

投稿論文
Paper
(In Japanese)

パターン認識概念に基づく月降水量の解析とシミュレーション

ANALYSIS AND SYNTHESIS OF MONTHLY PRECIPITATION DATA BASED ON PATTERN RECOGNITION

宇治橋康行*・高瀬信忠**・家門邦彦***

By Yasuyuki UJIHASHI, Nobutada TAKASE and Kunihiko KAMON

A time series of hydrologic data occurs in well defined groups possessing collective properties of the data. Such a collection of properties can be called a hydrologic pattern. The pattern indicates the inter-relationship between adjacent values within the groups i. e. the persistence. A method of streamflow synthesis based on the concept of pattern recognition was first described by Panu *et al.* The present paper aims at improving Panu's method using the ISODATA algorithm for pattern analysis to adapt to highly variable hydrologic data in Japan. The new model is applied to monthly precipitation data at Kanazawa, Fukui and Toyama in the Hokuriku region.

Keywords : time series analysis, data synthesis, pattern recognition, ISODATA

1. ま え が き

水資源システムは、その耐用年数にわたって十分に機能することが望まれる。したがって、計画・設計に用いられるデータは、過去の観測データだけでなく将来システムが機能する期間内に起こりそうなデータでなければならない。このようなデータは過去の時系列データの解析からシミュレーションによって得られる。Thomas-Fieringの研究以来¹⁾、この分野では多くの研究が行われ、種々のモデルが提案され実用に供されてきた。この間の経緯については、Jackson²⁾、Panuら³⁾によりレビューが行われている。

最近Panuら⁴⁾はHurst⁵⁾やそれ以前から注目されていた水文データ中のグループの存在に着目し、グループを構成するデータの集合的性質を用いてパターン認識概念に基づくシミュレーションモデルを開発し、カナダの月流量時系列のシミュレーションを行い、時系列レベル、月レベルにおいてシミュレートされたデータは観測デー

タのもつ種々の統計量を十分な精度で再現することを報告している。彼らの手法は従来の時系列解析にみられない新しいものであり、その最も大きな特徴は時系列が異なる確率法則に従う複数の確率過程の合成よりなる母集団から生成されるとした点にある。すなわち、水文時系列中に存在する明確なグループ（これを水文パターンとよんだ）、たとえば、高水流量と低水流量あるいは雨期と乾期はそれぞれ異なる確率法則から生成されると考えた。彼らのモデルでは、データに対する何の前処理も確率構造を仮定する必要もない。

本論文では、変動パターンの複雑なわが国の水文データの特徴を考慮して、クラスタリングにISODATAアルゴリズムを用いることによりPanuらのモデルを修正拡張したモデルを提案している。さらに、モデルを北陸地方の3地点の月降水量データに適用し、降水量の変動パターンの解析、データシミュレーションを行ったものである。

2. 水文データ解析とパターン認識

パターン認識、あるいはその一分野である文字認識、音声認識、画像認識等に関しては多くの成書がみられるが^{6),7)}、ここでは水文データ解析との関連においてパターン認識について概説する⁸⁾。はじめに基本的な用語の定

* 正会員 工修 金沢大学助手 工学部土木建設工学科
(〒920 金沢市小立野 2-40-20)

** 正会員 工博 金沢大学教授 工学部土木建設工学科
(同上)

*** 工修 (株)大林組中国電力柳井 LNG タンク JV (研究当時金沢大学大学院工学研究科学生)




Fig.1 Schematic diagram of pattern recognition system.

義について述べる。

パターン認識 (pattern recognition)…対象について観測を行い、さらに、これら観測情報から特徴あるいは重要な属性を抽出し、対象を識別可能なクラスに分類すること。

対象 (object)…われわれが認識分類しようとする物、物理現象および概念等である。水文データの解析においては与えられた全観測系列が対象となるのではなく1年のあるシーズン (後述の金沢の場合では1シーズンの長さが3か月である) に対応する水文時系列の一部。

パターンベクトル (pattern vector)…対象に関して行われた観測 (measurement) の結果得られた n 個の観測値の集合からなる n 次元ベクトル $X=(X_1, X_2, \dots, X_n)$ 。ここではパターンベクトルを単にパターン (pattern) ともいう。具体的には、後述の金沢の月降水量の例では1シーズンが3か月であるのでパターンベクトルは3か月の月降水量を要素にもつ三次元ベクトル、たとえば $X=(247.0, 270.0, 91.0)$ (各要素の単位は mm) のようになる。

特徴、特徴ベクトル (feature, feature vector)…パターンベクトルは対象に関するすべての情報を含んでおり、この中には認識に無意味な情報も含まれている。認識に有効、必要な重要な情報あるいは属性を特徴とよび、特徴を要素にもつ m 次元ベクトル (通常 $m \leq n$) を特徴ベクトルとよび、パターンベクトルの要素から特徴を抽出することを特徴抽出 (feature extraction) という。ただし、本研究の場合では前述のパターンベクトルが必要なすべての情報を含み、かつ、不必要な情報は含まれていないのでパターンベクトルを解析の対象とした。

クラス (class)…類似したパターンどうしがつくる集合。類似度の尺度としては通常距離を用い、互いに近いパターンどうしを集めたもの。パターンクラス (pattern class) ともいう。クラスターも同義に用いる。

標準ベクトル (reference vector)…1つのパターンクラス内のパターンベクトル (特徴ベクトル) を代表するようなパターンである。そのパターンクラスに属するパターンベクトルの標準ベクトルからの隔たりは標準ベクトルの要素のまわりのパターンベクトルの確率分布による。したがって、標準ベクトルは統計的平均の意味でパターンクラス内のパターンを代表する。

パターン認識の一般的な手順は Fig.1 のように表わされよう⁹⁾。

3. パターン認識概念に基づくモデルの基本構成

パターン認識概念に基づく水文データの解析・シミュレーションモデルは、Fig.2 のフローチャートに示されるように、1) パターン解析、2) パターン構造の統計的解析、3) データシミュレーションアルゴリズムの3つの要素から構成される。

(1) パターン解析

モデル構成の第1段階であるパターン解析は、さらに、パターンベクトルの構成とクラスタリング手順からなる。

a) パターンベクトルの構成 水文データの解析にパターン認識の概念を適用するためには、まず N 年間の時系列データを対象に分割し、パターンベクトル系列を得る必要がある。前述の定義から時系列データの対象への分割は、各年を K 個のシーズンに分割することで

Panu ら¹⁰⁾は時系列のシーズンへの分割においてコレ

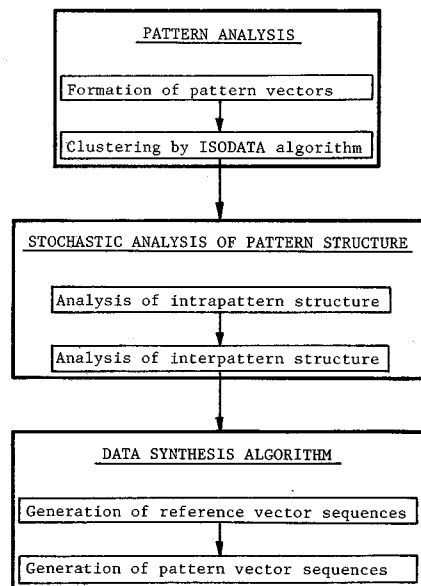


Fig.2 Flow diagram of model.

ログラム解析, ペリオドグラム解析によりシーズンの数と長さを決定し, さらに, ピーク-谷解析により各シーズンの始まりを定めている. ここで, ピーク-谷解析とは, 時系列 $\{r_i, i=1, 2, \dots, T\}$ において, $r_{i-1} < r_i > r_{i+1}$ ならばピークの生起, $r_{i-1} > r_i < r_{i+1}$ ならば谷の生起, それ以外の場合はピーク, 谷とも不生起としておのおのの頻度を求めるものである. 本論文では, 後述のわが国における水文データの特性から, さらに, 各月の値が年最大あるいは年最小となる年数, 年平均値以上あるいは以下となる年数も用いたが, 詳細はモデルの適用例において述べる. これらの情報に基づいて N 年間の時系列データは $N \times K$ 個の対象に分割され, 1 シーズン内の n 個の観測値から形成される $N \times K$ 個の n 次元パターンベクトルが形成される.

b) クラスタリング Panu らは, シーズンの背後に存在する物理現象を念頭におき同じシーズンに生起するパターンは年ごとに異なっているが, これらは同じパターンクラスに属するものであると考えた. すなわち, 彼らは時系列を生成する確率法則は各シーズンごとに異なるが, 同一シーズンでは同じであるとした. 彼らの対象としたデータに対して, 最小距離基準と要素誤認基準を用いることによりほとんど誤認なく, これらのパターンを認識できることを示している.

Fig. 3 に 1975 年 12 月から 1984 年 11 月までの 10 年間の金沢の月降水量を示すが, 図中には 12 月から 11 月までを 1 年としたときの各年の最大値および最小値を記録した月を同時に記入してある. 図からわかるように, この 10 年間をみても年最大値, 年最小値を記録する月は毎年同じではなく, 7, 8 月のように年最大にも年最小にもなる月もある. また, 1 年の中の変動パターンも年ごとにかなり異なっているのがわかる. 通常, われわれが時系列の対象への分割を通じて手にするものは, n 次元空間の一点としてのパターンである. パターンを数学的, 統計的に処理する場合, 空間上で互いに近接したパターンは, そのパターンを発生させた物理法則が全く異

なっている同一のパターンクラスに属するとみなされる. したがって, 複雑な変動パターンを示すわが国の水文データに対しては, 同一シーズンに生起するパターンが同一パターンクラスに属すると考えると Panu らの用いた分類基準では多数の誤認が生じる.

本研究ではこれらの点を考慮し, シーズンとパターンクラスとの 1 対 1 の対応はないものとし, われわれが手にしている $N \times K$ 個のパターンから構成されるパターン空間の構造について, 何の先見の情報ももっていないという立場に立ち, すべてのパターンを ISODATA アルゴリズムを用いたクラスタリングにより分類した. 各シーズンに各パターンクラスに属するパターンが, どれくらい生起したかという分類結果によって各シーズンの特性および年間の変動パターンについて言及できる. またシーズンとパターンクラスが 1 対 1 に対応している場合には, クラスタリングにより同一シーズンには同じパターンクラスに属するパターンのみが生起する結果が得られるであろう. したがって, シーズンとパターンクラスの対応については, 本研究での考え方の方がより広い適用性をもっているものと思われる.

c) ISODATA アルゴリズム¹¹⁾ ISODATA アルゴリズムは, Ball and Hall によって考案されたもので, アルゴリズムの一般的な手順は以下のようである.

第 0 ステップ…初期値パラメーターおよび閾値パラメーターを与える.

第 1 ステップ…与えられた M_0 個の初期クラスター中心に対して, すべての観測パターンをユークリッド距離を尺度として最も近いクラスター中心に割り当てる. この結果, クラスター C_j に割り当てられたパターン数がパラメーター η (クラスターを形成するために必要な最小パターン数) より小さければ, このクラスターは棄てられるが, 残ったクラスターに対して, クラスター内の平均ベクトル

$$z_j = 1/N_j \sum_{i=1}^{N_j} x_i \dots \dots \dots (1)$$

を用いてクラスター中心を置き換える. ここに, N_j はクラスター C_j に属するパターンの数, x_i はパターンベクトルである.

第 2 ステップ…各クラスター C_j に対して, クラスターの中心から各点までの距離の平均 d_j , 標準偏差ベクトル $\sigma_j = (\sigma_{1j}, \sigma_{2j}, \dots, \sigma_{nj})$, クラスター内の距離 d_j の全クラスターにわたる平均量 d を, それぞれ次式により計算する.

$$d_j = 1/N_j \sum_{i=1}^{N_j} \|x_i - z_j\| \dots \dots \dots (2)$$

$$\sigma_{ij} = \left\{ 1/N_j \sum_{k=1}^{N_j} (x_{ik} - z_{ij})^2 \right\}^{1/2} \dots \dots \dots (3)$$

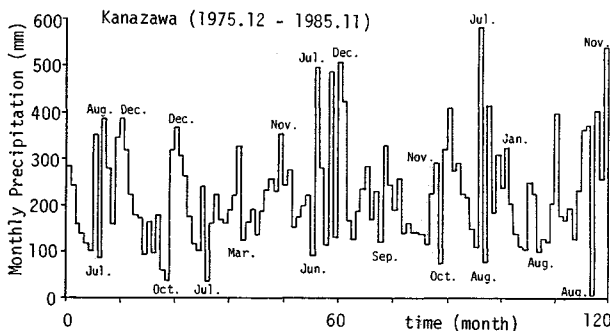


Fig. 3 Monthly precipitation pattern at Kanazawa.

$$d = 1/M_m \sum_{j=1}^{M_m} N_j d_j \dots\dots\dots (4)$$

ここに、 M_m は第 m 回目の反復計算で形成されているクラスターの数。

第3ステップ…第3ステップはクラスターの分割、結合である。クラスター C_k 内のパターン各要素の標準偏差の最大値が与えられたパラメーター θ_s より大きければ、その軸に沿ってクラスターを分割する。2つのクラスター C_k と C_l のそれぞれのクラスター中心 z_k と z_l の間の距離が与えられたパラメーター θ_l より小さければ、これら2つのクラスターは別個のクラスターとはみなされず2つのクラスターを結合する。

第4ステップ…最後のステップは、以上のステップを与えられた回数 I_{max} だけ反復することである。

クラスター分析の統計的推測の面については、ほとんど何も知られておらず、指定する必要のある各種パラメーターの値を選択するために利用できる一般的な指針や、データに依存した簡単な方法もない¹²⁾。著者らが、このアルゴリズムを用いた経験では、初期値パラメーターの影響は小さく初期クラスター中心の数 $M_0=1$ 、初期クラスター中心ベクトル $Z_0=(0,0,0)$ を用いれば十分である。クラスタリングの結果に大きく影響するパラメーターは、 η 、 M 、 θ_s 、 θ_l の4つである。結果として望むクラスターの数 M については、指定された M に対してアルゴリズムの実行結果 $M/2 \sim 2M$ 個のクラスターに分割される。また、通常パターン空間の構造が不明であるのでクラスターをいくらにすればよいかも不明である。したがって M の値としてはおよその上限、下限のクラスター数から定めればよく、本研究の場合 $M=5$ とした。 η はクラスターを形成するのに必要なパターン数であり、これを大きくとると棄てられるパターンが増え、小さすぎるとパターンクラスの統計的構造の推定精度が悪くなる。ここでは $\eta=20$ を用いた。 θ_s は最大標準偏差パラメーターであり、これによりパターンクラス内のパターンのばらつきが制限される。 θ_l はパターンクラスが別個のパターンクラスとみなされるために必要なパターン中心間の最小距離であり、ここでは θ_s に対しては与えられたデータの各月の分散の最小値の1/2、 θ_l は、各シーズンに属するすべてのパターンの

平均ベクトルを求め、これらの間の距離の最小値を目安としてラウンドナンバーを用いた。

本研究で用いたパラメーターの値を Table 1 に示す。最大反復回数 $I_{max}=20$ を用いたが、12回前後の反復計算で収束した。

(2) パターン構造の統計的解析

a) パターン内構造の解析 特定のパターンクラスのパターン内構造 (intrapattern structure) は、クラスターを構成する各パターンの標準ベクトルのまわりの確率分布で表わされ、ここでは多変数正規分布を用いる。もし、第 j パターンクラスに属するパターンの各要素が多変数正規性を満たさない場合には、各要素の周辺正規性を検定し、正規性を満たさない要素に対して Hinkley 変換¹³⁾、Box・Cox 変換¹⁴⁾ 等を行い多変数正規分布とすればよい。第 l パターンクラスが多変数正規分布は

$$p(x_i) = (2\pi)^{-n/2} |C_l|^{-1/2} \cdot \exp\{-1/2(x_i - z_l)^T C_l^{-1}(x_i - z_l)\} \dots\dots\dots (5)$$

と表わされる。ここに、 x_i は第 l パターンクラスのパターンベクトル、 C_l は第 l パターンクラスの分散共分散行列、 z_l は第 l パターンクラスの標準ベクトルであるが、分散共分散行列 C_l は、次式で求められる。

$$C_l = \frac{1}{N_l} \sum_{i=1}^{N_l} x_{li} x_{li}^T - z_l z_l^T \dots\dots\dots (6)$$

ここに、 x_{li} は第 l パターンクラスの第 i パターンベクトル

b) パターン間構造の解析 パターン間構造 (interpattern structure) は、時系列中の連続するシーズンにおける標準ベクトルの生起を規定するものである。この依存関係は標準ベクトル間の持属性を表わし、ここでは、一次の Markov 連鎖を用いた。第 l パターンクラスから第 m パターンクラスへの遷移確率は、シーズンごとに異なるので過程は nonhomogeneous である。さらに、水文過程の周期性を仮定すれば、第 k シーズンにおける標準ベクトル z_m の生起確率は、次式となる。

$$p(z_{kmi}) = \begin{cases} p(z_m(k) | z_l(k-1)), & k \geq 2, \dots, K \\ p(z_m(k) | z_l(K)), & k = 1 \end{cases} \dots\dots\dots (7)$$

第 $(k-1)$ シーズンの標準ベクトル z_l から第 k シーズンの標準ベクトル z_m への遷移確率は

$$p_{klm} = \beta_{lm}(k) / \beta_l(k) \dots\dots\dots (8)$$

Table 1 ISODATA algorithm parameters.

Parameter	Symbol	Value		
		Kanazawa	Fukui	Toyama
Number of initial cluster centers	M_0	1	1	1
Initial cluster center	Z_0	(0,0,0)	(0,0,0)	(0,0,0)
Number of clusters desired	M	5	5	5
Minimum number of samples desired in a cluster	η	20	20	20
Maximum standard deviation allowed clusters	θ_s	50	50	50
Minimum distance required between clusters	θ_l	100	70	100
Minimum number of pairs of clusters that can be lumped	L	1	1	1
Number of iteration allowed	I_{max}	20	20	20

によって求められる。ここに、 $\beta_{lm}(k)$ は第 $(k-1)$ シーズンにおける第 l パターンクラスに属するパターンベクトルから第 k シーズンにおける第 m パターンクラスに属するパターンベクトルへの遷移の観測された総数。 β_l は第 $(k-1)$ シーズンにおける第 l パターンクラスに属するパターンベクトルの観測総数である。

(3) データシミュレーション

(1), (2) で定められたパターン内およびパターン間の統計的構造に基づいて、データシミュレーションは以下のように行われる。その手順は、まず、初期値として前シーズンに生じたパターンの属するパターンクラスを与え、一様乱数を発生させ一次 Markov 遷移行列に従って各シーズンに生起するベクトルの属するパターンクラスを定める。後述の金沢の例のように 8 つのパターンクラスに分割されたような場合は、Table 3 の遷移確率行列に従って、3, 8, 2, 4, 4, 1, 6, ... のようにパターンクラスが定められる。これらのパターンクラスに標準ベクトルを対応させることによって標準ベクトル系列が得られる。次に、正規乱数を用い各パターンクラスの変数正規分布に従って、次の最小距離基準を満たすパターンベクトルを発生させ、標準ベクトル系列をパターンベクトル系列に変換する。すなわち、前ステップで定められたパターンクラスの標準ベクトルに距離が最も近いようなパターンベクトルをシミュレートする。

$$\|x_s - z_i\| < \|x_s - z_j\|, \quad j=1, \dots, M; 1 \neq j \dots (9)$$

ここに、 x_s はシミュレートされたパターンベクトル、 z_i は今発生させようとしているパターンベクトルが属するべきパターンクラスの標準ベクトルである。

4. 実際データへの適用結果と考察

(1) パターン解析結果

解析に用いたデータは金沢(1886~1986年, 101年間)、福井(1897~1984年, 88年間)、富山(1939~1985年, 47年間)の3地点における月降水量データである。Fig. 4, Fig. 5に各地点のコレログラムおよびペリオドグラムをそれぞれ示す。また、Fig. 6にピーク-谷解析の結果を、Fig. 7に年平均値を越える回数 N_a 、年平均値以下になる回数 N_b を示す。Fig. 4, Fig. 5にみられる3か月周期およびFig. 7に示されるように3, 4, 5月の3か月が年平均値以下となる回数が多いことから3地点とも3か月を1シーズンとして4シーズンに分割することとした。

各シーズンの始まりはFig. 6のピーク-谷解析の結果から、各シーズンに大きなピークまたは谷を1つずつ含むようにすることおよび前述のFig. 7の結果から第1シーズンを12~2月、第2シーズンを3~5月、第3シーズンを6~8月、第4シーズンを9~11月とした。この

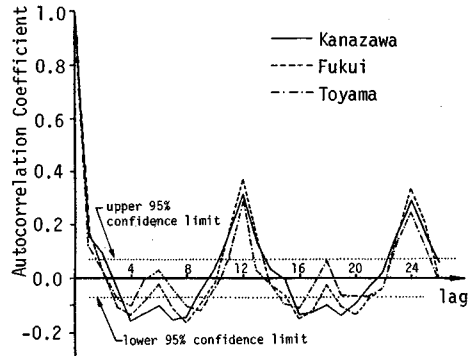


Fig. 4 Correlogram of monthly precipitation.




Fig. 5 Periodogram of monthly precipitation.

結果は第1シーズンから第4シーズンをそれぞれ冬, 春, 夏, 秋とすれば気象学的季節分けとも一致する。この結果、金沢、福井、富山でそれぞれ、400個、348個、184個のパターンが得られる。

Table 1に示したパラメーターを用いて ISODATA アルゴリズムを実行した結果、金沢、福井、富山でそれぞれ8個、8個、5個のパターンクラスに分割された。得られた標準ベクトルをFig. 8に、また、各パターンクラスに属するパターンベクトルの数とともにTable 2に示す。Table 2にはパターンベクトルの生起数のシミュレーション結果も合わせて示した。Table 2, Fig. 8から、北陸地方の降水の変動パターンについて以下のことがわかる。

- ① 第1シーズンでは多降水パターンが全体の約8割を占め、冬季の降水量が毎年多い。




Fig. 6 Peak and valley histogram.




Fig. 7 Histogram of N_a and N_b .

- ② 第2シーズンではシーズン中の変動が少なく、しかも少降雨であるパターンが約7割を占め年間で最も降水が少なく経年変動も小さい。
- ③ 第3シーズンは梅雨を含むシーズンであるが、およそ4年に1回は少雨パターンが生起する。また、梅雨の最盛期はシーズン半ばの7月であることがわかる。
- ④ 第4シーズンは、秋雨前線、台風の有無によって多くの降水パターンが生じるが、卓越するパターンが3つある。
- ⑤ 1シーズンが1パターンクラスに対応するケースはみられないが、各シーズンには2~4個の卓越する変動パターンが存在する。

3地点の合計21個のパターンクラスについてKolmogorov-Smirnov検定を行った結果、各パターンクラスに属するパターンベクトルの要素の標準ベクトルのまわりの多変数分布は有意水準5%で多変数正規分布であるとみなされた。また、各パターン間の共分散行列を求

めたところこれら行列の共分散要素は十分小さく、各パターンクラスは互いに独立であるとみなせた。Table 3に各地点の遷移確率行列を示す。

(2) シミュレーション

シミュレーションは、データ年数と同じ年数のシミュレーションをそれぞれ30回行った。年時系列レベルでのシミュレーション結果をTable 4に示す。Table 4より、3地点の観測値の統計量は金沢、福井の尖度、富山のHurst係数を除いてすべてシミュレーションデータの95%信頼限界内に入っており年時系列レベルでの再現性は良好であるといえる。また、Table 2に示されるように各シーズンのパターンベクトルの生起数も十分再現されている。月レベルでの結果をFig. 9, 10に示す。図より金沢、富山での3, 8月の分散を除いて他のすべての月の平均、分散ともシミュレーションデータの95%信頼限界内にあり、月レベルにおいてもデータの再現性は良好であるといえる。Fig. 11にはコログラムを示すが、この図から各地点とも観測地はシミュレーション

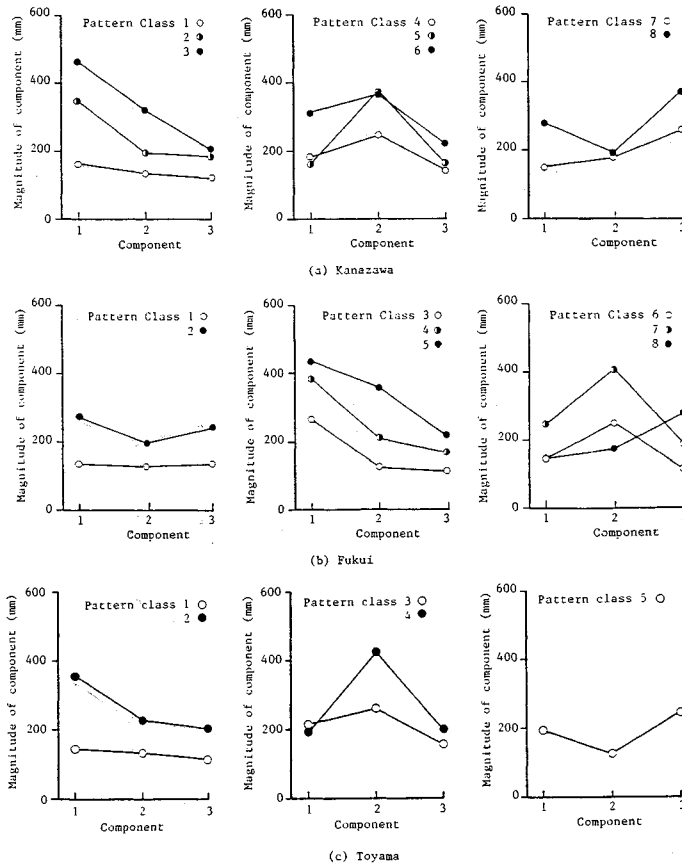


Fig.8 Reference vectors.

Table2 Summary of intrapattern structures.

(a) Kanazawa

Pattern Class	Reference vector						Occurrence times of pattern vectors at each season							
	Component			Standard deviation			Historical data				Synthetic sequences			
	1	2	3	1	2	3	1	2	3	4	1	2	3	4
1	164.5	136.6	121.7	43.1	43.2	42.0	1	67	28	14	1.0(1.0)	67.3(5.4)	27.9(3.4)	22.4(3.3)
2	347.3	197.1	183.7	67.0	45.6	47.5	32	2	5	21	31.3(4.9)	2.0(1.6)	5.5(2.5)	20.9(4.2)
3	463.0	322.1	204.4	60.7	74.0	74.1	25	0	1	2	25.3(4.8)	0(0)	0.9(1.0)	1.7(1.4)
4	184.0	247.8	140.0	43.4	25.3	39.6	12	14	17	5	11.6(2.8)	13.9(3.0)	15.8(2.8)	5.0(2.6)
5	162.4	372.9	163.3	71.7	88.0	79.3	6	1	23	7	5.3(1.7)	0.6(1.0)	22.7(4.7)	7.4(2.6)
6	311.3	365.8	218.4	40.6	86.2	67.0	22	0	3	7	22.5(3.7)	0(0)	2.8(1.8)	8.0(3.2)
7	280.6	191.5	367.6	68.2	57.8	48.1	1	0	6	23	1.1(0.9)	0(0)	5.4(2.1)	22.0(4.3)
8	148.7	175.9	255.7	45.3	57.8	48.1	1	16	17	21	0.8(0.8)	15.2(3.7)	17.0(4.4)	21.0(3.8)

(b) Fukui

Pattern Class	Reference vector						Occurrence times of pattern vectors at each season							
	Component			Standard deviation			Historical data				Synthetic sequences			
	1	2	3	1	2	3	1	2	3	4	1	2	3	4
1	138.5	127.5	135.9	34.1	36.7	39.4	0	58	14	22	0(0)	56.1(4.0)	13.3(3.7)	22.4(3.6)
2	272.8	198.7	242.4	40.9	52.7	50.5	16	0	7	22	16.2(2.9)	0(0)	7.3(2.2)	21.3(3.7)
3	261.9	125.2	111.8	39.9	46.8	44.3	0	9	19	9	0(0)	10.3(2.7)	18.7(4.7)	10.3(2.6)
4	383.8	209.7	165.4	50.8	47.8	43.2	18	0	3	8	17.3(3.6)	0(0)	3.0(1.9)	7.6(2.8)
5	436.5	357.7	217.5	87.7	63.2	75.3	22	0	0	2	21.4(4.1)	0(0)	0(0)	1.8(1.2)
6	144.2	249.4	112.4	46.1	47.0	45.2	3	13	24	8	2.8(1.7)	13.0(3.3)	22.9(4.4)	7.8(2.8)
7	243.9	405.8	186.5	55.2	83.7	60.7	27	0	8	1	27.2(3.9)	0(0)	7.7(2.8)	0.7(0.7)
8	146.6	174.7	279.5	44.8	55.9	53.5	1	7	12	15	1.1(1.1)	6.6(2.5)	12.1(2.6)	14.0(2.6)

(c) Toyama

Pattern Class	Reference vector						Occurrence times of pattern vectors at each season							
	Component			Standard deviation			Historical data				Synthetic sequences			
	1	2	3	1	2	3	1	2	3	4	1	2	3	4
1	146.6	132.4	115.4	43.0	44.6	35.4	2	40	12	12	2.2(1.4)	38.5(2.7)	11.7(3.4)	11.0(3.1)
2	356.6	228.4	203.3	54.3	72.6	59.2	18	0	3	14	17.3(4.0)	0(0)	2.9(1.6)	14.2(2.7)
3	213.1	260.1	153.5	53.3	47.1	48.9	16	0	10	10	16.6(2.8)	0(0)	9.0(2.8)	9.6(2.9)
4	192.1	423.8	198.7	77.7	90.3	86.8	8	0	12	1	7.4(2.7)	0(0)	12.8(3.1)	0.6(0.9)
5	193.6	125.8	248.7	56.4	45.9	63.8	2	6	9	9	1.5(1.1)	6.5(2.7)	8.4(2.5)	9.5(3.2)

():standard deviation

Table 3 First order transition matrices.

(a) Kanazawa

First season								Second season									
	1	2	3	4	5	6	7	8		1	2	3	4	5	6	7	8
1	1.0								1	0.343	0.06	0.015	0.194	0.119	0.03	0.164	0.075
2	0.656		0.031	0.157			0.156		2				0.5	0.5			
3	0.64	0.08		0.08			0.2		3								
4	0.667			0.166			0.167		4	0.071			0.072	0.571		0.286	
5	0.833			0.167					5	1.0							
6	0.682			0.182			0.136		6								
7							1.0		7	0.188	0.062		0.125	0.375	0.063	0.125	0.062
8	1.0								8								

Third season								Forth season									
	1	2	3	4	5	6	7	8		1	2	3	4	5	6	7	8
1	0.107	0.214		0.036	0.036	0.036	0.321	0.25	1	0.286		0.286	0.143	0.143	0.142		
2	0.2	0.2		0.4			0.2		2		0.333	0.143	0.143	0.047	0.286		0.048
3									3			0.5		0.5			
4	0.177	0.235	0.059	0.117			0.176	0.236	4	0.2	0.4	0.4					
5	0.087	0.261	0.043	0.087	0.087	0.13	0.087	0.218	5	0.143	0.286	0.143	0.143	0.285			
6		0.667						0.333	6	0.429	0.286			0.285			
7	0.294	0.118			0.118	0.059	0.235	0.176	7	0.381	0.238			0.048	0.333		
8					0.167	0.5	0.333		8	0.044	0.347	0.261	0.174		0.131	0.043	

(b) Fukui

First season								Second season									
	1	2	3	4	5	6	7	8		1	2	3	4	5	6	7	8
1									1	0.207	0.103	0.276	0.017		0.224	0.086	0.086
2	0.625		0.125			0.25			2								
3									3	0.111		0.333			0.333		0.223
4	0.722		0.056			0.111	0.111		4								
5	0.546		0.136			0.182	0.136		5								
6	1.0								6	0.077			0.077		0.308	0.154	0.385
7	0.704		0.111			0.111	0.074		7								
8	1.0								8	0.143		0.143			0.571	0.143	

Third season								Forth season									
	1	2	3	4	5	6	7	8		1	2	3	4	5	6	7	8
1	0.143	0.286	0.071			0.143	0.357		1	0.136		0.273	0.182		0.409		
2	0.143	0.286				0.429	0.143		2	0.182		0.136	0.364		0.273	0.046	
3	0.316	0.263	0.053	0.105	0.053		0.053	0.158	3	0.333		0.111	0.333	0.222	0.111		
4	0.333	0.334	0.333						4	0.25		0.25	0.25		0.25		
5									5				0.5		0.5		
6	0.292	0.292	0.125	0.042		0.125	0.125		6	0.125			0.25		0.625		
7	0.25		0.125	0.5			0.125		7				1.0				
8	0.25	0.25	0.167	0.083	0.083		0.167		8	0.267		0.4	0.067	0.067	0.206		

(c) Toyama

First season					Second season						
	1	2	3	4	5		1	2	3	4	5
1	1.0					1	0.275	0.05	0.175	0.275	0.225
2	0.778				0.222	2					
3	0.333	0.25	0.167		0.25	3					
4	0.875				0.125	4					
5	1.0					5	0.167	0.167	0.5	0.166	

Third season					Forth season						
	1	2	3	4	5		1	2	3	4	5
1	0.333	0.25	0.167		0.25	1		0.417	0.25	0.333	
2	0.667	0.333				2		0.357	0.429	0.071	0.143
3	0.1	0.2	0.3	0.1	0.3	3	0.1	0.3	0.4	0.2	
4	0.25	0.5	0.167		0.083	4		1.0			
5	0.222	0.223	0.333		0.222	5	0.111	0.444	0.333	0.112	

データの 95% 信頼限界内にあることがわかる。

以上の結果から、本モデルによりデータのもつ種々の統計量、平均、分散、ひずみ度、Hurst 係数のほか、自己相関構造も十分再現されておりシミュレーションモデルとして十分であることが示された。

5. 結 語

本研究で得られた結果を要約すると次のようである。

(1) コレログラム、ペリオドグラム、ピーク-谷解

析および年平均以上、あるいは以下となる年数に基づくシーズン分割結果は通常の季節と一致した。


(2) ISODATA アルゴリズムを用いたパターン解析の結果、シーズンとパターンクラスには 1 対 1 の対応はないが、各シーズンには卓越する 3, 4 個のパターンが存在し、このパターンによりシーズンおよび年間の降水特性を明らかにすることができた。

(3) パターン内およびパターン間の統計構造に基づく本モデルによるシミュレーション結果は年時系列レベ


Table 4 Comparison of statistics from annual historical and synthetic sequences.

	Kanazawa			Fukui			Toyama		
	Mean	S.D.	H.D.	Mean	S.D.	H.D.	Mean	S.D.	H.D.
Mean	215.3	3.15	214.0	201.8	2.56	201.2	196.5	3.60	195.8
S.D.	105.9	2.43	102.5	102.8	2.41	99.5	98.3	3.18	95.4
lag 1 A.C.	0.163	0.029	0.161	0.181	0.023	0.170	0.105	0.042	0.117
Skewness	0.927	0.073	1.010	1.041	0.046	1.068	1.047	0.109	1.070
Kurtosis	3.553	0.257	4.429	3.935	0.208	4.465	3.987	0.386	4.700
Hurst Co.	0.524	0.008	0.525	0.520	0.006	0.526	0.527	0.008	0.601


H. D. : Historical data



(a) Kanazawa



(b) Fukui




(c) Toyama


Fig. 9 Comparison of monthly means for historical monthly precipitation and 95 % confidence interval for 30 synthetic sequences.

ル, 月レベルの両方で良好であった。


ここでは水文時系列の変動パターンの解析とデータシミュレーションのみを扱ったが, 本モデルは水文パターンの確率評価や予測問題への適用も可能である。さらに, 水文データのパターン分類の考えは, 一雨降雨のような



(a) Kanazawa



(b) Fukui



(c) Toyama

Fig. 10 Comparison of monthly standard deviation for historical monthly precipitation and 95 % confidence interval for 30 synthetic sequences.

短時間系列の時空間的変動パターンの解析にも適用できよう。

最後に本研究をまとめるにあたって適切な助言を頂いた山梨大学 竹内邦良教授に感謝の意を表します。

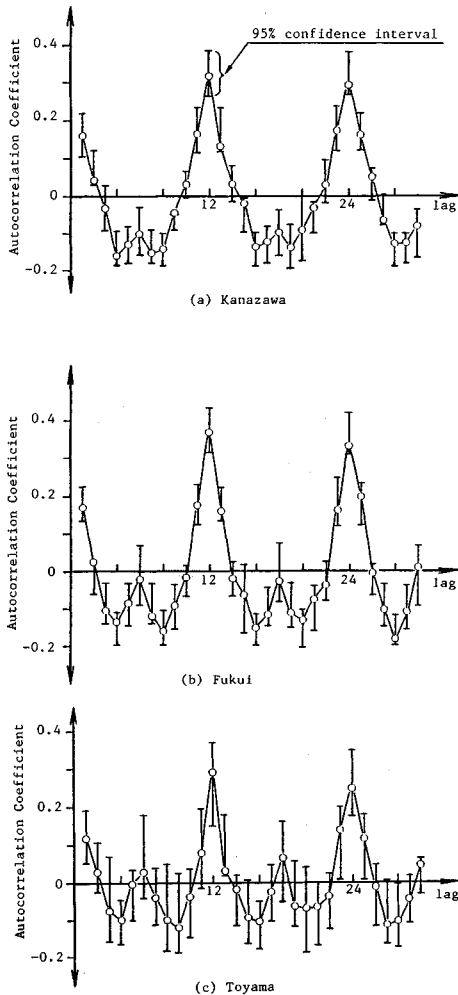


Fig.11 Comparison of correlogram for historical monthly precipitation and 95 % confidence interval for 30 synthetic sequence.

参考文献

1) Thomas, H.A. and Fiering, M.B. : Mathematical

synthesis of streamflow sequences for the analysis of river basins by simulation, in Design of Water Resources Systems, edited by A. Mass *et al.*, Harvard University Press, 1962.

- 2) Jackson, B. B. : The use of streamflow models in planning, Water Resources Research, Vol. 11, No. 1, pp. 54 ~63, 1975.
- 3) Panu, U. S. and Unny, T. E. : Stochastic synthesis of hydrologic data based on concepts of pattern recognition I, Journal of Hydrology, Vol. 46, pp. 5 ~34, 1980.
- 4) Panu, U. S. and Unny, T. E. : A feature prediction model in synthetic hydrology based on pattern recognition, Water Resources Research Vol. 14, No. 2, pp. 335 ~344, 1978.
- 5) Hurst, H. E. : Long-term storage capacity of reservoirs, Transaciton of American Society of Civil Engineering, Vol. 16, pp. 770~808, 1951.
- 6) Tou, J. T. and Gonzelez, R. C. : Pattern recognition principles, Addison-Wesley, 1974.
- 7) 坂井利之編：パターン認識の理論，共立出版，1967.
- 8) Panu, U. S. and Unny, T. E. : Entropy concept in feature extraction and hydrologic time series synthesis, in Modeling Hydrologic Processes, edited by Morel, H. J. *et al.*, Water Resources Publications, 1979.
- 9) Laveen, K. : Pattern in pattern recognition : 1968~1974, IEEE Transactions on information theory, Vol. IT-20, No. 6, pp. 697~722, 1974.
- 10) Panu, U. S. and Unny, T. E. : Stochastic synthesis of hydrologic data based on concepts of pattern recognition II, Journal of Hydrology, Vol. 46, pp. 197~217, 1980.
- 11) たとえば，前出6).
- 12) Gnanadesikan, R. : Methods for statistical data analysis of multivariate observations, John Wiley & Sons, 1977.
- 13) Hinkley, D. V. : On quick choice of power transformation, Applied Statistics, Vol. 26(1), pp. 67~69, 1977.
- 14) Box, G. E. P. and Cox, D. R. : An analysis of transformations, Journal of Royal Society, Service B, Vol. 26, pp. 211~252, 1946.

(1988.12.1・受付)