

REGULAR PAPER

階層型ニューラルネットワークの形式化について

On the Formalizations for Multilayer Perceptron

山崎 浩^{1,*}, 師玉 康成²
Hiroshi Yamazaki^{1,*}, Yasunari Shidama²

1 長野県工科短期大学校, 長野県上田市下之郷 813-8

1 Nagano Prefecture Institute of Technology. 813-8, Shimonogho Ueda, Nagano, Japan

2 長野県軽井沢町

2 Karuizawa, Nagano, Japan

1 yamazaki@cse.pit-nagano.ac.jp

2 shidama@cs.shinshu-u.ac.jp

* Corresponding Author: yamazaki@cse.pit-nagano.ac.jp

Proof checked by Mizar Version: 8.1.10 and MML Version: 5.64.1388

Received: December 10, 2020. Accepted: April 30, 2021.

Abstract

In this paper, the hierarchical neural networks is formalized by finite sequence of mappings. The input-output map of the this neural network is represented as a composite map of this finite sequence. The compactness of the set of these composite map is proved by applying Ascoli-Arzelà's theorem.

1 はじめに

本稿では筆者らが作成している階層型ニューラルネットワークの形式化表現について途中経過を報告する。この形式化による階層型ニューラルネットワークは有次元空間上の写像の有限列として表現される。また、このニューラルネットワークによる入出力の関係は、それを定義する写像の有限列の直列的な合成関数として表現される。Rosenblatt の Perceptron [1] 以降、階層型ニューラルネットワークは 1986 年の Rumelhart [2] らの誤差逆伝搬法、最近の Deep Learning [3] の実用化など流行を繰り返してきた。人工知能研究の重要な道具であり、工学的な有用性と共に、関数近似論でも興味深い課題を提供してきた。例えば Sprecher [4] および Hecht-Nielsen [5] は Kolmogorov の定理 [6](ヒルベルト 13 番問題の否定的解決) が 4 層のニューラルネットワークに適用できることを示した。また Funahashi [7] は Miyake-Irie [8] の結果を用いて、中間層の入出力関数がシングモイド関

数である3層ニューラルネットワークによってコンパクトな台を持つ任意の連続関数が近似できることを示した。最近では Deep Learning で中間層を増やすことにより何故学習効果が上がるのかなど重要な未解決課題が残されている。階層型ニューラルネットワークは Mizar Mathematical Library(以後 MML) でも系統的な形式化表現は未だなされていない。階層型ニューラルネットワークを形式化表現しようとする場合、その一つに有向グラフを用いる方法が考えられる。グラフ理論に関する MML ではグラフの位相的な性質の抽象化・一般化が行われている [9-13]。

例えば Nakamura は [13] でそれを用いた Dijkstra's Shortest Path Algorithm の精密な形式化を行っている。しかしながら非線形関数の近似の議論など、関数系の理論の形式化にこれらを用いることは容易ではない。このため、筆者らは階層型ニューラルネットワークに関しての関数系の理論の形式化に使いやすい方法を意図して、形式化を進めている。

2 階層型ニューラルネットワークの形式化

2.1 写像の有限列を用いた形式化表現

周知のように階層型ニューラルネットワークは、入力信号を与える入力層、出力信号を出す出力層、それらの中間に配置される複数の中間層によって構成されている。本稿では各層をベクトル値を入力する有限次元ベクトル空間上の写像とみなし、それらの複数の写像の有限列によってニューラルネットワークを形式化する方法を報告する。このニューラルネットワークによる入出力の関係は、それを定義する写像の有限列全部の合成写像として表現される。

第 i 番目の層はそれに連結する第 $i-1$ 番目の層から出力される実数ベクトルを入力とし、第 $i+1$ 番目の層への入力となる実数ベクトルを出力する。これは入力ベクトルが属する有限次元実数ベクトル空間から出力ベクトルが属する有限次元実数ベクトル空間への写像として表現できる。この第 i 番目の層を表す写像を N_i で表現する。第 $i-1$ 番目の層からの出力であり同時に、第 i 番目の層への入力である実数ベクトルが属する実数ベクトル空間の次元を k_i で表す。入出力層及び中間層の総数を n 個とすれば、上記の各層を表す長さ n の写像の有限列 $\{N_i\}_{1 \leq i \leq n}$ と各関数 N_i の定義域・値域である実数ベクトル空間の次元を表す長さ $n+1$ の自然数の有限列 $\{k_i\}_{1 \leq i \leq n+1}$ が下記のように与えられる。

$$N_i : x \in \mathbf{R}^{k_i} \mapsto N_i(x) \in \mathbf{R}^{k_{i+1}} \quad 1 \leq i \leq n \quad (1)$$

入力層が N_1 , 出力層が N_n であり,

$$N_i \quad 2 \leq i \leq n-1 \quad (2)$$

が中間層である。

それらを直列に合成した写像

$$N_n \circ N_{n-1} \circ \cdots \circ N_2 \circ N_1 \quad (3)$$

が階層型ニューラルネットワークの入出力の関係を表す写像であり、 k_1 次元実数ベクトル空間 \mathbf{R}^{k_1} から k_{n+1} 次元実数ベクトル空間 $\mathbf{R}^{k_{n+1}}$ への写像である。

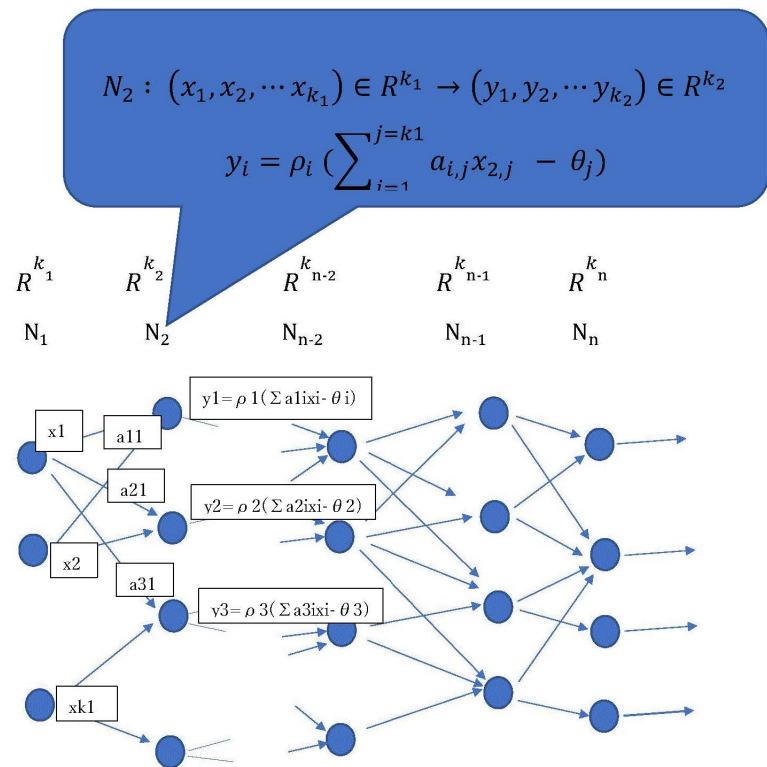


図 1. 階層型ニューラルネットワーク

上記の性質をもった写像の有限列と各写像の定義域・値域の空間の次元数の有限列を次のように、述語 (predicate) と属性 (attribute) で定義した。

Listing 1. NEURONS1: def 1 def 2

```

definition
let n be Nat,
      k be FinSequence of NAT,
      N be FinSequence;
pred N is Multilayer_perceptron_with k,n
means
  :: NEURONS1: def 1

  len N = n & len N + 1 = len k
  &
  for i be Nat st 1 <= i & i < len k holds
    N.i is Function of REAL-NS (k.i), REAL-NS (k.(i+1));
end;

```

```

definition
let N be FinSequence;
attr N is Multilayer_perceptron_like
means
  :: NEURONS1: def 2
  ex k be FinSequence of NAT
    st
    len N + 1 = len k
    &
    for i be Nat st 1 <= i & i < len k holds

```

```

N.i is Function of REAL-NS (k.i),REAL-NS (k.(i+1));
end;

```

NEURONS1 : def 1 は自然数 n , 自然数の有限列 k と有限列 N を引数 N, k, n にもつ述語を定義している. k, N の長さがそれぞれ $n+1, n$ であり, N の各要素 N_i $1 \leq i \leq n$ が k_i 次元実数ベクトル空間 \mathbf{R}^{k_i} から k_{i+1} 次元実数ベクトル空間 $\mathbf{R}^{k_{i+1}}$ への写像であることを表す述語である. ここで **REAL-NS(k.i)** は k_i 次元の数ベクトル空間 \mathbf{R}^{k_i} でユークリッドノルム $\|x\| = \sqrt{\sum_{i=1}^{k_i} x_i^2}$, $x = (x_1, x_2, \dots, x_{k_i}) \in \mathbf{R}^{k_i}$ によりノルムを定義した実ノルム空間を表している [14].

NEURONS1 : def 2 は有限列 $\{N_i\}_{1 \leq i \leq n}$ についてこれが写像の有限列であり, 隣あった写像どうしで共有する定義域, 値域の次元数を表す自然数の有限列 $\{k_i\}_{1 \leq i \leq n+1}$ が存在することを示す属性である.

この属性をもった写像の有限列が存在することを示すのが以下の **cluster** 宣言であり, **mode** でこの属性をもった, 型変数を **Multilayer_perceptron** という名前で定義した.

Listing 2. cluster and mode

```

registration
cluster Multilayer_perceptron_like for FinSequence;
end;

definition
mode Multilayer_perceptron
is Multilayer_perceptron_like FinSequence;
end;

```

2.2 入出力の関係を表す合成写像と再帰的定義

前節で述べたように本稿では各層をベクトル値を入出力する有限次元ベクトル空間上の写像とみなし, (1) 式の写像の有限列によってニューラルネットワークを表現する. それらを直列に合成した (3) 式の写像

$$N_n \circ N_{n-1} \circ \dots \circ N_2 \circ N_1$$

が階層型ニューラルネットワークの入出力の関係を表す写像であり, k_1 次元実数ベクトル空間 \mathbf{R}^{k_1} から k_{n+1} 次元実数ベクトル空間 $\mathbf{R}^{k_{n+1}}$ への写像である. この合成写像の定義を形式化するには, 以下のように逐次構成される写像の有限列 $\{p_i\}_{1 \leq i \leq n}$ を用いる.

$$\begin{aligned}
p_1 &= N_1 \\
p_2 &= N_2 \circ p_1 \\
p_3 &= N_3 \circ p_2 \\
&\vdots \\
p_n &= N_n \circ p_{n-1}
\end{aligned} \tag{4}$$

これを使って記述したものが以下 **NEURONS1 : def 3** である.

Listing 3. NEURONS1:def 3

```

definition
let n be Nat,
    k be FinSequence of NAT,
    N be FinSequence;
assume N is Multilayer_perceptron_with k,n;
assume len N <> 0;
func OutPutFunc(N,k,n)
  -> Function of REAL-NS (k.1), REAL-NS (k.(n+1))
  means
  :: NEURONS1:def 3

ex p be FinSequence
  st
  len p = len N & p.1 = N.1
  & ( for i be Nat st 1 <= i & i < len N holds
    ex NN be Function of REAL-NS (k.(i+1)),REAL-NS (k.(i+2)),
    pp be Function of REAL-NS (k.1),REAL-NS (k.(i+1))
    st NN=N.(i+1) & pp =p.i & p.(i+1) = NN*pp )
  & it = p.(len N) ;
end;

```

上記は任意に与えられた自然数 n , 自然数の有限列 k と長さ n の写像の有限列 N で **NEURONS1 : def 1** で定義された述語 **N is Multilayer_perceptron_with k, n** が成り立つもの, すなわち, 階層型ニューラルネットワークを構成するものについて上記の合成による写像を以下のように引数 N, k, n をもった **Functor OutPutFunc(N, k, n)** で定義している. この **Functor OutPutFunc(N, k, n)** の定義の正当性 (与えられた N, k, n について定義の条件を満たす \mathbf{R}^{k_1} からへの写像が一意に存在すること) の証明には (4) 式で定義される写像の有限列 $\{p_i\}_{1 \leq i \leq n}$ の一意存在を証明すればよい. 以下にその方法を証明の記述一部を抜粋しながら説明する.

有限列 $\{p_i\}_{1 \leq i \leq n}$ の存在を証明するには再帰的定義を利用する.

MML では再帰的定義は公理図式 (scheme) として **RECDEF_1** などに収録されている. 本稿の形式化では以下を用いている.

Listing 4. RECDEF_1:sch 4

```

scheme :: RECDEF_1:sch 4
  FinRecExD{D() -> non empty set,A() -> Element of D(), N() -> Nat,
    P[object,object,object]}:
ex p being FinSequence of D() st len p = N() & (p.1 = A() or N() = 0) &
  for n st 1 <= n & n < N() holds P[n,p.n,p.(n+1)]
provided
for n being Nat st 1 <= n & n < N() for x being Element
of D() ex y being Element of D() st P[n,x,y];

```

上記の scheme **RECDEF_1 : sch 4** では, 空でない集合 D の要素の有限列 $\{p_i\}_{1 \leq i \leq n}$ の再帰的構成手続きが書かれている. これを本稿の有限列 $\{p_i\}_{1 \leq i \leq n}$ に当てはめるには, の各要素 p_i が写像であることから各 p_i を全て含む何らかの写像の集合を導入する必要がある. しかしながら (1) 式に示したように

$$N_i : x \in \mathbf{R}^{k_i} \mapsto N_i(x) \in \mathbf{R}^{k_{i+1}} \quad 1 \leq i \leq n$$

各 N_i の定義域, 値域は $\mathbf{R}^{k_i}, \mathbf{R}^{k_{i+1}}$ であり, 各 N_i に共通の定義域, 値域ではない. こ

のため先ず $\{\mathbf{R}^{k_i}\}_{1 \leq i \leq n}$ の合併集合

$$X = \bigcup_{i=1}^{i=n} \mathbf{R}^{k_i}$$

を導入し, 各 N_i の定義域, 値域が全てこの合併集合 X の部分集合になっている X の中から X の中への部分関数全部の集合 $\mathbf{PFuncs}(X, X)$ を用いる. この $\mathbf{PFuncs}(X, X)$ は **PARTFUN1 : def 3** に以下のように定義されている.

Listing 5. PARTFUN1: def 3

```

definition
  let X, Y;
  func PFuncs(X, Y) -> set means
  :: PARTFUN1: def 3
  x in it iff ex f being Function st x = f & dom f c= X & rng f c= Y;
end;

```

この X と $\mathbf{PFuncs}(X, X)$ を用いて式 (4) の漸化式を表す述語を記述しているのが以下の部分である.

Listing 6. PFuncs

```

set
X0 = { the carrier of REAL-NS (k.i)
       where i is Nat : 1 <= i & i <= len N + 1 };

1 <= 1 & 1 <= len N + 1 by NAT.1:11;
then
the carrier of REAL-NS (k.1) in X0 ;
then
reconsider X = union X0 as non empty set by TARSKI: def 4;

defpred P1[ Nat , object , object ]
means
ex pp be PartFunc of X, X,
  NN be Function of REAL-NS (k.($1+1)), REAL-NS (k.($1+2))
st pp = $2 & NN = N.($1+1) & $3 = NN * pp;

```

さらに **schemeRECDEF_1 : sch 4** を適用するために以下の補題を証明した.

Listing 7. Lemma A3

```

A3: for i being Nat st 1 <= i & i < len N holds
  for x being Element of PFuncs(X, X)
  ex y being Element of PFuncs(X, X) st P1[i, x, y]

```

この補題 A3 と **schemeRECDEF_1 : sch 4** を用いて式 (4) で定義した写像の有限列 $\{p_i\}_{1 \leq i \leq n}$ を導入した記述が以下の部分である.

Listing 8. Lemma A16

```

consider p being FinSequence of PFuncs(X, X)
such that
A14: len p = len N
and
A15: p.1 = N1 or len N = 0
and
A16:
  for i being Nat st 1 <= i & i < len N holds P1[i, p . i, p . (i + 1)]
from RECDEF_1: sch 4(A3);

```

このようにして導入した写像の有限列 $\{p_i\}_{1 \leq i \leq n}$ の一意性については MML に収録されている公理図式 (scheme) **RECDEF_1 : sch7** を用いている.

Listing 9. RECDEF_1:sch 7

```

scheme :: RECDEF_1:sch 7
  FinRecUn{A() -> object, N() -> Nat, F,G() -> FinSequence,
    P[object,object,object]}:
  F() = G()
provided
  for n st 1 <= n & n < N() for x,y1,y2 being set st P[n,x,y1] & P[n,x
,y2] holds y1 = y2 and
  len F() = N() & (F().1 = A() or N() = 0) & for n st 1 <= n & n < N()
holds P[n,F().n,F().(n+1)] and
  len G() = N() & (G().1 = A() or N() = 0) & for n st 1 <= n & n < N()
holds P[n,G().n,G().(n+1)];

```

この scheme は漸化式による有限列の構成手続きについて初期値が同じであれば構成された有限列も同じであることを帰納法によって示すものである. この scheme を使って式 (4) で定義した写像の有限列 $\{p_i\}_{1 \leq i \leq n}$ の一意性を示した記述が以下である.

Listing 10. Uniqueness

```

defpred P1[Nat,object,object]
means
  ex NN be Function of REAL-NS (k.($1+1)),REAL-NS (k.($1+2)),
  pp be Function of REAL-NS (k.1),REAL-NS (k.($1+1))
  st NN=N.($1+1) & pp=$2 & $3 = NN*pp ;

A34: len p1 = len N & (p1.1 = N.1 or len N = 0)
  & for i be Nat st 1 <= i & i < len N holds P1[i,p1.i,p1.(i+1)] by A32;

A35: len p2 = len N & (p2.1 = N.1 or len N = 0)
  & for i be Nat st 1 <= i & i < len N
  holds P1[i,p2.i,p2.(i+1)] by A33;

A36: for i being Nat st 1 <= i & i < len N holds
for x, y1, y2 being set st P1[i,x,y1] & P1[i,x,y2] holds y1 = y2 ;
p1=p2 from RECDEF_1:sch 7(A36,A34,A35);
hence F1=F2 by A32,A33;

```

3 階層型ニューラルネットワークの集合

前章で各層をベクトル値を入出力する関数とみなし,(1) 式

$$N_i : x \in \mathbf{R}^{k_i} \mapsto N_i(x) \in \mathbf{R}^{k_{i+1}} \quad 1 \leq i \leq n$$

の関数の有限列によってニューラルネットワークを形式化した. それらを直列に合成した (3) 式の写像

$$N_n \circ N_{n-1} \circ \cdots \circ N_2 \circ N_1$$

が階層型ニューラルネットワークの入出力の関係を表す写像であり, k_1 次元実数ベクトル空間 \mathbf{R}^{k_1} から k_{n+1} 次元実数ベクトル空間 $\mathbf{R}^{k_{n+1}}$ への写像である. 以下のように, 自然数 n と自然数の有限列 k に対して, 定義 **NEURONS1 : def 1** の条件

N is_Multilayer_perceptron_with k, n を満たす階層型ニューラルネットワークにつ

いて **NEURONS1 : def 3** で定義された階層型ニューラルネットワークの入出力の関係を表す写像 **OutPutFunc(N, k, n)** の全部の集合 **NEURONS(n, k)** を以下のように定義した.

Listing 11. NEURONS

```

definition
let n be Nat,
      k be FinSequence of NAT;
func
  NEURONS(n,k)  $\rightarrow$  Subset of
  Funcs(the carrier of REAL-NS (k.1),the carrier of REAL-NS (k.(n+1)))
equals
  :: NEURONS1:def 4

{ F where F is Function of REAL-NS (k.1),REAL-NS (k.(n+1))
  : ex N be FinSequence
  st N is Multilayer_perceptron_with k,n
  & F = OutPutFunc(N,k,n) };
end;

```

次節でこの **NEURONS(n, k)** の部分集合に前回報告した Ascoli-Arzelá の定理を適用する.

4 有限次元空間における写像の集合についての Ascoli-Arzelá の定理

筆者らは, 前回, 以下の形式化した Ascoli-Arzelá の定理を報告した.

Listing 12. ASCORI:19

```

theorem :: ASCORI:19
for M be non empty MetrSpace,S be non empty compact TopSpace,
T be NormedLinearTopSpace,
F be non empty Subset of
  R_NormSpace_of_ContinuousFunctions(S,T),
  G be Subset of Funcs(the carrier of M, the carrier of T)
st S = TopSpaceMetr(M) & T is complete & G = F
holds
  Cl(F) is compact
iff
  ( for x be Point of M holds G is equicontinuous_at x )
&
for x be Point of S,
  Fx be non empty Subset of (MetricSpaceNorm T)
  st Fx = {f.x where f is Function of S,T :f in F }
holds
  (MetricSpaceNorm T) | Cl(Fx) is compact;

```

上記の定理で写像の値域 **T** が有限次元空間の場合は有界閉集合は compact 集合になるため, 以下のように簡潔な命題になる.

Listing 13. NEURONS1:27

```

theorem :: NEURONS1:27
for M be non empty MetrSpace,S be non empty compact TopSpace,
T be NormedLinearTopSpace
st S = TopSpaceMetr(M) & T is complete & T is finite-dimensional

```

```

& dim (T) <> 0
holds
for G be Subset of Funcs(the carrier of M, the carrier of T),
  H be non empty Subset of
    (MetricSpaceNorm R_NormSpace_of_ContinuousFunctions(S,T))
st G = H
holds
  Cl(H) is sequentially_compact
iff
  G is equibounded & G is equicontinuous;

```

前章で形式化した、自然数 n と自然数の有限列 $\{k_i\}_{1 \leq i \leq n+1}$ に対して、定義 **NEURONS1 : def 1** の条件 **N is_Multilayer_perceptron_with k, n** を満たす写像の有限列 $\{N_i\}_{1 \leq i \leq n}$ について以下の条件を課す。

Listing 14. LayerFunc

```

definition
let X,Y be RealNormSpace ;
let F be Function of X,Y ;
let D,K be Real ;
pred F is_LayerFunc D,K means
:: NEURONS1: def 5
  ( for x,y be Point of X holds ||.F.x-F.y.|| <= D*||.x-y.|| )
  &
  ( for x be Point of X holds ||.F.x.|| <= K );
end;

definition
let n be Nat;
let k be FinSequence of NAT;
let D,K be Real ;
let N be FinSequence;
pred N is_LayerFunc_Seq D,K,k,n
means
:: NEURONS1: def 6
  len N = n
  & N is_Multilayer_perceptron_with k,n
  & for i be Nat st 1<=i & i < len k
    holds
      ex Ni be Function of REAL-NS (k.i),REAL-NS (k.(i+1))
        st N.i = Ni & Ni is_LayerFunc D,K;
end;

```

NEURONS1 : def 5 は、前述の Ascoli-Arzelá の定理の同程度有界性 equibounded と同程度連続性 equicontinuous に対応する。 **NEURONS1 : def 6** は $\{N_i\}_{1 \leq i \leq n}$ の各層を表す写像がその条件を満たすことを表している。(1) 式のニューラルネットワークを構成する各写像 N_i は具体的には、例えば、 $x = (x_1, x_2, \dots, x_{k_i}) \in \mathbf{R}^{k_i}$ に対して

$$N_i(x) = (y_1, y_2, \dots, y_{k_{i+1}}) \in \mathbf{R}^{k_{i+1}} \quad (5)$$

$$y_j = \rho_a \left(\sum_{h=1}^{k_i} a_{j,h} \cdot x_{k_h} - \theta \right) \quad 1 \leq j \leq k_{i+1} \quad (6)$$

という形をしている。ここで ρ_a はシグモイド関数と呼ばれ、

$$\rho_a(x) = \frac{1}{1 + e^{-ax}} \quad (7)$$

などである。 a はシグモイド関数 ρ_a の傾斜の最大値を決めるパラメータである。

$$\{a_{j,h}\}_{1 \leq j \leq k_{i+1}, 1 \leq h \leq k_i}$$

は第 i 層から第 $i+1$ 層への結合係数と呼ばれる。

(7) 式のシグモイド関数はリプシッツ連続かつ有界であり、対象とするニューラルネットワーク全てのシグモイド関数 ρ_a のパラメータ a や結合係数 $a_{i,j}$ の絶対値に上限が存在すれば、条件 **NEURONS1** : **def 5 NEURONS1** : **def 6** は満たされる。

本稿ではこのような各写像 N_i の具体的な形には立ち入らず、一般的な連続写像の場合について議論する。

これらの条件のもとに、**NEURONS**(n, k) の部分集合に Ascoli-Arzelá の定理を適用すると以下の命題が得られる。

Listing 15. NEURONS1:35

```

theorem :: NEURONS1:35
for n be Nat,
   k be FinSequence of NAT,
   S be non empty compact strict TopSpace,
   X be non empty Subset of (REAL-NS (k.1)),
   T be NormedLinearTopSpace
st
  S is SubSpace of (TopSpaceNorm (REAL-NS (k.1)))
  & the carrier of S = X
  & X is compact
  & T is complete & T is finite-dimensional
  & dim (T) <> 0
  & REAL-NS (k.(n+1)) = the NORMSTR of T
holds
for G be non empty Subset of R_NormSpace_of_ContinuousFunctions(S,T),
   D,K be Real
st
  0 < D & 0 < K
  &
  G c= { F|X where F is Function of REAL-NS (k.1),REAL-NS (k.(n+1))
        : ex N be non empty FinSequence
          st N is_LayerFunc_Seq D,K,k,n
            & F = OutPutFunc(N,k,n) }
holds
  Cl(G) is compact;

```

以上のように、ニューラルネットワークの各層 N_i に条件を課すことを前提にニューラルネットワークを表現する連続写像の集合 **NEURONS**(n, k) の閉部分集合が compact 集合であることが示される。これは、**NEURONS**(n, k) に属するニューラルネットワークに何らかの性能評価が与えられ、それがこの **NEURONS**(n, k) の部分集合上の実数値連続関数の場合、その評価関数の最大 (最小) 値とそれを与えるニューラルネットワークの存在を保証する。また、この部分集合内で結合係数の学習など何らかの逐次アルゴリズムで、この部分集合内の元の無限列が生成されるときに、その無限列の集積点の存在を保証する。このような意味で、上記の compact 性は有用な性質である。

5 まとめ

本稿では階層型ニューラルネットワークの形式化について報告した。ニューラルネットワークの入出力及び中間各層をベクトル値を入出力する有限次元ベクトル空間上の写像とみなし、それらの複数の写像の有限列によってニューラルネットワークを表現した。このニューラルネットワークによる入出力の関係は、それを定義する写像の有限列全部の合

成写像として表現される。前回報告した Ascoli-Arzelá の定理について写像の値域が有限次元空間の場合の命題を形式化し、ニューラルネットワークの入出力の関係を表す写像全部の集合についての compact 性に関する命題を形式化した。しかしながら、現時点の形式化は各層を表す写像についての具体的な形、例えば、結合係数やシグモイド関数などについての考察までには至っていない。Funahashi [7] が既に証明しているニューラルネットワークによる非線形関数の近似可能性定理などもまだ、形式化がなされていない。さらには、最近話題となっている Deep Learning について何故、中間層を増やすことによって、学習精度が向上するのかという重要な課題についてもその課題の形式化にも至っておらず、今後さらに形式化の研究が必要である。これらの形式化に興味を持たれた読者の積極的な参加を歓迎する。

参考文献

- [1] Rosenblatt F. The Perceptron: A Probabilistic Model for Information Storage and Organization in the Brain. *Psychological Review*. 1958;65(6):386–408.
- [2] Rumelhart DE, Hinton GE, Williams RJ. Learning representations by back-propagating errors. *Nature*. 1986;323(6088):533–536.
- [3] Schmidhuber J. Deep Learning in Neural Networks: An Overview. *Neural Networks*. 2015;323(61):85–117.
- [4] Sprecher D. On the structure of continuous functions of several variables. *Translations of American Mathematical Society*. 1965;(115):340–355.
- [5] Hecht-Neilsen R. Kolmogorov mapping neural network existence theorem. In: *IEEE First International Conference on Neural Networks*. 3; 1987. p. 11–13.
- [6] Kolmogorov A. On the representation of continuous function of many variables by superposition of continuous function of one variable and addition. *Doklady Akadmeii Nauk SSSR*. 1957;(144):679–681.
- [7] Funahashi K. On the approximate realization of continuous mappings by neural networks. *Neural Networks*. 1989;(2):183–192.
- [8] Irie B, Miyake S. Capability of three-layered perceptron. In: *IEEE International Conference on Neural Networks*. 1; 1988. p. 641–648.
- [9] Hryniewiecki K. Graphs. *Formalized Mathematics*. 1991;2(3):365–370. Available from: http://fm.mizar.org/1991-2/pdf2-3/graph_1.pdf.
- [10] Nakamura Y, Rudnicki P. Vertex Sequences Induced by Chains. *Formalized Mathematics*. 1996;5(3):297–304. Available from: http://fm.mizar.org/1996-5/pdf5-3/graph_2.pdf.
- [11] Nakamura Y, Rudnicki P. Euler Circuits and Paths. *Formalized Mathematics*. 1997;6(3):417–425. Available from: http://fm.mizar.org/1997-6/pdf6-3/graph_3.pdf.

- [12] Nakamura Y, Rudnicki P. Oriented Chains. Formalized Mathematics. 1998;7(2):189–192. Available from: http://fm.mizar.org/1998-7/pdf7-2/graph_4.pdf.
- [13] Chen JC, Nakamura Y. The Underlying Principle of Dijkstra’s Shortest Path Algorithm. Formalized Mathematics. 2003;11(2):143–152. Available from: http://fm.mizar.org/2003-11/pdf11-2/graph_5.pdf.
- [14] Endou N, Shidama Y. Completeness of the Real Euclidean Space. Formalized Mathematics. 2005;13(4):577–580. Available from: http://fm.mizar.org/2005-13/pdf13-4/real_ns1.pdf.

Mizar article information

Works in Progress

COSP3 $C(\Omega)$ space and $C_0(\Omega)$ space

by Hiroshi Yamazaki and Yasunari Shidama

Summary: In this article, first we give a definition of a functional space which is constructed from all continuous functions defined on a compact topological space. We prove that this functional space is a Banach space. Next, we give a definition of a function space which is constructed from all continuous functions with bounded support. We also prove that this function space is a normed space.

ASCORI Ascoli – Arzela’s theorem

by Hiroshi Yamazaki and Yasunari Shidama

Summary: In this article, the Ascoli-Arzela’s theorem is formalized. First, we gave definitions of equicontinuousness and equiboundedness of a set of continuous functions. Next, we formalized the Ascoli-Arzela’s theorem by those definitions, and proved this theorem.

NERONS1 Formalizations for Multilayer perceptron

by Hiroshi Yamazaki and Yasunari Shidama

Summary:

In this article, the hierarchical neural networks (Multilayer perceptron) is formalized by finite sequence of mappings. The input-output map of the this neural network is represented as a composite map of this finite sequence. The compactness of the set of these composite map is proved by applying Ascoli-Arzela’s theorem.