自己組織化マップの特性を利用した降雨予測

RAINFALL PREDICTION BASED ON SELF-ORGANIZING MAP

西山浩司¹・遠藤伸一²・神野健二³

Koji NISHIYAMA, Shinichi ENDO and Kenji JINNO

¹正会員 理修 九州大学助手 工学研究院(〒812-8581 福岡市東区箱崎6丁目10-1)
 ²学生会員 九州大学大学院工学府都市環境システム工学専攻(〒812-8581 福岡市東区箱崎6丁目10-1)
 ³正会員 工博 九州大学教授 工学研究院(〒812-8581 福岡市東区箱崎6丁目10-1)

In this study, complicated atmospheric patterns in a rainy season (BAIU) were classified into 100 patterns, using the Self-Organizing Map (SOM) algorithm. In addition, rainfall probability exceeding 30mm/6h in Northern Kyushu were predicted using the Artificial Neural Networks (ANNs). Considering high-dimensional complicated atmospheric patterns can be replaced by the location of a node specified in the two-dimensional map, the coordinates (two elements) of the node were used for the learning of ANNs. As a result, using the SOM, nodes characterized by the Low-Level Jet and associated ample water vapor distribution were significantly related to heavy rainfall events. Paying attention to heavy rainfall events, predicted rainfall probabilities using ANNs showed clear-cut relationships between meteorological field pattern and heavy rainfall.

Therefore, it can be expected that the incorporation of the coordinates of a node in the map into ANNs contributes to the down-sizing of the ANNs structure and helps the understanding of input-and-output relationships.

Key Words : Self-Organizing Map (SOM), Artificial Neural Networks, rainfall prediction

1.はじめに

短期予報を対象にした降水予報¹⁾や洪水予測を目的に したダウンスケール降水予測2)は,数値予報モデルの出 力結果から得られる予測因子と観測雨量情報との間の関 連性を構築することによって得られる.その際,精度向 上のためには,雨量情報と因果関係を持つ予測因子を選 択することが重要なことは言うまでもない.この際,一 般に,予測因子には,数値モデルの格子点直上の気象要 素が選ばれることが多い³³⁴. しかし,降水,特に豪雨の 発生は,面的な情報,即ち,総観規模の気象場と密接に 関わっている点⁵⁾を考慮すると,面的な気象場の情報を 降雨予測手法に活用することは有意義である.例えば, 台風による反時計回りの暖湿気流が前線を刺激するパ ターンや梅雨末期の湿舌を伴う下層ジェットなどを如何 に取り込むかということになる.しかし,気象場を構成 するデータ数は膨大であるため、予測因子として、それ らの膨大なデータをそのまま利用することは現実的でな い⁶⁾.よって,複雑な気象場の特徴をパターン化して降 雨予測に活用することが望ましい".

そこで本論文では,最初に梅雨前線の活動とそれに伴う暖湿気流の流入によって特徴付けられる気象場を,自己組織化マップ(SOM: Self-Organizing Map)アルゴリズ

ム⁸によって分類する.SOMは,多次元の複雑なデータの相互関連性を,2次元配列上に視覚的に表現し,分類 することができるアルゴリズムである.次に,SOMの 特性に着目して,分類された気象場パターンを入力して 降水確率を予測するニューラルネットワーク手法につい て述べる.最後に,SOMによって分類された気象場と 雨量情報の間の因果関係が,ニューラルネットワークに よる降雨予測の結果に反映しているか調べる.

2.降雨予測手法の概略

(1) SOMによる気象場の分類手法

本論文では,SOMのノード配列を,図-1に示すよう に,近傍のノード間の位置関係が六角形になるような2 次元配列に設定する.各ノードには,入力ベクトル(学 習サンプル)と同じ次元を持つ参照ベクトルが割り当て られる.この参照ベクトルは,入力ベクトルを使った繰 返し学習によって更新され,最終的には,各ノードに分 類された入力ベクトルの特徴を代表するようになる. よって,参照ベクトルの各要素は,入力ベクトルの対応 する要素と同じ意味を持つ.尚,図-1のノード配列表示 は,学習サンプルの特徴を2次元配列で視覚的に表現し たもので,SOMの議論の際,マップと呼ばれている. SOMアルゴリズムの計算過程は,入力ベクトルの正 規化と参照ベクトルの初期化の後,次のように行われる. まず,入力ベクトルxが与えられると,2次元マップ上の 全てのノードの参照ベクトルmiと比較され,両者のユー クリッド距離 ||x - mi||が最小になるように,入力ベクト ルに最も近い参照ベクトルが取り出される.そのノード cは勝者ノードと呼ばれる.次に,各ノードの参照ベク トルは,次式に従って修正される.

$$\boldsymbol{m}_{i}(t+1) = \boldsymbol{m}_{i}(t) + \boldsymbol{h}_{ci}\left(\boldsymbol{t}_{e}, \left\|\boldsymbol{r}_{c} - \boldsymbol{r}_{i}\right\|\right) \left[\boldsymbol{x}(t) - \boldsymbol{m}_{i}(t)\right]$$
(1)

ここに、tは学習ステップ、t_eldepoch数(全サンプル1回 分の学習を1 epochと呼ぶ)、 r_c 、 r_i は、それぞれ勝者 ノードとノードiの位置ベクトルを示す、 h_{ci} は近傍関数 と呼ばれ、1 epoch分の学習の間は、一定の値が与えられ る、参照ベクトルは、(2)式のガウス分布に従って、勝者 ノードに近いノードほど強く修正され、勝者ノードから の距離が近傍半径 $\sigma(t_e)$ 以内に含まれるノードのみ修正し、 それよりも遠いノードは修正しないようにする、

$$h_{ci}(t_{e}, \|\mathbf{r}_{e} - \mathbf{r}_{i}\|) = \alpha(t_{e}) \cdot exp\left(-\frac{\|\mathbf{r}_{e} - \mathbf{r}_{i}\|^{2}}{2\sigma^{2}(t_{e})}\right) \quad (\|\mathbf{r}_{e} - \mathbf{r}_{i}\| \le \sigma(t_{e}))$$

$$h_{ci}(t_{e}, \|\mathbf{r}_{e} - \mathbf{r}_{i}\|) = 0.0 \quad (\|\mathbf{r}_{e} - \mathbf{r}_{i}\| > \sigma(t_{e})) \quad (2)$$

学習率α(t_e)と近傍半径σ(t_e)は,epoch数の増加に従って小 さくなるように(3)式で設定し,それぞれ0.01と1.1を下回 れば,それらの値に固定する.即ち,修正の程度は,学 習回数とともに小さくなる.同時に修正範囲も小さくな り,最終的には,勝者ノードとその最近傍ノードのみ修 正する.

$$\alpha(t_e) = max \left\{ \alpha(0) \frac{T_e - t_e + 1}{T_e}, \quad 0.01 \right\}$$

$$\sigma(t_e) = max \left\{ \sigma(0) \frac{T_e - t_e + 1}{T_e}, \quad 1.1 \right\}$$
(3)

尚,初期の学習率と近傍半径をそれぞれ0.2と5に設定し, T_e は100とする.この一連の操作(式(1)から(3)) は,500 epoch分繰り返される.また,マップの大きさを 10×10 に設定する.その学習の結果,本論文で扱う気象 場のパターンが,100種類に分類され,マップ上のいず れかのノードに割り当てられる.

本論文では,梅雨期における気象場のパターンを表現 するために,可降水量(PW)及び850hPa面の風速成分 (2成分)の3要素を選ぶ.これらの要素は,東アジア域 の気象庁領域客観解析データのGPV(1日2回)から抽出 され,1996年から98年までの6,7月の366サンプルが用 いられる.その対象領域は,図-2のように,北部九州を 中心に9個の領域からなる.ここで,各領域の緯度経度 幅を2度に設定し,領域ごとに各要素の領域平均値が計 算される.以上の設定に基づき,入力ベクトルは,9領 域3要素の合計27次元から構成され,学習サンプルから 得られる最大値と最小値を用いて正規化された量で表現 する.その並びは,可降水量(*PW*),風の東西成分 (*U*),南北成分(*V*)の順で次式のように表す.

$$\boldsymbol{x} = (PW_1 \cdots PW_g \ U_1 \cdots U_g \ V_1 \cdots V_g) \tag{4}$$

尚,添え字の番号は,図-2 に示すように対象領域内の 各領域の番号を示す.



図-1 SOM の2次元ノード配列



図-2 気象場を表現するための対象領域.中央の太い四角は雨 量を抽出するための領域.

(2) ニューラルネットワークモデルの構築

本論文では,気象場パターンを入力して,降水確率を 求めるニューラルネットワークモデルを構築する.まず, SOMの性質を利用した入力要素の選択について述べる. 前節で述べたように,27次元で表現した気象場は, SOMの学習の結果,100パターンに分類され,2次元上 の各ノードに分配される.ここで着目すべきことは,各 ノードの位置が重要な意味を持っている点である.即ち, 学習の結果,位置的に近いノード群は互いに類似した特 徴を持ち,反対に遠いノードどうしは,互いに異なった



図-3 各ノードの数値と灰色の丸の大きさは,6時間に30mmの雨量を超えるイベント数を表している.括弧は各ノードに 分類された気象場の数を示す.マップの周辺に,いくつかの気象場の特徴を示す参照ベクトルを示した.AとBは,梅雨 期の豪雨時に特有の気象場のグループを示している.

性質を持つように組織化される.ノードの位置の違いが, 気象場のパターンの違いを反映している.この性質を利 用すると,ノードを特徴付ける気象場のパターンを, SOMのノードの座標に置き換えて考えることができる. そこで,100パターンからなる2次元のノード座標値(X_i, Y_i)を学習のための入力要素として選択する.

次に,教師データについて述べる.最初に,図-2の太 い四角で囲まれる対象領域内(福岡近傍のGPV点を中心 にして緯度経度1度幅)で,GPVの設定時間(9時,21 時)から6時間雨量(レーダアメダス解析雨量)を計算 し,領域内最大の6時間雨量を取り出す.次に,その雨 量が30mm以上を示した場合に1を,そうでない場合に0と して,教師データに与える.よって,ニューラルネット ワークで出力される値は,{0,1}の範囲内で,6時間に 30mmの雨量を超える降水確率を表す.

本論文では,入力層・中間層・出力層の3層からなる Feed-Forward型ニューラルネットワークを採用する.入 力層には2個のノードが配置され,SOMの座標が与えら れる.中間層には8個のノードを配置する.出力層の ノードは1個で,教師データとしての雨量情報(0または 1)が与えられる.尚,入力・教師データは{0,1}の範囲 で正規化される.この結合形式では,入力層から中間層,

及び中間層から出力層への結合の重みは合計で24個,中 間層と出力層の各ノードに合計9個のバイアスが与えら れる. それらの重みとバイアスは, Back-Propagation手法 による学習に従って決定される.学習率とモーメンタム は0.2,初期の重みとバイアスの値は,一様乱数を発生 させて, {-0.5, 0.5}の範囲で与えられる.非線形性を表 現するため,中間層と出力層の各ノードへの出力関数に は,シグモイド関数が採用される.以上の設定に従って, 学習回数が進むと誤差(出力値と教師データとの間の RMSE) が小さくなるが, 重みとバイアスの数の合計に 対する学習サンプル数の比が30倍以下の場合,ノイズま で学習して過適合 (Overfitting)を引き起こすことがあ る⁹⁾.そこで,学習に利用しないテストサンプルを入力 して,学習ステップごとのRMSEを求め,その値が最小 になる学習ステップを探索する(Cross-Validation手法). また,初期の重みとバイアスの組み合わせによっては, 局所解に陥り,良好な結果を与えない場合もあるので, その組み合わせを100通り発生させ, Cross-Validation手 法によって得られたテストサンプルのRMSEの中(100 通り)から最小のケースを選ぶ.尚,全サンプルから学 習及びテストサンプルを分割する際には,両者の間の特 性に偏りがないことが望ましいので, SOMの性質を活

表-1 グループAとBに属するノードに分類されたイベントとそれに対する雨量を示す.TEはテストサンプルに割り当て られたことを示している.日付の中の括弧は9時または21時を示す.

NODE	DATE	mm/6h	NODE	DATE	mm/6h	NODE	DATE	mm/6h
59 (A)	19960610(21)	12	79 (A)	19960619(21)	136	10 (B)	19970706(09)	25
60 (A)	19960628(09)	58	79 (A)(TE)	19970710(21)	9	10 (B)	19970706(21)	60
60 (A)	19970702(09)	67	80 (A)	19960624(09)	67	10 (B)(TE)	19970711(21)	58
60 (A)	19970702(21)	22	80 (A)	19970707(09)	110	10 (B)	19980625(21)	63
60 (A)	19970716(21)	155	80 (A)	19970707(21)	49	10 (B)	19980626(09)	75
60 (A)(TE)	19980701(21)	84	80 (A)	19970708(09)	80	20 (B)(TE)	19960617(21)	83
69 (A)(TE)	19960617(09)	37	80 (A)	19970708(21)	78	20 (B)	19960624(21)	96
69 (A)	19960620(09)	57	80 (A)	19970709(09)	52	20 (B)	19960625(09)	51
69 (A)	19960620(21)	70	80 (A)	19970709(21)	78	20 (B)	19960627(21)	21
69 (A)	19960621(09)	21	80 (A)	19970710(09)	118	20 (B)	19960629(21)	74
70 (A)	19960625(21)	80	80 (A)(TE)	19970711(09)	87	20 (B)	19960704(21)	30
70 (A)	19970712(09)	51	80 (A)	19980619(09)	153	20 (B)(TE)	19980626(21)	21
70 (A)(TE)	19970712(21)	50	90 (A)	19980621(09)	36	20 (B)	19980701(09)	45
79 (A)	19960608(09)	26	10 (B)	19970701(21)	65			

用する.前節の結果,366個の全サンプルは,100個のN ずれかのノードに分類される.各ノードに特徴が類似し たサンプルが集まっていることを考慮して,各ノードに 割り当てられたサンプルを学習用とテスト用に分割する ¹⁰⁾.この際,各ノードのサンプルを,0または1の雨量情 報(教師データ)に対応するグループに分割し,それぞ れのグループ(2個以上サンプルがある場合)から少な くとも1つを無作為抽出して,テストサンプルに割り当 てる.それ以外は全て学習サンプルに割り当てる.その 結果,学習及びテスト用に対し,それぞれ275個,91個 のサンプルが割り当てられた.

3.気象場パターンの分類

本章では,前章の手続きに従って分類された梅雨期の 気象場のパターンとそれに対する雨量との関連性につい て考察する.その結果を図-3に示す.マップの周辺に, いくつかのパターン(ノードの特徴を示す参照ベクト ル)を選んで図示した.豪雨時によく現れる特有のパ ターンは,マップの右端全体に認められ,下層ジェット と湿舌によって特徴づけられる.その他,上端右側の領 域(例:NODE98)に,北部九州(対象領域の中心)の 北西領域の低気圧循環のパターンが認められる.下端中 央部(例:NODE6)には,太平洋高気圧の影響を受け た循環が認められる.マップ中央部(例:NODE45)は, 梅雨前線が南部九州に存在するパターンを示している. マップの左中央部(例:NODE41)と左上方は,乾燥し た気象場を示している.

ここで,マップ右側の豪雨時に現れるパターンに着目 して,雨量との関連性を調べる.6時間で30mmを超える 雨量を示した頻度を見ると,2つのグループA,Bが存在 することがわかる.それらのグループでは,表-1に示さ れるように,大きな雨量を示しており,100mm/6hを超 える豪雨も多く含まれる、どちらのグループも、下層 ジェットと湿舌によって特徴付けられるパターンである が、その軸の位置に違いがある、グループAの特徴とし て,北部九州から南部九州にかけて,下層ジェットと湿 舌の軸があり,その北側では,乾燥空気の影響が認めら れる.そのため,北部九州付近は梅雨前線帯に位置し, 多量の降雨を示すイベントが集中したと考えられる.こ こで最も特徴的なことは,NODE80に分類されたイベン ト(10イベント)の全てが6時間で30mmを超える雨量を 示し,100mm/6hを超えるイベントも3例あったことであ る.さらに興味深いことに,1997年7月7日から11日にか けて南部九州の出水を襲った豪雨と土石流に関して, 表-1でも確認できるように,同時期のイベントが NODE80に含まれていた.その意味で,NODE80は,豪 雨と密接に関連したノードであると考えられる.一方, Bでは,下層ジェットと湿舌のパターンが北部九州より 北西側に位置している.この場合も,太平洋高気圧の周 辺部に沿って湿った空気が流入しやすく、大気が不安定 になったため多量の降雨がもたらされたと考えられる.

4.予測結果の考察



図-4 各ノードの座標を入力して得られた降水確率 (%)とそのコンターライン(40%から10%刻み).



図-5 検証用サンプルを適用して得られた判定結 果.図中の詳細は図-3と同じ.

本章では,2章の手続きに従って構築された降水確率 の予測手法を,検証用サンプルに適用して予測結果を示 し,前章で述べた気象場のパターンと雨量との因果関係 が,予測結果に反映されているかどうかを検証する.

最初に,本論文で扱った予測手法についての特徴につ いて述べる.2章で扱ったように,SOMのノードを特徴 付ける100種類のパターンが,100個のノードの2次元座 標値(X,Y)によって表現できると考え,それをニューラ ルネットワークの学習のための入力要素とした.よって, 予測の段階では,気象場が提示されたら,その入力ベク トルを,学習後のSOMに入力して,その気象場が,ど のノードに属するか判定される.その際,ノードは100 個しかないので,そのいずれかに判定されることになる. 次に,判定されたノードの座標値を,完成したニューラ ルネットワークモデルに入力して,6時間で30mmの雨量 を超える降水確率を求める.この際,判定された座標値 も100個の中のいずれかの値を示すので,結局,降水確 率も100個になることがわかる. 表-2 検証用のサンプルを使って,グループAとBに属 するノードに判定されたイベントに対する雨量と降水確 率を示す.表中の詳細は表-1と同じ.

DATE	mm/6h	NODE	確率(%)
19990617(09)	44	60 (A)	64
19990624(09)	175	69 (A)	60
19990624(21)	105	69 (A)	60
19990617(21)	39	70 (A)	86
19990702(21)	76	70 (A)	86
19990606(21)	147	79 (A)	78
19990626(21)	73	80 (A)	93
19990623(09)	41	90 (A)	55
19990629(09)	186	90 (A)	55
19990702(09)	116	10 (B)	67
19990729(09)	145	10 (B)	67
19990729(21)	20	10 (B)	67
19990616(21)	21	20 (B)	59
19990623(21)	53	20 (B)	59



図-6 1999年6月26日21時の気象場.図中のコンター ラインは可降水量を示し,40mmから10mm刻みで示 される.図中の格子は図-2と同じ.

そこで,SOM上の100個のノード座標値を入力して得られた降水確率を図-4に示し,前章の分類結果(図-3,表-1)と比較する.豪雨時によく現れる特有の気象場パターンを示すグループA,Bに着目すると,6時間で30mmを超える雨量のイベント数(テストサンプルを除く)は,Aで22例中18,Bで11例中9もあり,ともに81%の高い頻度を示す.その結果,両グループに属するノードの多くが,60%を超えるような比較的大きな降水確率を示したと考えられる.特に,NODE80では,ニューラルネットワークの学習段階で,学習に用いられた全てのイベント(9例)が,6時間で30mmを超えていたため,93%という高い降水確率を与えたと考えられる.よって,

ニューラルネットワークの学習は, SOMで分類された 梅雨期特有の気象場のパターンと強い雨量との因果関係 を十分に反映していると考えられる.

次に,検証用のサンプルを用いて,上記の因果関係が 反映するかどうかを検証する. 1999年6,7月の118個の 気象場を検証サンプルとして使用した.まず,SOMに よって気象場の判定を行い,その結果をニューラルネッ トワークモデルに入力して降水確率を求めた.SOMに よる判定結果を図-5に示し,グループA,Bの中のノー ドに判定されたイベントの雨量と降水確率を表-2に示す. その結果,6時間で30mmの雨量を超えるイベントの多く が,降水確率の大きいグループA,Bに含まれるノード に属すると判定された.そのイベント数は,Aで9例中 全イベント,Bで5例中3イベントと高い頻度を示す (図-5).また,100mm/6hを超えるイベントが,両グ ループ合計で14例中6例もあったことは梅雨期の豪雨の 激しさを示している、以上の考察から、梅雨期特有の気 象場のパターンと強い雨量との因果関係が,検証用のサ ンプルに対しても反映していることを示している.一例 として,NODE80に判定された1999年6月26日21時のイ ベントについて見ると,図-6に示すように,南西から北 東に延びる下層ジェットと湿舌が特徴的である.北部九 州と朝鮮半島の間の対馬海峡付近が,可降水量が急激に 変化している領域で,梅雨前線帯に属していたと考えら れる.そのため,この気象場はNODE80に判定され,結 果的に93%の高い降水確率が与えられた.

5. 結論

本論文では,多次元の複雑な関連性を視覚的に分類す ることを可能にする自己組織化マップ(SOM:Self-Organizing Map)アルゴリズムを用いて,梅雨期の複雑 な気象場を分類した.さらに,SOMの特性に着目して, 分類された気象場パターンを入力して,6時間で30mmの 雨量を超える降水確率を予測するニューラルネットワー ク手法を構築した.

まず,学習用サンプルを利用して,梅雨期の気象場を 分類した.その結果,梅雨期特有で豪雨時に出現する気 象場のパターンは,実際,大きな雨量と密接に関連して いた.この因果関係は,ニューラルネットワークによる 学習にも反映され,豪雨と関連するパターンでは,大き い降水確率を示した.次に,検証用サンプルを予測手法 に適用すると,豪雨時に出現する気象場のパターンと判 定されたイベントの多くは,実際も,30mmを超える大 きな雨量を示していた.よって,梅雨期特有の気象場パ ターンと判定された場合,大雨が起こる降水確率を高く することが期待できる.しかし,各ノードに分類される イベントの数が少ないため,今後はサンプル数を増やし て,SOMによる分類とニューラルネットワークによる 予測の信頼性を向上させる必要がある.

本論文で構築された予測手法では、ノードの位置の違 いが気象場のパターンの違いを反映するというSOMの 特性を考慮して,マップ上のノードの座標(2要素)を, ニューラルネットワークの入力要素とした.この場合, 多次元の気象場が2次元の座標値で表現できたことにな リ,ネットワークの簡素化が実現できた.さらに,ノー ド自体が,気象場のパターンを示すため,入出力の因果 関係が明瞭になった.即ち,予測される出力値(降水確 率)の数は、ノードの数(パターンの数)と同一である ので,パターンごとに降水確率を与えることができ,因 果関係が明瞭になったことを示す.よって,降水確率が 与えられると,どのノードに判定されたのか,それがど の気象場を示すのか,因果関係をフィードバックして考 えることができる.今後は,SOMによる気象場の分類 が予測結果に強く反映されることを考慮して,気象場を 定義する領域の位置・大きさ・解像度,どの気圧面のど の気象要素を扱うべきか,など最適な気象場の選定が最 重要課題になる.

参考文献

- Antolik, M. S. : An overview of the National Weather Service's centralized statistical quantitative precipitation forecasts, *J. Hydrol.*, Vol.239, pp.306-337, 2000.
- 2) Olsson, J., Uvo, C. B, Jinno, K., Kawamura, A., Nishiyama, K., Koreeda, N., Nakashima, T. and Morita, O. : Neural network for rainfall forecasting by atmospheric downscaling, Journal of *Hydrologic Engineering*, Vol.9, No.1, pp. 1-12, 2004.
- Kuligowski, R. J., Barros. A. P. : Localized precipitation forecasts from a numerical weather prediction model using artificial neural network. *Weather and Forecasting*. Vol. 13, pp. 1194-1204, 1998.
- Hall, T., Brooks, H. E., Doswell, C. H. : Precipitation forecasting using neural network. *Weather and Forecasting*. Vol. 14, pp. 338-345, 1999.
- 5) 西山浩司, 遠藤伸一, 神野健二, 河村 明: 自己組織化マッ プを利用した梅雨期特有の気象場の分類, 水工学論文集, 49, pp.241-246, 2005年3月.
- Hsieh, W. W., Tang, B., : Applying neural network models to prediction and data analysis in meteorology and oceanography, *Bull Amer. Meteror. Soc*, Vol. 79, No. 9, pp. 1855-1870, 1998.
- 7) 立平良三:新しい天気予報,東京堂出版,1994.
- Kohonen T., : Self-Organizing Maps, Springer Series in Information Sciences, Vol. 30, 1995.
- 9) Amari, S., Murata, N., Muller, K., Finke, M., Yang, H.: Asymptotic statistical theory of overtraining and cross-validation, *IEEE Transaction on Neural Networks*, Vol. 8, No. 5, pp. 985-996, 1997.
- 10) Bowden, G. J., Mayer, H. R., Dandy, G. C., : Optimal division of data for neural network models in water resources applications, *Water Resources Research*, Vol. 38, No. 2, 2002.

(2005.9.30受付)