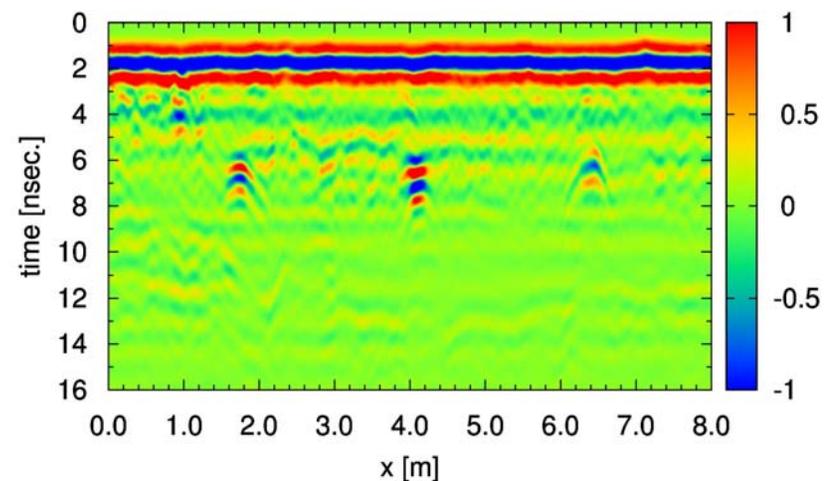


# 超高速シミュレーション技術に基づいた 地中レーダによる社会インフラ劣化 高精度診断システムの研究開発

園田 潤†      木本 智幸‡

† 仙台高等専門学校

‡ 大分工業高等専門学校



# 本発表の概要

- 問題：地中レーダ画像からの物体識別（材質や大きさ等）
- 熟練者による画像判読（例：道路空洞検出は40～70%）
- 人工知能による判定 ⇒ 学習用のレーダ画像生成が困難
- 本研究のアプローチ：
  1. FDTD シミュレーションによる学習用レーダ画像生成と、CNN によるシミュレーション画像の識別率検証（不均質土壌でも識別率80%程度以上は可能）
  2. 学習したシミュレーション画像による実験画像識別（少量画像の4種類の材質判定で95%程度識別可能）
  3. 数値から画像化・イメージングへ（GANを用いた深層学習による画像生成で逆問題や超解像化など）

# 地中レーダの概要とその応用

- 地中レーダ：数百 MHz の電波を地中に入射し，地中の誘電率の相違による反射波を地上で観測
- 誘電率差が大・大きさが大・浅部ほど検出されやすい
- 地中レーダの例：



震災不明者搜索

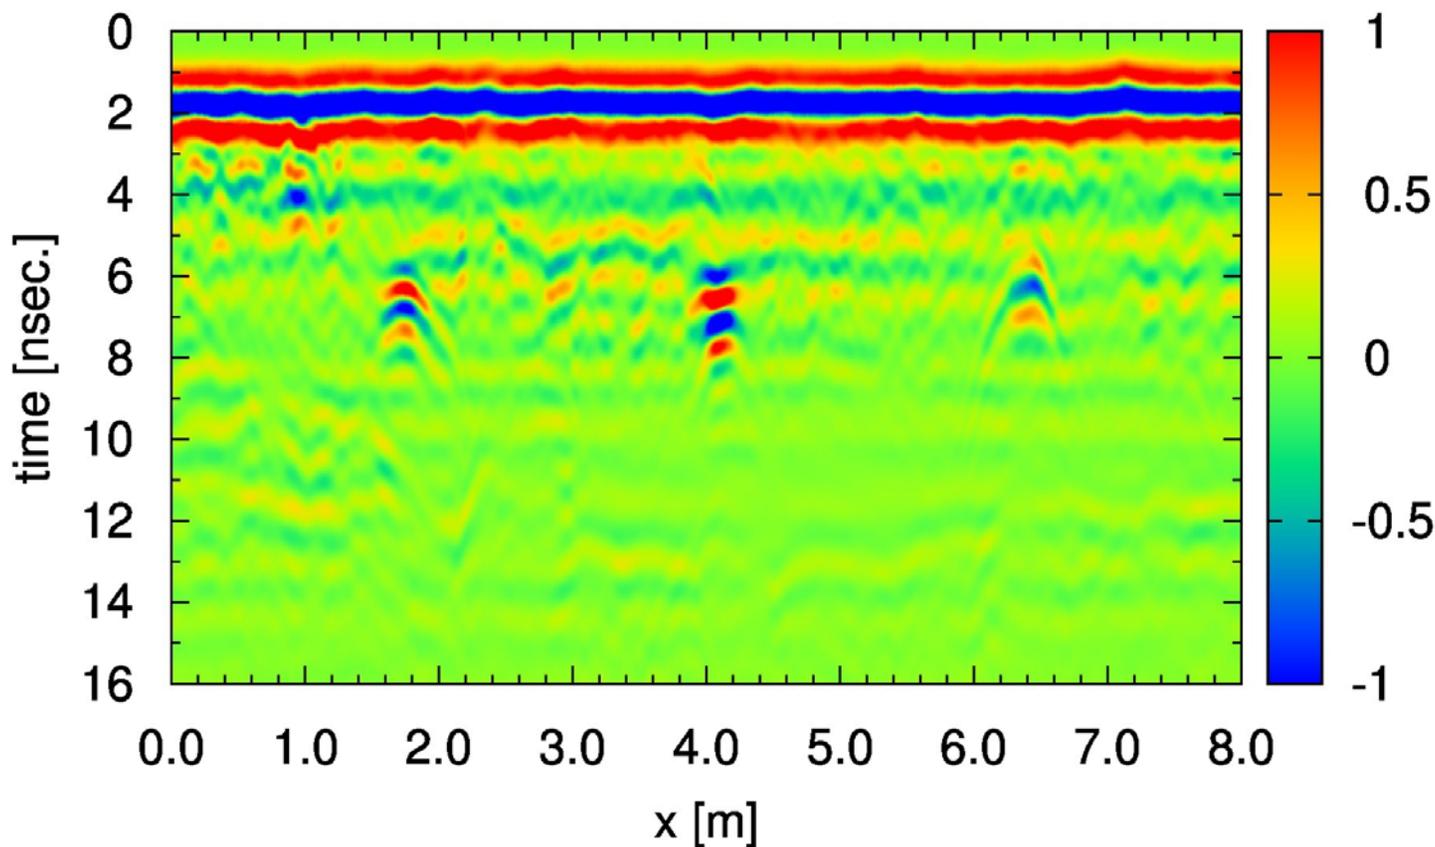


シールドアンテナ

(上：500 MHz，下：800 MHz)

# 地中レーダ画像の例：砂場モデル実験

- 地中レーダを用いた地中物体検出問題（材質・大きさ）



地中レーダ画像（地中の断面に相当）

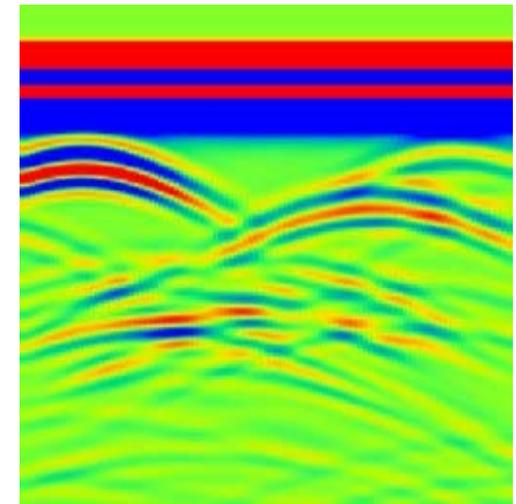
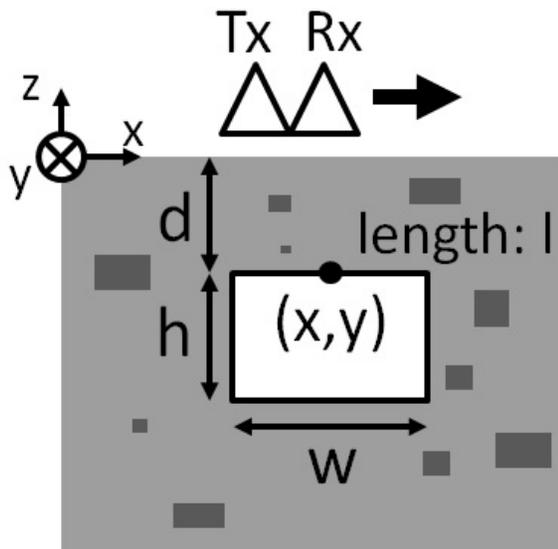
左から深さ 30cm の幅 10cm・20cm の空洞，1cm 径の金属管

# 物体識別の既存研究

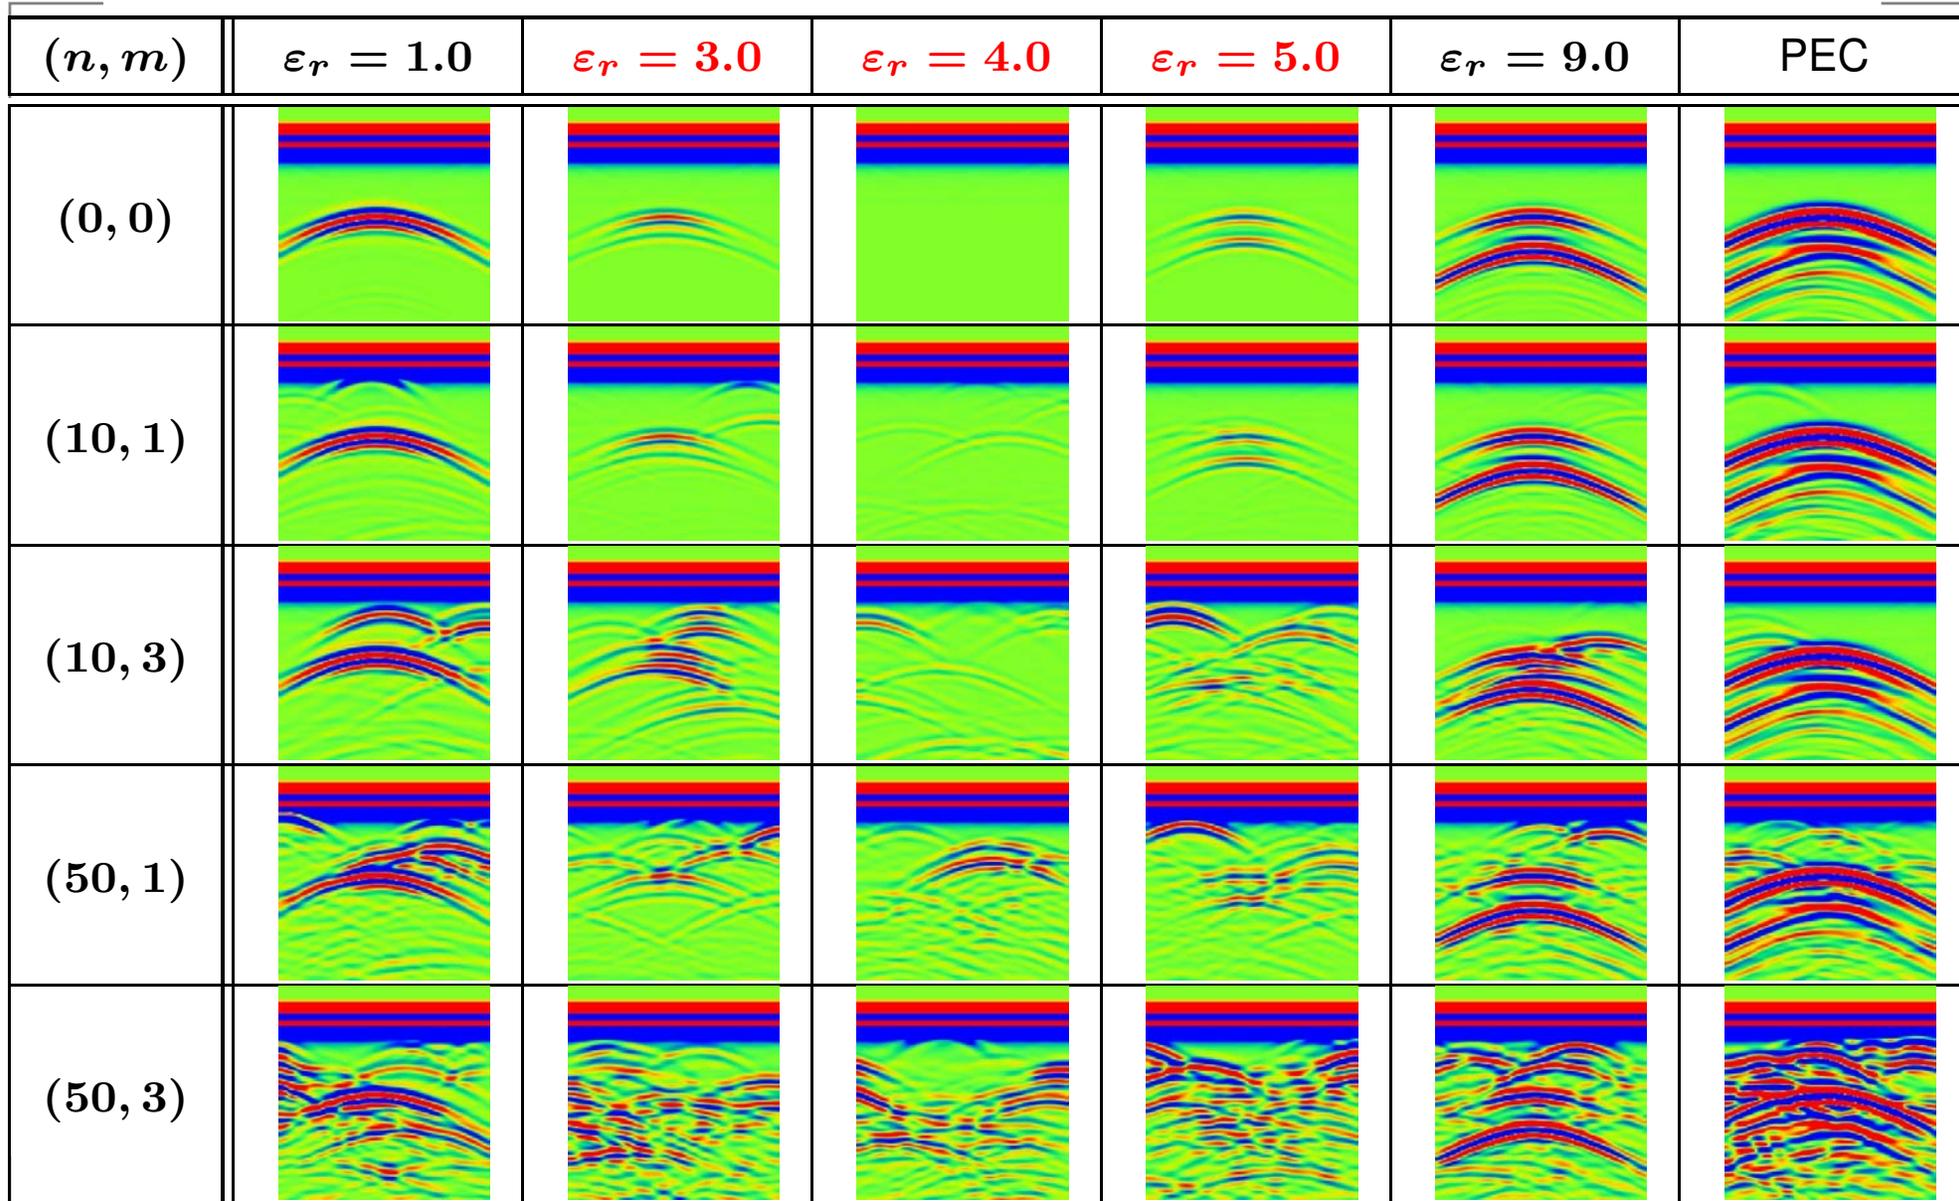
- ニューラルネット NN による機械学習で自動識別（手書き文字などの画像ベースと同じ発想）
- 埋設管・地雷の自動識別などの研究  
P. Gamba et al. 2000 , S. Carosi et al. 2005 , J.S. Kobashigawa et al. 2011, I. Giannakis et al. 2016  
⇒ 物体の有無程度でも識別率 8 割程度 , データ数 100 程度 , 2 次元問題 , 識別時間など実用化はまだ
- 近年の高速計算機の発展で Deep NN が注目  
識別率の向上・高度化の期待  
× 学習用データセットをどう用意するかの問題
- GPU クラスタを用いた FDTD シミュレーションによる 100 万規模の学習用地中レーダ画像の生成（園田 2016）  
⇒ CNN によりシミュレーション画像を高い確率で識別

# FDTD 法による学習用レーダ画像生成

- 物体の大きさや位置（3次元問題）・材質，周囲の不均質性，レーダ周波数をパラメータに
- FDTD 法：計算コスト高いが並列計算向き
- GPU Tesla K20m 64 台で FDTD  $\Rightarrow$  タスク並列で 64 モデルを同時計算（1 画像を 15 分程度で生成/64 台）



# FDTD法で生成した地中レーダ画像の例



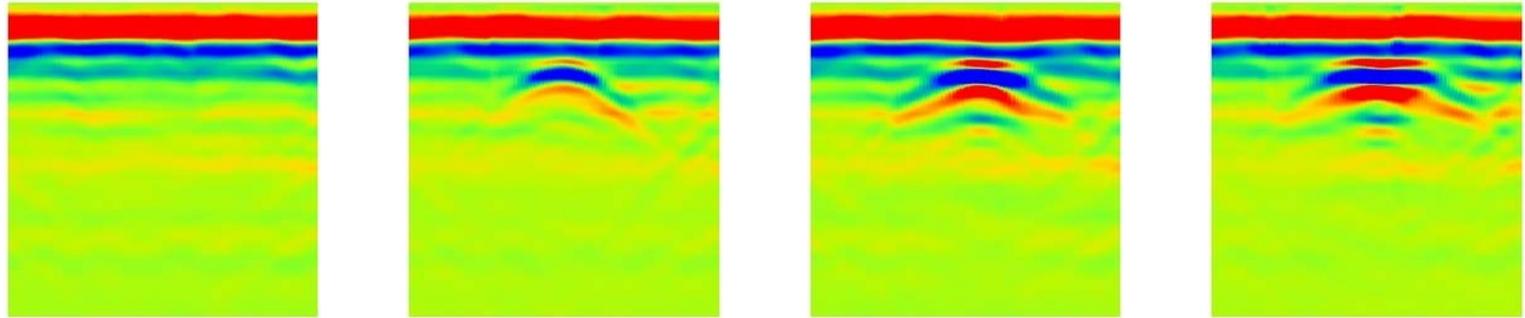
不要散乱体のパラメータ： $n$  は  $1 \text{ m}^3$  あたりの個数， $m$  は平均サイズ

# モデル実験による識別率の検証

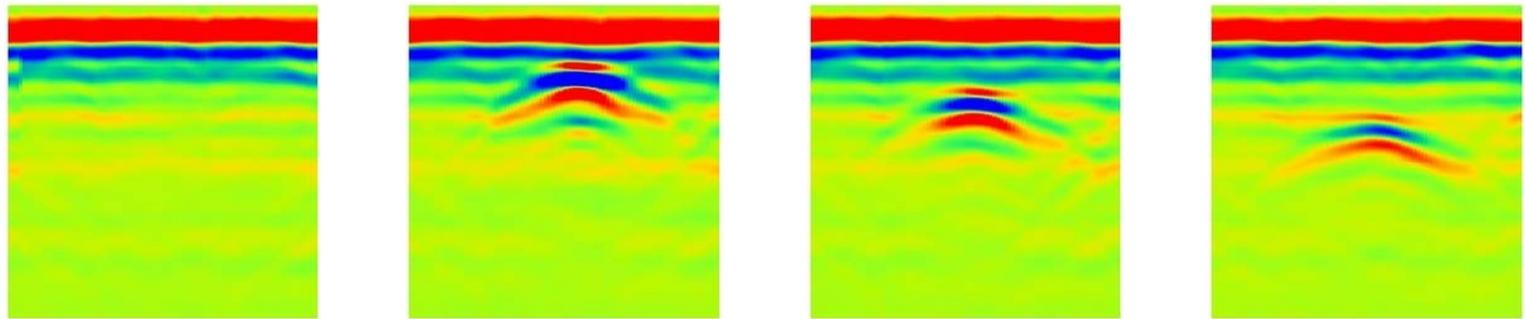
- シミュレーションで生成したレーダ画像が実際のレーダ画像の認識でも使用できるかの検証
- 地中レーダは実際に掘ってみないと何か分からない  
正解が分からないという問題で実際の検証も困難
- コンクリートブロックによるモデル実験：なし（コンクリート）・空洞・土・水



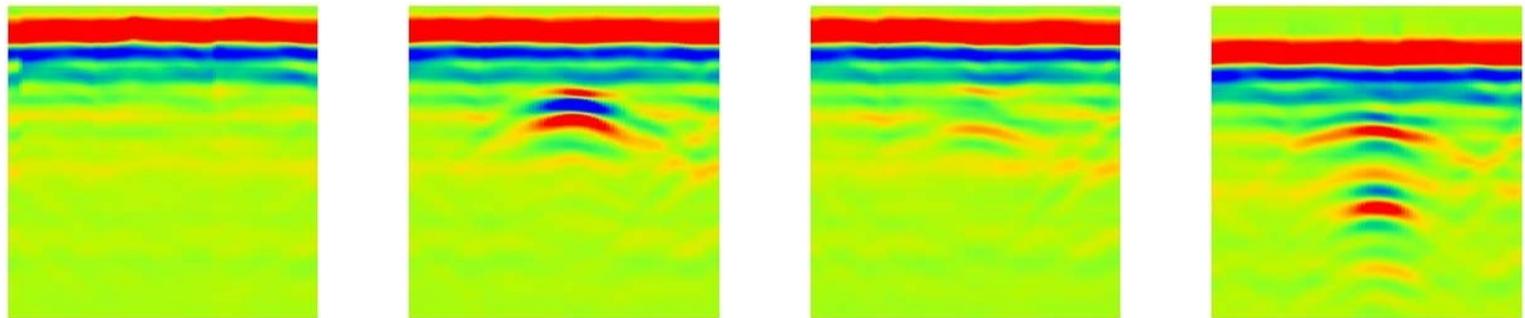
# モデル実験によるレーダ画像例



深さ  $d = 12$  cm の幅  $w = 0, 7, 14, 21$  cm の空洞



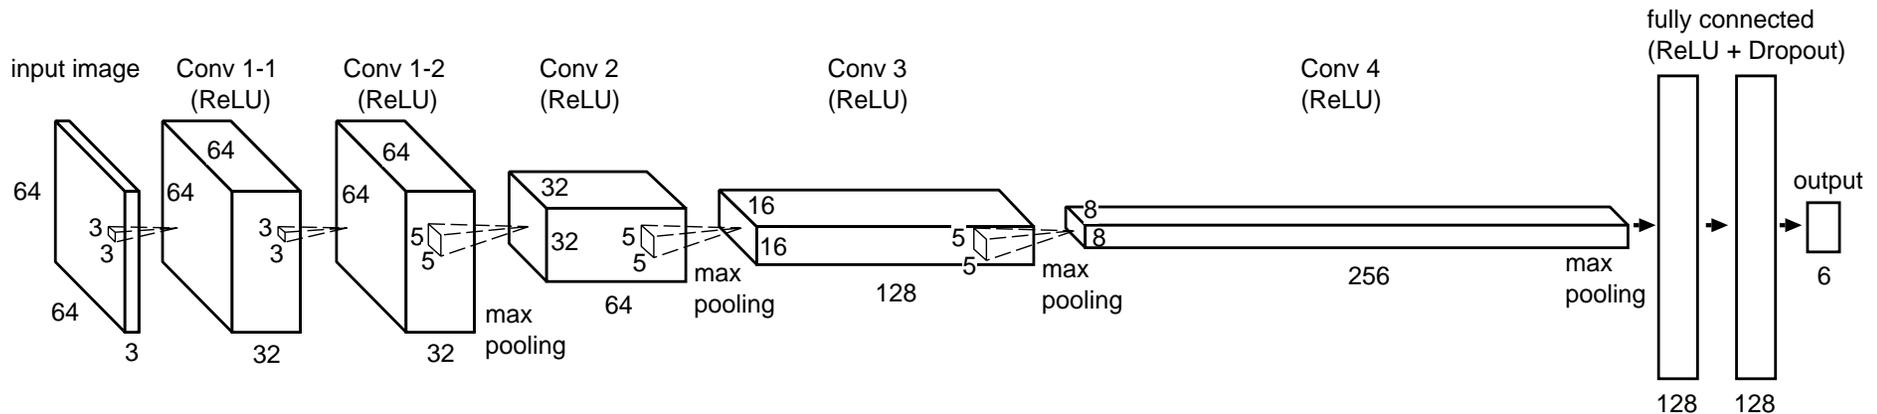
深さ  $d = 12, 18, 24$  cm の幅  $w = 14$  cm の空洞 (左  $w = 0$ )



深さ  $d = 18$  cm で幅  $w = 14$  cm の物体なし, 空洞, 土, 水

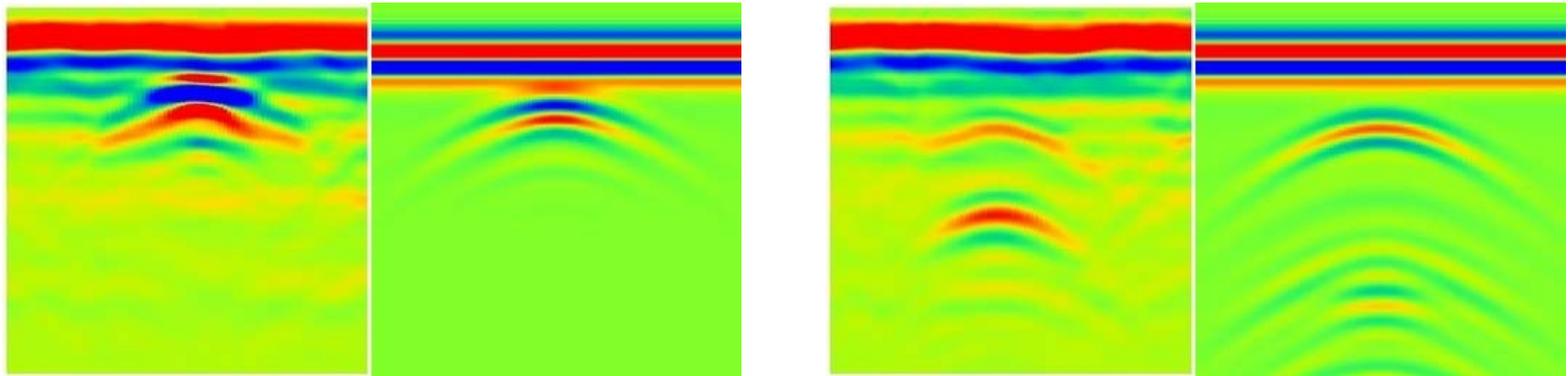
# CNNによる実験画像の材質の識別

- 5層CNNによる材質4種類の識別
  - 学習：シミュレーション画像4~180枚
  - 検証：実験画像180枚
- 20回交差検証の正解率の平均値
- 学習・推論に用いる5層CNN

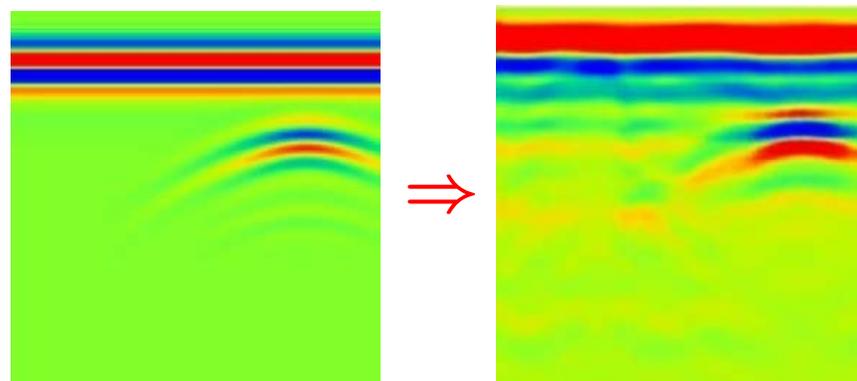


# Conditional GANによる擬似画像生成

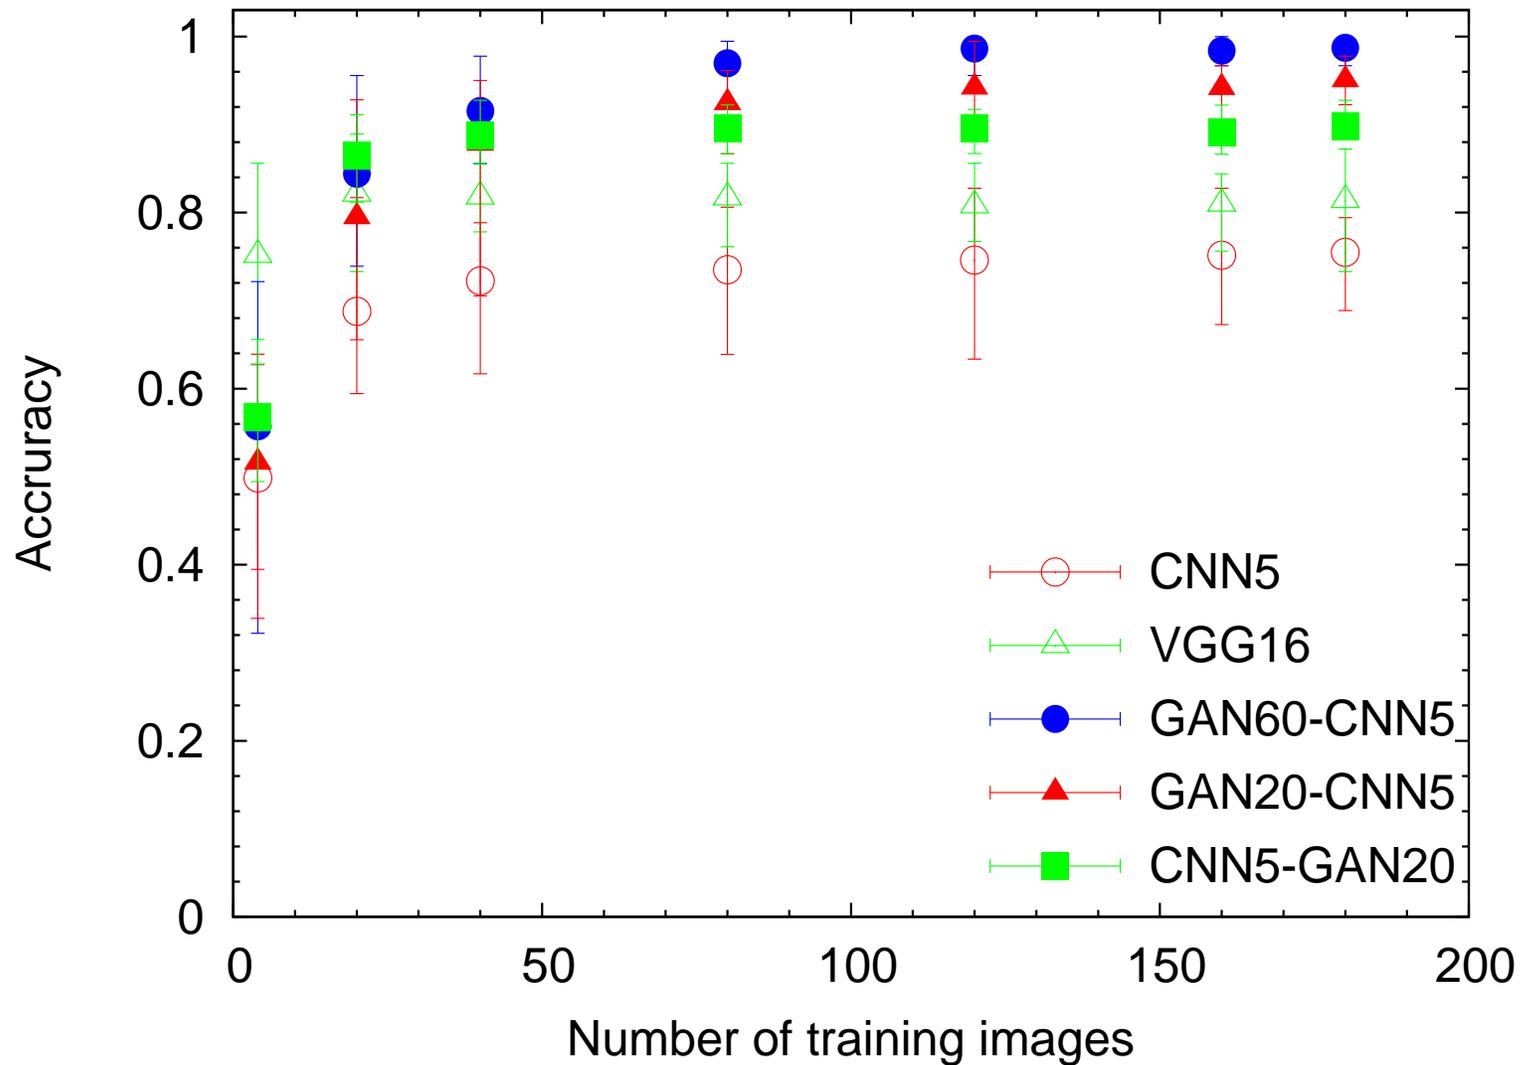
- Conditional GAN: 教師付きのGANでImage-to-Image (GAN: ランダムノイズから画像生成)
- 実験画像 (右) とシミュレーション画像 (左) を学習



- シミュレーションから疑似レーダ画像生成



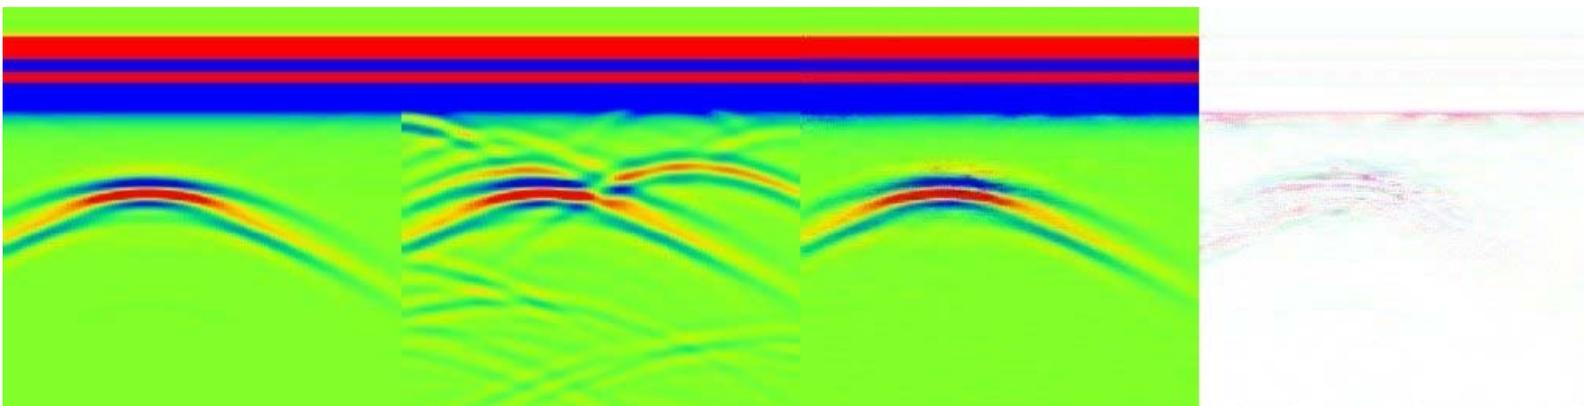
# cGANの疑似画像生成による識別率向上



CNN5: 75% , ImageNet-VGG16: 80% , cGAN: 95%

# GANの地中レーダ画像への適用1

- クラッタあり画像 ⇒ クラッタ除去画像



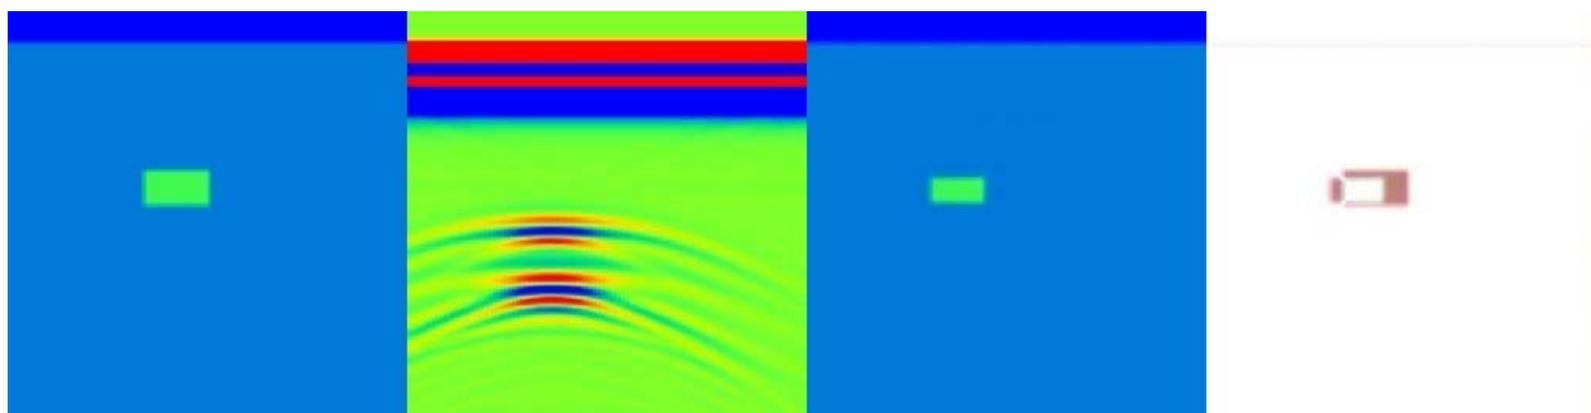
正解画像

入力画像

推定画像

差分画像

- 地中レーダ画像 ⇒ 地中モデル (逆問題)



正解モデル

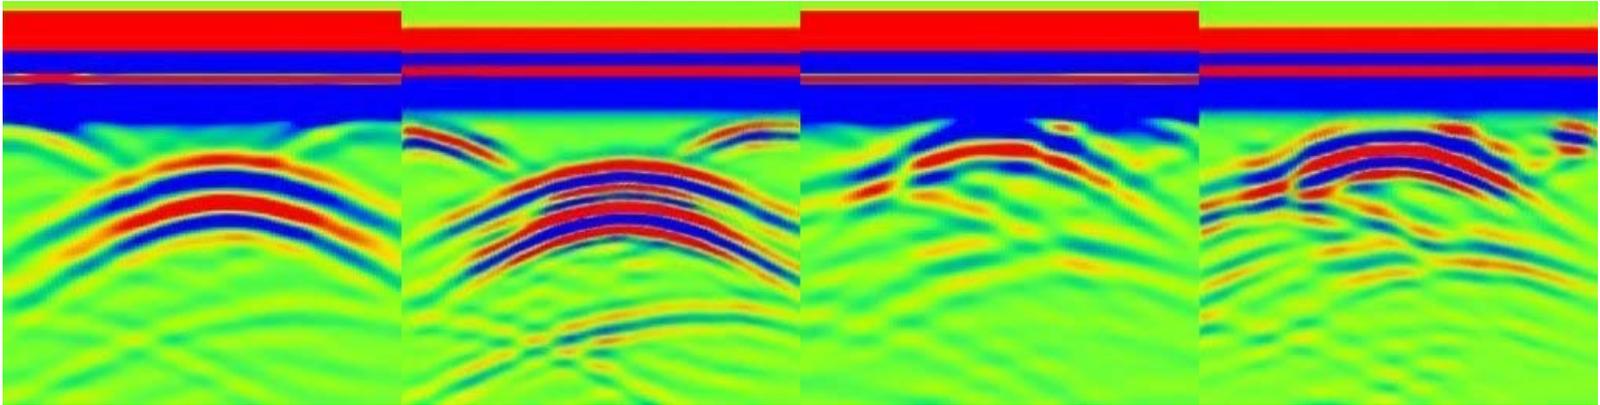
入力画像

推定モデル

差分画像

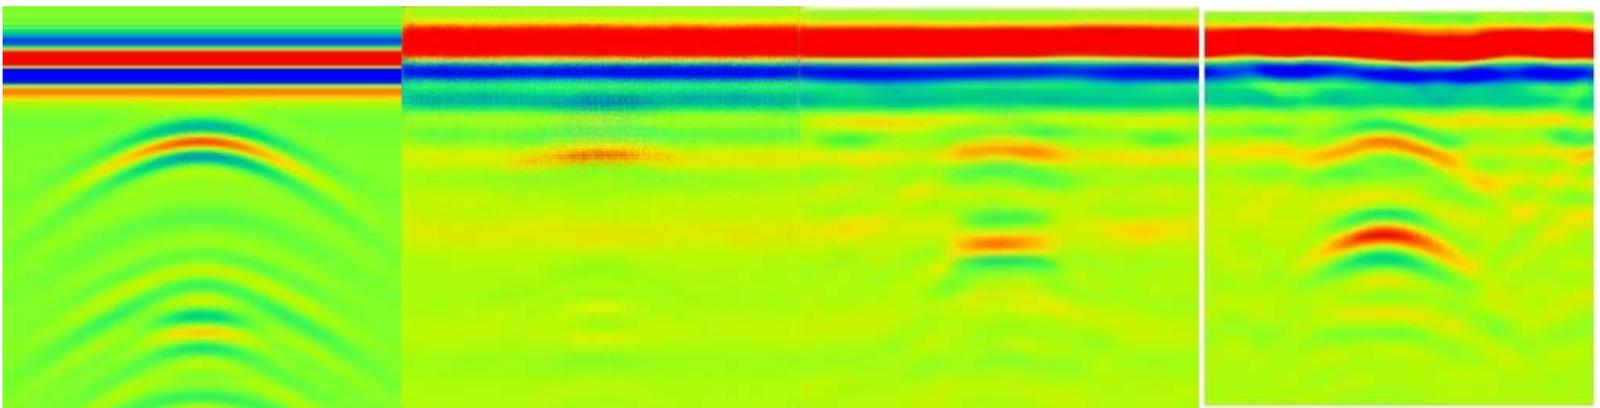
# GANの地中レーダ画像への適用2

- 低周波画像 ⇒ 高周波画像（超解像）



低周波画像 高周波画像 低周波画像 高周波画像

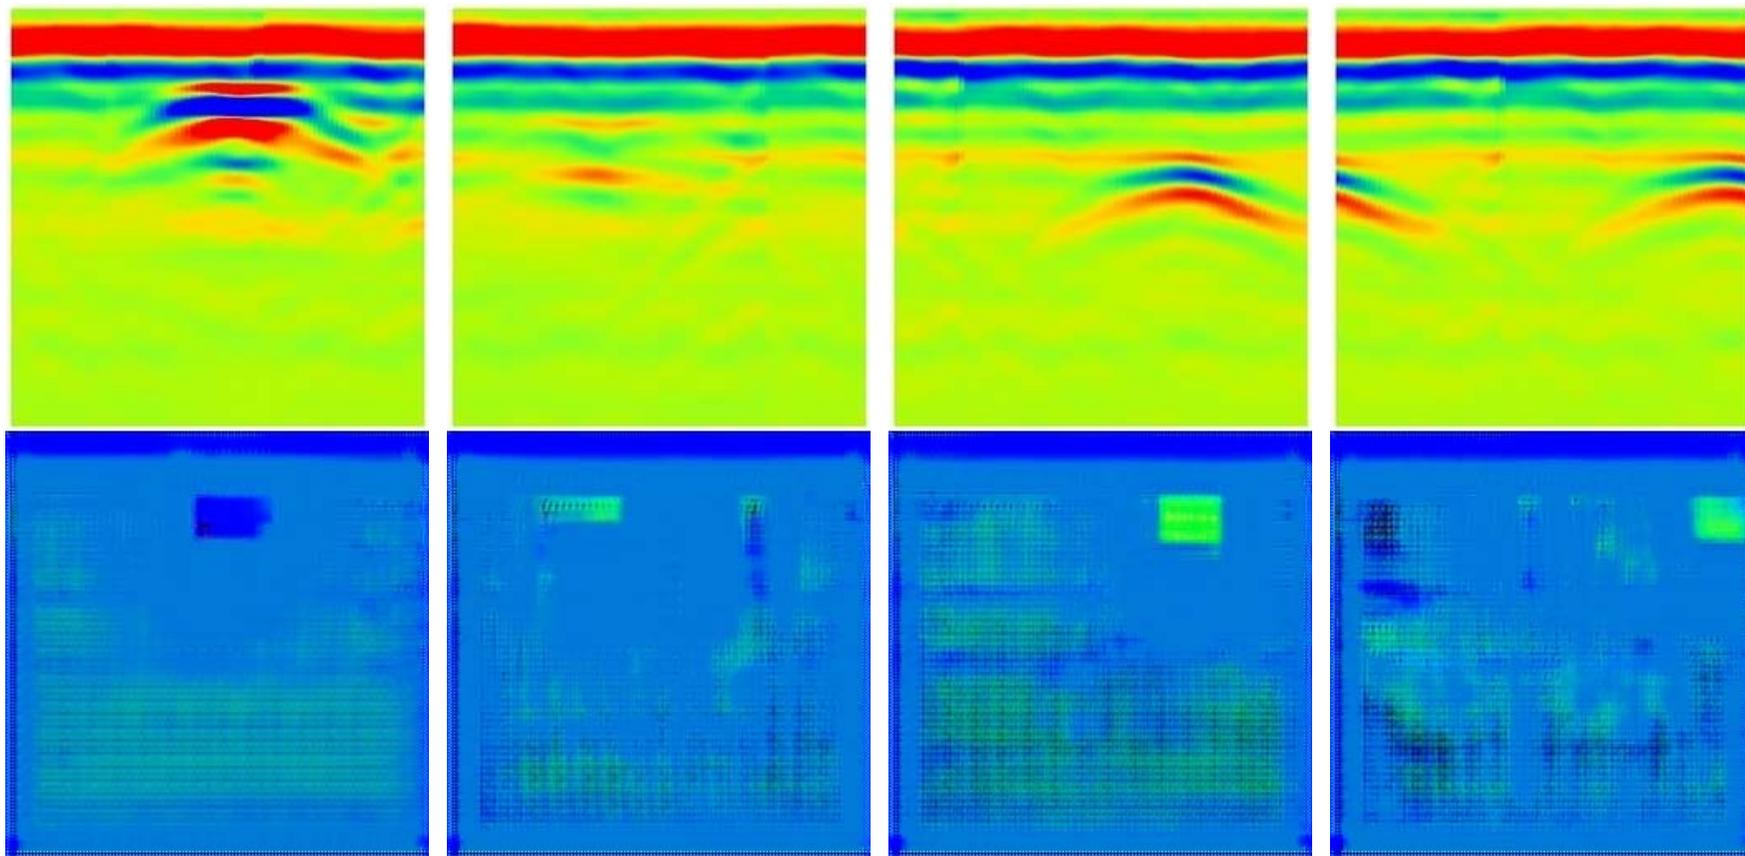
- シミュレーション画像 ⇒ 疑似実験画像



シミュレーション → 50 epoch → 500 epoch 実験画像

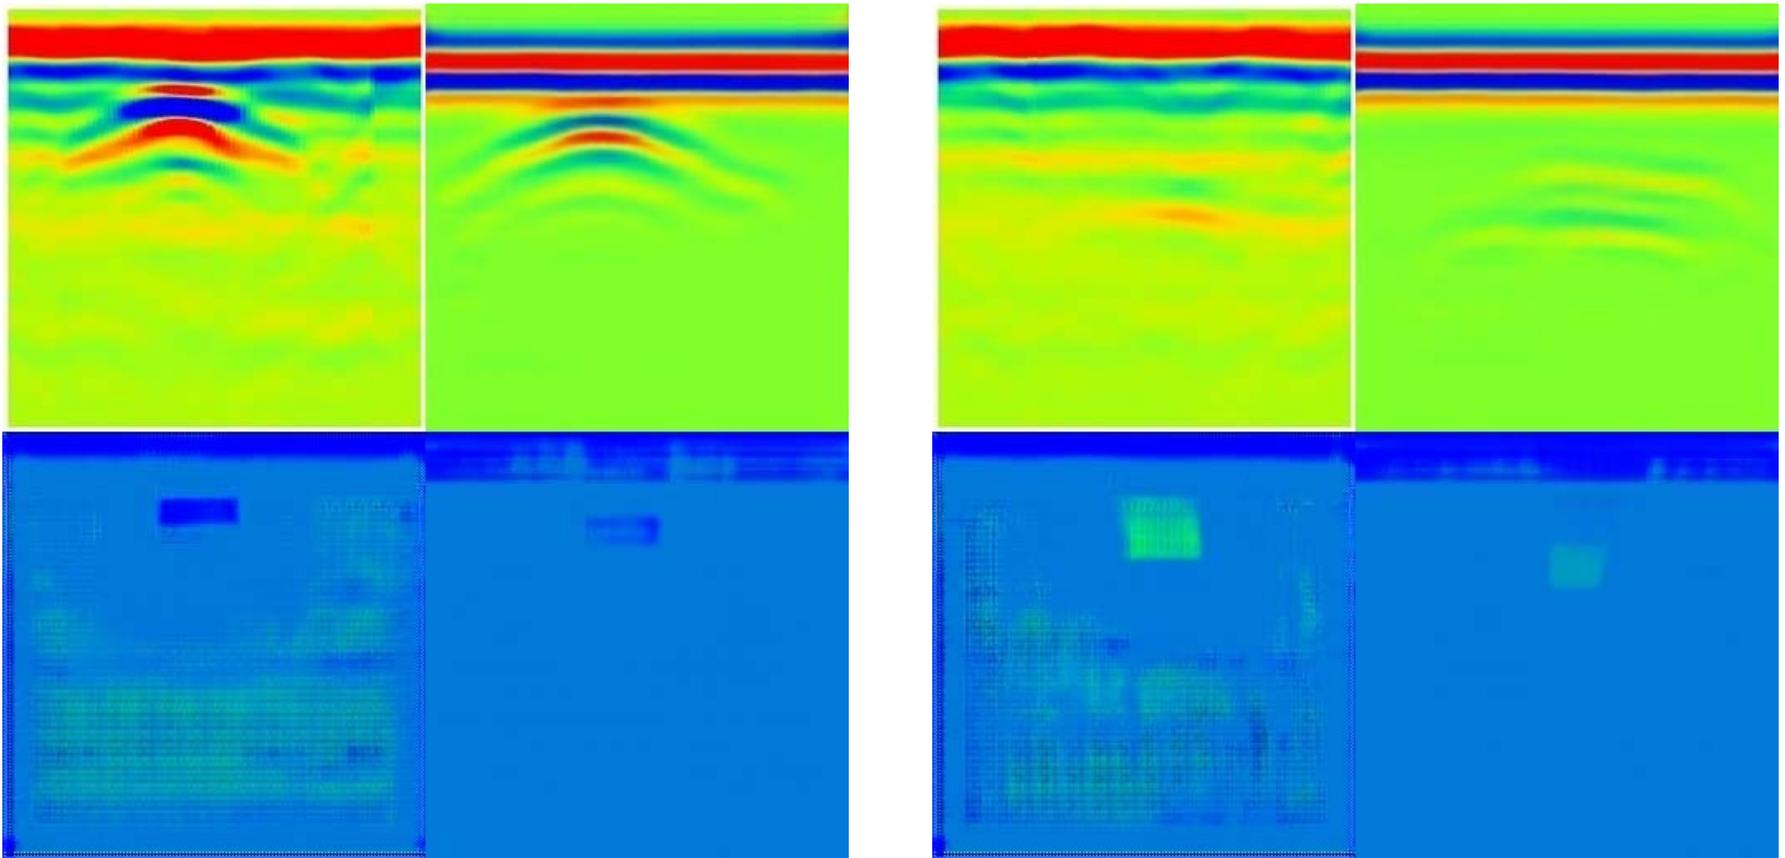
# モデル実験によるレーダ画像での逆推定

- シミュレーションで学習した結果でモデル実験の画像を逆推定



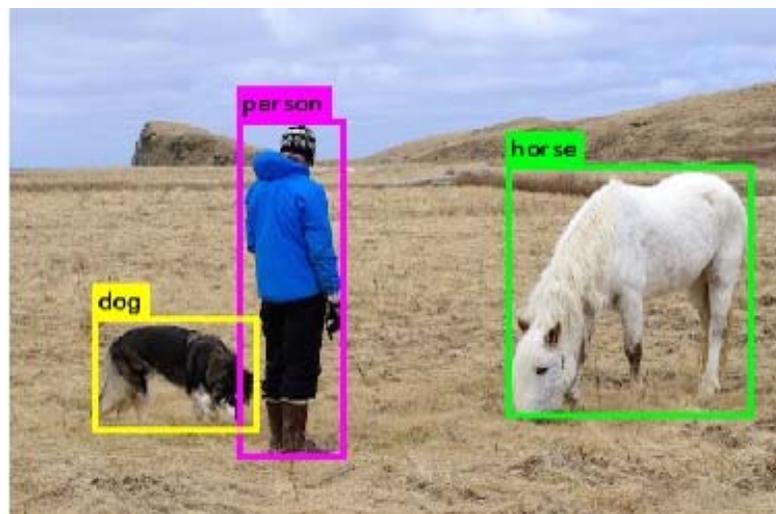
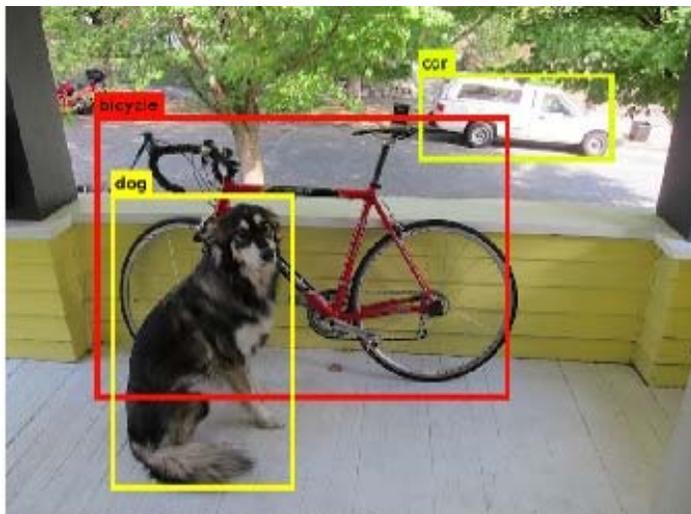
# StackGAN (多重GAN) の適用

- 実験画像とシミュレーション画像に差違
- GAN で実験画像をシミュレーション画像に変換し、さらに GAN で逆推定 (StackGAN)



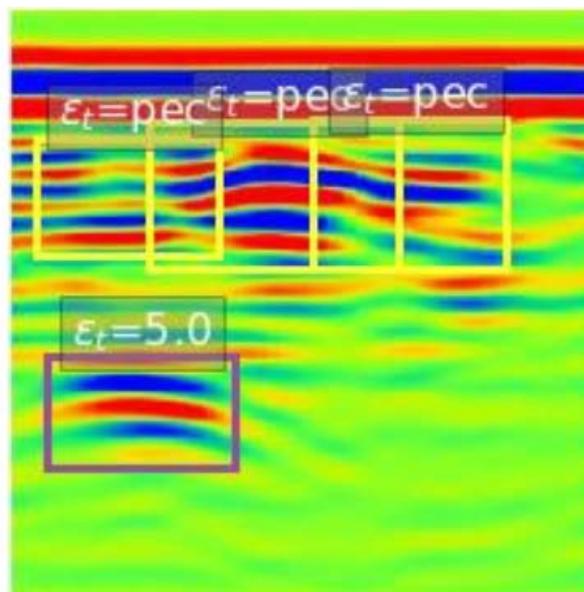
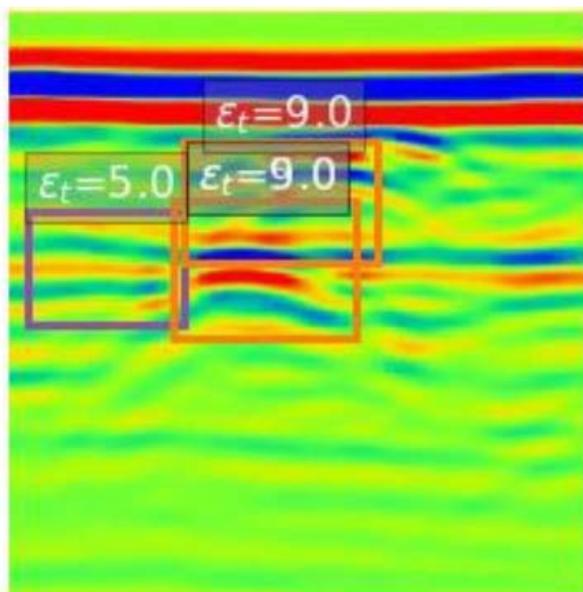
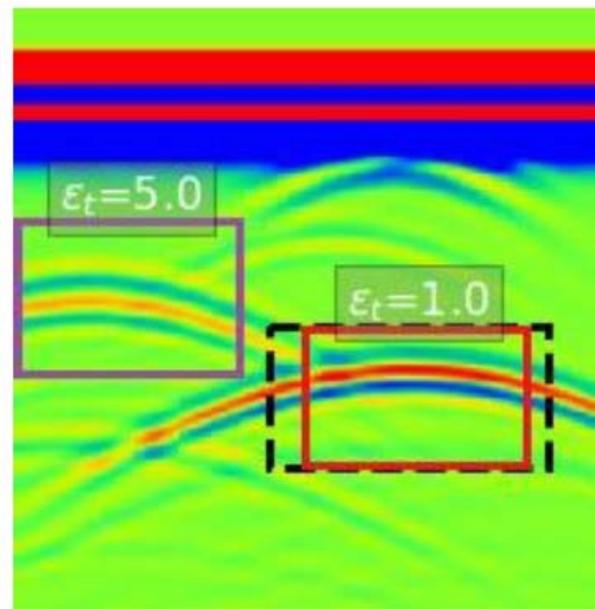
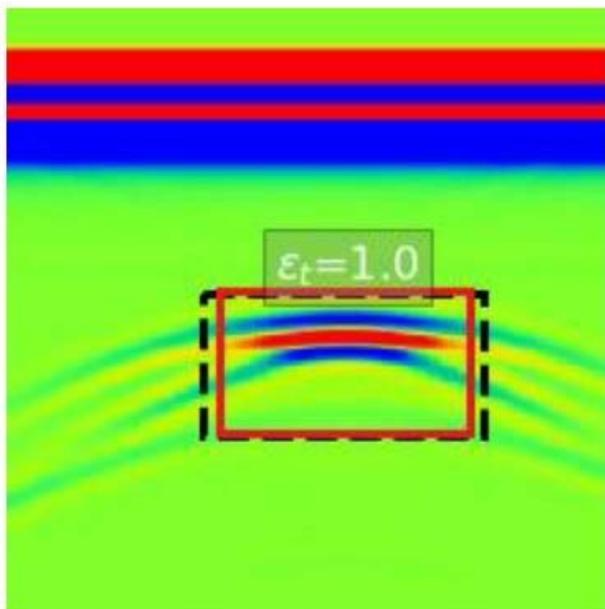
# YOLO による物体検出

- YOLO (You Only Look Once) (CVPR 2016)
- 画像中の物体検出例



YOLO のサンプル画像より

# YOLOによるレーダ画像の物体検出例



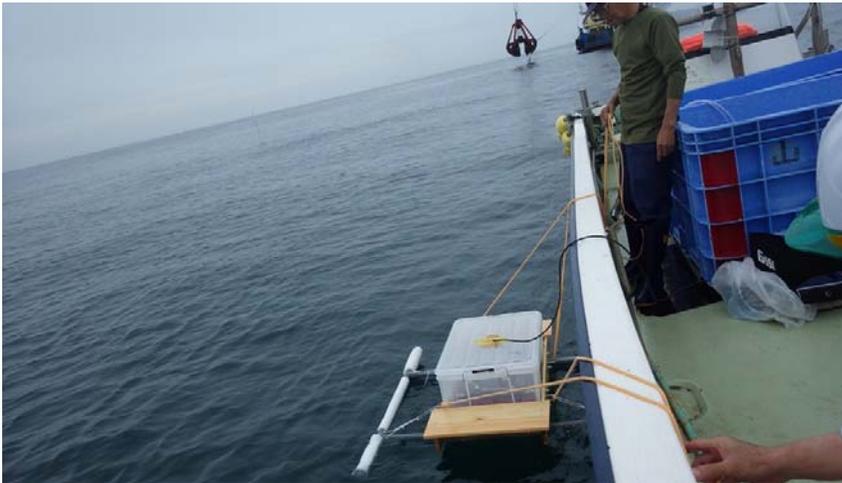
# 研究成果の地域課題への応用例



東日本大震災不明者搜索



堤防空洞探査



津波海底瓦礫探査



阿蘇山火山灰探査

# まとめと今後の展開

- 目的：地中レーダ画像の物体識別・画像化
- 方法：深層学習（畳み込みニューラルネットワーク CNN や敵対的生成ネットワーク GAN）の適用
- 結果：
  - 学習用教師付レーダ画像をシミュレーションで生成
  - CNN によるレーダ画像の物体識別
  - GAN による画像生成技術を利用した内部構造画像化・クラッタ除去・超解像化・学習用画像の高精度化
- 今後の展開：
  - 実験画像に対する高精度化
  - 道路や河川堤防など社会インフラ点検など実際の地中レーダへの応用