術の概要

## Adversarial AutoEncoder (AAE) + 正規分布

### オートエンコーダ



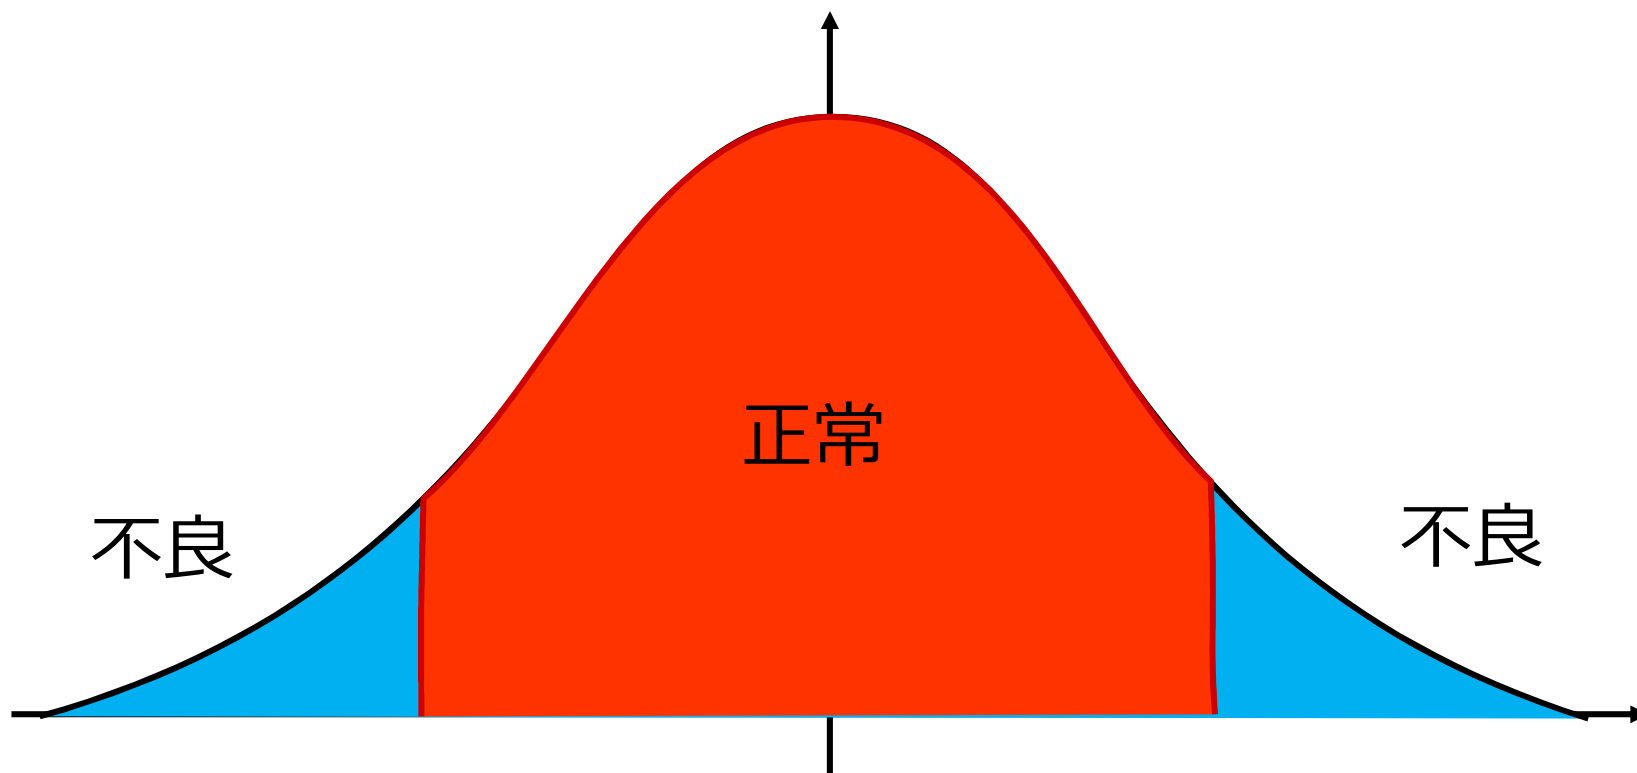
# 新技術の学習結果



- オートエンコーダの潜在変数は、画像特徴をよく表し、さらに正規分布に従う。
- 大量の正常画像と少量の不良画像を学習させることで、正規分布の中心（平均）に正常特徴、分布の外側に不良特徴が集まる。



# 得られる正規分布



- オートエンコーダの潜在変数は、画像特徴をよく表し、さらに正規分布に従う。
- 大量の正常画像と少量の不良画像を学習させることで、正規分布の中心（平均）に正常特徴、分布の外側に不良特徴が集まる。

# 異常検知手法

## Hotelling's T-Square

- 大量の正常データ（ベクトル）から正常状態モデルを作成する
- 正常データは正規分布に従っていると仮定
- 正規分布の平均と分散から，未知データに対する異常度を算出

正規分布の  
確率密度関数

$$N(x | \mu, \Sigma) = \frac{|\Sigma|^{-1/2}}{(2\pi)^{1/2}} \exp\left\{-\frac{1}{2}(x - \mu)^T \Sigma^{-1}(x - \mu)\right\}$$

異常度


$$a(x') = -\ln N(x' | \lambda, \Sigma)$$

$$\propto (x' - \mu)^T \Sigma^{-1}(x' - \mu)$$

マハラノビス距離

# 異常検知手法


- サンプル数が次元数よりも圧倒的に大なら、異常度はカイ2乗分布に従う




# 異常検知例（白米の異常検知）

- 白米データセット約3万点
- そのうち、6.5%ほどが異常データ
- 異常データには白濁や割れ、欠けあり
- 16次元の多変量標準正規分布を対象に


正常データ




異常データ



# 異常検知例（白米の異常検知）

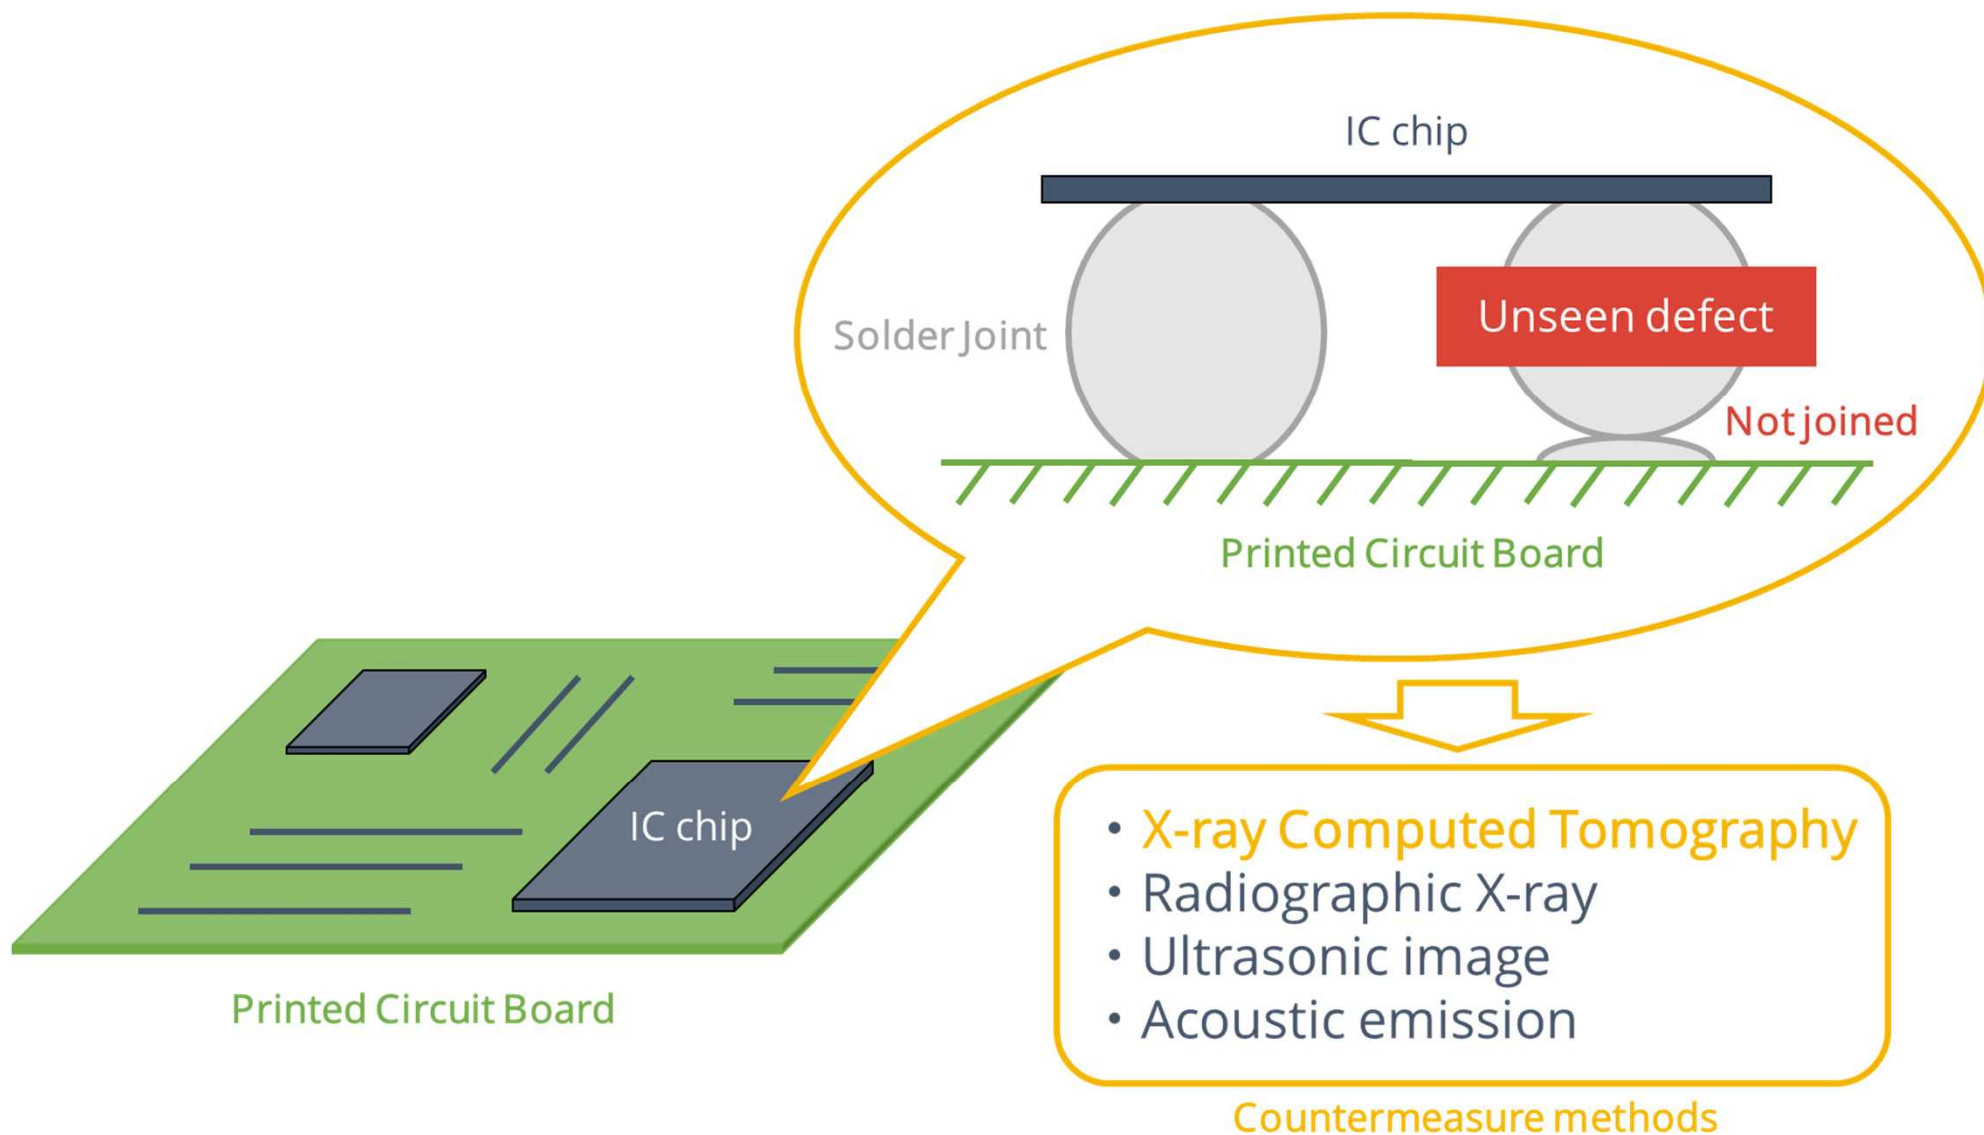


平均に近い入力  
(正常)

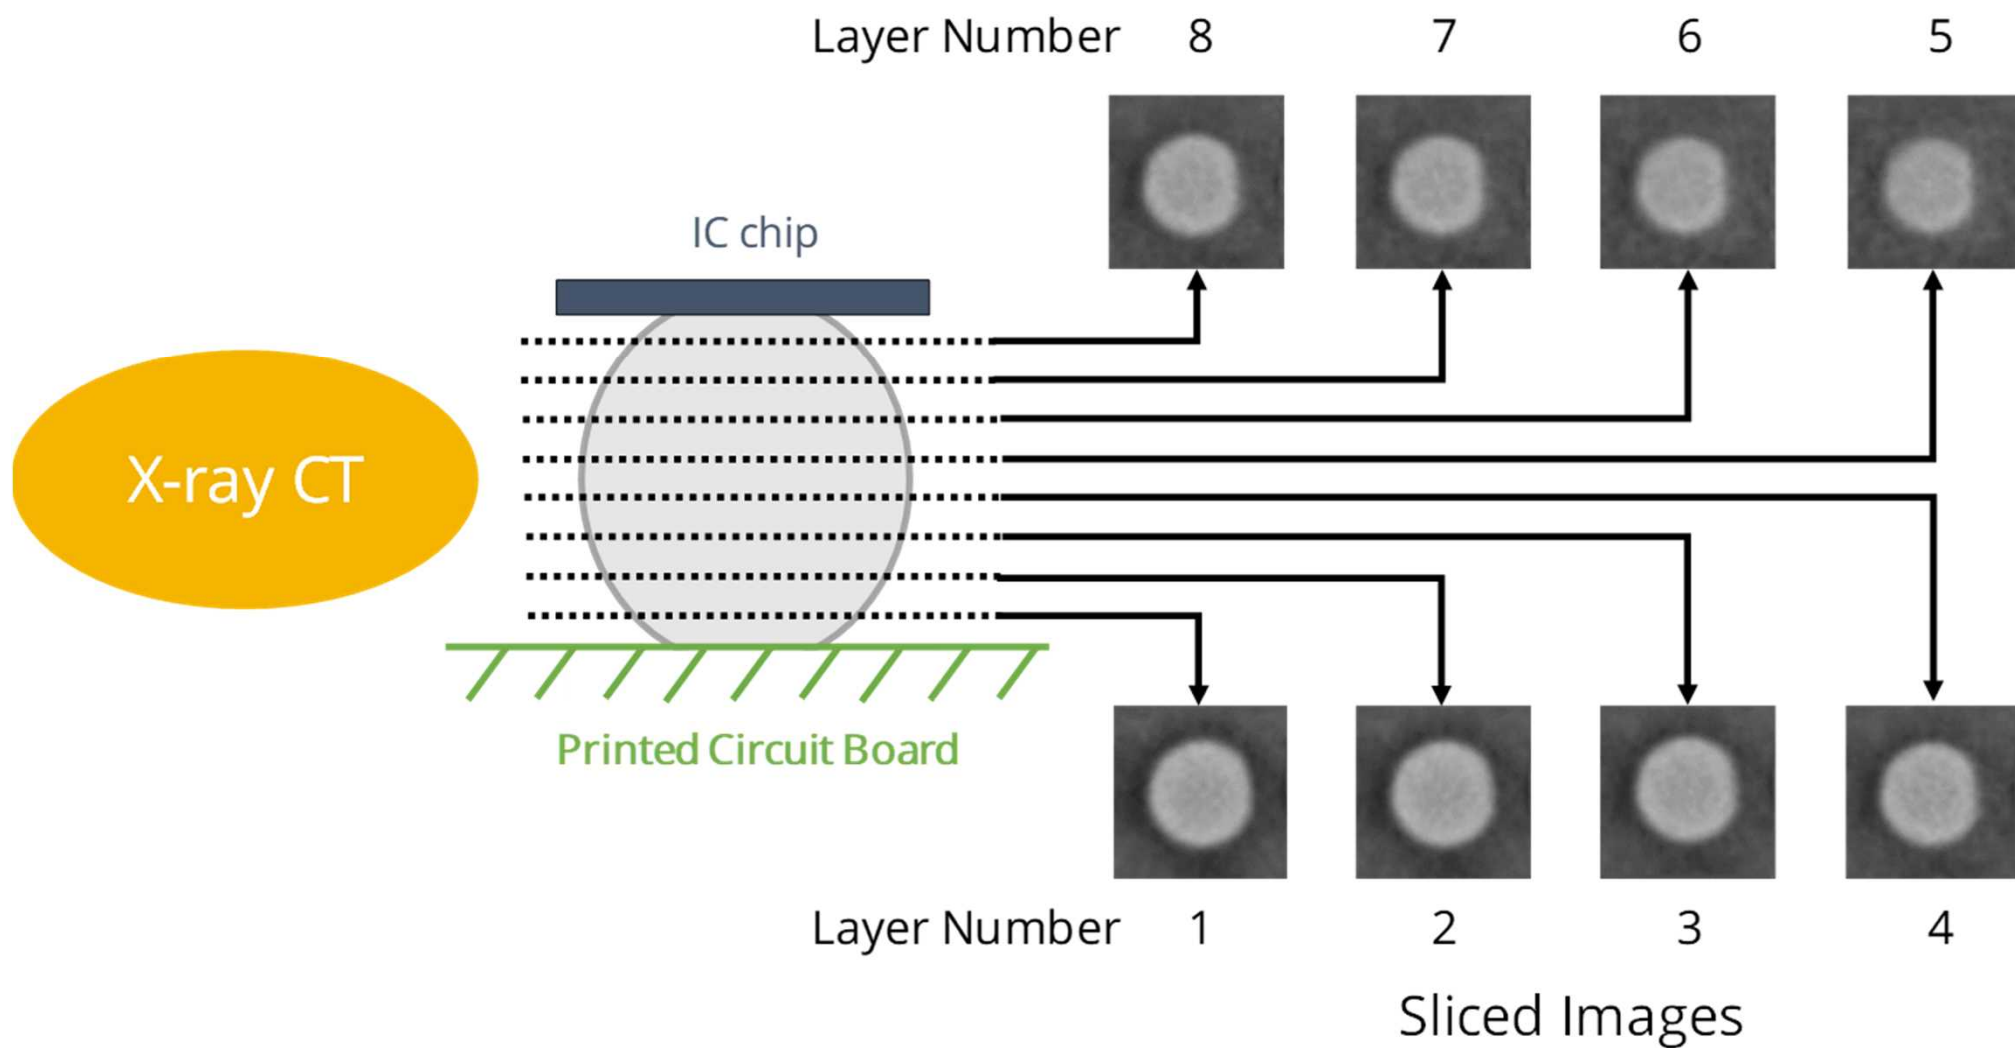


平均から遠い入力  
(異常)

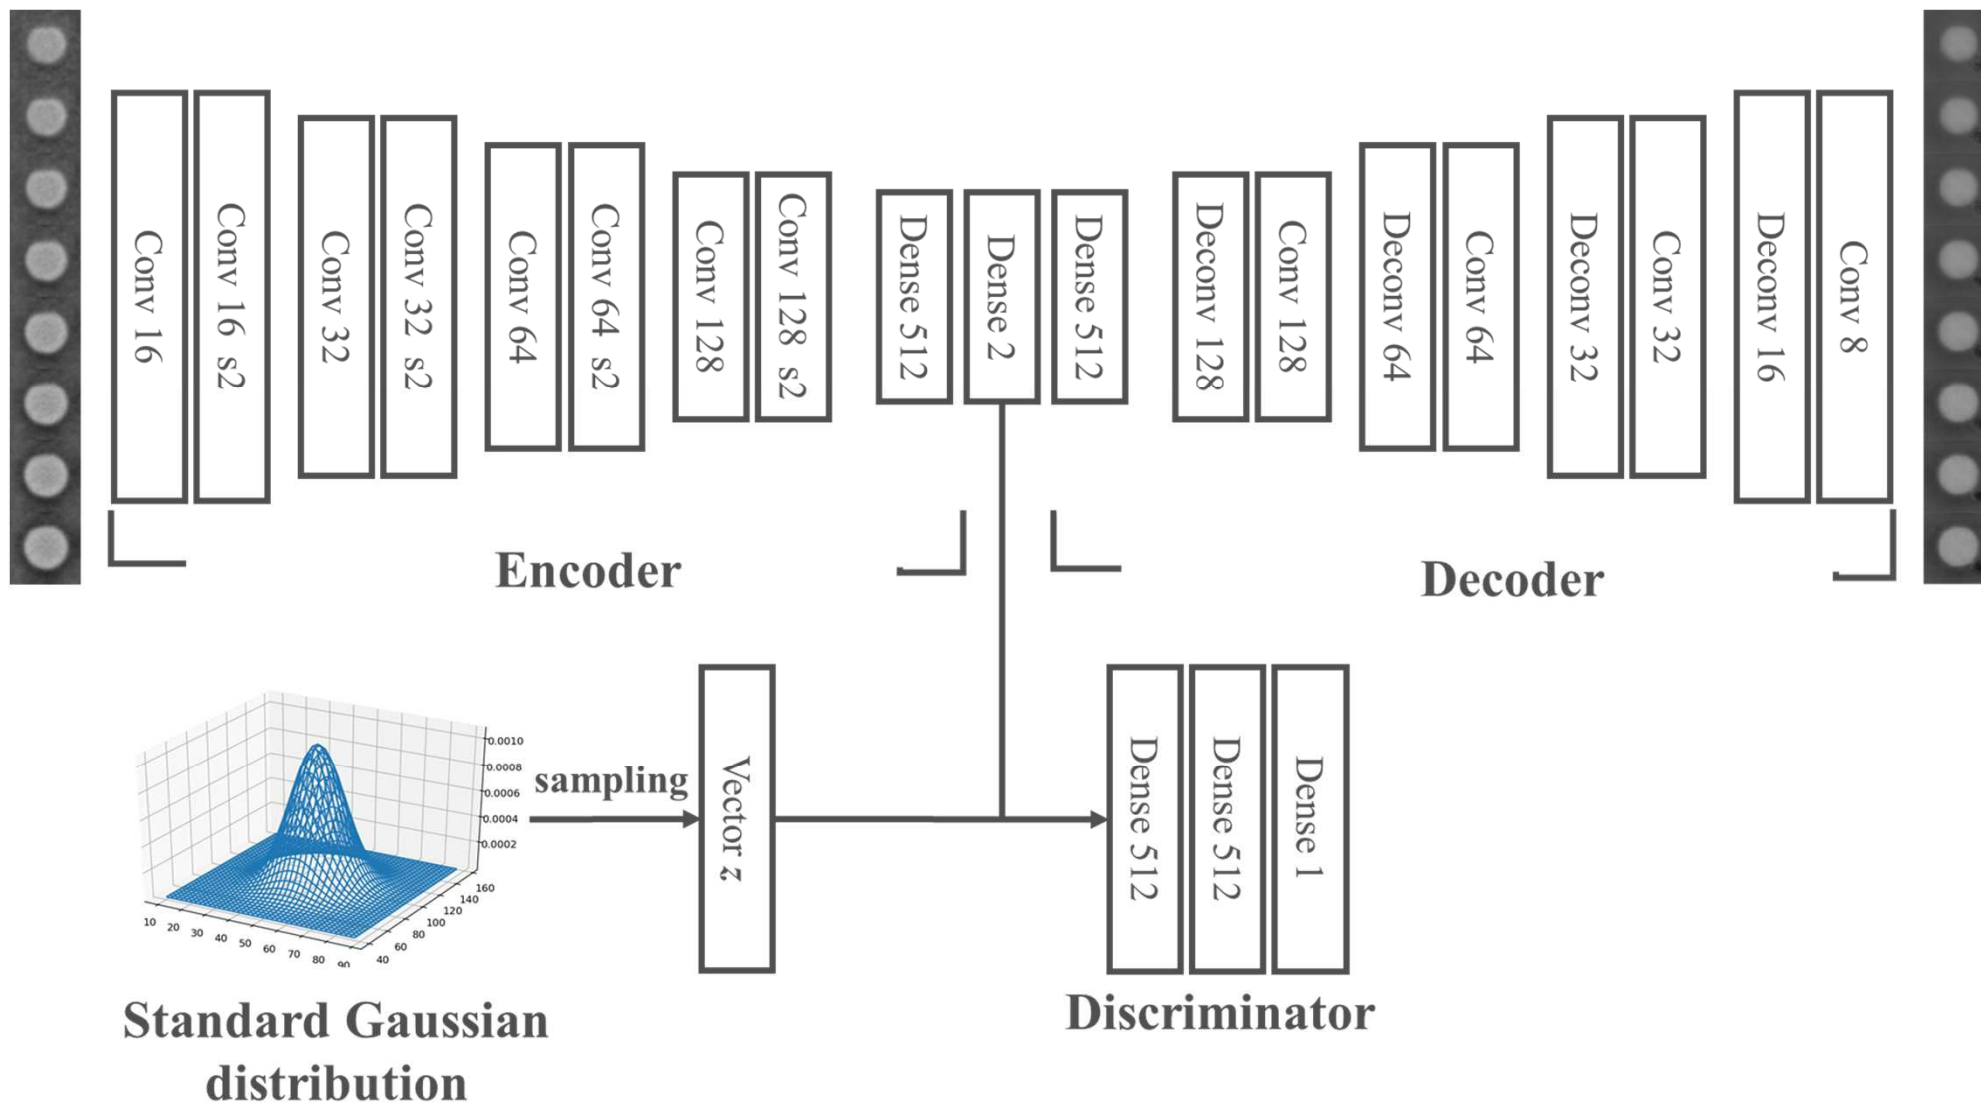
# 異常検知例 (ハンダ検査)



# 異常検知例 (ハンダ検査)




# 異常検知例 (ハンダ検査)





# 異常検知例 (ハンダ検査)



Normal Sliced Images

Anomalous Sliced Images

	Amount of training data	Amount of test data	False positive rate
Handmade features + one class SVM	3,510,000 + 0	2,908,386 + 410	1.07%
AAE + Hotelling's T square	47,736 + 450	574,236 + 450	0.00%

正確には3つの見逃し

# 新技術の特徴・従来技術との比較

- 大量の正常サンプルと、少量の不良サンプルから正常分布の学習を可能とした。
- 正常分布は正規分布に従うのでしきい値決定を簡素化した。
- 製品によってはほぼ100%の検出率を達成した。

## 想定される用途

- 大量の不良サンプルが入手できない場面での外観検査にも深層学習の高精度な検査を導入可能。
- 判別時は小さなネットワークで良いので高速に検査可能。
- 製品が正規分布に従う製造品の外観検査に広く応用可能。

# 実用化に向けた課題

- 実際に実用化例あり。
- ネットワークのチューニングに多大な時間と経験が必要なため、汎用的なネットワーク構造の開発が必要。
- 少量すら不良サンプルが入手できない場合（正常品のみ）についての研究を開始している。

# 企業への期待

- 応用事例をご紹介ください。
- 少量すら不良サンプルが入手できない場合についての共同研究を希望。

# 本技術に関する知的財産権

- 発明の名称 : 異常品判定方法
- 出願番号 : PCT/JP2018/37352
- 出願人 : 岐阜大学
- 発明者 : 加藤邦人、中塚俊介、  
相澤宏旭

# お問い合わせ先

岐阜大学

研究推進・社会連携機構 神谷 英昭

TEL 058-293-3182

FAX 058-293-3346

e-mail [h\\_kamiya@gifu-u.ac.jp](mailto:h_kamiya@gifu-u.ac.jp)