

時系列信号の非定常性検出・状態分類手法の提案

MIZUTA, Hirohisa / ENDO, Masaaki / 八名, 和夫 / 水田, 博久 / 遠藤, 雅明 / YANA, Kazuo

(出版者 / Publisher)

法政大学計算科学研究センター

(雑誌名 / Journal or Publication Title)

法政大学計算科学研究センター研究報告 / Bulletin of Computational Science Research Center, Hosei University

(巻 / Volume)

14

(開始ページ / Start Page)

129

(終了ページ / End Page)

134

(発行年 / Year)

2001-03-31

(URL)

<https://doi.org/10.15002/00024928>

時系列信号の非定常性検出・状態分類手法の提案

遠藤 雅明 水田 博久 八名 和夫
法政大学工学部電子情報学科

ネットワークトラフィック時系列, 音声信号, 脳波等の非定常な時系列信号の解析において状態変化の検出・分類が必要となることは多い. このとき事前に存在する状態がわからない場合には教師無し学習が必要とされる. そこで本稿では非定常時系列信号を対象とした教師無し学習による新たな分類手法を提案する. これは Lattice フィルタと自己組織化マップ (Self-Organizing Maps:SOM) を組み合わせることで実現される. 本稿ではまず Lattice フィルタの概要と適応推定方法, SOM の特徴である近傍の概念について述べ, 次に AR モデルに基づくシミュレーションデータと人の音声データを用いた解析結果を報告し, 提案手法により良好に検出・分類が行われることを示す.

1 まえがき

ネットワークトラフィック時系列, 音声信号, 脳波等, 非定常な時系列信号としてとらえられる現象は多く, これらの信号解析において状態変化の検出・分類は重要なテーマである [1][2]. この場合, 分類手法は学習の仕方教師有り学習と教師無し学習の2つに大別される. これは, あらかじめ分類したい状態がわかっているか, わかっていないかの違いにより選択される. 実際分類を行う場合には, どのような状態が存在するか事前にわからないことの方が多く, 後者の教師無し学習が必要とされる. 教師無し学習の代表例としては, 自己組織化マップ (Self-Organizing Maps:SOM) があげられる [3][4]. SOM は人間の脳をモデルにしており, 特徴マップを用いて分類が行なわれる. ただし, 静的な信号パターンを主な対象として考えられており, 時系列信号の分類にはあまり向かない.

そこで, 本論文では時系列信号と相性の良い Lattice フィルタを用いることで, 時系列信号を対象とした新たな非定常性の検出・分類手法を提案する. この手法の特徴は, マップ化することにより視覚的に状態変化を把握でき, かつ時系列信号を直接解析することが可能で面倒な前処理を行う必要がない. さらに教師無し学習であるため, 事前に存在する状態を把握できない場合にも用いることができる.

AR モデルに基づくシミュレーションデータ解析を行い, 本提案手法の妥当性を検討した後, 音声認識の例として, 音声時系列に対する母音 (/a/, /i/, /u/, /e/, /o/) の分類を行い, 本提案手法の有効性を検討する.

2 Lattice フィルタ

本論文では, Lattice フィルタと SOM を組み合わせることにより, 非定常性の検出・分類を実現している. ここでは, Lattice フィルタの理論について簡単に述べる. また, Lattice フィルタは時系列信号の解析に有利な特徴を有しており, その特徴についても述べる.

2.1 Lattice フィルタの構成

Lattice 構造は, 前向きと後向きの予測誤差フィルタを結合した構造であり, フィルタ次数に等しい段数で構成される. (図 1参照)

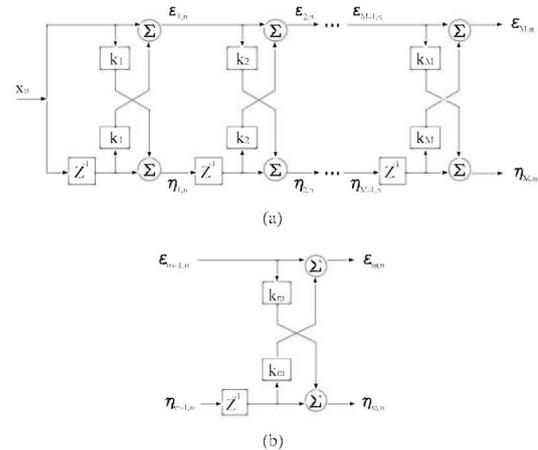


図 1. (a)M 段 Lattice 構造. (b)m 段目の Lattice 構造

ここで, x_n は時点 n における入力, $\epsilon_{m,n}$ はフィルタ次数 m , 時点 n における前向き予測誤差, $\eta_{m,n}$ は同じくフィルタ次数 m , 時点 n における後向き予測誤差, k_m はフィルタ次数 m における反射係数, そして z^{-1} は遅延素子である.

図 1(b) のように m 段目の関係に注目すると, 出力 $\epsilon_{m,n}$, $\eta_{m,n}$ と入力 $\epsilon_{m-1,n}$, $\eta_{m-1,n-1}$ の間には, 以下の関係が成り立つ.

$$\epsilon_{m,n} = \epsilon_{m-1,n} + k_m \eta_{m-1,n-1} \quad (1)$$

$$\eta_{m,n} = \eta_{m-1,n-1} + k_m \epsilon_{m-1,n} \quad (2)$$

つまり, m 段目の Lattice フィルタではデータ x_n が入力される毎に, 出力として前向きと後向きの予測誤差 $\epsilon_{m,n}, \eta_{m,n}$ を出力する.

Lattice フィルタは, 式 (1),(2) に含まれる反射係数 k_m ($m = 1, 2, \dots, M$) を指定すれば, その特性は完全に決定される. そこで, この反射係数を適応推定することで, 動的システムのモデリングを行う.

2.2 適応推定

各反射係数の適応推定は, 現時点 n の各出力である前向きと後向き予測誤差の自乗和 (評価関数と呼ぶ) を最小とするように行う (図 2参照).

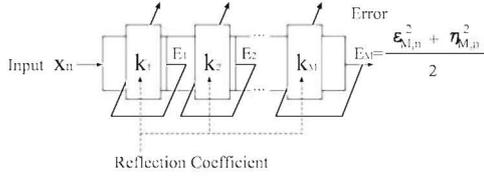


図 2. 反射係数の適応推定

ここで、 m 段目に注目して考えると評価関数は

$$E_m = \frac{\epsilon_{m,n}^2 + \eta_{m,n}^2}{2} \quad (3)$$

となる。この評価関数は k_m の 2 次関数であるため、導関数 $\frac{\partial E_m}{\partial k_m}$ を求め 0 とおけば最小値が求まる。しかしながら、この値はシステムが非定常であるために、誤差曲面の方向が時間とともに変化してしまい、真の誤差になりえない。そこで、各時刻毎に評価関数を減少させる方向に変化させ、最適値に収束させる。評価関数を減少させる方向 (勾配) は

$$\frac{\partial E_m}{\partial k_m} = \epsilon_{m,n}\eta_{m-1,n-1} + \eta_{m,n}\epsilon_{m-1,n} \quad (4)$$

となるので、これを用いて変化量を以下のように定義する。

$$\mu(\epsilon_{m,n}\eta_{m-1,n-1} + \eta_{m,n}\epsilon_{m-1,n}) \quad 0 < \mu < 1 \quad (5)$$

ここで、 μ はステップサイズパラメタという。以上で変化量が決定したので最終的に更新式は以下ようになる。

$$k_m[n+1] = k_m[n] - \mu(\epsilon_{m,n}\eta_{m-1,n-1} + \eta_{m,n}\epsilon_{m-1,n}) \quad (6)$$

よって、上式を用いて各段の反射係数 $k_m (m = 1, 2, \dots, M)$ を時間とともに更新していくことで適応推定を行う。これによりデータ x_n が入力される毎に、反射係数とそのデータに合うように修正され、システムのモデリングが行われる。

2.3 Lattice フィルタの性質

Lattice フィルタの特徴的な性質についてまとめる。

1. データが 1 点入力される毎に、前向きと後向きの予測誤差を出力する。
2. 反射係数によって特性が決定される。
3. 全ての反射係数の大きさは 1 より小さい。
4. 各段での後向き予測誤差が互いに直交している。

$$E[\eta_{i,n}\eta_{k,n}] = \begin{cases} P_k, & i = k \\ 0, & i < k - 1 \end{cases} \quad (7)$$

3 アルゴリズム

本論文は、時系列信号に対する検出・分類手法を提案しており、ここではそのアルゴリズムについて説明する。

本アルゴリズムは、前述の Lattice フィルタを複数配置してマップを作成し、そこに SOM の近傍概念を導入することで、教師無し学習による分類を可能にする。以下にその手順を示す。

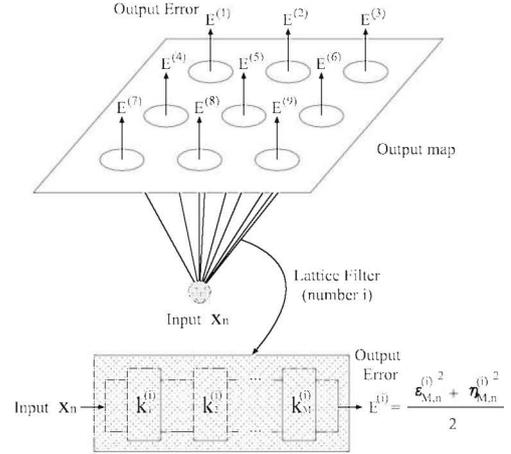


図 3. 提案アルゴリズム概念図

1. 複数の Lattice フィルタを、1 次元か 2 次元に配置してマップを作成する。ここでは例として、2 次元 3×3 のマップを示す (図 3)。図において、入力から出力マップに繋がる線一本一本が Lattice フィルタを表しており、それぞれ別々の反射係数 $k_m^{(i)} (m = 1, 2, \dots, M)$ を持つ。ここで、 m はフィルタ次数で、 (i) がフィルタ番号を表す。
2. 配置した各 Lattice フィルタの反射係数 $k_m^{(i)} (m = 1, 2, \dots, M)$ を ± 1 の一様乱数で初期化する。初期値はさまざまなパターンをとることが望ましい。そこで、Lattice フィルタの反射係数は 1 より小さいという性質を考慮し、 ± 1 の一様乱数を初期値とした。
3. 近傍の初期範囲を大きく設定する。近傍とは、選択されたフィルタの周りを囲むもので (図 4 参照)、この範囲に含まれるフィルタは、誤差が小さくなるように反射係数の更新を行う。近傍に含まれる Lattice フィルタの係数を全て更新することで、距離的に近いフィルタは似ている反射係数を持つことが期待され、マップ上にクラスタが形成される。なお、最初に近傍を広くとることは局所的なクラスタを作成させないために重要である。
4. データ x_n を全てのフィルタに入力し、式 (8) により誤差を計算する。この値が最小となったフィルタが、もっとも入力に合う反射係数を持つことになるので、そのフィルタを選択する。

$$E_n = \lambda E_{n-1} + \frac{\epsilon_{m,n}^2 + \eta_{m,n}^2}{2} \quad (8)$$

上式は、瞬時誤差のみで評価すると安定しない場合があることを考慮して、誤差を過去の重み付き和として評価するように修正を加えている。

5. 選択されたフィルタと、その近傍のフィルタの反射係数を式 (6) により更新させる。これにより、マップ上でもっとも合う反射係数を、さらに入力データに合わせる (入力データを学習させる)。
6. 全入力データ $x_n (n = 0, 1, \dots, N)$ に対して、4-5. を行うことで入力データをフィルタに学習させる。

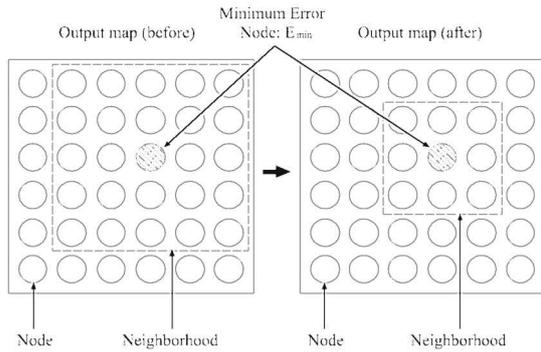


図 4. 近傍の減少

7. 近傍を時間とともに減少させながら (図 4 参照), ステップ 4.-6. を繰り返す. このように, 近傍を減少させていくことにより, 徐々にクラスタが明確になり, 最終的に各状態毎のクラスタが形成される.

上記の過程により, 各入力の状態パターンに合う反射係数が別々のフィルタで形成され, マップ上に複数のクラスタが自動的に作成される.

4 シミュレーション

本提案手法の妥当性を検討するために, まず, Lattice フィルタと相性の良い AR モデルに従う, 2 状態のシミュレーションデータを作成し, 状態分類が可能であるか確認する.

4.1 データ作成

シミュレーションデータとして, 式 (9) に示す単純な 2 次の AR モデルに従うデータを作成する. ここで, e_n は白色雑音過程である.

$$x_n = \sum_{k=1}^2 a_k x_{n-k} + e_n \quad (9)$$

作成するシミュレーションデータは計 1000 点で, システムの状態変化を前半 (0-500 点) と後半 (500-1000 点) において AR 係数を変えることで実現する. (表 1, 図 5 参照)

data (point)	AR coefficient		
	a_1	a_2	e_n^2
0 - 500	1.4211	-0.5789	0.1263
500 - 1000	-0.9473	-0.0526	0.1894

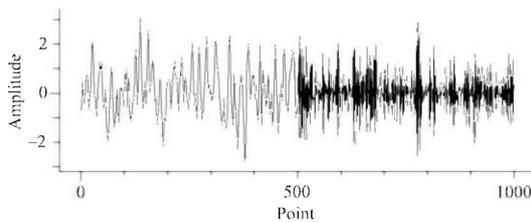


図 5. 作成したシミュレーションデータ

4.2 解析結果

解析に使用したパラメタの設定値は以下の通りである.

パラメタ	設定値
マップサイズ	32 × 1
学習回数	1000
近傍半径の初期値	16
フィルタ次数	2
重み定数	0.96

ここで状態数は, シミュレーションデータであるため 2 状態であることがあらかじめ分かっているが, 事前に状態数がわからない場合を想定しているので, マップサイズを 32 × 1 と状態数より多く設定している. また, 簡単のため今回は 1 次元のマップにしたが, もちろん 2 次元でも可能である. 学習回数については, 学習曲線等を見て学習の終りを判定するべきだが, 今回は分類可能であることを確認することが目的なので 1000 回と固定にした. 近傍半径の初期値は, 一般的にマップサイズの半分程度の値が使われるので, ここでもそのようにした. フィルタ次数は AR モデルと揃えるため 2 次とした. また, 重み定数はここでは経験的に決めているが, この値は過去のデータをどの程度重要視するかを表しているので, 小さすぎると現在の点のみで学習しようとするため異なるフィルタが選択される傾向があり, 大きすぎると逆に過去の点を重要視しすぎるため, 同一フィルタが選択されてしまう傾向がある.

次に, 本提案手法による状態分類結果を図 6 に示す. この図は, 各データ (横軸) を入力した際の, 誤差が最小となったフィルタ番号 (縦軸) を表している.

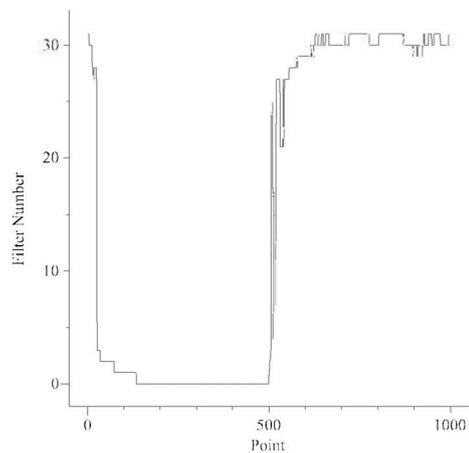


図 6. シミュレーションデータの解析結果

図 6 に示した解析結果をみると, 最初の 50 点目付近までは安定していないが, それ以後はフィルタ番号 0 付近が選択されている. また状態変化後である 500 点目以降は, こちらも 50 点目付近までは安定していないが, それ以降はフィルタ番号 30 付近が選択されている. このことから異なる状態 (前半と後半) において, それぞれ別のフィルタ (0 番付近と 30 番付近) が選択されており, 良好に 2 状態の分類が行なわれていることがわかる.

シミュレーション解析結果より、状態変化の前後においてマップ上で明らかに違うフィルタが選択されることが確認され、良好に分類が行なわれることを示した。しかし、これはあくまでもシミュレーションであり、Lattice フィルタで確実に推定可能である AR モデルを用いてデータを作成している。そこで、次に実データを用いて提案手法の妥当性をさらに検討していく。

5 音声認識

人の音声は準周期的な信号であるため、Lattice フィルタによりモデリングしやすい。そこで、本手法の音声認識への応用例として、人の音声時系列を用いた母音 (/a/, /i/, /u/, /e/, /o/) の分類を行い、有効性を確認する。

5.1 記録方法

被験者である 24 歳の成人男性の音声をマイク装置で入力し、サンプリング周波数 8000Hz、量子化 16bit で A/D 変換したものを記録した。被験者には約 1 秒間づつ各母音 (/a/, /i/, /u/, /e/, /o/) を発音してもらい、母音の間は無音状態を置く。以上のようにして、得られた音声波形を図 7 に示す。

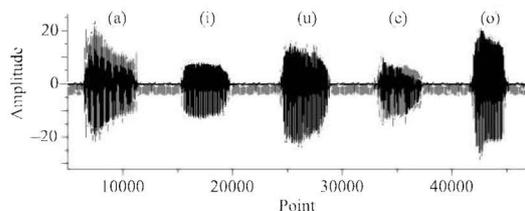


図 7. 音声波形データ

5.2 解析結果

解析に使用したパラメータを表 3 に示す。

表 3. パラメータ設定値	
パラメータ	設定値
マップサイズ	32 × 1
学習回数	1000
近傍半径の初期値	16
フィルタ次数	16
重み定数	0.99

パラメータ値は、先程のシミュレーションデータの時とほぼ同じに設定した。ただし、フィルタ次数のみ音声データに合わせるために、16 次とした。

本手法による分類結果を図 8 に示す。この図は、各データ (横軸) を入力した際の、誤差が最小となったフィルタ番号 (縦軸) を表している。

図 8 に示した解析結果をみると、(i) と (e) において多少重なる部分があるが、大部分では各母音 (/a/, /i/, /u/, /e/, /o/) 毎に別々のフィルタが選択されている。また、ノイズ部分 (母音以外) では明らかにフィルタ番号 30 付近が選択されており、データの振幅が違うこともあるが、音声と非音声の分類がしっかりと行われていることがわかる。

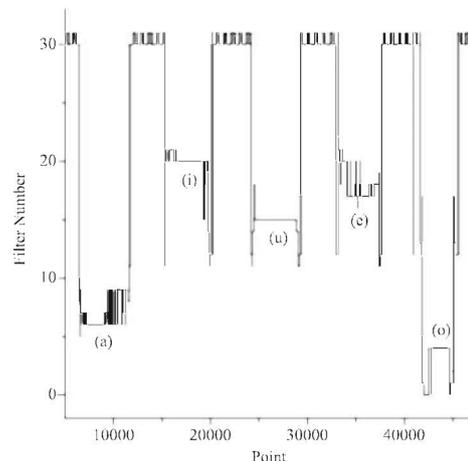


図 8. 音声データの解析結果

人の音声データの解析から、ほぼ満足できる分類結果が得られた。さらに精度を高めるためには、音声の統計的性質等を考慮に入れていく必要がある。なお、結果のみを報告させていただくと、各母音間に無音状態がないデータの場合でも同程度の分類精度が得られており、各母音毎の特徴をきちんと捉えていると言える。

以上の結果は、シミュレーションデータよりは精度が低い、状態数が増えていること等を考慮すると、良好な結果が実データからも得られたと言える。

6 むすび

本稿では、Lattice フィルタを 1 次元あるいは 2 次元に配置してマップを作成し、そこに、近傍の概念を導入することで、新たな時系列信号の検出・分類手法を提案した。提案手法の妥当性を検討するために、AR モデルに従うシミュレーションデータと人の音声データを用いて、それぞれ解析を行った。シミュレーションでは、完全に状態毎に異なるフィルタが選択され良好に分類が行われた。一方、音声データでは、多少重なる部分が存在したものの状態毎に異なるフィルタが選択され、各母音の分類が可能であることを示した。これら結果から、時系列信号を対象とした非定常性の検出・分類手法として提案手法の有効性を確認できた。

本提案手法は教師無し学習であるため、存在する状態が未知である場合にも有効であり、かつ時間とともに変動の性質が変化する脳波や音声といった信号に対して、状態変化の検出・分類を行うことが期待できる。そこで、今後はノイズの変化をモニタリングすることで、製品交換時期を自動的に判断するシステム等への応用を考えていきたい。

参考文献

- [1] Principe J.C., Cala S.K. and Chang T.G. "Sleep Staging Automaton Based on the Theory of Evidence," IEEE Trans. Biomed. Eng., BME-36,5, pp.503-509 1989.
- [2] S. Austin, G.Zavaliagos, J.Makhoul, and R.Schwartz, "Speech recognition using segmental neural nets," Proc. ICASSP92, pp.1-625-1-628, 1992.

- [3] T. Kohonen, "Self-organization and associative memory," Third Edition, Springer-Verlag, 1989.
- [4] X.Zhang and Y. Li, "Self-organizing map as a new method for clustering and data analysis," Proc. Int. joint Conf. on Neural Networks, pp.111-297-302, 1992.
- [5] F. Itakura and S. Saito, "Digital Filtering Techniques for Speech Analysis and Synthesis," paper 25-C-1, Proc. 7th Int. Conf. pp.261-264, 1971.
- [6] J. Makhoul, "New Lattice Methods for Linear Prediction," Proc. IEEE International Conference on Acoustics Speech, and Signal Processing 76, 1976.
- [7] S. ハイキン著, 武部幹 訳, "適応フィルタ入門," 現代工学社, 1987.
- [8] 辻井重男監修, "デジタル信号処理の基礎," 電子情報通信学会編, 5-6 章, 1988.
- [9] T. コホネン著, 徳高平蔵, 岸田悟, 藤村喜久郎 訳 "自己組織化マップ", シュプリンガー・フェアラーク東京, 1997.
- [10] R. ビール T. ジャクソン著, 八名和夫監訳 "ニューラルコンピューティング入門", 海文堂, 1993.
- [11] 船久保登著, "パターン認識," 共立出版株式会社, 1991.

キーワード.

ラティスフィルタ、自己組織化マップ、非定常性検出、状態分類、時系列信号

Summary.

Detection and Classification of Nonstationarity in Time Series.

Masaaki Endo Hirohisa Mizuta Kazuo Yana
Department of Electrical Infomatics , Colleague of Engineering , Hosei University

A method of detecting and classifying nonstationarity in observed time series is proposed. The method enables dynamic unsupervised classification by the combination of self-organizing maps (SOM) and the lattice filter. The method has been validated by a speech signal analysis. Japanese vowels have been successfully classified by the proposed method. The method may be useful for the analysis of various nonstationary signals such as speech signals, local area network traffic changes or bio-signals.

Keywords.

Lattice Filter, Self-Organizing Maps, Detection and Classification, Time Series