

修士論文

Sentinel-2/MSI を用いた GAN による 水田の異常検知

令和 6 年度修了

三重大学大学院 工学研究科 情報工学専攻
データサイエンス研究室

小川 将平

Abstract

Global warming and extreme weather events have caused a serious problem in rice growth. Damage by wild birds and beasts is also becoming more serious, and one of the causes is the increase in abandoned farmland due to the aging of farmers and lack of labor. In addition, the decline in the number of farmers has led to the necessity of managing expansive tracts of farmland. Hence, it is important to quickly detect anomalies in agricultural fields for taking appropriate action. Satellite remote sensing has been used to determine the spatial distribution of crop growth in large agricultural fields. Mahalanobis' distance (MD) and generative adversarial network (GAN) are often used as anomaly detection methods. Machine learning-based anomaly detection is currently utilized in the medical and manufacturing fields, thus there is a possibility of its utilizations in the field of remote sensing as well. The objective of this study is to detect anomalies in paddy fields over a wide area using satellite images based on GAN. We used the Multispectral Instrument (MSI) onboard Sentinel-2 observed on 17 July 2023, in the middle of the rice growing season. The target area was the entire Okayama Prefecture, Japan, and paddy field pixels were identified by farmland parcel polygon data. The considerable outliers, represented by clouds, were removed manually. To distinguish anomaly, the MD was calculated for each pixel using 10 bands with the spatial resolution of 10 m and 20 m. Anomalous pixels were determined based on the threshold for MD. We modified the GAN models from image-based to spectral-based architecture. Two models, the Fast Anomaly Detection with Generative Adversarial Networks (f-AnoGAN) and Efficient-GAN, were used to compare performance. Both models could generate similar spectral reflectance for normal paddy field pixels using the fully connected neural network, and could detect the anomalous pixels that have different spectra from those normal pixels. The area under the receiver operating characteristic curve (ROC-AUC) of anomaly detection was 0.942 for f-AnoGAN and 0.946 for Efficient-GAN, indicating the effectiveness of GAN. Anomaly scores for all pixels were calculated using Efficient-GAN, and visual confirmation of the anomaly pixels was performed. The anomaly score for areas changed to buildings or

solar panels was very high, and the anomaly score for areas growing other crops such as lotus roots was slightly higher. However, the anomaly score for abandoned land was low because it was difficult to distinguish between grass and paddy rice at Sentinel-2's 10-meter resolution and was not recognized as an anomaly pixel. These results indicate the limitations and potential of anomaly detection using Sentinel-2.

目次

Abstract	i
第 1 章 緒言	1
1.1 研究背景	1
1.2 関連研究	3
1.2.1 マハラノビス距離を用いた異常検知	3
1.2.2 f-AnoGAN を用いた異常検知	3
1.2.3 ハイパースペクトル画像における GAN を用いた異常検知	3
1.2.4 Efficient-GAN を用いた異常検知	4
1.2.5 GAN を用いた荒廃農地の判定	4
1.3 研究目的	5
第 2 章 準備	6
2.1 Sentinel-2	6
2.1.1 研究対象地	6
2.1.2 使用したバンド	7
2.2 ポリゴンデータ	8
2.3 関連手法	9
2.3.1 マハラノビス距離	9
2.3.2 Generative Adversarial Network	10
第 3 章 提案手法	12
3.1 前処理	12
3.2 データセット作成	13
3.3 GAN による異常検知	13
3.3.1 f-AnoGAN	14
3.3.2 Efficient-GAN	15
3.3.3 スペクトルベースの学習	16

3.3.4	アーキテクチャ	16
3.3.4.1	Generator	16
3.3.4.2	Discriminator	17
3.3.4.3	Encoder	18
第 4 章	実験方法	19
4.1	実験データ	19
4.2	評価指標	19
4.3	実験条件	21
第 5 章	結果と考察	22
5.1	モデル学習結果	22
5.2	スペクトルの比較	23
5.3	異常検知精度	24
5.4	マハラノビス距離と異常度の相関	27
5.5	異常画素検知の例	28
第 6 章	結言	32
6.1	まとめ	32
6.2	今後の課題	33
付録 A		34
A.1	Sentinel-2 のデータとプログラムの詳細	34
A.2	データセット詳細	35
A.3	GAN による生成画像	35
A.4	閾値の選定	36
A.5	全画素の異常スコア	37
付録 B		38
B.1	PlanetScope を用いた異常検知	38
B.1.1	使用データ	38
B.1.2	データセット	39
B.1.3	実験結果	40
B.1.3.1	異常検知精度	40
B.1.3.2	異常スコアの可視化	42
謝辞		43

目次

1.1	水稻うるち玄米の一等級比率の推移	1
1.2	耕作放棄地面積の推移	2
2.1	対象地域	7
2.2	筆ポリゴン	9
2.3	ユークリッド距離	10
2.4	マハラノビス距離	10
2.5	GAN アーキテクチャ	11
3.1	水田画素	12
3.2	全画素のマハラノビス距離	13
3.3	Generator アーキテクチャ	17
3.4	Discriminator アーキテクチャ (f-AnoGAN)	17
3.5	Discriminator アーキテクチャ (Efficient-GAN)	18
3.6	Encoder アーキテクチャ	18
4.1	平均反射率	20
5.1	Loss 値の推移	22
5.2	BiGAN の Loss 値の推移	23
5.3	生成スペクトル	24
5.4	ROC 曲線	25
5.5	異常スコアの分布	26
5.6	詳細分布	26
5.7	混同行列	26
5.8	相関散布図	27
5.9	異常スコアの可視化	28
5.10	異常検出例 (ソーラーパネルや建物)	29

5.11 異常検出例 (他の作物)	29
5.12 異常スコアの高い耕作放棄地の例	30
5.13 異常スコアの低い耕作放棄地の例	30
5.14 MD が低いが異常スコアが少し高かった例	31
5.15 MD が高いが異常スコアが低かった例	31
A.1 3次元散布図	35
A.2 ヒストグラム	36
A.3 生成画像	36
A.4 閾値と F 値の関係	37
A.5 異常スコア分布	37
B.1 PlanetScpoe	38
B.2 マハラノビス距離 (PlanetScope)	39
B.3 平均反射率 (PlanetScope)	40
B.4 異常スコアの分布	40
B.5 ROC 曲線	41
B.6 混同行列	41
B.7 耕作放棄地の例	42

表目次

2.1	MSI の仕様	8
4.1	データセット	19
4.2	混同行列	20
4.3	学習パラメータ	21
5.1	精度評価	27
B.1	データセット (PlanetScope)	39
B.2	精度評価	41

第 1 章

緒言

1.1 研究背景

異常気象や地球温暖化は水稻の成長に大きな影響を与える。特に地球温暖化のような気候変動により日本の平均気温は少しずつ上昇しており、今後もこの傾向が続くと予測されている。例えば、2010 年と 2019 年には夏季の高温の影響により、主な水稻の産地で白未熟粒等の高温障害が増加し、全国的水稻うるち玄米の一等級比率が大きく低下するなどの被害が出ている [1](図 1.1)。また、2023 年にも猛暑の影響で米の収量が激減し、2024 年の米不足による価格高騰に繋がっている。このように水稻は気候変動の影響を特に受けやすい。



図 1.1: 水稻うるち玄米の一等級比率の推移

さらに日本では、野生鳥獣の被害が深刻化している。令和 5 年度の野生鳥獣による農作

物の被害は 164 億円にのぼる [2]. 特に農作物被害額の 6 割がシカとイノシシによるものと明らかになっており、全国各地の里山においてシカ・イノシシ対策が求められている. このような獣害の原因の一つとして、農業従事者の高齢化や労働力不足による耕作放棄地の増加が挙げられる. 草木が生い茂った農地は野生動物の隠れ家や餌場となり、人里に近づく鳥獣の生息域が拡大することに繋がる. 日本の耕作放棄地は年々増えており、2015 年では 420000 ha にまで増加している [3](図 1.2). また、農家数の減少により広大な農地を管理する必要が生じており、経営体当たりの農地面積も増加している. そのため、農地の異常をいち早く察知し、適切な対応をとることが重要である. しかし、農地の現地調査による確認は多大な時間がかかることが問題となっている.




図 1.2: 耕作放棄地面積の推移

衛星リモートセンシングは、広大な農地における作物の生育の空間分布を把握するために利用されてきた. これにより、農薬・肥料の散布や収穫を適切な時期に実施することが容易になる. さらに、Sentinel や Landsat [4] の衛星画像はオープンデータであるため、誰でも簡単にデータを分析することができる.

機械学習を利用した異常検知により、獣害の影響などを早期に発見することで、農業生産の向上が期待される. マハラノビス距離 (Mahalanobis' distance: MD) は、多変量データ解析における点や分布間の距離を測定するための統計的尺度である. Generative adversarial network (GAN) は、用意されたデータから特徴を学習し、擬似データを生成することができる生成モデルである. GAN は画像生成だけでなく、画像からのモザイク除去、音声生成、超解像などにも利用されている. また、マハラノビス距離や GAN は、

正しいデータを与えずに特徴量を学習する「教師なし学習」として、異常検知に用いられることも多い。現在、GAN はリモートセンシングの分野で広く使われているが、その多くは超解像を扱っている。機械学習を用いた異常検知は、現在、医療や製造の分野で活用されており、リモートセンシングの分野でも活用できる可能性がある。

1.2 関連研究

様々な研究が、MD や GAN を用いた異常検知の有用性を示唆している。

1.2.1 マハラノビス距離を用いた異常検知

Amrit らはハイパースペクトル画像をユークリッド距離とマハラノビス距離を用いて分析し、慢性骨髄性白血病（Chronic Myeloid Leukemia: CML）と健康な血中サンプルから好中球を分類した [5]。各ハイパースペクトル画像に対して、主成分分析（Principal component analysis: PCA）を使用して、61 または 49 バンドのうち、該当する 7 つの高情報バンドが識別された。ユークリッド距離は 2 点間で計算されるため、与えられた分布を 1 つの点で表す必要があることなどから、分類におけるユークリッド距離の限界が述べられた。結果として、ユークリッド距離は CML 好中球の検出感度に関しては優れていることがわかったが、マハラノビス距離は、健康な好中球の検出と CML 好中球と健康な好中球の区別に優れていた。

1.2.2 f-AnoGAN を用いた異常検知

Thomas らは網膜（Optical Coherence Tomography: OCT）画像について、f-AnoGAN を用いた異常検知を行った [6]。彼らは、健康な訓練データの生成モデルを構築し、GAN の潜在空間への新しいデータの高速マッピング技術を提案し、評価した。画像から潜在的エンコーディングへのマッピングを学習するために、識別器誘導画像間マッピングアプローチ（image-z-image-fast: izi_f ）が初めて利用された。その結果 f-AnoGAN を用いた異常検出精度は 93% で、他手法より高い値となった。さらに、2 人の網膜専門家による視覚的チューリングテストにより、生成された画像は実際の正常な網膜 OCT 画像と区別できないことが示された。

1.2.3 ハイパースペクトル画像における GAN を用いた異常検知

Wang らは変分的背景推論と生成的逆境フレームワークに基づくハイパースペクトル異常検出ネットワーク（Variational Background Inference and Generative Adversarial

Network-Anomaly Detection: VBIGAN-AD) を提案した [7]. VBIGAN モデルは、ハイパースペクトル画像の背景分布特性を学習し、再構成誤差を利用することで検出性能を向上させることができた. VBIGAN フレームワークはサンプル GAN と潜在 GAN から構成され、データ分布を捉えるために 2 つのサブネットワークを介してデータサンプルと潜在サンプルの関係を確立させた. Encoder, Generator と 2 つの Discriminator はそれぞれ完全結合層を持ち、擬似スペクトルの生成と識別を可能にした. 5 つのハイパースペクトル画像データセットを用いた実験の結果、提案モデルの精度が他手法より高い値となった.

1.2.4 Efficient-GAN を用いた異常検知

Fujioka らは Efficient-GAN ベースの異常検出を使用して、乳房超音波検査における正常組織、良性腫瘍、または悪性腫瘍の画像を診断することを目的とした [8]. 彼らのモデルは双方向 GAN に基づいており、学習中にジェネレーターと識別器とともに、入力サンプルを潜在空間にマッピングするエンコーダーを同時に学習した. これにより、テスト中に潜在表現を回復するという計算コストの高いステップを回避した. 異常カラーマップは、入力テスト画像とトレーニング済みジェネレータから生成された画像との差を導出し、グレースケールからカラースケールに変換することによって作成された. 悪性腫瘍は良性腫瘍よりも異常スコアが有意に高く、良性腫瘍は正常組織よりも異常スコアが有意に高い結果となった. また、正常組織を良性腫瘍および悪性腫瘍から区別するための感度、特異度、Area Under the Curve (AUC) 値が高く、正常組織を悪性腫瘍から区別するための値はさらに高い結果となった.

1.2.5 GAN を用いた荒廃農地の判定

櫻井は機械学習を用いて航空写真による荒廃農地の自動判別手法を提案した [9]. 彼は、ディープラーニングによる画像鮮明化技術の一つである Real-Enhanced Super-Resolution Generative Adversarial Network (Real-ESRGAN) を用いて航空写真データの画像鮮明化処理を行った. 学習モデルには、事前学習済みモデルの Real-ESRGAN_x4plus が用いられ、元画像の 4 倍の大きさの画像が生成された. これらの画像を Convolutional Neural Network (CNN) で学習し、学習モデルを用いて耕作か不耕作か判定した. 評価方法として、評価データの耕作・不耕作それぞれ 100 個に対して交差検証を 4 回繰り返すことで、400 個の画像が推定された. 評価の結果、F 値が田で 0.61、畑で 0.80 という結果となり、田では高い精度が得られなかった. また、GAN を用いた画像鮮明化処理による精度向上の効果は見られなかった. 田の精度が低い場合の例として、耕作している土地でも時期によって裸地の場合、耕作中の稲架掛けや水田境目の畦畔が存在する場合、不耕作の裸地で

画像上の濃淡が無くなり水が張っている状態との判別が困難な場合、また不耕作でも水が張っている場合などが挙げられた。

1.3 研究目的

本研究の目的は、衛星画像を用いた GAN による広範囲の水田の異常検知である。異常の対象としては、害虫や鳥獣などによる水田の部分的な異常、また獣害の原因の一つである耕作放棄地や水田以外の土地利用である。衛星画像の水田画素を、MD を用いて正常か異常かに分類した。異常検知に特化した生成モデルである f-AnoGAN と Efficient-GAN を用いた。これらのモデルは各バンドの特徴を学習するために、画像ベースからスペクトルベースのアーキテクチャに変更された。完全連結ニューラルネットワークを使用することで、このモデルは正常な水田画素に対して類似したスペクトル反射率を生成することが期待される。二つの GAN モデルの精度を比較し、GAN の有用性を検証した。

第 2 章

準備

2.1 Sentinel-2

Sentinel-2 [10] は、欧州宇宙期間（European Space Agency: ESA）が運用する太陽同期軌道衛星であり、EU が主導するコペルニクス計画の一環として運用されている。コペルニクス計画の主な目的は、地球の現状とその変動を定量的に把握することで、環境保護や持続可能な発展のための政策立案をサポートすることである。Sentinel-2A, 2B はそれぞれ 2015 年 6 月 23 日及び 2017 年 3 月 7 日に打ち上げられ、同一軌道上を正反対の位置で動く。Sentinel-2 に搭載された Multispectral Instrument (MSI) は、他の中空間分解能の衛星よりも高い空間分解能と時間分解能（5 日間）を持つ。Sentinel-2 は可視光、近赤外光、短波長赤外光にわたる 13 バンドのマルチスペクトルデータを観測することができ、観測視野も 290 km と広く、植生、土壌、水域の観測に優れている。空間分解能は 10 m, 20 m, 60 m でバンド毎に異なる。Sentinel-2 では、Level-1C と Level-2A の 2 つのプロダクトが提供されている。Level-1C は輝度値を反射率に変換し、オルソ補正が適用されたデータである。デジタル標高モデル（Digital Elevation Model: DEM）を使用して画像データを地図投影することで位置情報が補正される。Level-1C の反射率は大気上端反射率が提供される。Level-2A は Level-1C に対して大気補正が適用されたデータである。大気補正により、大気中のガスやエアロゾルの影響が除去され、さらに地形補正により影などの影響も除去される。Level-2A の反射率は地表面反射率が提供されている。

2.1.1 研究対象地

対象地域は、作付け時期の変動が比較的少ない岡山県 (図 2.1) である。岡山県の耕作放棄地率は 2015 年で 27% と全国でも高い比率となっている [11]。観測日は 2023 年 7 月 17 日であり、稲の生育期真っ只中である。画像データは、地理的位置、季節、雲量などを

考慮し，コペルニクスのデータスペースエコシステム経由でダウンロードされた．




図 2.1: 対象地域

2.1.2 使用したバンド

本研究では，Sentinel-2 の 13 バンドのうち空間分解能が 10 m と 20 m の計 10 バンド (表 2.1) を使用した．可視光域では Band 2, Band 3, Band 4, 可視光域と近赤外域の境界であるレッドエッジ域では Band 5, Band 6, Band 7, 近赤外域では Band 8, Band 8a, 短波長赤外域では Band 11, Band 12 を使用した．特に水稻のような作物は，近赤外の帯域で強く反射するという特徴を持つ．

表 2.1: MSI の仕様

Satellite Platform		Sentinel-2B	
Product type		Level-1C	
Observation frequency (day)		10	
Central wavelength (nm) and spatial resolution (m) of the band	Band 2, Blue	490	10
	Band 3, Green	560	10
	Band 4, Red	665	10
	Band 5, VNIR	705	20
	Band 6, VNIR	740	20
	Band 7, VNIR	783	20
	Band 8, NIR	842	10
	Band 8a, NIR	865	20
	Band 11, SWIR	1610	20
	Band 12, SWIR	2190	20

2.2 ポリゴンデータ

本研究では水田の位置を特定するために、ポリゴンデータ (図 2.2) を使用した。このポリゴンデータは「筆ポリゴン」[12] と呼ばれ、地理情報システム (Geographic Information System: GIS) ソフトウェアで利用できる農地区画情報である。このデータは、農林水産省統計局が耕地面積の総合調査のために作成したものである。筆ポリゴンは、衛星画像等の空中写真データを GIS のマップ上に表示し、目視で判読した筆ごとの形状に沿って手作業で作成されている。ただし現地測量や現地確認、各種台帳との突合を行っていないため、現況の農地、各種の台帳等の状況とは一致しない場合がある。各ポリゴンは、ID、耕地の種類、公表年、緯度、経度、重心座標などの属性データを持っている。筆ポリゴンは農林水産省のサイトから 2023 年度分がダウンロードされた。これらのデータは市区町村毎に geojson ファイルとして保存されている。2 種類の耕地 (畑と水田) のうち、水田のみを使用した。



図 2.2: 筆ポリゴン

2.3 関連手法

2.3.1 マハラノビス距離

マハラノビス距離 [13] は、多変量空間における距離尺度であり、各次元の相関を距離として表現することができるため、教師なし学習における異常検出手法の一つとして用いられる。ユークリッド距離とは異なり、対象データセットの分散・共分散行列の逆行列を用いて計算されるため、データの相関を考慮することができる。したがって、分布からの異常値の度合いを定量化することができる。しかし、調査対象のデータが多数の変数にわたって測定されている場合、冗長な情報や相関する情報が多く含まれることがある。このデータの多重共線性により、転置できない特異またはほぼ特異な分散・共分散行列が生成される。さらに、データセットのサンプルの数は変数の数よりも大きくなければならない。マハラノビス距離 $D(\vec{x})$ は式 (2.1) で定義される。

$$D(\vec{x}) = \sqrt{(\vec{x} - \vec{\mu})^T \Sigma^{-1} (\vec{x} - \vec{\mu})} \quad (2.1)$$

\vec{x} : 2 変数以上を含むデータベクトル

$\vec{\mu}$: \vec{x} の平均ベクトル

Σ : 分散共分散行列

マハラノビス距離は行列の計算や分散の計算があるため、二乗した数の和の平方根で求められるユークリッド距離よりも計算量が多くなる。また、分散・共分散行列が単位行列になるデータで計算すると、マハラノビス距離とユークリッド距離は等しくなる。この場合、それぞれの変数の標準偏差が1で、変数間に相関がないことを意味する。

ランダムに生成された20個の二次元データ点に基づいて、原点からのユークリッド距離とマハラノビス距離をそれぞれ算出し、グラフ化したものを図2.3, 2.4に示す。ユークリッド距離は、単なる2点間の直線距離であるため、円によりデータの中心点に対する等しい距離が表されている[14]。マハラノビス距離は、データ点間の相関を考慮しているため、楕円によりデータの中心点に対する等しい距離が表されている。点0と9は、中心点からのユークリッド距離はほぼ同じであるが、マハラノビス距離において中心点からそれぞれ0.55と2.09離れている。この例は、データ点の分散・共分散行列を考慮に入れることの効果を示している。




図 2.3: ユークリッド距離




図 2.4: マハラノビス距離

2.3.2 Generative Adversarial Network

GAN [15] は Generator と Discriminator の2つのニューラルネットワークで構成されている(図2.5)。Generator は、ランダムノイズを入力として、データ分布と似たサンプルを生成する。Discriminator は、Generator が生成した偽物のデータと本物のデータを区別するための判別モデルであり、生成データが本物である確率を出力する。Discriminator は実データと生成データを最大限に識別しようとし、Generator は識別ネットワークを欺こうとしてデータを生成する。この2つのネットワークを交互に競合させ、学習を進めるこ

とにより, Generator は本物の画像に近い偽物の画像を生成することができる.

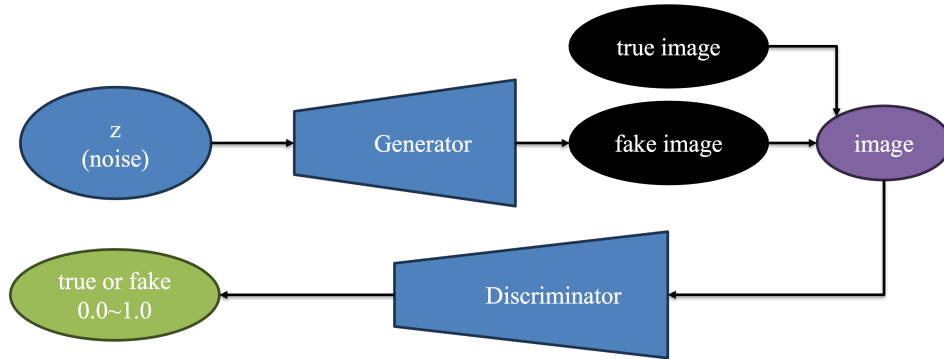


図 2.5: GAN アーキテクチャ

2つのネットワークの競合関係は, 損失関数を共有させることで表現される. GAN の損失関数 $V(D, G)$ は式 (2.2) で定義される.

$$\min_G \max_D V(D, G) = \mathbb{E}_{x \sim p_{\text{data}}(x)} [\log D(x)] + \mathbb{E}_{z \sim p_z(z)} [\log(1 - D(G(z)))] \quad (2.2)$$

x : 入力

z : ノイズ

$p_{\text{data}}(x)$: 実データの分布

$p_z(z)$: ノイズの分布

$D(x)$: Discriminator が出力した, 入力 x が実データである確率

$G(z)$: Generator がノイズ z から生成したデータ

Generator は損失関数の値を小さくすることを目的に, Discriminator は損失関数の値を大きくすることを目的に学習させる.

第 3 章

提案手法

3.1 前処理

Sentinel-2 の空間分解能が 20m であるバンド画像をすべて 10m に近傍法 (Nearest neighbor algorithm) を用いて補間した。また市区町村毎に分割された筆ポリゴンを一つのファイルに統合した。Sentinel-2 の水田画素のみを抽出するために、ベクトルデータである各ポリゴンの境界を縮小した。さらに、雲や雲影などの外れ値を除去するために手作業で雲マスクを作成し、雲がかかっている水田画素を除去した。筆ポリゴンにより 10m 解像度の Sentinel-2 画像における水田画素が同定された。各水田画素は筆ポリゴンの ID 値を割り当てた (図 3.1)。これらの処理は、地理空間情報データの閲覧、編集、解析機能を持つオープンソースソフトウェアである QGIS [16] によって行われた。



図 3.1: 水田画素

3.2 データセット作成

10m 解像度である全 10 バンドの Sentinel-2 画像を重ね合わせ、同定された水田画素の ID と座標から各画素の反射率が抽出された。抽出された全 842064 画素の ID、座標、反射率は CSV ファイルに保存された。

データセット作成のため、各画素のマハラノビス距離 (図 3.2) を算出した。本研究では、画素数が多いため、次元削減は行わず各画素の 10 バンドの反射率を変数とした。このとき、式 (2.1) の分散・共分散行列は 10×10 の行列式となる。マハラノビス距離が 3 より小さい画素を正常、5.5 より大きい画素を異常としてラベルを付与した。閾値は各画素を目視で確認し設定した。閾値処理により、579539 個の正常画素と 32037 個の異常画素に分けられた。




図 3.2: 全画素のマハラノビス距離

3.3 GAN による異常検知

本研究では、異常検知に用いる GAN モデルとして f-AnoGAN と Efficient-GAN の 2 つのモデルを用いた。2 つの GAN モデルを画像ベースからスペクトルベースのアーキテクチャに変更した。画像ベースモデルでは、畳み込み層を用いたダウンサンプリングにより

特徴抽出を行う．スペクトルベースモデルでは，正常の水田画素の類似スペクトル反射率を生成するために完全連結層を用いた．

3.3.1 f-AnoGAN

f-AnoGAN は異常検知モデルの一つであり，Generator, Discriminator, Encoder の 3 つのネットワークから構成される．f-AnoGAN は AnoGAN [17] が改良されたものであり，推論中に学習フェーズが存在するため時間がかかるという問題を改良した．f-AnoGAN では，推論段階での勾配降下による探索が排除され，推論プロセスが高速化される．f-AnoGAN では通常，WGAN アーキテクチャ [18] が使用される．通常の画素のみを用いた Generator と Discriminator の学習に続いて，Generator と Discriminator の最適化されたパラメータを用いて Encoder の学習が行われる．WGAN では，2 つの確率分布間の距離を測定する手法である Wasserstein 距離 [19] が損失関数として用いられる．学習の最適化は，損失関数に勾配ペナルティを適用することで達成される．エンコーダの学習では，異常画素を識別するために，識別器が入力する特徴空間の残差を考慮した izi_f アーキテクチャを使用した．WGAN の学習に使用した同じデータ，すなわち正常画素のみを用いて学習したデータに加え，さらに実画素と再構成画素の画素統計量を計算した． izi_f アーキテクチャにおける Encoder 学習の損失関数 $L_{izi_f}(x)$ は式 (3.1) で定義される．

$$L_{izi_f}(x) = \frac{1}{n} \|x - G(E(x))\|^2 + \frac{1}{n_d} \|f(x) - f(G(E(x)))\|^2 \quad (3.1)$$

x : 入力画素

$G(E(x))$: 再構成画素

$\|\cdot\|^2$: 残差の 2 乗和

$f(\cdot)$: 中間層の識別特徴量

n_d : 中間特徴表現の次元数

正常画素と異常画素の両方を含むテストデータセットを用いて，生成された画素と正常画素を比較することで，異常度を算出する．f-AnoGAN の異常検出は，テストデータごとに異常スコアを決定する．各画素の異常度 $A(x)$ は式 (3.2) で定義される．

$$A(x) = A_R(x) + k \cdot A_D(x) \quad (3.2)$$

x : テストデータ

$A_R(x)$: 本物と偽物のスペクトルの平均 2 乗誤差

$A_D(x)$: 本物と偽物のスペクトルの識別特徴の平均 2 乗誤差

k : 重み係数

3.3.2 Efficient-GAN

Efficient-GAN [20] [21] も、異常検知によく使われる GAN ベースのアーキテクチャであり、f-AnoGAN と同様に、Generator, Discriminator, Encoder の 3 つのネットワークから構成される。しかし、Efficient-GAN は、BiGAN [22] と呼ばれる双方向 GAN が採用されており、学習中に Generator と Discriminator とともに入力サンプルを潜在空間にマッピングする Encoder が同時に学習される。これにより、テスト中に潜在表現を回復する計算コストのかかるステップを回避することができる。Generator, Discriminator, Encoder は同じ損失関数を共有し、Generator と Encoder が最小化し、Discriminator が最大化するようにモデルが更新される。BiGAN の損失関数 $V(D, E, G)$ は式 (3.3) で定義される。

$$\min_{G,E} \max_D V(D, E, G) = \mathbb{E}_{x \sim p_x} [\mathbb{E}_{z \sim p_E(\cdot|x)} [\log D(x, z)]] + \mathbb{E}_{z \sim p_x} [\mathbb{E}_{x \sim p_G(\cdot|z)} [1 - \log D(x, z)]] \quad (3.3)$$

z : 潜在変数

x : 正常スペクトル

$p_x(x)$: x の分布

$p_z(z)$: z の事前分布

$p_E(z|x)$: Encoder によって x から得られる z の条件付き分布

$p_G(x|z)$: Generator によって z から生成される x の条件付き分布

$D(x, z)$: Discriminator がペア (x, z) が正常スペクトルから生成されたものと判断する確率

式 (3.3) を簡略化したものは式 (3.4) で定義される。

$$\min_{G,E} \max_D V(D, E, G) = \mathbb{E}_{x \sim p_x} [\log D(x, E(x))] + \mathbb{E}_{z \sim p_x} [\log(1 - D(G(z), z))] \quad (3.4)$$

$E(x)$: Encoder の出力

$\log D(x, E(x))$: x とそれに対応す $E(x)$ を入力とする場合の Discriminator の予測の対数

$G(z)$: z から Generator が生成した偽スペクトル

$\log(1 - D(G(z), z))$: データペア $(G(z), z)$ を Discriminator が誤認識する確率の対数

正常スペクトルが真のデータとして Discriminator が認識するように学習する部分と、Generator が正常スペクトルと似たデータを生成するように学習する部分に分かれている。

Efficient-GAN の異常検出では、再構成損失と識別器ベースの損失の凸組み合わせに基づいて、テストデータがどれだけ異常であるかを測定する異常度を用いる。Efficient-GAN の異常度 $A(x)$ は式 (3.5) で定義される。

$$A(x) = \alpha L_G(x) + (1 - \alpha) L_D(x) \quad (3.5)$$

x : テストデータ

$L_G(x)$: 再構成損失

$L_D(x)$: Discriminator の損失

α : $0 < \alpha < 1$ の重み係数

3.3.3 スペクトルベースの学習

画像学習においては、畳み込み層を用いて画像内の局所的なパターンの学習を行う。また畳み込み層は、画像の空間的構造を保持したまま処理をするため、画像の特定のパターンがどこに存在するかを学習することができる。しかし、全結合層においては、データ全体を処理するため、各要素間の全体的な依存関係の学習を行う。また全結合層は、データを一次元にフラット化するため、空間的な位置情報や局所的なパターンは無視される。

本研究で用いるスペクトルデータは反射率が並んだ 1×10 の一次元データである。そのため、位置情報を無視し入力ベクトルと出力ベクトルの間の特徴変換を学習できる全結合層を用いる。全結合層を用いることで、潜在ベクトルの次元を順次拡張することができ、多様なスペクトルを生成することができる。さらにスペクトルの要素間の相関を学習することで、正常スペクトルに似たスペクトルを生成することができる。

3.3.4 アーキテクチャ

本研究で用いた 2 つの GAN モデルに含まれる Generator, Discriminator, Encoder のアーキテクチャの概要を示す。各アーキテクチャにおいて、学習を安定させるために、LeakyReLU と Batch Normalization を採用した。

3.3.4.1 Generator

図 3.3 は、Generator のアーキテクチャを示す。f-AnoGAN と Efficient-GAN の Generator におけるアーキテクチャは同じである。本研究で使用する Generator は、3 つの全結合層、LeakyReLU 層、2 つの Batch Normalization 層、また 1 つの Sigmoid 層で構成される。Generator はランダムにサンプリングされた低次元のノイズ (潜在ベクトル) を入力と

して全結合層を用いて高次元のスペクトルデータを生成する．また最後の層には Sigmoid 関数が適用され、値が 0 から 1 の範囲に正規化することで、出力値を反射率の範囲に収めた．




図 3.3: Generator アーキテクチャ

3.3.4.2 Discriminator

Discriminator のアーキテクチャは f-AnoGAN と Efficient-GAN で少し異なる．各モデルにおける Discriminator のアーキテクチャを以下で説明する．

- f-AnoGAN

図 3.4 は、f-AnoGAN における Discriminator のアーキテクチャを示す．f-AnoGAN での Discriminator は、3 つの全結合層と 2 つの LeakyReLU 層で構成される．Discriminator は、Generator によって生成されたスペクトルもしくは正常スペクトルのどちらかが入力され、「本物」か「偽物」を判別する．入力されたスペクトルは Linear 層により次元圧縮され連続値のスコアとして出力される．f-AnoGAN における識別は入力スペクトルの真偽を判定することであり、潜在空間との対応を考慮しない．




図 3.4: Discriminator アーキテクチャ (f-AnoGAN)

- Efficient-GAN

図 3.5 は、Efficient-GAN における Discriminator のアーキテクチャを示す．f-AnoGAN での Discriminator は、3 つの全結合層、2 つの LeakyReLU 層、また 1 つ

の Sigmoid 層で構成される。Discriminator は、潜在ベクトルとスペクトルのペアが入力され、このペアが実データ由来か生成データ由来かを判別する。つまり、入力として正常スペクトルと Encoder が正常スペクトルから生成する潜在ベクトルのペア、またはランダムにサンプリングされた潜在ベクトルと Generator がこの潜在ベクトルを入力として生成したスペクトルのペアが与えられる。Efficient-GAN では入力画像と潜在ベクトルの整合性を判定する。また、Efficient-GAN における Discriminator の最終層には Sigmoid が適用され 0 から 1 の範囲で出力される。




図 3.5: Discriminator アーキテクチャ (Efficient-GAN)

3.3.4.3 Encoder

図 3.6 は、Encoder のアーキテクチャを示す。f-AnoGAN と Efficient-GAN の Encoder におけるアーキテクチャは同じである。Encoder は、3 つの全結合層、2 つの LeakyReLU 層、また 1 つの Tanh 層で構成される。Encoder は正常スペクトルを入力として、潜在空間へのマッピングを行う。つまり、Linear 層において次元圧縮が行われる。また、最終層では Tanh が使用されることで、出力は -1 から 1 の範囲に正規化される。




図 3.6: Encoder アーキテクチャ

第 4 章

実験方法

4.1 実験データ

マハラノビス距離の閾値処理により正常画素と異常画素に分けられたものから，実験用データセットを作成した (表 4.1). トレーニングデータは正常画素のみの 300000 個からなる．テストデータは正常画素 32000 個と異常画素 32037 からなる．データセットに含まれない 478027 画素は学習に使用されなかった．トレーニングデータとテストデータの ID 値の重複は考慮しなかった．

表 4.1: データセット

train	test	
正常	正常	異常
300000	32000	32037

各バンドの画素値は 0 から 1 に正規化した．正常画素と異常画素の違いを確認するため，平均反射率を算出した．図 4.1(a) は学習に用いた 300000 個の正常画素の平均反射率，図 4.1(b) はテストに用いた 32037 個の異常画素の平均反射率である．両グラフの形状は似ているが，異常画素の反射率の値が大きいことがわかる．特に，Band 6, 7, 8, 8a, 11 の値が 0.20 より大きい．

4.2 評価指標

分類問題の評価でよく用いられる ROC-AUC は，GAN モデルの全体的な精度を評価するために用いられた．ROC-AUC は，縦軸に TPR(真陽性率)，横軸に FPR(偽陽性率) をとった ROC 曲線下の面積を表す．TPR と FPR はそれぞれ式 (4.1), (4.2) で定義される．




図 4.1: 平均反射率

ROC 曲線は、正常分類と異常分類の閾値を変えた場合の TPR と FPR の値をプロットすることで表される。さらに、F1-score が高くなるように異常スコアの最適な閾値を求め、予測ラベルを生成し、予測ラベルと実際のラベルを比較して混同行列 (表 4.2) を計算した。

表 4.2: 混同行列

予測 正解	予測	
	正常	異常
正常	TP	FN
異常	FP	TN

混同行列の各要素を用いて, Accuracy(精度), Precision(再現率), Recall(適合率), Precision と Recall の調和平均である F1-score(F 値) を評価指標とした。各評価指標は式 (4.3), 式 (4.4), 式 (4.1), 式 (4.5) で表される。

$$TPR = Recall = \frac{TP}{TP + FN} \quad (4.1)$$

$$FPR = \frac{FP}{FP + TN} \quad (4.2)$$

$$Accuracy = \frac{TP + TN}{TP + FP + FN + TN} \quad (4.3)$$

$$Precision = \frac{TP}{TP + FP} \quad (4.4)$$

$$F1 = \frac{2 \times (Precision \times Recall)}{Precision + Recall} \quad (4.5)$$

TP : 正常と予測された正常画素数

FP : 正常と予測された異常画素数

FN : 異常と予測された正常画素数

TN : 異常と予測された異常画素数

Precision が高く Recall が低い場合は、異常画素を正常画素として認識する検出漏れが多いモデルと言え、Precision が低く Recall が高い場合は、正常の水田画素を異常と認識する過検出が多いモデルと言える。

4.3 実験条件

f-AnoGAN と Efficient-GAN の 2 つのモデルを実装し学習した。本研究のすべてのアルゴリズムは Python3.12.1 で計算され、2 つの GAN モデルは機械学習ライブラリである Pytorch を用いて実装された。実行環境は 8 コア CPU を搭載した MacOS である。各モデルの学習時のパラメータを表 4.3 に示す。また、どちらのモデルについても潜在空間の次元数を 5 に設定した。

表 4.3: 学習パラメータ

	f-AnoGAN	Efficient-GAN
バッチサイズ	30000 (wgan), 50000 (encoder)	100000
エポック数	350 (wgan), 100 (encoder)	250
学習率	0.0002	0.0002
最適化関数	Adam	Adam

第 5 章


結果と考察

5.1 モデル学習結果


f-AnoGAN と Efficient-GAN の学習結果を以下に示す.

- f-AnoGAN

図 5.1(a) は WGAN の Loss 値の推移を表す. Discriminator の Loss 値は 7 付近からエポックごとに, 0 付近に収束し上手く学習が行われた. Generator の Loss 値は 0 から 1 の間で推移しており, ほぼ変動がない. 最終エポック付近では Discriminator 及び Generator の Loss 値が 0.3 ほどで変わらなくなった. Generator と Discriminator のパラメータを固定し, Encoder の学習を行った結果を図 5.1(b) に示す. 1 エポック目から Loss 値が 0.07 と非常に低く, 3 エポック目には Loss 値が 0.03 でそれ以降は値がほぼ変わらなかった. WGAN の学習が上手く行えていたため, Encoder の Loss 値も綺麗に収束したと考えられる.



(a) WGAN



(b) Encoder

図 5.1: Loss 値の推移

- Efficient-GAN

図 5.2 は BiGAN の Loss 値の推移を示す. Generator と Encoder は損失関数を共有

しているため、Loss 値の推移は同じである。Discriminator の Loss 値が高くなると、Generator と Encoder の Loss 値が低くなる。このように、2つの損失関数は対称の動きをしており、さらに多くのエポックで学習した場合も同じ動きが繰り返されると考えられる。また、2つの Loss の値が同じ値になったエポックでのパラメータが最適なモデルと考えられる。




図 5.2: BiGAN の Loss 値の推移

5.2 スペクトルの比較

各 GAN モデルにおいて、最終エポックの最後のバッチで Generator によって生成されたスペクトルを比較した。Generator の最終層には sigmoid 関数が適用されており、各水田画素のスペクトルは 0 から 1 の値を取る。図 5.3(a) は wgan 学習時の最終バッチで生成された 30000 画素の平均反射率である。Band 8a のみかなり高い値をとっていることから、本研究の f-AnoGAN モデルは一部のスペクトルのみを大きな特徴として捉えていると考えられる。正常画素の平均スペクトルにおいても、Band 7, 8a の値が高いため、一部の情報は学習できていると言える。しかし、Band 6, 8 についてはスペクトルの特徴として捉えられていない。図 5.3(b) は Encoder 学習時の最終バッチで生成された 50000 画素の平均反射率である。wgan の学習時とグラフの概形はほぼ変わらないが、Band 8a の値が低くなっている。Encoder 学習において生成された Band 8a の反射率は正常画素の反射率とほぼ同じであった。図 5.3(c) は BiGAN 学習時の最終バッチで生成された 100000 画素の平均反射率である。Band 6, 7, 8, 8a の値が高くなっており、正常画素のスペクトルの概形と非常に良く似ているため、植生の特徴をよく捉えていると言える。生成されたス

ペクトルから，Efficient-GAN のモデルの方が正常画素のスペクトルを上手く学習できた．

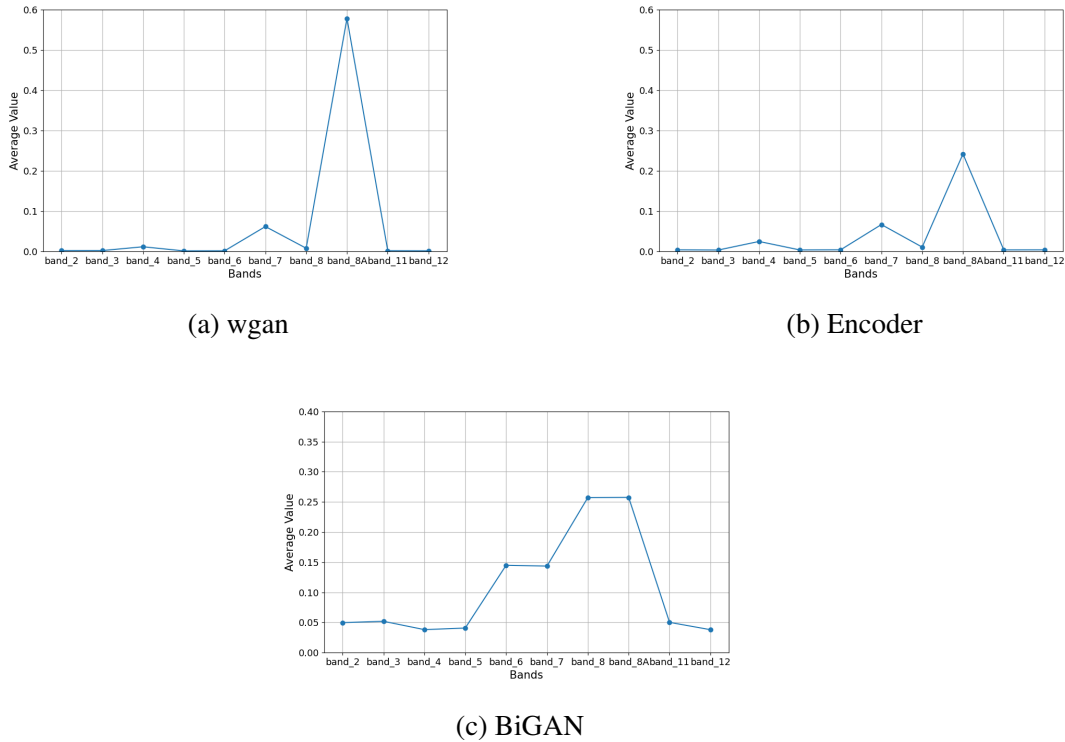


図 5.3: 生成スペクトル

5.3 異常検知精度

学習された各モデルにテストデータを入力し，各水田画素の異常スコアを算出し精度評価を行った結果を示す．全体の精度である ROC-AUC を求めるための ROC 曲線を，図 5.4(a)，5.4(b) に示す．f-AnoGAN 及び Efficient-GAN の ROC-AUC はそれぞれ 0.942，0.946 となり，どちらも高い値を示した．グラフの概形はどちらも，原点から急激に左上に近づき上辺に沿って進んでいることから，理想的なグラフと言える．これはモデルが高い感度と特異度を持っていることを示している．

各モデルにおける異常スコアの分布を，図 5.5(a)，5.5(b) に示す．全体の異常スコアの範囲は f-AnoGAN では 0.00795～2.251 で，Efficient-GAN では 0.232～4.986 となった．各モデルで異常スコアの算出方法が異なることからこのような違いが現れたと考えられる．ラベルごとに異常スコアを見てみると，f-AnoGAN における正常ラベルの範囲は 0.00795～0.116 で，異常ラベルの範囲は 0.00974～2.251 であった．また，Efficient-GAN における正常ラベルの範囲は 0.274～1.257 で，異常ラベルの範囲は 0.232～4.986 であっ

た. 各モデルにおいて, 正常ラベルと異常ラベルで異常スコア最小値はほぼ変わらなかった. さらに, 各モデルの異常スコア分布においてラベルの重なりがある所の詳細を, 図 5.6(a), 5.6(b) に示す. どちらのモデルにおいてもラベルごとの分布の山が分かれていることから正常画素と異常画素の特徴を捉えることができている. 特に, Efficient-GAN の方が各ラベルの分布の山がはっきり分かれている. また, f-AnoGAN では 0.030~0.060, Efficient-GAN では 0.60~0.80 で正常ラベルと異常ラベルの重なりが大きくなっていることが分かる.

各モデルの異常スコアに閾値を設定することで作成された混同行列を, 図 5.7(a), 5.7(b) に示す. 閾値は f-AnoGAN で 0.047, Efficient-GAN で 0.662 であった. これらの混同行列から求められた Accuracy, Precision, Recall, F-1 score を, 表 (5.1) に示す. f-AnoGAN は, Recall, Precision 共に, ほぼ同じ精度で F-1 score は 0.866 であった. Efficient-GAN では, Precision は f-AnoGAN よりも低いがその他の評価指標においては, f-AnoGAN よりも高い結果となり, F-1 score は 0.871 であった. 理由として, Efficient-GAN の方がより正常スペクトルに似たスペクトルを生成していたからだと考えられる. 本実験においては, Efficient-GAN の方が異常検知において優れたモデルと言える.






図 5.4: ROC 曲線




(a) f-AnoGAN




(b) Efficient-GAN

図 5.5: 異常スコアの分布




(a) f-AnoGAN




(b) Efficient-GAN

図 5.6: 詳細分布



(a) f-AnoGAN



(b) Efficient-GAN

図 5.7: 混同行列

表 5.1: 精度評価

	f-AnoGAN	Efficient-GAN
Accuracy	0.866	0.867
Precision	0.869	0.847
Recall	0.863	0.895
F-1 score	0.866	0.871

5.4 マハラノビス距離と異常度の相関

各テストデータの異常スコアとマハラノビス距離の相関をモデル毎に算出した結果を、図 5.8(a), 5.8(b) に示す。相関係数は、f-AnoGAN で 0.723, Efficient-GAN で 0.744 となり、どちらも強くはないが相関を示している。f-AnoGAN では、正常画素における相関係数が 0.299 と特に相関が低い。さらに、異常画素の分布が上方向と横方向に広がっており、大きな相関があるとは言えない。特にマハラノビス距離が 25~50 の画素において異常スコアが著しく大きくなった。また Efficient-GAN においても、異常画素の分布が上方向と横方向に広がっており、相関は見られなかった。これらの結果より、どちらのモデルもマハラノビス距離の観点とは違う観点で異常を検知していると言える。

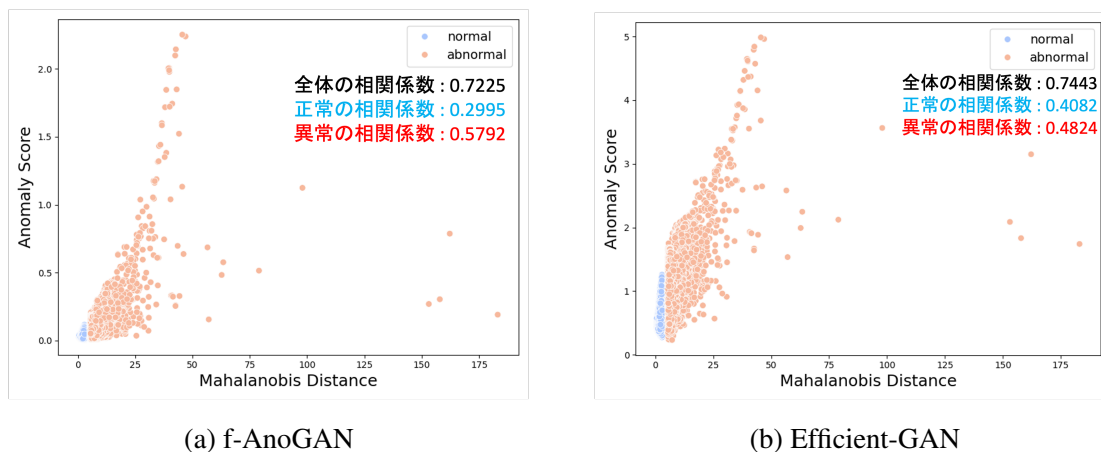


図 5.8: 相関散布図

5.5 異常画素検知の例

実際に異常画素検知が出来ているか目視で確認するために、全 842064 画素を f-AnoGAN よりも精度が高かった Efficient-GAN に入力し、異常スコアを算出した。Sentinel-2 の各水田画素に異常スコアの値を持たせることによって視覚的に確認した。図 (5.9) は、Sentinel-2 の各水田画素を異常スコアごとに、色分けを行い可視化したものである。この画像と耕作放棄地が記された農地ナビ [23]、また航空画像を用いて耕作放棄地の異常スコアと、異常スコアが高い画素の土地利用を確認した。




図 5.9: 異常スコアの可視化

図 5.10(a) は異常スコアが特に高かった土地利用の例である。また、図 5.10(b) は Sentinel-2 と同じ場所で解像度が高い航空画像である。異常スコアが特に高かった場所は、水田から建物やソーラーパネルに変化した場所で、異常スコアは 2 以上となっている。特にソーラーパネルに変化した場所は反射率が正常画素よりも非常に高く、違いが顕著に出たと考えられる。また、水田から更地や駐車場になった場所も反射率の違いが顕著に出たため、上手く異常として認識された。この結果から、元々水田が存在していた場所の土地利用の変化を検出できると考えられる。

図 5.11(a) は異常スコアが少し高かった土地利用の例である。また、図 5.11(b) は Sentinel-2 と同じ場所で解像度が高い航空画像である。異常スコアが少し高かった場所




(a) Sentinel-2

(b) 航空画像

図 5.10: 異常検出例 (ソーラーパネルや建物)

は、レンコンなどの他の作物が栽培されている場所で、異常スコアは 1.4~2.0 となっている。レンコン栽培が行われている画素は反射率の違いに関しては大きくは変わらないが、正常画素がうまく学習できたことにより、微妙な違いを検出できたと考えられる。特に岡山市や倉敷市ではレンコン栽培が盛んなため、このような土地利用法が多くみられた。



(a) Sentinel-2

(b) 航空画像

図 5.11: 異常検出例 (他の作物)

耕作放棄地については、異常スコアは低いものが多く異常画素として検出することが難しかった。図 5.12(a) は、異常スコアが少し高かった耕作放棄地の例である。また、図 5.12(b) は Sentinel-2 と同じ場所で解像度が高い航空画像である。異常スコアが 1.0~1.4 ほどで、レンコンが栽培されている場所よりは、低い値となった。異常スコアが少し高い耕作放棄地は、草木があまり生えておらず、更地に近い状態の場所や背の高い草木が生い茂っている場所が多かった。これにより、水田画素とのスペクトルの違いが検出できたと考えられる。

図 5.13(a) は、異常度が低かった耕作放棄地の例である。また、図 5.13(b) は Sentinel-2 と同じ場所で解像度が高い航空画像である。異常スコアは 0.8 未満であり、水田画素とほ




図 5.12: 異常スコアの高い耕作放棄地の例

ば同じ値であった。またマハラノビス距離の値も 2~4 と低い値を示した。これは、放棄により草木が生い茂ることで 10m 解像度の Sentinel-2 では、反射率の違いを認識することができなかったことが原因であると考えられる。



図 5.13: 異常スコアの低い耕作放棄地の例

図 5.14(a) は、マハラノビス距離が低いが異常スコアが少し高かった例である。また、図 5.14(b) は Sentinel-2 と同じ場所で解像度が高い航空画像である。図の赤い点で記された画素はマハラノビス距離が 3 未満であるが異常スコアが 0.8 以上であった画素を示している。これらの農地は正常な水田であるにもかかわらず部分的に異常スコアが高い値となった。これは実際に獣害などによる部分的な異常も考えられるが、稲の品種や作付け時期の違いなども考えられる。

図 5.15(a) は、マハラノビス距離が高いが異常スコアが低かった例である。また、図 5.15(b) は Sentinel-2 と同じ場所で解像度が高い航空画像である。図の白い点で記された画素はマハラノビス距離が 5.5 より大きい値であるが異常スコアが 0.59 未満であった画素を示している。この農地は正常な水田であり、マハラノビス距離が高かったが GAN で

は正常と検知された。

これらの結果から正常な水田でも異常と検知された画素が多く見られたので、ドローンなどを用いて部分的な異常の原因を突き止める必要がある。また稲の品種や作付け時期の違いなどによる異常スコアの相関を調べることで水田の詳細を把握することができると考える。



(a) Sentinel-2

(b) 航空画像

図 5.14: MD が低いが異常スコアが少し高かった例



(a) Sentinel-2

(b) 航空画像

図 5.15: MD が高いが異常スコアが低かった例

第 6 章

結言

6.1 まとめ

本研究では, Sentinel-2 データを用いて, GAN による水田の異常検知を行った. 各水田画素のマハラノビス距離を算出し, 閾値に従って正常画素と異常画素に分割したデータを, 画像ベースからスペクトルベースに変更した 2 つの GAN モデルで学習させた. 全結合層を用いて各画素のスペクトルを学習することで, 正常画素のスペクトルに似たスペクトルを生成し, GAN によって異常画素を検出することができた. モデルの全体的な精度であるの ROC-AUC は, f-AnoGAN で 0.942, Efficient-GAN で 0.946 であり, どちらも高い精度を示した. また, 各テストデータの異常スコアに閾値を与え, 2 つのモデルの傾向をみた. f-AnoGAN は検出漏れが少ないが過検出が多いモデルの傾向が見られ, F-1 score の値は 0.825 となった. Efficient-GAN は, 検出漏れは f-AnoGAN よりも多いが, F-1 score は 0.858 と高い結果になった. 各画素のマハラノビス距離と異常スコアに大きな相関は見られなかった.

抽出された全画素を Efficient-GAN に入力し, 異常スコアを算出し, 目視での評価を行った. 水田から建物やソーラーパネルに変化していた場所の異常スコアはとても高い結果となった. また, レンコンなどの他の作物を栽培している場所の異常スコアも少し高い値を示した. これらより, 本研究の GAN モデルは土地利用の変化などを検出することに長けていると言える. しかし, 草木が生い茂り他の水田画素との反射率の違いがみられなかった為, 耕作放棄地の多くを異常画素として検出することができなかった. また, 正常な水田においても異常スコアが少し高い画素がいくつか見受けられた. これらの結果から, Sentinel-2 を用いた異常検知の有用性と限界が示された.

6.2 今後の課題

本研究では、Sentinel-2 データを用いて水田に対する異常の検出を試みたが、多くの耕作放棄地を異常として検知することができなかった。つまり、10m 解像度の Sentinel-2 データでは、耕作放棄地と水田を反射率で区別することが困難であることが示された。耕作放棄地を異常として検出するためには、さらに高解像度の衛星や、航空画像を用いて画素ごとの反射率を検出する必要がある。これにより、草木と水稻の区別が容易になると考えられる。他にも、耕作放棄地ごとに反射率や画像単位での特性を見つけることにより、田畑として再生可能かどうかの判別もする事が必要である。

また、正常な水田を異常として誤検知した例も多くあった。異常の詳細を知るためにはドローンなどを用いて、正常な水田においての部分的な異常を突き止め、それらの画素の特徴を異常として捉える必要がある。また、稲の品種や作付け時期の違いによる異常スコアの相関が解明できれば、より詳細な異常検知が可能になると考えられる。

付録 A

A.1 Sentinel-2 のデータとプログラムの詳細

本研究に関するデータ及びプログラムは全て google drive の以下のディレクトリ

- /共有アイテム/DS_Lab2024_Mgr/研究データ_ResearchData/小川将平/Sentinel/

画素抽出とデータセット作成のプログラムは全て以下のディレクトリ

- /共有アイテム/DS_Lab2024_Mgr/研究データ_ResearchData/小川将平/Sentinel/code/
 - 画像抽出
 - * extract.py
 - データセット作成
 1. distance.py (マハラノビス距離の算出, ラベル付与)
 2. convert.py (各画素の反射率正規化)
 3. divide2.py (正常画素と異常画素の分割)

f-AnoGAN の実行コードは全て以下のディレクトリ

- /共有アイテム/DS_Lab2024_Mgr/研究データ_ResearchData/小川将平/Sentinel/GAN/f-AnoGAN
 - 実行手順
 1. train_wgangp.py
 2. train_encoder_izif.py
 3. test_anomaly_detection.py

Efficient-GAN の実行コードは全て以下のディレクトリ

- /共有アイテム/DS_Lab2024_Mgr/研究データ_ResearchData/小川将平/Sentinel/GAN/Efficient-GAN

– 実行手順

1. train_BiGAN.py
2. test_anomaly_detection.py

A.2 データセット詳細

抽出された全 842064 画素におけるバンド 4, 8, 11 を用いた散布図を図 A.1 に示す. 各バンドの反射率は正規化前のものである.




図 A.1: 3 次元散布図

マハラノビス距離の散らばりを表すヒストグラムを図 A.2 に示す. マハラノビス距離が 2~3 の画素が一番多いことが分かる.

A.3 GAN による生成画像

図 A.3(a) は wgan の学習において, 320 エポックで生成された 25 枚の画像である. 図 A.3(b) は Encoder の学習において, 67 エポックで生成された 25 枚の画像である. 図 A.3(c) は BiGAN の学習において, 240 エポックで生成された 25 枚の画像である. これ





図 A.2: ヒストグラム


らの全ての画像は 10 個のスペクトルを 0~1 に正規化してグレースケールで表示したものである．図 (5.3) で示されたスペクトルのように値が高いバンドほど白く映っている．



(a) wgan



(b) Encoder



(c) BiGAN

図 A.3: 生成画像

A.4 閾値の選定

2 つのモデルにおいて，混同行列を作成するために用いた異常スコアの閾値と F1 score の関係を，図 A.4(a)，図 A.4(b) に示す．

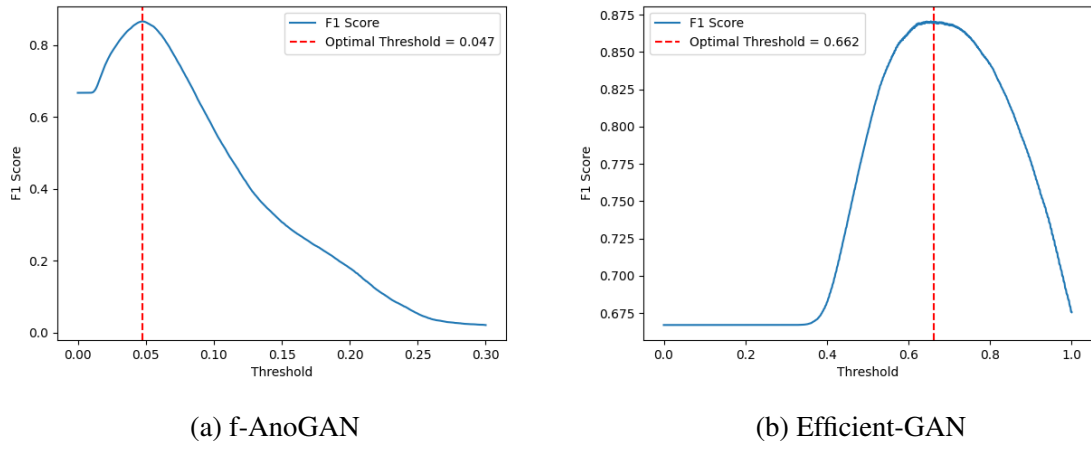


図 A.4: 閾値と F 値の関係

A.5 全画素の異常スコア

学習済み Efficient-GAN に全画素を入力し、異常スコア (図 A.5) を求めた。




図 A.5: 異常スコア分布

付録 B

B.1 PlanetScope を用いた異常検知

B.1.1 使用データ

PlanetScope [24] は、2026 年に打ち上げられた衛星で、アメリカの Planet Lab が運用する世界初の超高頻度工学衛星画像である。時間分解能は 1 日で空間解像度は 3.0 m と Sentinel-2 よりも高い。また、8 バンドのマルチスペクトルデータを観測可能である。

対象地域は岡山市付近 (図 B.1) であり、筆ポリゴンは岡山市，倉敷市，総社市，玉野市，瀬戸内市，赤磐市を使用した。観測日は、本研究の Sentinel-2 と同じ 2023 年 7 月 17 日である。




図 B.1: PlanetScpoe

B.1.2 データセット

12 ページの 3.1 節で説明した方法で PlanetScope 出の水田画素を抽出し、各画素のマハラノビス距離を算出した (図 B.2)。抽出された画素数は 3129704 個であった。




図 B.2: マハラノビス距離 (PlanetScope)


マハラノビス距離が 3 より小さい画素を正常、6 より大きい画素を以上としてラベルを付与し、実験用データセットを作成した (表 B.1)。トレーニングデータは正常画素のみの 1000000 個からなる。テストデータは正常画素 72000 個と異常画素 71736 個からなる。

表 B.1: データセット (PlanetScope)


train	test	
正常	正常	異常
1000000	72000	71736

図 B.3(a) は学習に用いた 1000000 個の正常画素の平均反射率、図 B.3(b) はテストに用いた 71736 個の異常画素の平均反射率である。赤外域である Band 8 の値が特に高くなっ

ていることがわかる。



(a) 正常スペクトル




(b) 異常スペクトル

図 B.3: 平均反射率 (PlanetScope)


B.1.3 実験結果

B.1.3.1 異常検知精度

テストデータにおける異常スコアの分布を図 B.4 に示す。図 B.4(a) は全体の分布を示す。全体の異常スコアの範囲は 0.290~3.324 であった。また、正常ラベルと異常ラベルが重なっている部分の分布を図 B.4(b) に示す。正常ラベルと異常ラベルが重なっている部分は、Sentinel-2 の画素よりも少なく正常画素と異常画素がより綺麗に分かれていることが分かる。



(a) 全分布



(b) 詳細分布

図 B.4: 異常スコアの分布

図 B.5 は ROC-AUC を求めるための ROC 曲線を示す。ROC-AUC の値は 0.992 と非常に高い値を示した。これは正常画素と異常画素の区別が Sentinel-2 を用いた時よりもはっきりしていることが考えられる。また、異常スコアに閾値を設定することで作成

された混同行列を，図 B.6 に示す．この時の閾値は 0.603 であった．混同行列から求められた Accuracy, Precision, Recall, F-1 score を，表 (B.2) に示す．どの指標においても Sentinel-2 を用いた実験よりも高い精度となり，F-1 score の値は 0.955 という結果になった．




図 B.5: ROC 曲線




図 B.6: 混同行列

表 B.2: 精度評価

Accuracy	0.955
Precision	0.948
Recall	0.962
F-1 score	0.955

B.1.3.2 異常スコアの可視化

Sentinel-2 の実験と同様に全画素を Efficient-GAN に入力し、各画素の異常スコアを可視化した。Sentinel-2 の実験と同様に水田から建物やソーラーパネルに変化した場所や、レンコンなどの他の作物が栽培されている場所は異常として検知された。しかし耕作放棄地 (図 B.7) については、Sentinel-2 の実験と同様に異常スコアは低い結果となった。解像度が高くなったにも関わらず異常として検出されなかった原因として、PlanetScope のバンド数の少なさが挙げられる。特に PlanetScope は赤外域のバンドが 1 個しかなく水稻との違いを検知できなかったと考えられる。




図 B.7: 耕作放棄地の例

謝辞

本研究において、的確なご指摘、助言をご教授いただきました松岡真如教授に深く感謝いたします。また、日頃からアドバイスをしていただいた研究室の先輩方、同期及び後輩の皆様に感謝いたします。そして最後に、私の大学院生活を支えてくれた家族に今一度感謝の意を示し、本論文の結びといたします。

参考文献

- [1] 農林水産省. 気候変動が水稻に与える影響. <https://www.maff.go.jp/j/seisan/kankyo/ondanka/attach/pdf/index-133.pdf>. アクセス日: 2025/1/19.
- [2] 農林水産省. 野生鳥獣による農作物被害状況について. https://www.maff.go.jp/j/seisan/tyozyu/higai/hogai_zyoukyou/attach/pdf/index-40.pdf. アクセス日: 2025/1/19.
- [3] 内閣府ホームページ. 農地・耕作放棄地面積の推移. https://www5.cao.go.jp/keizai-shimon/kaigi/special/2030tf/281114/shiryoul_2.pdf. アクセス日: 2025/1/19.
- [4] Landsat Science. Data access. <https://landsat.gsfc.nasa.gov/data/data-access/>. アクセス日: 2025/1/19.
- [5] Amrit Panda, Ram Bilas Pachori, and Neeta Devi Sinnappah-Kang. "Classification of chronic myeloid leukemia neutrophils by hyperspectral imaging using Euclidean and Mahalanobis distances". *Biomedical Signal Processing and Control*, Vol. 70, p. 103025, 2021.
- [6] Thomas Schlegl, Philipp Seeböck, Sebastian M Waldstein, Georg Langs, and Ursula Schmidt-Erfurth. "f-AnoGAN: Fast unsupervised anomaly detection with generative adversarial networks". *Medical image analysis*, Vol. 54, pp. 30–44, 2019.
- [7] Zhiwei Wang, Xue Wang, Kun Tan, Bo Han, Jianwei Ding, and Zhaoxian Liu. "Hyperspectral anomaly detection based on variational background inference and generative adversarial network". *Pattern Recognition*, Vol. 143, p. 109795, 2023.
- [8] Tomoyuki Fujioka, Kazunori Kubota, Mio Mori, Yuka Kikuchi, Leona Katsuta, Mizuki Kimura, Emi Yamaga, Mio Adachi, Goshi Oda, Tsuyoshi Nakagawa, et al. "Efficient anomaly detection with generative adversarial network for breast ultrasound imaging". *Diagnostics*, Vol. 10, No. 7, p. 456, 2020.
- [9] 櫻井淳. "GAN を用いた航空写真からの荒廃農地の判定に関する研究". 第 21 回情報

- 科学技術フォーラム講演論文集, Vol. 21, No. 4, pp. 307–308, 2022.
- [10] Sentinel Wiki. Sentinel-2. <https://sentiwiki.copernicus.eu/web/s2-mission>. アクセス日：2025/1/19.
- [11] 農林水産省. ③ 耕作放棄地面積. <https://www.maff.go.jp/chushi/kyoku/jigohyoka/attach/pdf/index-51.pdf>. アクセス日：2025/1/19.
- [12] 農林水産省. 農地の区画情報（筆ポリゴン）のデータ提供・利用. <https://www.maff.go.jp/j/tokei/polygon/>. アクセス日：2025/1/19.
- [13] Roy De Maesschalck, Delphine Jouan-Rimbaud, and Désiré L Massart. "The mahalanobis distance". *Chemometrics and intelligent laboratory systems*, Vol. 50, No. 1, pp. 1–18, 2000.
- [14] Saeed Ahmed, YoungDoo Lee, Seung-Ho Hyun, and Insoo Koo. "Covert cyber assault detection in smart grid networks utilizing feature selection and euclidean distance-based machine learning". *Applied Sciences*, Vol. 8, No. 5, p. 772, 2018.
- [15] Ian Goodfellow, Jean Pouget-Abadie, Mehdi Mirza, Bing Xu, David Warde-Farley, Sherjil Ozair, Aaron Courville, and Yoshua Bengio. "Generative adversarial nets". In *Advances in neural information processing systems*, Vol. 27, 2014.
- [16] QGIS. Qgis ユーザーガイド. https://docs.qgis.org/3.34/ja/docs/user_manual/index.html. アクセス日：2025/1/19.
- [17] Thomas Schlegl, Philipp Seeböck, Sebastian M Waldstein, Ursula Schmidt-Erfurth, and Georg Langs. "Unsupervised anomaly detection with generative adversarial networks to guide marker discovery". In *International conference on information processing in medical imaging*, pp. 146–157. Springer, 2017.
- [18] Qingfeng Wang, Xuehai Zhou, Chao Wang, Zhiqin Liu, Jun Huang, Ying Zhou, Changlong Li, Hang Zhuang, and Jie-Zhi Cheng. "WGAN-based synthetic minority over-sampling technique: Improving semantic fine-grained classification for lung nodules in CT images". *IEEE Access*, Vol. 7, pp. 18450–18463, 2019.
- [19] Tudor Manole, Sivaraman Balakrishnan, and Larry Wasserman. "Minimax confidence intervals for the sliced Wasserstein distance". *Electronic Journal of Statistics*, Vol. 16, No. 1, pp. 2252–2345, 2022.
- [20] Houssam Zenati, Chuan Sheng Foo, Bruno Lecouat, Gaurav Manek, and Vijay Ramaseshan Chandrasekhar. "Efficient gan-based anomaly detection". *arXiv preprint arXiv:1802.06222*, 2018.
- [21] Houssam Zenati, Manon Romain, Chuan-Sheng Foo, Bruno Lecouat, and Vijay Chandrasekhar. "Adversarially learned anomaly detection". In *2018 IEEE International conference on data mining (ICDM)*, pp. 727–736. IEEE, 2018.

-
- [22] Jeff Donahue, Philipp Krähenbühl, and Trevor Darrell. "Adversarial feature learning". *arXiv preprint arXiv:1605.09782*, 2016.
- [23] eMAFF 農地ナビ. 遊休農地かどうか. <https://map.maff.go.jp/>. アクセス日：2025/1/19.
- [24] Sentinelhub. Planetscope. <https://docs.sentinel-hub.com/api/latest/data/planet/planet-scope/>. アクセス日：2025/1/19.