DNB と BT データを用いた ANN による漁火検出モデルについて

Fishery lights detection model by ANN using DNB and BT data

長谷川大輔*・浅沼 市男**・山口 崇志***

朴 鍾杰**・マッキン ケネス ジェームス**

Daisuke HASEGAWA, Ichio ASANUMA, Takashi YAMAGUCHI

Jonggeol PARK and Kenneth J. MACKIN

Abstract : Day and Night Band (DNB) of Visible Infrared Imaging Radiometer Suite (VIIRS) on the Suomi National Polar-Orbiting Partnership (S-NPP) has exhibited a capability to detect the fishery lights in the night time. The distribution of fishery lights, which are corresponding to the distribution of fishery resources, has a significant information for fishery industries and resource managements. Unfortunately, it is difficult to distinguish the fishery lights on DNB images because the lunar lights reflected by clouds are observed simultaneously. In this study, the artificial neural network (ANN) was developed to detect the fishery lights apart from the lunar lights reflected by clouds. The ANN was trained to simulate the DNB lights with the brightness temperature at $3.7\mu\text{m}$ ($\text{BT}_{3.7}$) and the fraction of Moon illumination in date and location. The fishery lights were given as the absolute error between the predicted and the observed DNB. The errors were compared between the pixel based ANN and the convolutional NN (CNN), and the pixel based ANN was superior to the CNN due to convolution of the cloud pixels.

1. はじめに

南シナ海は世界で2番目に大きな半閉鎖海域であるとともに、河川流入水域を含む大規模な海洋生態系を作り、沿岸諸国による漁業活動が沿岸水域から排他的経済水域を超えて展開されており、沿岸諸国間の調整が進んでいない (Rosenberg, 1999; Dang, 2012; Muallil, 2014)。一方、東シナ海・黄海は大陸河川により供給される豊かな栄養塩を基礎とし、生産性が極めて高い海域であり、沿岸諸国間の漁業協定が締結され、南シナ海と比較すると、秩序を持った漁業が展開されている (Qu et al., 2005; 山田, 2015)。このような沿岸漁業の展開されている中、リモートセンシングによる漁業資源と管理の支援が求められており (CEAR-

AC, 2005)、その一つとして、Suomi National Polar-Orbiting Partnership (S-NPP) 衛星に搭載された Visible Infrared Imaging Radiometer Suite (VIIRS) の Day Night Band (DNB) による漁火の観測データから、季節的な漁業活動と漁場との相関、地域漁業協定への応用の可能性が検討されている (Straka et al., 2015)。この VIIRS は、陸域と雲の観測のための可視域、近赤外域、短波長赤外域、長波長赤外域に各1バンドずつ計5バンドで空間分解能375m, DNBの1バンドとともに、海洋と雲の観測のため可視近赤外波長帯域に7バンド、短波長赤外域に4バンド、中波長赤外域に2バンド、長波長赤外域に3バンドの計17バンドで空間分解能750m, 計22バンドを持つ。DNBは、500~900nmの単一波長帯域とし、750mの空間分解能を持ち、夜間の月光下の雲、街明かり、漁火などの観測のために利用される。VIIRS などの中解像度衛星画像は、航空機観測画像や高解像度衛星画像に比べて入手コストが低く、回帰日数が短く、時間分解能の高いデータが得られ、頻度の高い観測に適している。DNB

* 東京情報大学 (現:株式会社パスコ)

** 東京情報大学

***東京情報大学 (現:株式会社ソクダ技研)

「写真測量とリモートセンシング」VOL. 58, NO.1, 2019

図1 2016年2月23日月光下 NPP 観測 DNB 画像 (左) と BT_{3.7}画像 (右)

画像の1画素に対して、漁船の大きさは明らかに小さいものの、強力な漁火のため一つの画素として観察される (浅沼, 2013)。

DNB 画像において、雲に反射された月光と漁火は、単一波長帯域により観測されるため、波長依存性がないことから、満月などの月光の強い期間では、雲による反射光と漁火の判読が困難である。図1は VIIRS が2016年2月23日に南シナ海と近海を観測した DNB 分光放射輝度 ($\text{nW cm}^{-2} \text{sr}^{-1}$) 画像 (左) と $3.7\mu\text{m}$ 波長帯域の輝度温度 (Brightness Temperature (BT_{3.7})) (K) 画像 (右) である。BT_{3.7}画像において輝度温度の低く検出される雲は、月光を反射する雲の存在を示すことから、DNB と BT_{3.7}との回帰分析による漁火などの検出が議論されている (Asanuma et al., 2017)。しかしながら、DNB 画像から月光下の雲と海上の光源を区別するには、多時期の多様な雲を観測した大量の DNB および BT_{3.7}データ、月光データで構成された説明変数から得られる経験的手法が必要となり、一般的な回帰分析から多時期の月光下の DNB の複雑な大気状態を再現することは難しい。

本研究では、これまでの経験的手法に対して、DNB および BT_{3.7}データ、月光データから大気の状態を学習した ANN による漁火検出のモデルの構築の可能性を検討する。これまで、航空機観測画像や高解像度衛星画像における形状的な特徴の抽出など、従来の分類手法よりも高い分類精度を得るために、パターン認識や関数近似で実績のある多層パーセプトロン (Multi-Layer Perceptron (MLP)) や、畳み込み

ニューラルネットワーク (Convolutional Neural Network (CNN)) などの人工ニューラルネットワーク (Artificial Neural Network (ANN)) が応用されている (Czyzowska-Wisniewski et al., 2015 ; Fu et al., 2017 ; Yuan et al., 2017 ; Liu et al., 2018)。しかし、MLP や CNN による、空間分解能750m の DNB 画像から船舶の形状を認識することは難しい。ここでは、雲の存在を示す BT_{3.7}データから DNB データを再現し、DNB 観測データとの差分から船舶を検出することを目的とし、MLP や CNN により DNB 画像を再現するための近似関数 $f(x)$ を求める。回帰型の MLP と CNN の機能的な差異は畳み込みフィルタの適用のみである。図2は局所コントラスト正規化 (Local Contrast Normalization (LCN)) (Jarrett et al., 2009) の際に行われるガウシアンフィルタを用いた畳み込み処理を示す。図2の畳み込み処理では、中心画素 (1画素) と近傍を含む 5×5 画素の入力に対して、同じサイズの 5×5 ガウシアンフィルタとの積和が出力される。次式は 5×5 ガウシアンフィルタの総和を示す。

$$\sum_{p=1}^5 \sum_{q=1}^5 w_{pq} = 1 \quad (1)$$

また、次式は 5×5 画素と 5×5 ガウシアンフィルタとの積和 $\bar{x}_{ij}$ を示す。

$$\bar{x}_{ij} = \sum_{p=1}^5 \sum_{q=1}^5 w_{pq} x_{i+p, j+q} \quad (2)$$

そして、図2では、 20×20 画素の入力画像上で1画素ずつスライドしながら 5×5 画素の畳み込み処理を行い、 5×5 画素の中心画素の位置への積和の出力を繰

図2 5×5画素の畳み込み処理

り返して、最終的に16×16画素の出力画像が生成される。CNNを確立したLeCun et al. (1998)の文字認識やCNNを用いた顔認識(Albu, 2009)において、畳み込み処理に5×5画素が用いられており、本研究では、回帰型MLPへの入力にBT_{3.7}の5×5画素データを与えることで、空間分解能750mのDNB画像上の5×5画素の空間スケールの雲の再現に、LCNのような畳み込みフィルタと同等の関数を得ることの可能性も検討する。このため、回帰型MLPへの5×5画素の入力データのほか、5×5画素の中心画素の入力データを作成し、両入力データによる予測結果を評価する。

2. データと解析手法

2.1 VIIRS データ処理

Goddard Space Flight Center (GSFC (<https://directreadout.sci.gsfc.nasa.gov/>)) が提供する International Polar Orbiter Processing Package (IPOPP) を用いて、東京情報大学が受信した2017年1月1日～12月31日のVIIRS受信データから南シナ海上のDNBデータの分光放射輝度と3.7μmの輝度温度

BT_{3.7}の物理量、それぞれ0～100 (nW cm⁻² sr⁻¹) と180～320 (K) を1～255の値に正規化し、GeoTIFF画像を作成した。また、画像の全体の大きさは4,000×4,000画素であり、WGS84座標系(緯度・経度)における1画素の大きさは0.0075°×0.0075°とした。

DNBデータにおける漁火の位置情報は、Elvidge et al. (2015) のアルゴリズムを用いたアメリカ海洋大気庁(National Oceanic and Atmospheric Administration (NOAA)) のEarth Observation Group (EOG) (<https://www.ngdc.noaa.gov/eog/>) が公開しているCSVデータを使用した。

2.2 輝面率と月高度

天文学関連パッケージPyAstronomy (<https://www.hs.uni-hamburg.de/>) を利用し、Meeus (1998) に基づいた特定日の輝面率(Moon's illuminated fraction (%)) を求めた。次式は輝面率を示す。

$$k = \frac{1 + \cos i}{2} \quad (3)$$

k は輝面率、 i は位相角であり、輝面率の値を0～100%の範囲で評価するため、輝面率が0%に近いほど新月に近く、輝面率が100%に近いほど満月に近いことを示す。また、天文学アプリケーション XEphem に基づいた PyEphem (<http://rhodesmill.org/pyephem/>) を用いて特定の日付、世界時、経緯度、標高における見かけ上の仰角を示す月高度(°)を推定した。

2.3 回帰型MLP処理の流れ

2.3.1 入出力データセットの作成

図3は回帰型MLP処理の流れを示す。図3でANNにBT_{3.7}データとDNBデータを入力して、DNB(BT_{3.7})データ上で高い(低い)値を示す雲を学習したANNからDNBデータを予測する。そして、予測DNBデータとDNBデータとの差分では、DNBデータ上の雲が除去されて、DNBデータ上で雲と同じく高い値を示す漁火は残ると考えられるため、図3の流れで漁火を検出する。

図3の回帰型MLPでは学習に0～1の範囲のデータを学習に使用する。輝面率90%以上の2017年のVIIRS観測データについて、BT_{3.7}のデータから陸域と欠損値を含まない中心画素と近傍を含む5×5画素を任意でサンプリングし、DNBデータからBT_{3.7}に対応する5×5画素の中心画素の値をサンプリングし

図3 回帰型 MLP 処理の流れ

た。また、VIIRS 観測と同じ時間帯の輝面率を求め、0～1の範囲で正規化して使用した。さらに、BT_{3.7}の5×5画素の中心画素の経緯度の標高0mから観察した月高度を求め、0～1の範囲で正規化して使用した。回帰型MLPへの入力データセットとして、BT_{3.7}の中心画素と近傍を含む5×5画素のデータ、輝面率、月高度の合計27ユニットを作成し、入力データセットに対する出力データセットとしてDNBの中心画素のデータ（1ユニット）を用意した。1日の観測データ上1回のサンプリングで学習用入出力データセットを

1件作成するため、1日の観測データ上でM回サンプリングする。これを2017年の輝面率90%以上の観測データ数Sに対して行うため、全データ数はM×S件となる。ANNが入出力データセットから学習して予測したDNBは、学習に使用したDNB画像との誤差が少なくなるように学習されることから、全入出力データセット数のうち、任意の30%をテストサンプル法による検証用のデータとして確保し、学習から除外した。テストサンプル法による検証には大量なデータが必要なため、本研究では検証用のデータが1万件程

度得られるようにサンプリングを行った。一方で、図 3 の中心画素と近傍を含む BT_{3.7} データ 5 × 5 画素のうち、回帰型 MLP への入力データセットとして、中心画素、輝面率、月高度の合計 3 ユニットを作成し、入力データセットに対する出力データセットとして DNB の中心画素のデータ（1 ユニット）を用意した。また、中心画素データセットも全データセット数任意 30%（1 万件程度）を検証用データとして確保し、学習から除外した。2017 年に輝面率 90% 以上が推定された VIIRS 観測日は 1 月 10～15 日、2 月 9～14 日、3 月 10～15 日、4 月 9～14 日、5 月 8～14 日、6 月 7～12 日、7 月 7～12 日、8 月 5～10 日、9 月 4～9 日、10 月 3～8 日であり、11 月は 1、3、5 日のデータが欠損していたため 2、4、6 日、12 月は 3、6、7 日の

データが欠損していたため 2、4、5 日であった。2017 年 11、12 月を除いた 2、6、10 月の 3 時期のうち、図 3 に従い各月の 6 日間の VIIRS データ S から、検証データ数が 1 万件程度になるように各データセットを作成すると、サンプリング回数 M は 5,580、全データセット数 M × S 件は 33,480、学習用データセット数は 23,436、検証用データセット数は 10,044 であり、学習と検証に使用した。

2.3.2 回帰型 MLP のパラメータの設定

図 3 の回帰型 MLP には機械学習ライブラリである scikit-learn (<http://scikit-learn.org>) の機能のうち、MLP Regressor を使用した。表 1 は、解析に用いた MLP Regressor 仕様のパラメータの名称、役割、使用

表 1 解析に用いた MLP Regressor の設定パラメータ

名称	役割	値
hidden_layer_sizes	隠れ層の数とユニット数を指し、1 つの隠れ層に入力層のユニット数(中心画素で 3、5 × 5 画素で 27)を使用。	中心画素：3 5 × 5 画素：27
activation	活性化関数を指し、ロジスティック関数(logistic)は、次式に与えられるシグモイド関数(sigmoid) $\sigma(x)$ を使用。 $\sigma(x) = \frac{1}{1 + e^{-x}} \quad (4)$	logistic
solver	最適化手法を指し、確率的勾配降下法(stochastic gradient descent(sgd))を使用することで、DNB 予測値 $\hat{y}$ となるリニアスコアリング関数 $f(x)$ を学習するための入力 x のユニットと隠れ層のユニットとの重みのパラメータは次式により与えられる。 $w \leftarrow w - \eta \left(\frac{\partial R(w)}{\partial (w)} + \frac{\partial L(w^T x_i + b, y_i)}{\partial w} \right) \quad (5)$ w は重みのパラメータ、 η は学習率、 R は正則化項、 L は損失関数であり、学習データを任意で並び替えながら、損失関数の値が小さくなるように重みのパラメータの更新を繰り返す。	sgd
batch_size	学習用データをサンプルサイズごとに分けて重みを更新するためのミニバッチのサイズを指し、学習データ数(23,436)/VIIRS 観測日数(6)の数を使用。	3,906
learning_rate	重みの学習率の更新頻度を指す。アダプティブ(adaptive)は、学習時に損失が減少している間は学習率を重みの学習率の初期値として保持し、2 回の反復学習において連続して 1×10^{-4} よりも損失が減少しなかった場合に学習率を 1/5 に減らす手法。	adaptive
learning_rate_init	重みの学習率の初期値を指し、MLP Regressor 内で評価される学習の平均精度(表 2 の決定係数 R^2)の高い値を使用。	中心画素：0.5 5 × 5 画素：0.1
alpha	過学習を防ぐための極端な重みのデータに対する正則化のための係数。	0.0001
max_iter	反復学習の最大回数。	200
shuffle	反復学習ごとに学習データの並び替えを行う。	True
momentum	sgd の収束性能に関わる運動量。	0.9
nesterovs_momentum	ネステロフの加速法(Nesterov, 1983)。sgd による重み更新において momentum を考慮し、更新の効率化に関わる。	True

した関数、手法、値などの設定を示す。また、表2は、図3の回帰型MLP処理によって2017年2、6、10月の学習用データから作成された2月学習モデル、6月学習モデル、10月学習モデルの精度評価指標に使用した決定係数 R^2 、二乗平均平方根誤差（Root Mean Squared Error (RMSE)）、平均絶対誤差（Mean Absolute Error (MAE)）を示す。表2の R^2 は、MLP Regressor内で学習の平均精度に用いられており、表1の重みの学習率の初期値（learning_rate_init）は、MLP Regressor内で学習の平均精度の高い重みの学習率の初期値0.5（中心画素データセット）、0.1（5×5画素データセット）を使用した。表1の正則化係数（alpha）、最大反復回数（max_iter）、並べ替え（shuffle）、運動量（momentum）、ネステロフの加速法（nesterovs_momentum）（Nesterov, 1983）はMLP Regressorの標準の設定に従い学習を行った。2017年2、6、10月観測VIIRSデータの中心画素データ、5×5画素データを表1で設定したMLP Regressorに入力して、学習用データのDNB、検証用データのDNB

を予測した。そして、表2の予測DNBと検証用データのDNBとの R^2 は、学習用データのDNBとの R^2 よりも大きく、RMSEとMAEは学習用データのDNBとのRMSEとMAEよりも小さいため、過学習の可能性は低いと考えられた。

本研究では、2017年2、6、10月の3時期の学習モデルを用いて、輝面率90%以上の2016年2、6、10月に観測されたDNBと予測DNBとの誤差を、雲の除去されたDNBとして評価し、中心画素予測DNBに5×5ガウシアンフィルタによる畳み込み処理を行った。

3. 結 果

図4は2016年に観測された輝面率90%以上の2月23日、6月21日、10月16日のDNB画像、BT_{3.7}画像、中心画素モデルによる雲除去画像、5×5画素モデルによる雲除去画像である。2016年2月23日のBT_{3.7}画像を2017年2月の中心画素学習モデルと5×5画素学習モデルに入力、2016年6月21日のBT_{3.7}画像を2017年6月の中心画素学習モデルと5×5画素学習モデルに入力、2016年10月16日のBT_{3.7}画像を2017年10月の中心画素学習モデルと5×5画素学習モデルに入力し、図5に予測した中心画素予測DNB画像、5×5画素予測DNB画像、畳み込み処理した中心画素予測DNB画像を示す。また、図4と図5で観測・予測・雲除去DNB画像は分光放射輝度（nW cm⁻² sr⁻¹）、BT_{3.7}画像は輝度温度（K）、○は漁火の位置を示し、図4の雲除去画像は観測DNB値と予測DNB値との絶対値の誤差を示す。図4のDNB画像で雲と漁火を示す画素は白の濃淡、海域の画素は黒の濃淡を示し、雲と漁火を示す画素は海域よりも分光放射輝度値が高く、BT_{3.7}画像では輝度温度値が低く、黒の濃淡を示す。Elvidge et al. (2015)は漁火を信号強度の強弱で評価しており、図4の10月16日のDNB画像の漁火には、NOAAのEOGによって強い信仰強度の漁火、雲の近くに図4(a)の信号強度の弱い漁火が観測されていたが、雲除去画像では図4(a)の信号強度の弱い漁火も検出されていた。図4のDNB画像と図5の予測DNB画像を見ると、図4のDNB画像で雲らしき白の濃淡の画素は、図5の予測DNB画像で白の濃淡の画素を示し、海域の分光放射輝度値よりも高い分光放射輝度値が予測されていた。しかしながら、図4で6月21日の5×5画素

表2 2017年3時期学習モデルの精度評価指標

		$R^2=1-\frac{\sum_{i=1}^n(y_i-\hat{y}_i)^2}{\sum_{i=1}^n(y_i-\bar{y})^2}$			(6)
		$RMSE=\sqrt{\frac{1}{n}\sum_{i=1}^n(y_i-\hat{y}_i)^2}$			(7)
		$MAE=\frac{1}{n}\sum_{i=1}^n y_i-\hat{y}_i $			(8)
y_i : DNB		$\hat{y}_i$: 予測 DNB	$\bar{y}$: DNB の平均		
中心画素					
データセット		R ²	RMSE	MAE	
2 月	学習	0.597	0.193	0.142	
	検証	0.604	0.190	0.140	
6 月	学習	0.582	0.143	0.082	
	検証	0.591	0.142	0.081	
10月	学習	0.398	0.180	0.127	
	検証	0.428	0.176	0.125	
5 × 5 画素					
データセット		R ²	RMSE	MAE	
2 月	学習	0.521	0.210	0.154	
	検証	0.528	0.208	0.153	
6 月	学習	0.581	0.144	0.081	
	検証	0.592	0.141	0.080	
10月	学習	0.399	0.180	0.127	
	検証	0.429	0.176	0.126

図4 2016年観測 DNB 雲除去画像 (○は漁火)

図5 2016年予測 DNB 画像 (○は図4の漁火らしき光源の位置)

モデルによる雲除去画像は、中心画素モデルによる雲除去画像に比べて、漁火を示す画素の分光放射輝度値が低く、海域を示す黒い濃淡との低いコントラストが観察された。一方、図5で6月21日の予測画像の○を見ると、中心画素予測 DNB 画像の○の分光放射輝度値に比べて、5×5画素予測 DNB 画像の○の分光放射輝度値は高く予測されており、ぼやけたコントラストが観察された。

図5を見ると、左の中心画素予測 DNB 画像に比べて、真ん中の5×5画素予測 DNB 画像はぼやけて見えるが、右の畳み込み処理を行った中心画素予測 DNB 画像(以降、畳み込み画像)と似たコントラストを示した。一方で、表3は図4の観測 DNB 画像と図5の予測 DNB 画像との R^2 、RMSE、MAE を示す。表3で6月21日の5×5画素予測 DNB 画像との R^2 は約0.9であり、中心画素予測 DNB 画像との R^2 約0.8より

も高かった。また、畳み込み画像との R^2 は約0.9であり、中心画素予測 DNB 画像との R^2 約0.8より高く、5×5画素予測 DNB 画像との R^2 約0.9に接近していた。

表3 2016年観測 DNB の予測結果の評価指標

2016年 DNB	予測 DNB	R^2	RMSE	MAE
2 / 23	中心画素	0.591	0.199	0.139
	5 × 5 画素	0.598	0.211	0.150
	畳み込み	0.641	0.201	0.143
6 / 21	中心画素	0.784	0.219	0.168
	5 × 5 画素	0.893	0.210	0.163
	畳み込み	0.863	0.215	0.166
10 / 16	中心画素	0.878	0.452	0.421
	5 × 5 画素	0.875	0.463	0.428
	畳み込み	0.893	0.454	0.423

4. 考察とまとめ

南シナ海は世界で2番目に大きな半閉鎖海域であり、漁業活動が広く展開されているにも関わらず、政府から漁業機関への新しい規制や執行体制に対応した活動、あるいは排他的経済水域を超えた漁業活動に対応した活動などに関する沿岸諸国間での漁業協力については、ほとんど議論されていない。一方で、VIIRSが観測したDNB画像から漁業活動を示す漁火が観測されることから、沿岸諸国間あるいは国内での漁業協力を議論するための情報としての活用が考えられるが、月光下のDNB画像において漁火と雲を明確に判別することは難しい。このため、本研究では、(1)2017年2月、6月、10月の3時期に観測されたDNB画像の雲と線形的な応答があるBT_{3.7}データ、輝面率、月高度のデータセットをANNに入力し、2月学習モデル、6月学習モデル、10月学習モデルを作成した。(2)作成した学習モデルを用いて、2016年2月23日、6月21日、10月16日観測DNB画像の雲と応答したBT_{3.7}画像からDNB画像を予測した。(3)予測したDNB画像と観測DNB画像と予測DNB画像との絶対値の誤差を画像として出力した。この結果、NOAAのEOGによって観測された信号強度の強い漁火と雲近くの信号強度の弱い漁火は、雲が除去された絶対値の誤差画像で高いコントラストとして観察され、観測DNBデータと予測DNBデータとの差分の外れ値として観察されることが確認された。そして、本研究の学習モデルを用いた漁火の検出は、次式により与えられることが考えられた。

$$DNB_{Light} = DNB - (w^T BT_{3.7} + L_{error}) \quad (9)$$

ここで DNB_{Light} はDNBデータにおける漁火、 L_{error} は予測DNBにおける外れ値である。また、2016年6月21日に観測されたDNB画像と予測DNB画像とのR²によると、学習に5×5画素の近傍を与えた場合、予測精度は中心画素を与えた予測よりも高く、畳み込み画像は5×5予測DNB画像と近似していたことから、中解像度衛星画像でも畳み込みフィルタと同等の機能が得られると考えられた。しかしながら、5×5画素の近傍のうち、雲の空間スケールが大きい場合、畳み込みにより漁火の判別が難しくなることも観察された。さらに、本研究ではBT_{3.7}とDNBとの間で非線

形関係にある台風などの他の外れ値となる現象を明確に考慮していないため、季節的な学習モデルの精度について議論する場合、外れ値と近傍の空間スケールによって入力の前傍の大きさを変更しながら、ANNの学習率を更新するといった手法が効果的であると考えられた。

中解像度衛星画像であるDNBデータに観測される漁業活動を示す漁火は、沿岸諸国間あるいは国内での漁業協力を議論するための情報としての活用が期待されるが、月光下の雲がノイズとなる。本研究では、DNBデータとBT_{3.7}データとの線形的な関係を学習したANNのモデルを活用することで、DNB画像上から雲近くの信号強度の弱い漁火の検出も可能であり、学習に画素の前傍を与えると、前傍と雲の空間スケールによって、予測精度が異なることが分かった。

謝 辞

本研究は、Office of Naval Research Global (米国海軍研究事務所グローバル) のグラント N62909-15-1-2074 の研究成果の一部である。

(受付日2018.5.2, 受理日2019.1.8)

参考文献

- 1) 浅沼市男, 2013. Visible Infrared Imaging Radiometer Suits (VIIRS) による漁火観測, 写真測量とリモートセンシング52(3), pp.106-107.
- 2) 山田陽巳, 2015. 東シナ海・黄海の漁業資源 (総説), 水産庁・水産総合研究センター, 平成26年度国際漁業資源の現況, 63, pp.1-6.
- 3) Albu, R-D., 2009. Human Face Recognition Using Convolutional Neural Networks, Journal of Electrical and Electronics Engineering 2(2), pp.110-113.
- 4) Asanuma, I., T. Yamaguchi, J.G. Park, K. Mackin, J. Mittleman., 2017. Detection of Temporal Change of Fishery and Island Activities by DNB and SAR on the South China Sea, International Science Index International Journal of Computer, Electrical, Automation, Control and Information Engineering, 11(2), pp.252-255.
- 5) CEARAC, 2005. Integrated Report on Ocean Remote Sensing for the NOWPAP Region, 50pp.

- 6) Czyzowska-Wisniewski, E.H., van Leeuwen, W.J.D., Hirschboeck, K.K., Marsh, S.E., & Wisniewski, W.T., 2015. Fractional snow cover estimation in complex alpine-forested environments using an artificial neural network, *Remote Sensing of Environment*, 156, pp.403–417, doi : 10.1016/j.rse.2014.09.0262015.
- 7) Dang T.N., 2012. Fisheries Co-operation in the South China Sea and the (Ir) relevance of the Sovereignty Question, *Asian Journal of International Law*, 2(1), pp.59–88.
- 8) Elvidge, C.D., Zhizhin, M., Baugh, K., Hsu, F.C., 2015. Automatic Boat Identification System for VIIRS Low Light Imaging Data. *Remote Sens.*, 7(3), pp.3020–3036, doi : 10.3390/rs70303020.
- 9) Fu, G., Liu, C., Zhou, R., Sun, T., Zhang, Q., 2017. Classification for High Resolution Remote Sensing Imagery Using a Fully Convolutional Network. *Remote Sens.*, 9(5), 498, 21pp, doi : 10.3390/rs9050498.
- 10) Jarrett, K., Kavukcuoglu, K., Ranzato, M., LeCun, Y., 2009. What is the best multi-stage architecture for object recognition? In *ICCV*, pp. 2146–2153, doi : 10.1109/ICCV.2009.5459469.
- 11) LeCun, Y., Bottou, L., Bengio, Y., and Haffner, P. (1998). Gradient-Based Learning Applied to Document Recognition. *Proceedings of the IEEE*, 86(11), pp.2278–2324.
- 12) Liu, Y., Zhong, Y., Fei, F., Zhu, Q., Qin, Q., 2018. Scene Classification Based on a Deep Random-Scale Stretched Convolutional Neural Network. *Remote Sens.*, 10(3), 444, 23pp, doi : 10.3390/rs10030444.
- 13) Meeus, J., 1998. *Astronomical algorithms* (2nd ed.), Willmann-Bell, Richmond, 477pp.
- 14) Muallil, R.N., Mamauag, S.S., Cababaro, J.T., Arceo, H.O., and Alino, P.M., 2014. Catch trends in Philippine small-scale fisheries over the last five decades: The Fishers’perspective, *Marine Policy*, 47, pp.110–117.
- 15) Nesterov, Y., 1983. A method of solving a convex programming problem with convergence rate $O(1/k^2)$, *Soviet Mathematics Doklady*, 27(2), pp. 372–376.
- 16) Rosenberg, D., 1999. Environmental Pollution around the South China Sea: Developing a Regional Response to a regional problem Series: Resource Management in Asia-Pacific Working Paper, 20, doi : 10.1355/C521-1F.
- 17) Straka, W.C., Seaman, C., Baugh, K., Cole, K., Stevens, E., Miller, S.D., 2015. Utilization of the Suomi National Polar-Orbiting Partnership (NPP) Visible Infrared Imaging Radiometer Suite (VIIRS) Day/Night Band for Arctic Ship Tracking and Fisheries Management, *Remote Sens.*, 7(1), pp.971–989, doi : 10.3390/rs70100971.
- 18) Yuan, H., Yang, G., Li, C., Wang, Y., Liu, J., Yu, H., Feng, H., Xu, B., Zhao, X., Yang, X., 2017. Retrieving Soybean Leaf Area Index from Unmanned Aerial Vehicle Hyperspectral Remote Sensing: Analysis of RF, ANN, and SVM Regression Models, *Remote Sens.*, 9(4), 309, 14pp, doi : 10.3390/rs9040309.