

# ディープ多層構造型 GMDH-type ニューラルネットワークと CNN を用いた胸部画像の医用画像解析

## Medical image analysis of chest images using deep multi-layered GMDH-type neural network and convolutional neural network

近藤 正<sup>\*1</sup>  
Tadashi Kondo

高尾 正一郎<sup>\*2</sup>  
Shoichiro Takao

近藤 明佳<sup>\*3</sup>  
Sayaka Kondo

上野 淳二<sup>\*4</sup>  
Junji Ueno

<sup>\*1</sup> 徳島大学  
Tokushima University

<sup>\*2</sup> 徳島大学  
Tokushima University

<sup>\*3</sup> 徳島医用情報科学研究会  
Tokushima medical informatics laboratory


<sup>\*4</sup> 徳島大学  
Tokushima University

In this study, hybrid deep neural network is organized using the deep multi-layered Group Method of Data Handling (GMDH)-type neural network and the Convolutional Neural Network (CNN) and it is applied to the medical image analysis of chest images. In the deep GMDH-type neural network, the hyper parameters such as number of hidden layers, type of the neural network and useful input variables, are automatically selected to minimize prediction error criterion defined as Akaike's Information Criterion (AIC) or Prediction Sum of Squares (PSS) and the deep neural networks with the optimal complexity are automatically organized. This deep neural network algorithm is applied to medical image analysis of chest images, and the organs such as liver, heart and bone, are recognized and these regions are extracted accurately using the deep multi-layered GMDH-type neural networks.

### 1. はじめに

本研究では、ディープ多層型 GMDH-type ニューラルネットワークとコンボリューションニューラルネットワーク(CNN)を用いたハイブリッド型ニューラルネットワーク[1,2]を用いて、胸部 X 線 CT 画像の医用画像解析を行う。ディープ GMDH-type ニューラルネットワークは、非線形システムの同定に適しており、データ数が少ない場合でも適用でき、著者らのグループにより数種類のアルゴリズムが提案されている[1-4]。進化的計算法の一つである改良形発見的自己組織化法[5]を用いて、入力変数のすべての組み合わせを発生して有益な組み合わせのみを自己選択することにより多層構造をしたディープニューラルネットワークを自動的に構成することができる。本研究では、文献[1,2]のハイブリッド型ニューラルネットワークを用いて、胸部 X 線 CT 画像の解析を行う。

### 2. ディープ多層型 GMDH-type ニューラルネットワークと CNN を用いたハイブリッド型ディープニューラルネットワーク[1,2]



Optimum activation function is automatically selected from Sigmoid function, Radial basis function and Polynomial

Fig.1 Hybrid deep neural network architecture of deep multi-layered GMDH-type neural network and convolutional neural network (CNN)[1,2]

ディープ多層型 GMDH-type ニューラルネットワークと CNN を用いたハイブリッド型ディープニューラルネットワークの構造 [1,2]を Fig.1 に示す。このニューラルネットワークでは、CNN と

フィルタリングによって画像特徴量を発生させる。さらに、従来から医用画像に用いられている画像特徴量や位置情報などを加えてディープ GMDH-type ニューラルネットワークの入力変数にする。このディープニューラルネットワークでは、入力変数のすべての組み合わせを発生させて、有益な変数の組み合わせのみを自己選択し、選択した変数の組み合わせを用いてディープニューラルネットワーク構造を自己組織化する。

#### 2.1 CNN とフィルタリング

本研究では、学習に用いる大量の画像データをまだ準備できていないので、CNN での学習は行わずに、CNN のフィルタの値としてはあらかじめ既存のものを準備する。そして、フィルタとしてはガウシアンフィルタとラプラシアンフィルタを用いてコンボリューション層で計算を行い画像特徴量を発生させる。次に、プーリング層では、最大値、最小値、範囲などのフィルタリングを行い、画像特徴量の抽出を行う。

#### 2.2 ディープ多層型 GMDH-type ニューラルネットワーク[1,2]

本アルゴリズムの概要を以下に示す。本研究では原データを全てトレーニングデータとして用い、予測誤差評価基準(情報量基準 AIC[6]または予測誤差平方和 PSS[7])を用いる。

##### (1) 第 1 層

$$u_j = x_j \quad (j=1,2,\dots,p) \quad (1)$$

ここで、 $x_j$  はシステムの入力変数を示す。

##### (2) 第 2 層

入力変数どうしを組み合わせ、すべての組み合わせを発生させる。ニューロンは 1 型と 2 型の 2 種類を用い、さらに 1 型と 2 型に 3 種類のニューロン構造を発生させて、対象となる非線形システムの特徴に最も適したニューロン構造を、予測誤差が最小になるように自己選択する。

##### 1) シグモイド関数型ニューラルネットワークス

###### i) 1 型ニューロン構造

$\Sigma$ : (Nonlinear function)

$$z_k = w_1 u_1 + w_2 u_2 + w_3 u_3 + w_4 u_4 + w_5 u_5 + w_6 u_6 + w_7 u_7 + w_8 u_8 + w_9 u_9 + w_{10} u_{10} + w_{11} u_{11} + w_{12} u_{12} + w_{13} u_{13} + w_{14} u_{14} + w_{15} u_{15} + w_{16} u_{16} + w_{17} u_{17} + w_{18} u_{18} + w_{19} u_{19} + w_{20} u_{20} + w_{21} u_{21} + w_{22} u_{22} + w_{23} u_{23} + w_{24} u_{24} + w_{25} u_{25} + w_{26} u_{26} + w_{27} u_{27} + w_{28} u_{28} + w_{29} u_{29} + w_{30} u_{30} + w_{31} u_{31} + w_{32} u_{32} + w_{33} u_{33} + w_{34} u_{34} + w_{35} u_{35} + w_{36} u_{36} + w_{37} u_{37} + w_{38} u_{38} + w_{39} u_{39} + w_{40} u_{40} + w_{41} u_{41} + w_{42} u_{42} + w_{43} u_{43} + w_{44} u_{44} + w_{45} u_{45} + w_{46} u_{46} + w_{47} u_{47} + w_{48} u_{48} + w_{49} u_{49} + w_{50} u_{50} + w_{51} u_{51} + w_{52} u_{52} + w_{53} u_{53} + w_{54} u_{54} + w_{55} u_{55} + w_{56} u_{56} + w_{57} u_{57} + w_{58} u_{58} + w_{59} u_{59} + w_{60} u_{60} + w_{61} u_{61} + w_{62} u_{62} + w_{63} u_{63} + w_{64} u_{64} + w_{65} u_{65} + w_{66} u_{66} + w_{67} u_{67} + w_{68} u_{68} + w_{69} u_{69} + w_{70} u_{70} + w_{71} u_{71} + w_{72} u_{72} + w_{73} u_{73} + w_{74} u_{74} + w_{75} u_{75} + w_{76} u_{76} + w_{77} u_{77} + w_{78} u_{78} + w_{79} u_{79} + w_{80} u_{80} + w_{81} u_{81} + w_{82} u_{82} + w_{83} u_{83} + w_{84} u_{84} + w_{85} u_{85} + w_{86} u_{86} + w_{87} u_{87} + w_{88} u_{88} + w_{89} u_{89} + w_{90} u_{90} + w_{91} u_{91} + w_{92} u_{92} + w_{93} u_{93} + w_{94} u_{94} + w_{95} u_{95} + w_{96} u_{96} + w_{97} u_{97} + w_{98} u_{98} + w_{99} u_{99} + w_{100} u_{100} + w_{101} u_{101} + w_{102} u_{102} + w_{103} u_{103} + w_{104} u_{104} + w_{105} u_{105} + w_{106} u_{106} + w_{107} u_{107} + w_{108} u_{108} + w_{109} u_{109} + w_{110} u_{110} + w_{111} u_{111} + w_{112} u_{112} + w_{113} u_{113} + w_{114} u_{114} + w_{115} u_{115} + w_{116} u_{116} + w_{117} u_{117} + w_{118} u_{118} + w_{119} u_{119} + w_{120} u_{120} + w_{121} u_{121} + w_{122} u_{122} + w_{123} u_{123} + w_{124} u_{124} + w_{125} u_{125} + w_{126} u_{126} + w_{127} u_{127} + w_{128} u_{128} + w_{129} u_{129} + w_{130} u_{130} + w_{131} u_{131} + w_{132} u_{132} + w_{133} u_{133} + w_{134} u_{134} + w_{135} u_{135} + w_{136} u_{136} + w_{137} u_{137} + w_{138} u_{138} + w_{139} u_{139} + w_{140} u_{140} + w_{141} u_{141} + w_{142} u_{142} + w_{143} u_{143} + w_{144} u_{144} + w_{145} u_{145} + w_{146} u_{146} + w_{147} u_{147} + w_{148} u_{148} + w_{149} u_{149} + w_{150} u_{150} + w_{151} u_{151} + w_{152} u_{152} + w_{153} u_{153} + w_{154} u_{154} + w_{155} u_{155} + w_{156} u_{156} + w_{157} u_{157} + w_{158} u_{158} + w_{159} u_{159} + w_{160} u_{160} + w_{161} u_{161} + w_{162} u_{162} + w_{163} u_{163} + w_{164} u_{164} + w_{165} u_{165} + w_{166} u_{166} + w_{167} u_{167} + w_{168} u_{168} + w_{169} u_{169} + w_{170} u_{170} + w_{171} u_{171} + w_{172} u_{172} + w_{173} u_{173} + w_{174} u_{174} + w_{175} u_{175} + w_{176} u_{176} + w_{177} u_{177} + w_{178} u_{178} + w_{179} u_{179} + w_{180} u_{180} + w_{181} u_{181} + w_{182} u_{182} + w_{183} u_{183} + w_{184} u_{184} + w_{185} u_{185} + w_{186} u_{186} + w_{187} u_{187} + w_{188} u_{188} + w_{189} u_{189} + w_{190} u_{190} + w_{191} u_{191} + w_{192} u_{192} + w_{193} u_{193} + w_{194} u_{194} + w_{195} u_{195} + w_{196} u_{196} + w_{197} u_{197} + w_{198} u_{198} + w_{199} u_{199} + w_{200} u_{200} + w_{201} u_{201} + w_{202} u_{202} + w_{203} u_{203} + w_{204} u_{204} + w_{205} u_{205} + w_{206} u_{206} + w_{207} u_{207} + w_{208} u_{208} + w_{209} u_{209} + w_{210} u_{210} + w_{211} u_{211} + w_{212} u_{212} + w_{213} u_{213} + w_{214} u_{214} + w_{215} u_{215} + w_{216} u_{216} + w_{217} u_{217} + w_{218} u_{218} + w_{219} u_{219} + w_{220} u_{220} + w_{221} u_{221} + w_{222} u_{222} + w_{223} u_{223} + w_{224} u_{224} + w_{225} u_{225} + w_{226} u_{226} + w_{227} u_{227} + w_{228} u_{228} + w_{229} u_{229} + w_{230} u_{230} + w_{231} u_{231} + w_{232} u_{232} + w_{233} u_{233} + w_{234} u_{234} + w_{235} u_{235} + w_{236} u_{236} + w_{237} u_{237} + w_{238} u_{238} + w_{239} u_{239} + w_{240} u_{240} + w_{241} u_{241} + w_{242} u_{242} + w_{243} u_{243} + w_{244} u_{244} + w_{245} u_{245} + w_{246} u_{246} + w_{247} u_{247} + w_{248} u_{248} + w_{249} u_{249} + w_{250} u_{250} + w_{251} u_{251} + w_{252} u_{252} + w_{253} u_{253} + w_{254} u_{254} + w_{255} u_{255} + w_{256} u_{256} + w_{257} u_{257} + w_{258} u_{258} + w_{259} u_{259} + w_{260} u_{260} + w_{261} u_{261} + w_{262} u_{262} + w_{263} u_{263} + w_{264} u_{264} + w_{265} u_{265} + w_{266} u_{266} + w_{267} u_{267} + w_{268} u_{268} + w_{269} u_{269} + w_{270} u_{270} + w_{271} u_{271} + w_{272} u_{272} + w_{273} u_{273} + w_{274} u_{274} + w_{275} u_{275} + w_{276} u_{276} + w_{277} u_{277} + w_{278} u_{278} + w_{279} u_{279} + w_{280} u_{280} + w_{281} u_{281} + w_{282} u_{282} + w_{283} u_{283} + w_{284} u_{284} + w_{285} u_{285} + w_{286} u_{286} + w_{287} u_{287} + w_{288} u_{288} + w_{289} u_{289} + w_{290} u_{290} + w_{291} u_{291} + w_{292} u_{292} + w_{293} u_{293} + w_{294} u_{294} + w_{295} u_{295} + w_{296} u_{296} + w_{297} u_{297} + w_{298} u_{298} + w_{299} u_{299} + w_{300} u_{300} + w_{301} u_{301} + w_{302} u_{302} + w_{303} u_{303} + w_{304} u_{304} + w_{305} u_{305} + w_{306} u_{306} + w_{307} u_{307} + w_{308} u_{308} + w_{309} u_{309} + w_{310} u_{310} + w_{311} u_{311} + w_{312} u_{312} + w_{313} u_{313} + w_{314} u_{314} + w_{315} u_{315} + w_{316} u_{316} + w_{317} u_{317} + w_{318} u_{318} + w_{319} u_{319} + w_{320} u_{320} + w_{321} u_{321} + w_{322} u_{322} + w_{323} u_{323} + w_{324} u_{324} + w_{325} u_{325} + w_{326} u_{326} + w_{327} u_{327} + w_{328} u_{328} + w_{329} u_{329} + w_{330} u_{330} + w_{331} u_{331} + w_{332} u_{332} + w_{333} u_{333} + w_{334} u_{334} + w_{335} u_{335} + w_{336} u_{336} + w_{337} u_{337} + w_{338} u_{338} + w_{339} u_{339} + w_{340} u_{340} + w_{341} u_{341} + w_{342} u_{342} + w_{343} u_{343} + w_{344} u_{344} + w_{345} u_{345} + w_{346} u_{346} + w_{347} u_{347} + w_{348} u_{348} + w_{349} u_{349} + w_{350} u_{350} + w_{351} u_{351} + w_{352} u_{352} + w_{353} u_{353} + w_{354} u_{354} + w_{355} u_{355} + w_{356} u_{356} + w_{357} u_{357} + w_{358} u_{358} + w_{359} u_{359} + w_{360} u_{360} + w_{361} u_{361} + w_{362} u_{362} + w_{363} u_{363} + w_{364} u_{364} + w_{365} u_{365} + w_{366} u_{366} + w_{367} u_{367} + w_{368} u_{368} + w_{369} u_{369} + w_{370} u_{370} + w_{371} u_{371} + w_{372} u_{372} + w_{373} u_{373} + w_{374} u_{374} + w_{375} u_{375} + w_{376} u_{376} + w_{377} u_{377} + w_{378} u_{378} + w_{379} u_{379} + w_{380} u_{380} + w_{381} u_{381} + w_{382} u_{382} + w_{383} u_{383} + w_{384} u_{384} + w_{385} u_{385} + w_{386} u_{386} + w_{387} u_{387} + w_{388} u_{388} + w_{389} u_{389} + w_{390} u_{390} + w_{391} u_{391} + w_{392} u_{392} + w_{393} u_{393} + w_{394} u_{394} + w_{395} u_{395} + w_{396} u_{396} + w_{397} u_{397} + w_{398} u_{398} + w_{399} u_{399} + w_{400} u_{400} + w_{401} u_{401} + w_{402} u_{402} + w_{403} u_{403} + w_{404} u_{404} + w_{405} u_{405} + w_{406} u_{406} + w_{407} u_{407} + w_{408} u_{408} + w_{409} u_{409} + w_{410} u_{410} + w_{411} u_{411} + w_{412} u_{412} + w_{413} u_{413} + w_{414} u_{414} + w_{415} u_{415} + w_{416} u_{416} + w_{417} u_{417} + w_{418} u_{418} + w_{419} u_{419} + w_{420} u_{420} + w_{421} u_{421} + w_{422} u_{422} + w_{423} u_{423} + w_{424} u_{424} + w_{425} u_{425} + w_{426} u_{426} + w_{427} u_{427} + w_{428} u_{428} + w_{429} u_{429} + w_{430} u_{430} + w_{431} u_{431} + w_{432} u_{432} + w_{433} u_{433} + w_{434} u_{434} + w_{435} u_{435} + w_{436} u_{436} + w_{437} u_{437} + w_{438} u_{438} + w_{439} u_{439} + w_{440} u_{440} + w_{441} u_{441} + w_{442} u_{442} + w_{443} u_{443} + w_{444} u_{444} + w_{445} u_{445} + w_{446} u_{446} + w_{447} u_{447} + w_{448} u_{448} + w_{449} u_{449} + w_{450} u_{450} + w_{451} u_{451} + w_{452} u_{452} + w_{453} u_{453} + w_{454} u_{454} + w_{455} u_{455} + w_{456} u_{456} + w_{457} u_{457} + w_{458} u_{458} + w_{459} u_{459} + w_{460} u_{460} + w_{461} u_{461} + w_{462} u_{462} + w_{463} u_{463} + w_{464} u_{464} + w_{465} u_{465} + w_{466} u_{466} + w_{467} u_{467} + w_{468} u_{468} + w_{469} u_{469} + w_{470} u_{470} + w_{471} u_{471} + w_{472} u_{472} + w_{473} u_{473} + w_{474} u_{474} + w_{475} u_{475} + w_{476} u_{476} + w_{477} u_{477} + w_{478} u_{478} + w_{479} u_{479} + w_{480} u_{480} + w_{481} u_{481} + w_{482} u_{482} + w_{483} u_{483} + w_{484} u_{484} + w_{485} u_{485} + w_{486} u_{486} + w_{487} u_{487} + w_{488} u_{488} + w_{489} u_{489} + w_{490} u_{490} + w_{491} u_{491} + w_{492} u_{492} + w_{493} u_{493} + w_{494} u_{494} + w_{495} u_{495} + w_{496} u_{496} + w_{497} u_{497} + w_{498} u_{498} + w_{499} u_{499} + w_{500} u_{500} + w_{501} u_{501} + w_{502} u_{502} + w_{503} u_{503} + w_{504} u_{504} + w_{505} u_{505} + w_{506} u_{506} + w_{507} u_{507} + w_{508} u_{508} + w_{509} u_{509} + w_{510} u_{510} + w_{511} u_{511} + w_{512} u_{512} + w_{513} u_{513} + w_{514} u_{514} + w_{515} u_{515} + w_{516} u_{516} + w_{517} u_{517} + w_{518} u_{518} + w_{519} u_{519} + w_{520} u_{520} + w_{521} u_{521} + w_{522} u_{522} + w_{523} u_{523} + w_{524} u_{524} + w_{525} u_{525} + w_{526} u_{526} + w_{527} u_{527} + w_{528} u_{528} + w_{529} u_{529} + w_{530} u_{530} + w_{531} u_{531} + w_{532} u_{532} + w_{533} u_{533} + w_{534} u_{534} + w_{535} u_{535} + w_{536} u_{536} + w_{537} u_{537} + w_{538} u_{538} + w_{539} u_{539} + w_{540} u_{540} + w_{541} u_{541} + w_{542} u_{542} + w_{543} u_{543} + w_{544} u_{544} + w_{545} u_{545} + w_{546} u_{546} + w_{547} u_{547} + w_{548} u_{548} + w_{549} u_{549} + w_{550} u_{550} + w_{551} u_{551} + w_{552} u_{552} + w_{553} u_{553} + w_{554} u_{554} + w_{555} u_{555} + w_{556} u_{556} + w_{557} u_{557} + w_{558} u_{558} + w_{559} u_{559} + w_{560} u_{560} + w_{561} u_{561} + w_{562} u_{562} + w_{563} u_{563} + w_{564} u_{564} + w_{565} u_{565} + w_{566} u_{566} + w_{567} u_{567} + w_{568} u_{568} + w_{569} u_{569} + w_{570} u_{570} + w_{571} u_{571} + w_{572} u_{572} + w_{573} u_{573} + w_{574} u_{574} + w_{575} u_{575} + w_{576} u_{576} + w_{577} u_{577} + w_{578} u_{578} + w_{579} u_{579} + w_{580} u_{580} + w_{581} u_{581} + w_{582} u_{582} + w_{583} u_{583} + w_{584} u_{584} + w_{585} u_{585} + w_{586} u_{586} + w_{587} u_{587} + w_{588} u_{588} + w_{589} u_{589} + w_{590} u_{590} + w_{591} u_{591} + w_{592} u_{592} + w_{593} u_{593} + w_{594} u_{594} + w_{595} u_{595} + w_{596} u_{596} + w_{597} u_{597} + w_{598} u_{598} + w_{599} u_{599} + w_{600} u_{600} + w_{601} u_{601} + w_{602} u_{602} + w_{603} u_{603} + w_{604} u_{604} + w_{605} u_{605} + w_{606} u_{606} + w_{607} u_{607} + w_{608} u_{608} + w_{609} u_{609} + w_{610} u_{610} + w_{611} u_{611} + w_{612} u_{612} + w_{613} u_{613} + w_{614} u_{614} + w_{615} u_{615} + w_{616} u_{616} + w_{617} u_{617} + w_{618} u_{618} + w_{619} u_{619} + w_{620} u_{620} + w_{621} u_{621} + w_{622} u_{622} + w_{623} u_{623} + w_{624} u_{624} + w_{625} u_{625} + w_{626} u_{626} + w_{627} u_{627} + w_{628} u_{628} + w_{629} u_{629} + w_{630} u_{630} + w_{631} u_{631} + w_{632} u_{632} + w_{633} u_{633} + w_{634} u_{634} + w_{635} u_{635} + w_{636} u_{636} + w_{637} u_{637} + w_{638} u_{638} + w_{639} u_{639} + w_{640} u_{640} + w_{641} u_{641} + w_{642} u_{642} + w_{643} u_{643} + w_{644} u_{644} + w_{645} u_{645} + w_{646} u_{646} + w_{647} u_{647} + w_{648} u_{648} + w_{649} u_{649} + w_{650} u_{650} + w_{651} u_{651} + w_{652} u_{652} + w_{653} u_{653} + w_{654} u_{654} + w_{655} u_{655} + w_{656} u_{656} + w_{657} u_{657} + w_{658} u_{658} + w_{659} u_{659} + w_{660} u_{660} + w_{661} u_{661} + w_{662} u_{662} + w_{663} u_{663} + w_{664} u_{664} + w_{665} u_{665} + w_{666} u_{666} + w_{667} u_{667} + w_{668} u_{668} + w_{669} u_{669} + w_{670} u_{670} + w_{671} u_{671} + w_{672} u_{672} + w_{673} u_{673} + w_{674} u_{674} + w_{675} u_{675} + w_{676} u_{676} + w_{677} u_{677} + w_{678} u_{678} + w_{679} u_{679} + w_{680} u_{680} + w_{681} u_{681} + w_{682} u_{682} + w_{683} u_{683} + w_{684} u_{684} + w_{685} u_{685} + w_{686} u_{686} + w_{687} u_{687} + w_{688} u_{688} + w_{689} u_{689} + w_{690} u_{690} + w_{691} u_{691} + w_{692} u_{692} + w_{693} u_{693} + w_{694} u_{694} + w_{695} u_{695} + w_{696} u_{696} + w_{697} u_{697} + w_{698} u_{698} + w_{699} u_{699} + w_{700} u_{700} + w_{701} u_{701} + w_{702} u_{702} + w_{703} u_{703} + w_{704} u_{704} + w_{705} u_{705} + w_{706} u_{706} + w_{707} u_{707} + w_{708} u_{708} + w_{709} u_{709} + w_{710} u_{710} + w_{711} u_{711} + w_{712} u_{712} + w_{713} u_{713} + w_{714} u_{714} + w_{715} u_{715} + w_{716} u_{716} + w_{717} u_{717} + w_{718} u_{718} + w_{719} u_{719} + w_{720} u_{720} + w_{721} u_{721} + w_{722} u_{722} + w_{723} u_{723} + w_{724} u_{724} + w_{725} u_{725} + w_{726} u_{726} + w_{727} u_{727} + w_{728} u_{728} + w_{729} u_{729} + w_{730} u_{730} + w_{731} u_{731} + w_{732} u_{732} + w_{733} u_{733} + w_{734} u_{734} + w_{735} u_{735} + w_{736} u_{736} + w_{737} u_{737} + w_{738} u_{738} + w_{739} u_{739} + w_{740} u_{740} + w_{741} u_{741} + w_{742} u_{742} + w_{743} u_{743} + w_{744} u_{744} + w_{745} u_{745} + w_{746} u_{746} + w_{747} u_{747} + w_{748} u_{748} + w_{749} u_{749} + w_{750} u_{750} + w_{751} u_{751} + w_{752} u_{752} + w_{753} u_{753} + w_{754} u_{754} + w_{755} u_{755} + w_{756} u_{756} + w_{757} u_{757} + w_{758} u_{758} + w_{759} u_{759} + w_{760} u_{760} + w_{761} u_{761} + w_{762} u_{762} + w_{763} u_{763} + w_{764} u_{764} + w_{765} u_{765} + w_{766} u_{766} + w_{767} u_{767} + w_{768} u_{768} + w_{769} u_{769} + w_{770} u_{770} + w_{771} u_{771} + w_{772} u_{772} + w_{773} u_{773} + w_{774} u_{774} + w_{775} u_{775} + w_{776} u_{776$$

$f$ : (Nonlinear function)

$$y_k = 1 / (1 + \exp(-z_k)) \quad (5)$$

## 2) 放射基底関数(RBF)型ニューラルネットワークス

### i) 1型ニューロン構造

$\Sigma$ : (Nonlinear function)

$$z_k = w_1 u_i + w_2 u_j + w_3 u_i u_j + w_4 u_i^2 + w_5 u_j^2 - w_0 \theta_l \quad (6)$$

$f$ : (Nonlinear function)

$$y_k = \exp(-z_k^2) \quad (7)$$

### ii) 2型ニューロン構造

$\Sigma$ : (Linear function)

$$z_k = w_1 u_1 + w_2 u_2 + w_3 u_3 + \dots + w_r u_r - w_0 \theta_l \quad (r < p) \quad (8)$$

$f$ : (Nonlinear function)

$$y_k = \exp(-z_k^2) \quad (9)$$

## 3) 多項式型ニューラルネットワークス

### i) 1型ニューロン構造

$\Sigma$ : (Nonlinear function)

$$z_k = w_1 u_i + w_2 u_j + w_3 u_i u_j + w_4 u_i^2 + w_5 u_j^2 - w_0 \theta_l \quad (10)$$

$f$ : (Linear function)

$$y_k = z_k \quad (11)$$

### ii) 2型ニューロン構造

$\Sigma$ : (Linear function)

$$z_k = w_1 u_1 + w_2 u_2 + w_3 u_3 + \dots + w_r u_r - w_0 \theta_l \quad (r < p) \quad (12)$$

$f$ : (Linear function)

$$\begin{aligned} y_k &= z_k & (z_k > 0 \text{ の場合}) \\ y_k &= 0 & (z_k < 0 \text{ の場合}) \end{aligned} \quad (13)$$

ここで、各々のニューロンは $\Sigma$ と $f$ の2個の関数から構成され、 $w$ はニューロンの重み係数、 $p$ は入力変数の個数を示す。ディープ GMDH-type ニューラルネットワークスは、上記の6種類の活性化関数の中から、対象とする非線形システムの特徴に最も適した活性化関数を、情報量基準AIC[6]または予測平方和PSS[7]を用いて自己選択する。

次に、各々のニューロンに対して、トレーニングデータを用いて、主成分回帰分析により重み $w$ を推定する。そして、各々の組み合わせに対して、シグモイド関数型ニューロン、RBF型ニューロン、多項式型ニューロンの3種類のニューロンを発生して、発生した3種類の各々のニューロンに対して、AIC値又はPSS値の小さいものを $L$ 個選択する。

### 4) 総合特性変数( $\phi^*$ )の発生

総合特性変数( $\phi^*$ )は、シグモイド関数型、RBF型、多項式型ニューラルネットワークの3種類のニューラルネットワークに対して、つぎの線形結合式を用いて計算する。

$$\phi^* = a_0 + \sum_{k=1}^L a_k y_k \quad (14)$$

ここで、 $L$ は中間変数の個数、 $y_k$ は中間変数を示す。次に、(14)式のAIC又はPSS値が小さなニューロン構造を3種類の構造の中から、ディープ GMDH-type ニューラルネットワークの構造として自己選択する。次層の計算では、自己選択したニューロン構造のみを用いてニューラルネットワークの計算を行う。そして、総合特性変数( $\phi^*$ )と自己選択した $L$ 個のニューロンの出力値を次層の入力変数にセットして、次層の計算に移る。

### (3) 3層以上の層

3層以上の層では、第2層と同じ計算を繰り返す。ただし、ニューロンの構造は自己選択した構造のみを使用する。そして、(14)式のAICまたはPSSの値が減少しなくなる層で中間層の計算を停止する。中間層の計算を停止した場合、最終の中間

層を出力層とする。そして、ディープニューラルネットワーク構造は、各層で自己選択したニューロンを用いて構成する。

以上の手続きにより、多層構造をしたディープ多層型 GMDH-type ニューラルネットワークスを構成できる。

## 3. 胸部臓器の医用画像解析への応用

本研究では、ディープ多層型 GMDH-type ニューラルネットワークスを用いて、肝臓、心臓、骨などの胸部臓器の医用画像認識とその領域抽出を行った。医用画像としてX線CT画像を用いた。予測誤差の評価基準としてはPSSを用いた。

### 3.1 肝臓領域の医用画像認識と領域抽出

Fig.2に、ニューラルネットワークスを自己組織化するために用いた原画像を示す。ニューラルネットワークスの入力変数としては $N \times N$ 近傍領域の画像特徴量を用いた。これは、CNNにおいて、ガウシアンフィルタ、ラプラシアンフィルタ、最大値フィルタ、最小値フィルタ、レンジフィルタにより発生した5個の画像特徴量と、従来から用いられている統計学的特徴量である平均値、分散、標準偏差、及び位置情報( $x$ と $y$ 座標)の合計10個の入力変数を用いた。Table2に自己選択された画像特徴量を示す。近傍領域の大きさ $N$ は、2から10の値に対してニューラルネットワークスを自己組織化した。その結果、 $N$ が6の場合に、最も良い画像認識精度を得た。ニューラルネットワークスの出力変数は、0か1の値をとり、対象臓器の領域内部では1の値を出力するように学習させた。Fig.3に第1層における3種類のニューロンのPSS値を示す。シグモイド関数型が自己選択された。ディープ GMDH-type ニューラルネットワークスの計算は第8層で終了した。Fig.4に、各層におけるPSS値の変化を示す。層を通過することによりPSS値は徐々に減少して予測誤差が小さな値に収束した。





Fig.2 Original image

Fig.3 PSS in three types of neurons(1)




Fig.4 Variation of PSS(1)

自己組織化されたディープ GMDH-type ニューラルネットワークスによって肝臓領域を出力する。Fig.5に、ニューラルネットワークの出力画像を示す。次に、出力画像に対して画像の後処理が行われた。Fig.6に、ニューラルネットワークスの出力画像に後処理を行った画像を示す。Fig.7に原画像と後処理後の出力画像を重ね合わせ画像を示す。この画像から、ニューラルネットワークスによって画像認識された肝臓領域は、原画像の肝

臓領域によく一致していることがわかる。Fig.8 に差分画像(グレイ画像)を示す。

誤差逆伝播法(BP 法)を用いて学習する従来形ニューラルネットワークを用いて肝臓領域の画像認識を行った。ニューラルネットワークは、入力層、中間層、出力層の 3 層構造とした。学習データは、ディープ GMDH-type ニューラルネットワークと同じものを用いた。本研究では、中間層のニューロン数( $m$ )を変化させて画像認識を行った。Fig.9 に、 $m=5$ 、 $m=7$  と  $m=9$  の場合の出力画像を示す。これらのニューラルネットワークの出力画像には、肝臓領域でない領域や孤立点を多く含んでおり、画像認識精度が十分でないことがわかる。




Fig.5 Output image of the neural network(1)



Fig.6 Output image after the post-processing(1)




Fig.7 Overlapped image(1)





Fig.8 Gray scale image (1)



(a)  $m=5$

(b)  $m=7$

(c)  $m=9$

Fig.9 Output images of the conventional neural network (1)

### 3.2. 心臓領域の医用画像認識と領域抽出

心臓領域の抽出を目的とした新しいニューラルネットワークを自己組織化した。Table2に自己選択された画像特徴量を示す。近傍領域の大きさ  $N$  は 5 の場合に、最も良い画像認識精度を得た。ディープ GMDH-type ニューラルネットワークの計算は第 12 層で終了した。Fig.10 より、シグモイド関数型が自己選択された。Fig.11 に、各層における PSS 値の変化を示す。Fig.12 に最終層で得られた出力画像を示す。Fig.13 に、ニューラルネットワークの出力画像に後処理を行った画像を示す。Fig.14 に重ね合わせ画像を示す。




Fig.10 PSS in three types of neurons(2)




Fig.11 Variation of PSS(2)




Fig.12 Output image of the neural network(2)



Fig.13 Output image after the post processing (2)




Fig.14 Overlapped image(2)





Fig.15 Gray scale image (2)



(a)  $m=5$

(b)  $m=7$

(c)  $m=9$

Fig.16 Output images of the conventional neural network (2)

この画像から、ニューラルネットワークによって画像認識された心臓領域は、原画像の心臓領域によく一致していることがわかる。Fig.15 に、心臓領域のグレイ画像を示す。Fig.16 に BP 法を用いて学習する 3 層構造の従来型ニューラルネットワークによって得られた画像認識結果を示す。心臓領域でない領域や孤立点を多く含んでおり、画像認識精度が十分でないことが分かる。

### 3.3. 骨領域の医用画像認識と領域抽出

骨領域の抽出を目的とした新しいニューラルネットワークを自己組織化した。Table2に自己選択された画像特徴量を示す。近傍領域の大きさ  $N$  は、2 の場合に、最も良い画像認識精度を得た。ディープ GMDH-type ニューラルネットワークの計算は第 8 層で終了した。Fig.17 より、シグモイド関数型が自己選択された。Fig.18 に、各層における PSS 値の変化を示す。Fig.19 に最終層で得られた出力画像を示す。Fig.20 に、ニューラルネットワークの出力画像に後処理を行った画像を示す。Fig.21 に原画像と後処理後の出力画像を重ね合わせ画像を示す。ニューラルネットワークによって画像認識された骨領域は、原画像の骨領域によく一致している。Fig.22 にグレイ画像を示す。Fig.23 に、BP 法を用いて学習する 3 層構造の従来型ニューラルネットワークによって得られた画像認識結果を示す。



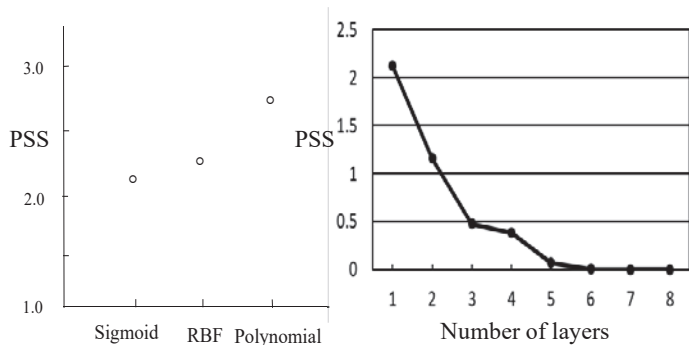


Fig.17 PSS in three types of neurons(3) Fig.18 Variation of PSS(3)




Fig.19 Output image of the neural network (3)



Fig. 20 Output image after the post processing (3)






Fig. 21 Overlapped image(3)




Fig.22 Gray scale image (3)



(a) m=5



(b) m=7



(c) m=9

Fig.23 Output images of conventional neural network (3)

Table 1 Number of hidden layers and type of neural network

Regions	Number of hidden layers	Type of neural network
Liver	8	Sigmoid function NN
Heart	12	Sigmoid function NN
Bone	8	Sigmoid function NN

### 3.4 考察

Table1 に、中間層の層数とニューラルネットワークの種類を示す。肝臓では 8 層、心臓では 12 層、骨では 8 層の中間層のディープニューラルネットワークが自己組織された。画像認識結果から、予測誤差 PSS は、層を積み重ねるごとに徐々に減少し最終層では PSS 値が小さな値に収束

した。また、ニューラルネットワークの種類としては、3つのニューラルネットワークともシグモイド関数型が自己選択された。次に、Table2 に有益な入力変数の自己選択結果を示す。本研究では、3つのニューラルネットワークで共通に自己選択された入力変数は、平均値、x 座標、標準偏差、最大値の 4 変数であった。CNN やフィルタリングで発生された画像特徴量も自己選択された。

### 4. むすび

本研究では、ディープ多層型 GMDH-type ニューラルネットワークと CNN を用いたハイブリッド型ニューラルネットワークを用いて胸部 X 線 CT 画像の医用画像解析を行った。肝臓、心臓、骨の領域をディープニューラルネットワーク(8 層、12 層、8 層の中間層のニューラルネットワーク)に画像認識させて領域抽出した。これらの画像認識精度は良かったが、BP 法を用いて学習する 3 層構造の従来型ニューラルネットワークでは、肝臓と心臓の画像認識精度が良くなかった。3 層構造ではネットワークの構造が簡単すぎて十分な画像認識精度が得られなかったものと考えられる。また、本研究で用いたディープ多層型 GMDH-type ニューラルネットワークは、ハイパーパラメータ(層の個数、有益な入力変数の選択、活性化関数の選択など)を予測誤差評価基準(PSS)を最小にするように自動的に決定しているため、医用画像解析問題への応用が容易であった。

### 謝 辞

本研究は、科学研究費補助金 JSPS KAKENHI Grant Number JP18K0420600 により補助を受けて実施された。

### 参 考 文 献

- [1] S. Takao, S. Kondo, J. Ueno and T. Kondo: Medical image recognition of brain regions using deep multi-layered GMDH-type neural network and convolutional neural network, *Proceedings of the Twenty-Fourth International Symposium on Artificial Life and Robotics* 2019, pp.115-121 (2019)
- [2] 近藤正、高尾正一郎、近藤明佳、上野淳二：ディープ GMDH-type ニューラルネットワークとコンボリューショナルニューラルネットワークを用いた臓器の自動医用画像認識、医療情報学会・人工知能学会 AIM 合同研究会資料 SIG-AIMED-006-05(2018)
- [3] S. Takao, S. Kondo, J. Ueno and T. Kondo: Medical image analysis of X-ray CT images using hybrid deep neural network of deep feedback GMDH-type neural network and convolutional neural network, *Proceedings of the Twenty-Fifth International Symposium on Artificial Life and Robotics* 2020, pp.435-442 (2020)
- [4] S. Takao, S. Kondo, J. Ueno and T. Kondo: Medical image diagnosis of liver cancer by hybrid deep neural network of deep logistic GMDH-type neural network and convolutional neural network, *Proceedings of the Twenty-Third International Symposium on Artificial Life and Robotics* 2018, pp.89-93 (2018)
- [5] S. J. Farlow ed.: Self-organizing methods in modeling, GMDH-type algorithm, New York: Marcel Dekker Inc. (1984)
- [6] H. Akaike: A new look at the statistical model identification, *IEEE Trans. Automatic Control*, vol.AC-19, no.6, pp.716-723 (1974)
- [7] H. Tamura, T. Kondo: Heuristics free group method of data handling algorithm of generating optimum partial polynomials with application to air pollution prediction, *Int. J. System Sci.*, vol.11, no.9, pp.1095-1111 (1980)

Table2 Selection of useful input variables in the deep GMDH-type neural networks

Regions \ Input variables	Gaussian filter	Laplacian filter	Maximum filter	Minimum filter	Range filter	Mean	X	Y	Variance	Standard deviation
Liver			○		○	○	○			○
Heart			○			○	○	○	○	○
Bone			○		○	○	○	○	○	○