

카오스 특징 추출에 의한 시계열 신호의 패턴인식

이 호섭, 공성곤
송실대학교 전기공학과
E-mail : hslee@elec3.soongsil.ac.kr

Pattern recognition of time series data based on the chaotic feature extraction

Ho-Seub Lee, Seong-Gon Kong
Dept. of Electrical Engineering, Soong-Sil University

ABSTRACT

This paper proposes the method to recognize of time series data based on the chaotic feature extraction. Features extract from time series data using the chaotic time series data analysis and the pattern recognition process is using a neural network classifier. In experiment, EEG(electroencephalograph) signals are extracted features by correlation dimension and Lyapunov experiments, and these features are classified by multilayer perceptron neural networks. Proposed chaotic feature extraction enhances recognition results from chaotic time series data.

1. 서론

최근 컴퓨터의 처리능력 향상과 인공지능 기법의 발달로 인해 인간만이 할 수 있는 많은 작업들이 컴퓨터에 의해 대체되고 있다. 특히, 신호의 패턴을 인식함으로서 이상을 판단하여 적절한 조치를 취하는 응용분야는 최근에 들어 빠르게 발전하고 있다. 이러한 응용분야에서는 다양한 종류의 신호에 대한 적절한 분석과 신뢰성 높은 인식방법이 필요로 되고 있다.

시계열 신호가 카오스 신호처럼 비주기성과 불규칙성이 클 경우에는 일반적인 선형 신호분석법(linear time series analysis)을 이용하여 적당한 특징을 추출하기 어렵다. 따라서, 이러한 신호의 인식에는 카오스 이론을 이용한 비선형 시계열 신호분석법(nonlinear time series analysis)을 통한 특징추출이 시도되고 있다[1].

본 논문에서는 카오스 특성을 지닌 대표적인 신호인 뇌파를 대상으로 비선형 신호분석법인 상관차원(correlation dimension)과 리아프노프 지수(Lyapunov exponent)를 이용해 특징을 추출하였으며, 이러한 특징을 신경망을 통해 학습함으로서 뇌파의 종류를 인식하였다.

2. 카오스 특징 추출

2-1 어트랙터 재구성

시계열 신호에서 카오스 특징인 상관차원과 리아프노프 지수를 추출하기 위해서는 임베딩 차원과 시간지연에 의한 어트랙터의 재구성이 필요하다.

어트랙터 재구성이란 시계열 신호를 위상공간으로 표

현하는 것을 말하며, 위상공간에서 나타난 궤적을 어트랙터라 한다. 어트랙터 재구성 방법은 Takens의 자연방법[2]을 사용했다. 즉, i 개의 데이터가 주어졌을 때, $x(i)$ 과 같이 주어지는 m 차원 벡터 $\hat{X}(i)$ 를 위상공간에서 순서대로 연결시킴으로서 어트랙터가 재구성 된다.

$$\begin{aligned}\hat{X}(1) &= (x(1), x(1+\tau), x(1+2\tau), \dots, x(1+(m-1)\tau)) \\ \hat{X}(2) &= (x(2), x(2+\tau), x(2+2\tau), \dots, x(2+(m-1)\tau)) \\ &\vdots \\ \hat{X}(i) &= (x(i), x(i+\tau), x(i+2\tau), \dots, x(i+(m-1)\tau))\end{aligned}\quad (1)$$

여기서 $x(i)$ 는 주어진 시계열 데이터이며, m 은 임베딩 차원(embedding dimension)을, τ 는 시간지연(time delay)을 나타낸다.

식 (1)을 이용해 어트랙터를 재구성하기 위해서는 임베딩차원과 시간지연이 사전에 결정되어야 한다.

2-2 임베딩 차원 및 시간지연의 결정

임베딩 차원을 결정하기 위해 Kennel 이 제안한 FNN(false nearest neighbor)방법[3]을 이용하였다. FNN이란, 어떤 임베딩 차원에서는 두 어트랙터위의 점이 근접점(nearest neighbor)이지만 임베딩 차원이 한 차원 증가될 경우에는 근접점이 되지 않는 점을 말한다.

FNN 방법이란, 임베딩 차원을 증가시키면서 FNN 비를 계산하여 FNN 비가 0% 근처일 때의 임베딩 차원을 찾아 그 시계열 데이터의 임베딩 차원으로 결정하는 방법이다. FNN 비는 주어진 각 데이터에서 FNN의 개수를 구하고 이를 어트랙터의 전체 점의 수로 나눔으

로써 계산된다.

시간지연은 Liebert 와 Schuster[4]가 제안한 상관적분 방법을 이용하여 결정하였으며 이는 시간지연의 변화에 따라 계산된 상관적분 값에서 첫번째 국부최소점(local minima)이 되는 점을 주어진 시계열 데이터의 시간지연으로 결정하는 방법이다.

임베딩차원 및 시간지연을 계산함으로써 어트랙터를 재구성할 수 있다. 어트랙터를 재구성함으로써 상관차원 및 리아프노프지수를 추출할 수 있게 된다.

2-3 상관차원의 계산

상관차원은 시계열 신호에 대한 재구성된 어트랙터의 기하학적 특징을 표현한다. 상관차원은 정수값이 아닌 실수로 표현되며 신호의 카오스적인 정도에 따라 그 값이 달라진다. 따라서, 어트랙터의 고유한 특성으로 상관차원을 사용할 수 있다.

재구성된 어트랙터로부터 상관차원을 계산하는 방법은 Gressberger 와 Procassia 가 제안한 방법[5]을 사용하였다. 이 방법은 어트랙터 상의 각 점에서 상관적분을 계산함으로써 상관차원을 결정하게 된다. 어트랙터의 한 점을 중심으로 반지름이 r 인 구(sphere)를 그리고 구내부 점의 수를 계수할 수 있다. 위와 같은 과정을 어트랙터 상의 각 점에서 반복하였을 때, 계수된 값들의 평균값을 상관적분이라 한다.

상관차원을 구하는 방법은 우선 상관적분 $C(r)$ 을 식(2)와 같이 정의한다.

$$C(r) = \frac{1}{N^2} \sum_{i=1}^N \sum_{j=1}^N \Theta\left(r - |\hat{\mathbf{x}}(i) - \hat{\mathbf{x}}(j)|\right) \quad (2)$$

여기서, Θ 는 step function이며, $\hat{\mathbf{x}}(i)$ 와 $\hat{\mathbf{x}}(j)$ 는 i 와 j 번째 어트랙터를 구성하는 점이다. 또한, N 은 데이터의 수를, r 은 반지름을, 그리고 $|\hat{\mathbf{x}}(i) - \hat{\mathbf{x}}(j)|$ 는 두 점사이의 유클리디안 거리를 나타낸다.

식(3)과 같이 $\log_2 r$ 대 $\log_2 C(r)$ 의 그래프를 그렸을 때, 선형 구간의 기울기값 및 y 절편을 구할 수 있으며 이 때 기울기값은 상관차원을 나타낸다.

$$\nu = \frac{d \log_2 C(r)}{d \log_2 r} \quad (3)$$

논문에서는 시계열 신호의 특징으로 상관차원, y 절편 그리고 다음에 살펴볼 리아프노프 지수를 사용하였다.

2-4 리아프노프 지수 계산

리아프노프 지수는 재구성된 어트랙터의 발산 또는 수렴에 대한 평균 지수로서 0보다 큰 양수일 경우에는 신호가 카오스적이며, 0보다 작을 경우에는 신호가 주기적임을 알려준다.

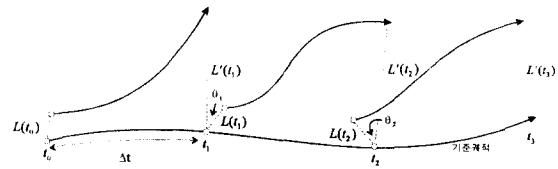


그림 1: Wolf 방법에 의한 리아프노프 지수의 계산

리아프노프 지수를 구하는 방법은 Wolf[6]의 방법을 사용하였으며 그림 1에 나타내었다. 계산과정은 다음과 같은 다섯가지 과정으로 세분된다.

첫째, 어트랙터의 기준캐치로부터 $L(t_0)$ 만큼 떨어져 있는 최근접 이웃점을 정한다. 둘째, Δt 이후의 t_1 에서 기준캐치 위의 점과 이웃캐치 사이의 거리를 $L'(t_1)$ 이라 하고, $L(t_0)$ 와 $L'(t_1)$ 의 거리를 구한다. 셋째, t_1 에서의 최근접 이웃점을 찾아 거리 $L(t_1)$ 을 계산한다. 넷째, Δt 시간이 지난 t_2 에서 둘째 과정을 반복하여 거리를 구한다. 다섯째, 위와 같은 과정을 M 번 반복하여 평균 거리를 계산하며, 최종적인 리아프노프 지수 λ 는 식(4)와 같다.

$$\lambda = \frac{1}{M\Delta t} \sum_{k=1}^M \log_2 \frac{L'(t_k)}{L(t_{k-1})} \quad (4)$$

여기서, M 은 반복횟수, $\Delta t = t_{k-1} - t_k$ 이다.

이렇게 구해진 리아프노프 지수는 M 이 커짐에 따라 하나의 값으로 수렴하게 된다.

3. 실험 및 결과

3-1. 실험 대상 시계열 신호

실험에 사용된 뇌파는 피실험자의 손가락에 피실험자가 익숙치 않은 동작을 하는 동안에 측정한 뇌파였다. 이 운동은 4 주 동안 훈련되었으며 1 주일 간격으로 뇌파를 측정하여 그림 2에 나타내었다. 뇌파신호는 1kHz로 샘플링 되었으며 총 데이터의 크기는 10000 샘플이다.



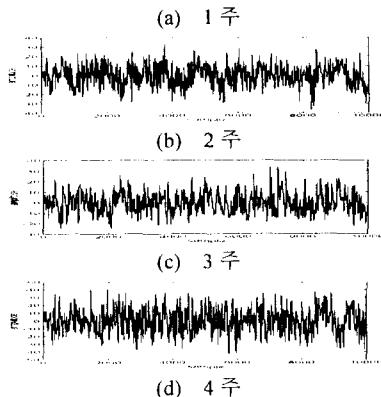


그림 2: 실험에 사용된 뇌파신호

3-2 특징 추출

특징추출을 위한 추출 구간은 각 뇌파 데이터에서 1000 샘플로 설정하였으며, 충분한 데이터를 얻기 위해 500 샘플씩 중복시켜 18 개의 구간을 얻었다. 처음 1000 개 샘플은 괴실험자가 운동을 시작하는 과도상태라 볼 수 있으므로 특징 추출 구간에서 제외하였으며 일반성을 얻기 위해 신호를 [-1,1]로 정규화 하였다.

우선 FNN 방법에 의한 최소 임베딩 차원 결정 결과는 그림 3 과 같다. 임베딩 차원이 4에서 FNN 비율이 0[%]로 떨어짐을 알 수 있다.

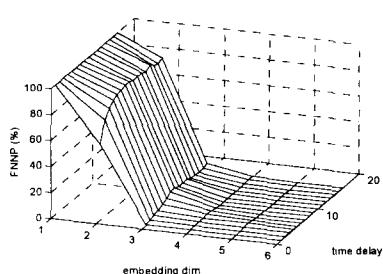


그림 3: 최소 임베딩 차원 설정

상관적분을 이용해 시간지연을 결정했을 때, 상관적분의 첫번째 국부최소점이 임베딩 차원의 변화와 무관하게 결정되어야 하지만, 실험결과 임베딩 차원에 따라 첫번째 국부최소점이 변하였다. 이런 문제로 인해 임베딩 차원을 3 차원부터 6 차원까지 변화시키면서 구한 첫번째 국부최소점을 평균하여 시간지연으로 결정하였다. 계산 결과 시간지연이 14 샘플임을 알 수 있었다. 그림 4 에서는 이러한 결과를 보여주고 있다. 이 때 m 은 임베딩 차원이며, O 표는 첫번째 최소점을 의미한다.

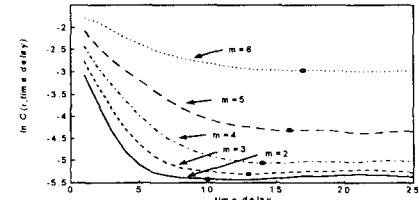


그림 4: 적절한 시간지연 설정

결정된 임베딩 차원과 시간지연을 이용해 4 가지 뇌파에 대한 상관차원, y 절편 그리고 리아프노프 지수를 계산하였다. 리아프노프 지수와 상관차원은 시간지연보다 임베딩 차원의 변화에 민감하였기 때문에 임베딩 차원을 3 차부터 6 차까지 변화시키면서 계산하였다.

상관차원 및 y 절편의 계산결과를 그림 5 와 같이 나타났으며, 선형구간의 기울기는 점선으로 표시하였다.

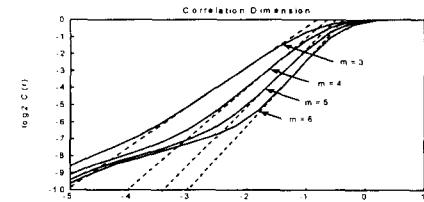


그림 5: 임베딩 차원에 따른 상관차원

그림 6 은 식 (4)를 이용해 계산한 리아프노프 지수를 보여주고 있다. 이때 사용한 파라미터로서 Δt 는 5 샘플로, M 은 190 으로 설정하였다.

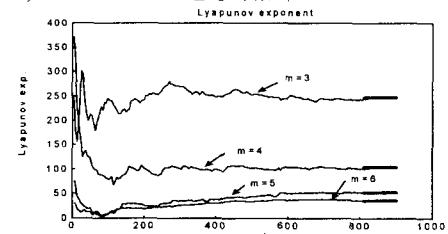


그림 6: 임베딩 차원에 따른 리아프노프 지수

뇌파에서 추출된 특징인 상관차원, y 절편 그리고 리아프노프 지수를 신경망을 이용해 학습시켜 뇌파의 종류를 인식하는데 이용하였다.

3-3. 신경망 분류기

신경망 분류기는 신호가 가지는 고유한 특징을 신경망에 학습시킴으로써 같은 종류의 신호가 들어왔을 때 이를 분류하여 인식하는 역할을 한다.

논문에서는 카오스 특징들을 추출해 이를 학습하여 분류하였다. 분류기의 입력은 상관차원, y 절편 그리고 리아프노프 지수로서 이러한 특징들은 뇌파신호를 나눈 각 구간에서 추출된다. 즉, 4 개의 뇌파신호를 구분 한 각 18 구간에서 구간마다 3 종류의 특징이 추출된다.

그러나, 이렇게 추출된 특징은 편차가 심하기 때문에 이동시키면서 평균을 내는 방법인 이동평균(moving average)을 사용하여 구한 최종 평균값을 학습데이터 및 테스트 데이터로 사용하였다. 이동평균의 계산방법은 18개 데이터에서 처음 5개에서 첫번째 평균을 구하고 1개씩 이동하면서 다음 평균을 구하는 방법을 이용하였다. 이러한 방법에 의해 총 14개의 특징값들이 최종추출이 되었고, 이중 8개는 학습데이터로, 6개는 테스트데이터로 사용하였다.

신호분류를 위해 구성한 전방향 다층구조신경망은 3-10-2 구조를 가지며 학습알고리즘은 오차역전파 알고리즘을 사용하였다. 입력은 상관차원, y 절편 그리고 리아프노프 지수으로 구성되며, 출력은 2개의 뉴런을 사용하였다. 즉, 4개의 각 뉴파신호는 출력으로서 이진값인 (0,0), (0,1), (1,0) 그리고 (1,1)을 갖는다. 중간층 뉴런 수는 실험에 의해 결정되며 10개 이상일 경우에는 모두 학습에 성공하였으며 비슷한 결과를 보여주었다. 또한, 학습을 위한 입력데이터는 [0,1]로 정규화하였으며, 뉴론의 활성함수는 모두 시그모이드(sigmoid)함수를 사용하였다.

학습상수(learning rate)는 0.01로 하였고, 식(5)과 같이 정의된 제곱오차합(SSE)이 0.01 될 때까지 학습을 반복하였다. 만일, 학습이 10000회까지 반복하여도 목표까지 도달하지 못하면 학습을 멈추도록 하였다

$$SSE = \sum_{i=1}^I \sum_{j=1}^J (y_{ij} - t_{ij})^2 \quad (5)$$

여기서, I는 전체 학습패턴의 개수, J는 출력노드의 개수이며 y_{ij} 와 t_{ij} 는 i번째 패턴에 대한 j번째 출력 뉴런의 원하는 출력값과 실제 출력값이다.

3-4 인식결과

임베딩 차원이 3 차원부터 6 차원까지 변할 때, 각각의 경우에 대해 제안한 카오스 특징인 상관차원과 y 절편 그리고 리아프노프 지수를 계산하고, 이러한 특징을 신경망으로 학습하여 신경망분류기를 구성하였다.

위와 같은 방법으로 구성된 신경망분류기를 4종류의 뉴파신호에 적용해 테스트하여 인식률을 조사한 결과는 그림 7과 같다.

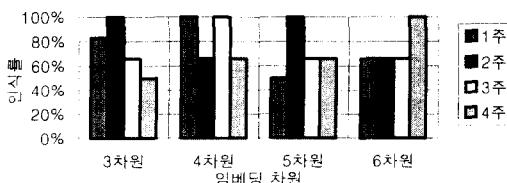


그림 7: 임베딩 차원에 따른 인식결과

인식결과 전체적인 인식률은 약 80%를 보였으며 임베딩 차원에 따라 인식률에 차이가 있음을 알 수 있다. 임베딩 차원이 4 차원인 경우 인식률이 가장 우수했으며 이는 2-2 절에서 계산한 임베딩차원과 일치함을 알 수 있었다.

4. 결론

본 논문에서는 카오스 이론을 이용한 시계열 데이터의 분석법에 대해 연구하였다. 카오스 성질을 갖는 시계열 데이터로부터 신호의 특징인 상관차원, y 절편 그리고 리아프노프 지수를 추출하였다. 또한, 신경망을 이용하여 추출된 신호의 특징을 학습시킴으로써 데이터의 종류를 판별하는 패턴인식 방법을 제안하였다.

이러한 방법은 카오스 특징 추출에 의한 패턴인식 방법을 사용함으로써 신경망 분류기의 구조가 단순해지는 이점을 갖고며 적은 수의 특징추출에도 불구하고 좋은 인식결과를 보여주었다. 그러나 카오스 특징 추출 과정에서 임베딩 차원, 시간지연, Δt , M 그리고 추출구간 설정 등으로 주어지는 파라미터의 영향이 인식률에 영향을 주므로 적절한 파라미터 선정이 중요하다.

결론적으로, 일반적인 방법으로 구분하기 어려운 시계열 데이터에 대해 카오스 특징추출 방법을 이용함으로써 그 특징을 추출할 수 있었으며 이를 신경망으로 학습하여 신호의 종류를 인식할 수 있었다.

참고문헌

- [1] 이병재, “카오스 이론을 이용한 생체 비선형 동역학 시스템의 특성 해석,” 연세대학교 대학원 박사학위 논문, 1995.8
- [2] F. Takens, “Lecture Notes in Mathematics”, D.A.Rand and L.S. Young(eds.), Springer, Vol.898, P.266, 1981
- [3] M.B. Kennel et al., “Determining Embedding Dimension for Phase Space Reconstruction using Geometrical Construction,” Physical Reviews A, Vol. 45, p.2403-3411, 1992.
- [4] W. Liebert and H.G. Schuster “Proper Choice of The Time Delay for The Analysis of Chaotic Time Series,” Physics Letters A, Vol.142, p.107-111, Dec. 1989.
- [5] P. Grassberger and I. Procaccia, “Characterization of Attractors,” Phys. Rev. Lett., Vol.50, No.5, p.346-349, Jan., 1983
- [6] Alan Wolf et al., “Determining Lyapunov Exponents from a Time Series,” Physica 16D, p. 285-317, 1985