ハイパースペクトル画像とニューラルネットワークを用いた物質判別のための GA によるチャンネル選択*

松岡 祐貴** 佐藤 惇哉** 加藤 邦人***

Channel Selection by GA for Substance Discrimination Using Hyperspectral Images and Neural Network

Yuki MATSUOKA, Junya SATO and Kunihito KATO

In this research, we aim to achieve better performance of substance discrimination using hyperspectral images than our latest work with PLS regression analysis. The PLS regression analysis necessitates training of classifiers whose total number is the same to the number of classes. Since training many classifiers is time-consuming, a neural network is applied to solve this problem. Moreover, genetic algorithm (GA) is introduced to obtain valid channels for the substance discrimination to avoid input of all the channels. Since this approach can optimize the number of valid channels and their types simultaneously, the proposed method is effective. In experiments, the proposed method and the previous method were compared with two image datasets. In the first dataset, the best intersection over union of the proposed method and previous method are 0.953 and 0.965. In the second dataset, the best accuracy of the proposed method is 0.859 while the previous method is 0.695.

Key words: neural network, genetic algorithm, hyperspectral images

1. 緒 言

現在、異物混入や自動運転などの様々な場面において物質を判別する手法が求められている。色特徴や形状を用いて判別する手法はその一つとして挙げられる。しかし、同じ物質であっても色や形状の違いにより正しく判別できない問題がある。この解決策として、色特徴や形状特徴に左右されない特徴を用いて物質を判別する方法を考える必要がある。

解決策の一例として、ハイパースペクトル画像を用いた物質判別手法がある。この手法は、対象物体に近赤外光を照射し、その反射率を特徴量として使用することで物体の種類を識別することができる。色や形状といった見えではなく、物質が固有に持つ情報を使用しているため、外乱にロバストな物体判別が可能となる。最新の研究として、服部らの手法¹⁾が挙げられる。この手法では、はじめに 650 nm から 1050 nm のハイパースペクトル画像に Partial Least Squares (PLS) 回帰分析を適用して Variable Influence on Projection (VIP) を取得する。VIP が高い任意の数のチャンネル(ある波長の画像)をユーザが選択する。次に、選択されたチャンネルのみを用いて再び PLS 回帰分析を適用することで、識別に有効なチャンネルのみで学習された識別器を生成する。しかし、文献¹⁾の手法では 2 クラス以上の物質を判別する際にはクラス数分の識別器の生成が必要であり、学習に手間がかかる。また、チャンネル選択のために途中でユーザの介入が必要である。

そこで、本研究では先行研究の問題を解決し、より高い判別精度を得ることを目的とする。提案手法では、PLS 回帰分析の代わりにニューラルネットワークを使用する。その理由は、ひとつのモデルで多クラス判別が可能だからである。したがって、学習の手間の削減が可能となる。しかし、PLS 回帰分析の適用で得られる VIP が使用できないため、識別に有

効なチャンネルを取得することができない。そこで、提案手法では遺伝的アルゴリズム²⁾ (GA)を使用する。その理由は、識別に有効なチャンネルを取得する問題は組み合わせ最適化問題として捉えることができ、GA はこのような問題を解くことが可能だからである。また、先行研究である服部らの手法は、VIP で識別に有効なチャンネルの種類を自動決定することができるが、使用するチャンネル数は決定できず、ユーザが何かしらの基準に基づいて事前に決定している。そこで、チャンネル数も自動決定するために、提案手法では GA の染色体表現と適応度関数の設計を工夫することで、チャンネルの種類に加えてチャンネル数も自動決定できる。

この GA とニューラルネットワークの組み合わせによる物質判別を実現するためには、GA のフレームワークにニューラルネットワークを導入する必要がある。具体的には、ある個体の染色体が指すチャンネルを用いてニューラルネットワークを学習し、バリデーションデータに適用して評価値を取得し、個体の適応度とする。これと同様の処理を全個体で行い、世代交代させる。これにより、最終的にクラス判別に有効なチャンネルの種類を持つ、学習済みニューラルネットワークが取得できる。このように、チャンネル数とその種類の同時最適化とニューラルネットワークの学習が全てひとつのシステムとなっているため、先行研究のように途中でユーザの介入する必要が無い。したがって、提案手法は手間が削減された手法である。

2. 関 連 研 究

ハイパースペクトル画像を用いた物質の判別手法はこれまでいくつか提案されてきた。

安部らは、日本の木彫像の用材として用いられるヒノキやカヤなどの 10 種類の樹種を対象に主成分分析を用いて非破壊的に判別した³⁾。波長(チャンネル)が 830nm から 1150nm の帯域を用いた場合、主成分分析の第 1 主成分と第 2 主成分のスコアプロットはカヤのプロットが他の樹種のプロットと別

* 原稿受付 平成 30 年 5 月 7 日
掲載決定 平成 30 年 11 月 5 日
** 岐阜大学 (岐阜県岐阜市柳戸 1-1)
*** 正 会 員 岐阜大学

れ、チャンネルが 1300nm から 2500nm の帯域では針葉樹と広葉樹のプロットが分かれた。岩本らは、1.1 μ m から 2.5 μ m のハイパースペクトル画像の二次微分スペクトルに重回帰分析を用いることで乾海苔の品質評価を行った⁴⁾。しかし、これらの手法はハンドメイドな特徴量と識別器を用いているため、認識システムの設計が難しい。そこで、ニューラルネットワークの導入が求められる。

松本らは、1.3 μ m から 2.3 μ m のハイパースペクトル画像を二次微分処理したデータをニューラルネットワークに入力することで、非破壊的に多種類のプラスチックを判別する方法を提案している⁵⁾。Anirbanらは、チャンネル固有のスペクトル空間特性を畳み込みニューラルネットワークを用いて判別を行った⁶⁾。Anirbanらが提案したネットワークモデルは独立した接続重量が少ない構造をしており、トレーニングデータの数が少なく済む。Yingらは、ハイパースペクトル画像のスペクトル情報と空間情報を最大限に利用するため、3次元畳み込みニューラルネットワークを提案し、判別精度の向上を達成した⁷⁾。これらの手法はニューラルネットワークによる識別を行っているが、チャンネル選択はせず、全波長(チャンネル)を入力している。そのため、実用上に大きな問題がある。

一方、GA を用いた特徴選択はこれまでいくつか提案されてきた。松井らは、MRI 画像組織分類を行う際、従来手法では特徴量の善し悪しを分類の結果で試行錯誤していたが、大量の計算時間が必要となるという問題が生じた。そこで GA を用いて特徴選択を行った⁸⁾。この提案手法では、GA とニューラルネットワークが使われているが、特徴選択した後にニューラルネットワークを構成しているため、選択された特徴がニューラルネットワークに最適かは疑問がある。

Cheng らは、Support Vector Machine(SVM)のパラメータと特徴部分集合を GA を用いて同時に最適化することにより SVM の分類精度を下げることなく、より少ない特徴量で分類精度を向上させた⁹⁾。この手法では、SVM のパラメータを最適化しており、入力するチャンネルの選択は行っていない。

Li らは、チャンネルをいくつかのグループに分割し、最適なチャンネルの組み合わせを探索するために GA と SVM を組み合わせたもので適応度を計算する。その後、どのグループのチャンネルを使うかを決定し、最後に分枝限定法を使用して、GA と SVM を組み合わせたもの結果から無関係なバンドを取り除く手法を提案している¹⁰⁾。この手法では、識別器に SVM を使用しているため、対象物質数識別を行う必要がある。また、チャンネルのグループ分け、GA で各グループからチャンネルを選択、分枝限定法でさらにチャンネルを減らすという複数のプロセスを経てチャンネル選択を行っている。提案手法では判別にニューラルネットワークを用いることにより一度の判別で複数の対象物質の判別が可能である。また、GA の適応度関数には、判別精度にチャンネルの数が少なければ適応度を上げる報酬項を追加している。これにより、GA だけで使用するチャンネル数が少なく識別器に最適なチャンネルの選択を行うことが可能である。また、スペクトル形状類似性解析の観点から、ある画素のハイパースペクトル情報を時系列とみなしてチャンネルを選択する手法も提案している¹¹⁾。Visual Assessment of cluster Tendency(VAT)というクラス数をもとに推定する手法で

クラス数を推定し、処理されたハイパースペクトル曲線からの重要なチャンネルを抽出、最後に、条件付き相互情報及び分枝限定法を行い、最適なチャンネルの組み合わせを決定して SVM で判別を行っている。この手法でも判別に SVM を用いているため、判別対象が多い場合には処理に多くの時間が必要となる。また、クラスタリングでユーザの手动指定が必要であることに加え、クラス数の推定で大きな推定しかできないため、最終的に得られるチャンネルが冗長、もしくは不十分である可能性がある。提案手法では判別にニューラルネットワークを使用しており、GA でチャンネルを選択する際、適応度にニューラルネットワークから得られる判別精度を使用しているため識別器に最適なチャンネルを選択している。

服部らは、PLS 回帰分析を用いて識別器を学習させ、肌と葉、アスファルト、その他のクラス判別に取り組んでいる¹⁾。リアルタイム処理を考慮すると全チャンネルの画像を入力するのは避けるべきであるため、識別に有効なチャンネルのみ入力する必要がある。これを決定するために、PLS 回帰分析によって得られる VIP の値が大きいチャンネルを使用することで、少ないチャンネル数で高い識別を達成している。しかし、チャンネル選択の際にユーザの介入が必要であり、クラス数分の識別器を学習させる必要があるため、手間がかかる。

本研究では、我々の先行研究である服部らの手法に注目し、この手法よりも高い識別性能を達成することを目標とする。説明したように、PLS 回帰分析ではクラス数分の識別器の生成が必要である。これを避けるために、我々はひとつのモデルで多クラス判別が可能なニューラルネットワークを使用する。しかし、VIP によるチャンネルの自動選択ができないため、新たな手法を考える必要がある。クラス判別に有効なチャンネルの組み合わせを選ぶ問題は組み合わせ最適化問題と捉えることができる。そこで、この問題を実用時間内で解くことが可能な GA を使用することとした。

3. ハイパースペクトル画像

ハイパースペクトル画像とは、RGB 画像のように3つのカラー画像から構成されるものではなく、各チャンネルの光の強度を表すグレースケール画像が数十枚から数百枚で構成されるものである。その様子を図 1 に示す。これは、2次元情報である画像にチャンネルの情報、つまり3次元目の特徴を加えることで、RGB の3チャンネルではとらえきれない情報を取得することが可能になる。これ以降出てくる全波長(チャンネル)とは、ハイパースペクトル画像の全ての枚数を表す。

4. ニューラルネットワークを用いた物質判別手法

Fig.1 Hyperspectral image

パースペクトル画像の画素値をニューラルネットワークに入力して学習を行い、多クラス分類を行う。

ここでは、3 物質(物質 1, 物質 2, 物質 3)を例に判別手順を示す。あるチャンネル w のハイパースペクトル画像内の座標 (i, j) の画素値を $I_w(i, j)$ とすると、抽出した画素値 x_w は式(1)のように表される。撮影した全波長(チャンネル) N 枚の画像から同じ座標の画素値を 1 画素ごとに抽出し、抽出した注目画素の画素群を X_n とすると式(2)のように表される。

$$x_w = I_w(i, j) \quad (1)$$

$$X_n = \begin{pmatrix} x_{w_1} \\ x_{w_2} \\ \vdots \\ x_{w_N} \end{pmatrix} \quad (2)$$

この画素値群を入力層のユニットの数をハイパースペクトル画像のチャンネル総数の N に設定したニューラルネットワークに入力する。これは注目画素のハイパースペクトル情報を入力していることを意味する。その様子を図 2 に示す。

ニューラルネットワークの出力層の活性化関数に softmax 関数を使用することで、出力層の各ユニットは対応した物質の推定値を出力するため、入力した画素がそれぞれどの物質であるかの確率を表す。出力層のユニットの数は、判別対象物質 M にリジェクトを加えた $M+1$ で設定する。出力層のユニットの中で推定値が最大となる物質に判別する。その様子を図 3 に示す。物質 1, 2, 3 とリジェクト(その他の物質)をそれぞれ y_1, y_2, y_3, y_4 とする。この処理を全画素で行い、最終的に物質判別画像を作成する。

5. ニューラルネットワークと GA を組み合わせた最適チャンネル選択手法

5.1 手法概要

ニューラルネットワークと GA を組み合わせた最適チャンネル選択手法では、GA を用いて判別に有効的なチャンネルの組み合わせを全波長(チャンネル)の中から選択する。

Fig.2 Input of hyperspectral images into the neural network

Fig.3 Substance discrimination by the neural network

Fig.4 Flowchart of GA

GA は、John Henry Holland が考案したメタヒューリスティックアルゴリズムである¹⁾。GAの特徴は、優れた解法が存在しておらず、探索解空間が広いために全探索で最適解を得るには現実的に困難と思われる問題に対して非常に有用であることである。そのため、実行時間内に比較的優れた解を求めることが可能である。また、多点探索アルゴリズムのため関数の連続性の影響を受けにくい。GAの流れを図 4 に示す。

はじめに、解の候補を染色体としてもつ初期個体集団を任意の数 L 生成する。本研究ではこの染色体をチャンネルとすることで最適チャンネルの選択を行う。初期個体集団生成後、各個体が染色体として持つチャンネルの画像の画素値のみをニューラルネットワークに入力し、適応度を取得する。適応度とは、その個体の優劣を実数で表したものである。

その後、適応度が高くなるチャンネルの組み合わせを持つ個体がより多くの子孫を残すように、適応度に基づいて個体を選択する。そして、選択された個体に対して、遺伝子座で遺伝子を交叉させ、染色体の更新処理を行う。交叉後、局所解に陥ることを防ぐために低確率で染色体の一部を突然変異させる。選択、交叉、突然変異を終えた後、個体を次世代に移し世代を交代する。世代交代を最大世代数 K まで繰り返す。適応度が最大の個体を持つチャンネルが最適チャンネルの組み合わせとなる。

本稿では、チャンネル数を任意に設定する方法と、チャンネル数も GA に決定させる方法で実験を行った。

5.2 手法 1 チャンネル数を任意に設定する方法

手法 1 では、個体の染色体をハイパースペクトル画像の全波長(チャンネル)の数 N を 2 進数で表現可能な m bit 数に設定する。例えば、 $N=250$ の場合、2 進数で表現するには 8bit 必要となるので $m=8$ となる。したがって、 e 個のチャンネルの組み合わせを GA で探索する場合、各個体の染色体長は $e \times m$ となる。バイナリで構成される各染色体を実数値にする際は式(3)を用いる。

$$C'_d = S_{\min} + \frac{J}{2^m - 1} (S_{\max} - S_{\min}) \quad (3)$$

Fig.6 In order to acquire fitness, we input only hyperspectral images of channels that individuals have as chromosomes and repeat selection, crossover and mutation until K generations

Fig.5 Convert bits to integer

式(3)中の $S_{\min}$ はハイパースペクトル画像の最小チャンネル, $S_{\max}$ は最大チャンネル, J は染色体を整数にした値である. このとき, C_d は実数値であるがチャンネルは整数であるため, C_d を整数 C_d にする. $N=6$ すなわち $m=3$, $e=3$ を例に図5に示す.

また, 適応度をニューラルネットワークから得られる accuracy とした. accuracy とは, 予測結果全体の正答率を表す指標であり, 0.0 から 1.0 までの値をとり, 1.0 に近づくほど優れた結果であることを意味する. accuracy の求め方を式(4)に示す.

$$accuracy = \frac{TP+TN}{TP+FP+FN+TN} \quad (4)$$

処理の流れを図6に示す. 図6は $N=6$, $m=3$, $e=3$ を例として示している. 個体の染色体はニューラルネットワークに入力するチャンネルを表している. 本研究ではチャンネル数を事前に指定し, チャンネルの種類を GA で決定する方法(手法1)と, チャンネル数とその種類の両方を決定する方法(手法2)を実験しており, 各手法で染色体の表現方法が異なる. 手法2の詳細は5.3節で述べる. 各個体の染色体に基づいて入力するチャンネルを決定し, ニューラルネット

Fig.7 Input Only hyperspectral image of channel whose chromosomal gene is 1

ワークにハイパースペクトル画像を入力して学習を行う. 学習後は accuracy を計算し, この値を適応度とする. 全個体の適応度を取得したら選択と交叉, 突然変異を行って次世代を生成する. この世代交代を繰り返すことで, accuracy を最大化するようなチャンネルの組み合わせを自動取得することができる.

5.3 手法2 チャンネル数も GA に決定させる方法

手法2では, チャンネルの組み合わせに加えて, 使用するチャンネル数も GA で選択させる. 個体の染色体長をハイパースペクトル画像の全波長(チャンネル)数 N と同じ bit 数に設定する.

染色体の 0 bit 目はハイパースペクトル画像の最小チャンネルに該当し, 最上位 bit は最大チャンネルに対応する. 染色体のある遺伝子が 0 の場合, それに対応するチャンネルの画像は使用せず, 1 の場合は使用する. 選択されたチャンネルに対応する画像の画素値のみをニューラルネットワークに入力し, accuracy を取得する. その様子を図7に示す.

このアイディアは判別に有効なチャンネルの選択と使用チャンネルの削減を行う. そのため, 可能な限り使用するチャンネルを少なくするために, 適応関数を accuracy に加え, チャンネル数が少ないほど報酬を与える報酬項を設定する. 報酬項には,

使用チャンネルが 1 個の場合報酬が 1, N 個の場合は 0 となる一次関数を作成した。新たに作成した適応度関数を式(5)に示す。

$$fitness = accuracy + \alpha \left(-\frac{1}{N-1} \beta + \frac{N}{N-1} \right) \quad (5)$$

また, $accuracy$ と選択されるチャンネル数の関係を調べるため, 新たにもう一つ適応度関数を作成した。これを式(6)に示す。

$$fitness = accuracy \times \alpha \left(-\frac{1}{N-1} \beta + \frac{N}{N-1} \right) \quad (6)$$

両式の α は $accuracy$ と第 2 項のパラメータを調整するための係数であり, β は個体が持つ 1 の遺伝子の総数である。これらの式の違いは, 加算か乗算かである。つまり, 式(5)は加算であるため, どちらかの項の値が高くなれば適応度が高くなる。式(6)は乗算であるため, 両項の値が高くなる必要がある。これらの式を比較することで $accuracy$ と選択されるチャンネル数の関係を調べることができる。

6. 実 験

6.1 従来手法

服部らは, ハイパースペクトル画像に対し, PLS 回帰分析を用いた物質判別を提案している²⁾。この手法では, PLS 回帰分析により, 1 対他の識別器を判別したい物質数分用意し, 各識別器から得られた推定値を用いて複数物質の判別を行う。また, PLS 回帰分析時に得られるパラメータにより算出される回帰係数 B および Variable Influence on Projection (VIP) という各特徴の重要度を表す指標をもとに使用チャンネルの選択を行う。本実験では, この手法を従来手法として比較を行う。

6.2 実験 1

実験 1 では, 手法 1 であるチャンネル数を任意に設定する方法について実験を行う。

本実験では肌, 葉, アスファルトの 3 物質を対象としたチャンネルが 650nm から 1050nm 間(2nm 間隔)の総数 201 枚のハイパースペクトル画像で実験を行った。このデータセットは服部らの研究で使用されているものと同じである。図 8 に示す 16bit 冷却 CCD カメラ (apogee 社製 Alta シリーズ U260) と, 液晶チューナブルフィルタ (CRI 社製 50989) を用いて, 暗室内で, 光源に 650nm から 1050nm までの光を照射できるハロゲンランプ(高儀社製 WLT-260)を使用して, 撮影されている。全部で 22 種類の画像を撮影し, 各種類で被験者と葉の種類が異なる。学習サンプル画像の一例を図 9 に, 未知サンプル画像の一例を図 10 に示す。ともに見た目が類似しているが, 本研究ではチャンネルを特徴量として使用しており, 形状や色は使用していないため, 見えの類似性は本研究に関係ないことに注意されたい。

Fig.8 Hyperspectral camera

Fig.9 Example of the train data

Fig.10 Example of the test data

Table 1 Parameters of 3 layer neural network
(a) Model

Layer name	Number of units	Activation
Input	201	-----
Hidden	128	Sigmoid
Output	4	Softmax

(b) Other parameters

Loss function	Cross entropy
Optimizer	Stochastic gradient descent
Learning rate	0.01
Batch size	100
Number of epoch	50

Table 2 Parameters of GA

Population size	50	50	100
Generation size	50	100	50
Crossover probability	0.95		
Mutation probability	0.05		
Selection method	Tournament		
Crossover method	Uniform		

本実験では, 先行研究に基づき, 学習画像 12 種, バリデーションデータ 3 種, テストデータ 7 種の合計 22 種類のハイパースペクトル画像を用いて実験を行った。

本実験では, ニューラルネットワークに 3 層ニューラルネットワークを用いた。3 層ニューラルネットワークのモデルを表

1 に示す。

GA の各パラメータを表 2 に示す。肌、葉、アスファルトデータセットはハイパースペクトル画像のチャンネル総数が 201 のため、2 進数表記を可能にするため $m = 8$ とした。チャンネル数は従来手法⁷⁾で 5 チャンネルが選択されていたため、 $n = 5$ とした。また、個体数、世代数は、50 個体 50 世代、50 個体 100 世代、100 個体 50 世代の 3 つの組み合わせで実験を行った。

判別結果の精度評価を行うために評価指標として Intersection over Union (IoU) を用いた。IoU とは、正解領域と予測領域の重なりを割合を示す値である。0.0 から 1.0 の値をとり、1.0 に近づくほど優れた結果であることを意味する。IoU は TP 、 FP 、 FN で求められる。 TP は正解領域と予測領域が一致している領域を表し、 FP は正解領域以外を誤って検出した領域を表し、 FN は正解領域を検出できなかった領域を表す。IoU の求め方を式(7)に示す。

$$IoU = \frac{TP}{TP + FP + FN} \quad (7)$$

全波長(チャンネル)(650nm から 1050nm)を用いて実験を行った判別結果を図 11 に、判別精度を表 3 に示す。図 11(a)、(b) は学習済みモデルに画像を入力して各画素が属するクラスを取得した後、そのクラスに基づいて色分けした結果である。赤色は肌、緑色は葉、青色はアスファルトと判別した結果を示す。全チャンネルを使用することで、チャンネルの種類が両手法で統一されているため、モデルによる識別性能を比較することができる。

本実験の結果から、従来手法よりも高い IoU で判別可能であることが確認できた。ほぼ同程度の結果であったが、ニューラルネットワークは PLS 回帰分析と異なり、クラス毎に識別器を学習させる必要がないため、学習の手間が少ない利点がある。したがって、ニューラルネットワークを使用する提案手法のアプローチは有効である。

また、5.2 節に示した最適チャンネル選択手法を用いて物質判別に最適なチャンネルを選択した。GA により選択されたチャンネルを表 4 に示す。

手法 1 を用いてチャンネル選択を選択し、選択されたチャンネルのみを用いて実験を行った判別結果を図 12 に、判別精度を表 5 に示す。図 12 (a) に 50 個体 50 世代の場合で選択された 5 チャンネルのみを使用した際の判別結果、図 12 (b) には 50 個体 100 世代の場合で選択された 5 チャンネルのみを使用した際の判別結果、図 12 (c) には 100 個体 50 世代の場合で選択された 5 チャンネルのみを使用した際の判別結果を示す。

(a) Our method (b) Conventional method

Fig.11 Substance discrimination results (all channel)

Table 3 IoU (all channel)		
	Our method	Conventional method
IoU	0.965	0.960

Table 4 Selected channels

Number of individuals	Number of generations	Selected channel (nm)
50	50	678,702,958,978,994
50	100	678,730,978,982,994
100	50	680,698,962,968,974

(a) 50 individuals and 50 generations

(b) 50 individuals and 100 generations

(c) 100 individuals and 50 generations

Fig.12 Substance discrimination results (Selected channel)

Table 5 IoU (Selected channels)

	50 individuals 50 generations	50 individuals 100 generations	100 individuals 50 generations
IoU	0.951	0.949	0.953

ンネルのみを使用した際の判別結果を示す。全チャンネルを使用した識別結果(図 11)と 5 チャンネルを使用した結果(図 12)を比較すると、図 12 の方が誤識別が多い。それは表 3 と表 5 を比較しても明らかである。この理由は、識別に利用するチャンネル数が 201 対して、5 チャンネルしか使用していないからである。しかし、多くのチャンネルを使用しなくても IoU の減少量は小さいため、GA により識別に有効なチャンネルが取得できていることが分かる。

実験の結果から、個体数、世代数を変更しても、チャンネルはほぼ同じ波長(チャンネル)帯から選択されており、判別精度も同程度である結果が得られたため、選択されたチャンネルは普遍的に選択されていることを確認した。

この理由を図 13 を用いて説明する。各グラフは 3 物質の反射率とチャンネルの関係を示しており、グラフ内の 5 つの縦線は提案手法によって取得されたチャンネルを示している。各結果を見ると、今回選択された 5 チャンネルは 700 nm 付近と 970 nm から 990 nm の二ヶ所に集まっていることが分かる。この理由は、葉は 700 nm から 750 nm にかけて反射率が大きく増加しており、また、肌は 970 nm 付近に吸収帯を持つ特徴があるからである。つまり、700 nm 付近のチャンネル選択で葉の反射率の変化量に関する特徴をとらえ、970 nm から 990 nm 付近のチャンネル選択で肌の反射率の変化量に関する特徴をとらえた方がクラス判別精度が高くなるため、提案手

法はこれらのチャンネルを選択したと考えられる。

従来手法の回帰係数 B および VIP により選択された 5 チャンネルのみを用いた実験の判別結果を図 14 に、判別精度を表 6 に示す。表 6 の提案手法である手法 1 の判別精度は本実験で IoU が最も高かった 100 個体 50 世代の場合で選択された 5 チャンネルのみを用いた実験の判別精度である。

次に、5 チャンネルを選択する場合で提案手法と従来手法を比較する。その結果を図 14 と表 6 に示す。提案手法の精度は、IoU が最も高かった 100 個体 50 世代で選択された 5 チャンネルを使用した結果である。提案手法と従来手法を比較する際、チャンネル選択の探索アルゴリズムが異なり、時間での優劣を判断するのは困難なため、同じデータと評価指標を使用し、手法間の優劣を決定する。実験結果より、従来手法である回帰係数 B を用いた際の物質判別が最も精度が良く、次に VIP、最後に提案手法が高かった。しかし、手法間の差は小さく、ニューラルネットワークはクラス毎の学習が不要なことを考慮すると、提案手法も有効的な手法であると言える。

本実験で使用したデータセットではすべての手法の性能が高く、手法間の優劣を判断することが難しい。そこで、判別するクラス数が多いデータセットで実験することにした。

6.3 実験 2

実験 2 では手法 2 であるチャンネル数も GA に決定させる方法について実験を行った。

Fig.13 Relationship between the reflectance and acquired wavelengths by the proposed method

Fig.14 Substance discrimination results (conventional method)

	Our method	B	VIP
IoU	0.953	0.965	0.957

Table 7 Parameters of 3 layer neural network

Layer name	Number of units	Activation
Input	220	-----
Hidden1	200	Sigmoid
Output	16	Softmax

(a) Model

Loss function	Cross entropy
Optimizer	Adam
Learning rate	0.01
Batch size	200
Number of epoch	10000

(b) Other parameters

Table 8 Parameters of GA

Population size	50
Generations size	100
Crossover probability	0.95
Mutation probability	0.05
Selection method	Tournament
Crossover method	Uniform

適応度関数の α は 0.1 から 1.0 までの 0.1 刻みで変更し実験を行った。

実験 2 では、Indian Pines データセット¹²⁾を使用した。対象物質（クラス）は 16 種類で、 $0.4 \mu\text{m}$ から $2.5 \mu\text{m}$ 間の 220 枚のハイパースペクトル画像である。このデータセットは、ハイパースペクトル画像が 1 種しかないため、各対象物質のサンプル数の 75% の画素を学習データ、残りの 25% の画素をテストデータとして使用した。また、学習データは各対象物質から 300 点ランダムに選択し、200 点を学習データ、100 点をバリデーションデータとして使用した。したがって、学習データ 3200 点（各対象物質の学習データ 200 点 $\times$ 対象物質数 16 種）、バリデーションデータ 1600 点（各対象物質のバリデーションデータ 100 点 $\times$ 対象物質数 16 種）で実験を行った。

本実験では、ニューラルネットワークに 3 層ニューラルネットワークを用いた。3 層ニューラルネットワークのモデルを表 7 に示す。

GA の各パラメータを表 8 に示す。Indian Pines データセットはチャンネル総数が 220 のため、個体の染色体長を 220 に設定した。

Indian Pines データセットでは学習データを 1 種のハイパースペクトル画像からランダムに画素値を選択しているため、画像全体を評価する IoU での評価ができない。そこで、評価指標に 5.2 節で説明した accuracy を使用した。

全波長(チャンネル)($0.4 \mu\text{m}$ から $2.5 \mu\text{m}$)を用いて実験を行った判別結果と従来手法の判別結果を図 15 に、判別精度を表 9 に示す。図 15(a)は正解画像を示す。図 15(b), (c)の各色は図 16 に示す各物質と判別した結果を示す。

実験 1 と同様に、全チャンネルを用いることで提案手法と従来手法のチャンネルを統一できるため、モデルの識別性能を平等に比較できる。結果より、ニューラルネットワークによる識別の方がより高精度であることが示されているため、クラス数が多い場合はニューラルネットワークを使用した方が高い精度が得られることが示された。したがって、提案手法のアプローチは有効である。

また、5.3 節に示した最適チャンネル選択手法を用いて物質判別に最適なチャンネルを選択した。GA により選択されたチャンネルのみを用いて実験を行った判別結果を図 17 に、判別精度を表 10 に示す。また、表 10 の accuracy とチャンネルの関係を図 18 に示す図 17(a)に式(5)を適応度関数とした際の accuracy が最も高い判別結果、図 17(b)に式(5)を適応度関数とした際の使用するチャンネル数が最も少なかった判別結果、図 17(c)に式(6)を適応度関数とした際の accuracy が最も高い判別結果、図 17(d)に式(6)を適応度関数とした際の使用するチャンネル数が最も少なかった判別結果を示す。実験 1 と同様、提案手法と従来手法を比較する際、チャンネル選択の探索アルゴリズムが異なり、時間での優劣を判断するのは困難なため、同じデータと評価指

Fig.17 Substance discrimination results (Selected wavelengths)

Table 10 Accuracy (selected wavelengths)

α	Equation (5)		Equation (6)	
	accuracy	Number of channels	accuracy	Number of channels
0.1	0.841	109	0.807	46
0.2	0.857	99	0.820	63
0.3	0.842	99	0.822	50
0.4	0.859	97	0.808	50
0.5	0.850	75	0.821	62
0.6	0.826	72	0.826	55
0.7	0.848	70	0.806	49
0.8	0.838	52	0.820	57
0.9	0.837	53	0.814	46
1.0	0.802	50	0.845	54
average	0.840	77	0.818	53

Fig.15 Substance discrimination results (all wavelengths)

Fig.16 Segmentation label

Table 9 Accuracy (all wavelengths)

	Our method	Conventional method
Accuracy	0.833	0.713

標を使用し、手法間の優劣を決定する。

実験の結果から、式(5)では α の値が小さいほど accuracy は高くなるが、使用するチャンネル数は多くなった。逆に α の値が大きくなるほど accuracy は低くなるが、使用するチャンネル数は減少した。式(6)では、 α の値の変化で accuracy とチャンネル数は大きく変わらなかった。

従来手法では VIP により 100 チャンネルが選択された。選択されたチャンネルのみを用いた実験の判別結果を図 19 に、判別精度を表 11 に示す。表 11 の提案手法である手法 2 の判別精度は、式(5)、(6)両式の中で accuracy が最も高かった判別精度と使用するチャンネル数が最も少ない判別精度である。

従来手法との比較を行った結果、提案手法である手法 2 で accuracy が最も高かった物質判別が最も精度がよく、全波長(チャンネル)を用いた際のニューラルネットワークを用いた物質判別手法、従来手法よりも高い判別精度が得られた。次に精度が高かったのは本手法で使用するチャンネル数が最も少ない物質判別であり、提案手法である手法 2 は従来手法よりも精度よく判別可能であることが確認できた。

表 10 より、GA が選択した中で最も accuracy が高かった物

質判別は、従来手法よりも使用するチャンネル数が 3 チャンネル少なかったが従来手法よりも精度よく判別可能であった。また、GA が選択した中で使用するチャンネル数が最も少なかったものは、従来手法の約半分にあたる 46 チャンネルしか使用していないが、従来手法よりも精度よく判別可能であった。この結果から、有効的なチャンネルを選択可能であることを確認した。

7. 結 言

本稿では、ハイパースペクトル画像を用いた物質判別に注目し、我々の先行研究である PLS 回帰分析よりも高い識別精度を達成することに取り組んだ。PLS 回帰分析はクラス数分の識別器生成が必要であり、手間であるため、ひとつのモデルで多クラス判別が可能であるニューラルネットワークを用いた。しかし、チャンネルの自動選択のためには新たな手法が必要であるため、この問題を組み合わせ最適化問題として捉え、GA を用いてチャンネルを選択することにした。識別

Fig.18 Graph of accuracy and number of channel

Fig.19 Substance discrimination results (conventional method)

Table 11 Comparison of accuracy (selected channels)

	Our method (Best accuracy)	Our method (Smallest wavelength)	Conventional method
accuracy	0.859	0.814	0.695

に有効なチャンネル数やその種類を最適化するために、染色体構造と適応度関数を工夫して設計することで、従来手法ではできていなかったチャンネル数とその種類の同時最適化を達成することができた。また、GA のフレームワークにニューラルネットワークを導入することで、GA によるチャンネルの最適化とモデルの学習をひとつのシステムにした。これにより、従来手法ではチャンネル選択と識別器の学習の間にユーザの介入が必要であったが、提案手法ではその介入が不要となる。実験では、二種類のデータセットを用いて実験した。その結果、

- (1) データセット 1 では提案手法の IoU が 0.953 であり、従来手法は 0.965 で同程度の性能であった。
- (2) クラス数が多いデータセット 2 では、提案手法は 0.859 の accuracy を達成し、関連研究は 0.695 であった。

これらの結果から、提案手法の有効性が示された。

今後の課題として、ニューラルネットワーク、GA のパラメータチューニングの問題が挙げられる。GA を使用するには、個体数、世代数、交叉手法、選択手法など必要なパラメータが多い。それに加え、提案手法では適応度関数にニューラルネットワークの用いているためさらにパラメータが多くなっている。これらのパラメータの最適値を見つけることは簡単ではない。そのため、本研究でも試行錯誤を繰り返し、パラメータチューニングを行ったが、より優れたパラメータが存在する可能性もある。したがってこれらのパラメータの決定する枠組みを考察することが今後の課題である。

参 考 文 献

- 1) 服部哲也, 加藤邦人: PLS 回帰分析を用いた近赤外物質判別および最適波長選択手法, 精密工学会誌, **83**,2 (2017)158.
- 2) D.E.Goldberg: Genetic Algorithm in Search, Optimization and Machine Learning, Addison-Wesley, (1989).
- 3) 安部, 渡辺, 石川, 能代, 藤井, 岩佐, 金子, 和田: 近赤外分光法を用いた非破壊的な樹種識別, MOKUZAI HOZON, **41**,4 (2015)162.
- 4) 岩本, 平田, 鈴木, 魚住: 近赤外スペクトル法による乾海苔品質の評価, 日本食品工業会誌, **30**,7 (1983)397.
- 5) 松本, 田辺, 佐伯, 天野, 上坂: 近赤外分光測定とニューラルネットワーク解析を組み合わせたプラスチック廃棄物の非破壊判別, BUNSEKI KAGAKU, **48**,5 (1999)483.
- 6) Anirban Santara, Kaustubh Mani, Pranoot Hatwar, Ankit Singh, Ankur Gtag, Kirti Padia, Pabitra Mitra: BASS Net: Band-Adaptive Spectral-Spatial Feature Learning Neural Network for Hyperspectral Image Classification, IEEE Transactions on Geoscience and Remote Sensing, **55**, (2017)5293.
- 7) Ying Li, Haokui Zhang, Qiang Shen: Spectral-Spatial Classification of Hyperspectral Imagery with 3D Convolutional Neural Network, Remote Sensing, **9**, (2017)67.
- 8) 松井, 菅波, 小杉: MRI 組織分類における遺伝的アルゴリズムによる特徴量の選択, 電子情報通信学会論文誌, **80**, D2 (1997)1712.
- 9) Cheng-Lung Huang, Chieh-jen Wang: A GA-based feature selection and parameters optimization for support vector machines, Expert Systems with Applications, **31**, (2006)231.
- 10) Shijin Li, Hao Wu, Dingsheng Wan, Jiali Zhu: An Effective Feature Selection Method for Hyperspectral Image Classification based on Genetic Algorithm and Support Vector Machine, Knowledge-Based Systems, **24**, 1, (2011) 40.
- 11) Shijin Li, Jianbin Qiu, Xinxin Yang, Huan Liu, Dingsheng Wan, Yuelong Zhu: A Novel Approach to Hyperspectral Band Selection based on Spectral Shape Similarity Analysis and Fast Branch and Bound Search, Engineering Applications of Artificial Intelligence, **27**, (2014) 241.
- 12) [http://www.ehu.eus/ccwintco/index.php?title=Hyperspectral Remote Sensing Scenes](http://www.ehu.eus/ccwintco/index.php?title=Hyperspectral_Remote_Sensing_Scenes) (閲覧日: 2018 年 8 月 5 日).