

## 코사인 모듈화 된 가우스 활성화 함수를 사용한 캐스케이드 코릴레이션 학습 알고리즘의 성능 향상

이상화\*, 송해상\*

### An Improvement of Performance for Cascade Correlation Learning Algorithm using a Cosine Modulated Gaussian Activation Function

Sang-Wha Lee\*, Hae-Sang Song\*

#### 요약

본 논문에서는 캐스케이드 코릴레이션 학습 알고리즘을 위한 새로운 클래스의 활성화 함수를 소개한다. 이 함수는 코사인으로 모듈화된 가우스 함수로서 편의상 이 활성화 함수를 코스가우스(CosGauss) 함수라고 칭하기로 한다. 이 함수는 기존의 시그모이드 함수(sigmoidal function), 하이퍼볼릭탄젠트 함수(hyperbolic tangent function), 가우스 함수(gaussian function)에 비해서 등성이(ridge)를 더 많이 얻을 수 있다. 이러한 등성들로 인하여 빠른 속도로 수렴하고 패턴인식 속도를 향상 시켜서 학습 능력을 향상시킬 수 있다. 캐스케이드 코릴레이션 네트워크에 이 활성화 함수를 사용하여 중요한 기준 문제(benchmark problem)의 하나인 이중나선 문제(two spirals problem)에 대하여 실험하여 다른 활성화 함수들과 결과 값을 비교하였다.

#### Abstract

This paper presents a new class of activation functions for Cascade Correlation learning algorithm, which herein will be called CosGauss function. This function is a cosine modulated gaussian function. In contrast to the sigmoidal, hyperbolic tangent and gaussian functions, more ridges can be obtained by the CosGauss function. Because of the ridges, it is quickly convergent and improves a pattern recognition speed. Consequently it will be able to improve a learning capability. This function was tested with a Cascade Correlation Network on the two spirals problem and results are compared with those obtained with other activation functions.

---

• 제1저자 : 이상화  
• 접수일 : 2006.06.12, 심사일 : 2006.06.22, 심사완료일 : 2006.07.16  
\* 서원대학교 컴퓨터정보통신공학부교수

▶ Keyword : 시그모이드 함수(sigmoidal function), 하이퍼볼릭탄젠트 함수(hyperbolic tangent function), 가우스 함수(gaussian function), 코스가우스 함수 (cosine modulated gaussian function), 캐스케이드 코릴레이션 알고리즘(Cascade Correlation algorithm)

### 1. 서론

가시존의 함수와 코사인 모듈화된 가우스 함수(cosine-modulated gaussian function)의 근본적인 차이점은 패턴 공간(pattern space)에서 획득한 등성이(obtained ridges) 또는 지역 융기(local bumps)의 숫자이다. 가우스 함수(gaussian function) 또는 한 쌍의 시그모이드 함수(sigmoidal function)는 입력 평면(input plane)에서 하나의 등성을 형성한다. 한 지역 융기는 입력 평면에서 한 쌍의 가우스 함수 또는 두 쌍의 시그모이드 함수에 의해서 생성된다. 그림 1 (a)~(c)는 시그모이드 함수, 가우스 함수 그리고 코스가우스 함수(CosGauss function)에 의한 패턴 분류의 예를 보여준다. 그림 2의 (a)~(c)에서는 입력 평면에서 등성을 형성하여 패턴을 분류하는 예를 보여준다.

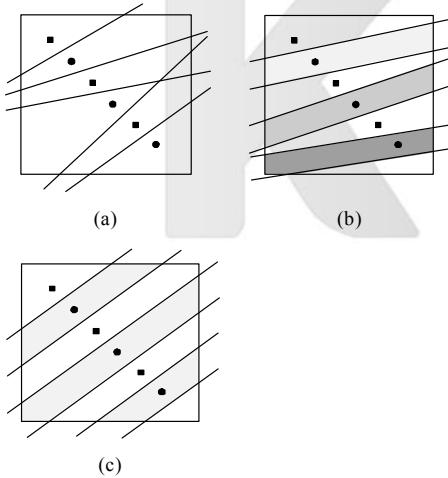


그림 1. 등성을 이용한 분류: (a): 5개의 시그모이드, (b): 세 개의 가우스, 그리고 (c): 하나의 코스가우스  
 Fig 1. Pattern classification using ridges: (a): with five sigmoidals, (b): with three gaussians and (c): with a CosGauss function.

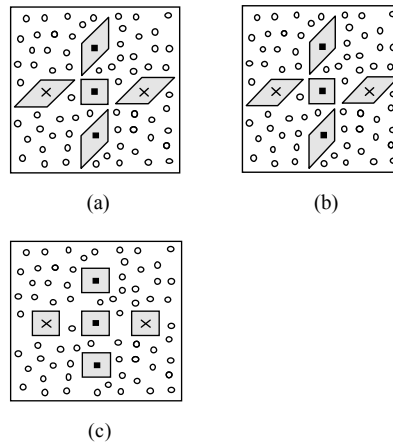


그림 2. 지역 융기를 이용한 패턴 분류: (a): 4쌍의 시그모이드, (b): 2쌍의 가우스, 그리고 (c): 한 쌍의 코스가우스  
 Fig 2. Pattern classification using local bumps (a): with four pairs of the sigmoids, (b): with two pairs of the gaussians and (c): with a pair of the CosGauss functions.

본 논문에서는 벤치마크 문제의 하나인 이중 나선 문제를 해결하기 위하여 캐스케이드 코릴레이션 학습 알고리즘을 소개하고 그의 특징에 대해서 알아본다. 실험에 사용할 새로운 코스가우스 활성화 함수를 소개하고 함수의 파라미터 값에 따른 등성이 수 및 형태의 차이점에 대해서 기술한다. 코스가우스 활성화 함수의 좋은 파라미터 값을 찾기 위하여 파라미터 값을 변경하면서 실험한 결과를 토대로 좋은 값을 가지고 이중나선 패턴 인식을 위한 실험을 하여 최종적으로 패턴 공간에서 인식한 이중 나선을 보여 준다.

### II. 캐스케이드 코릴레이션 알고리즘

캐스케이드 코릴레이션(Cascade Correlation) 네트워크[1]는 학습 중에 스스로 네트워크를 형성하므로 문제해결을 위하여 전문가가 미리 네트워크를 설계할 필요가 없는 특징을 갖고 있다. 초기 캐스케이드 코릴레이션 네트워크는 은닉 유닛과 은닉층 없이 입력뉴런과 출력뉴런의 완전한 연결에 의하여 구성된다. 캐스케이드 코릴레이션 학습 알고리

즘에서 은닉 유닛들은 네트워크에 한 번에 한 개씩 추가되고 선택된 가중치의 값은 변화하지 않는다. 여기에서 추가할 유닛의 출력과 네트워크의 잔여오차의 상호관계값(correlation value)의 극대화를 시도한다. 새로운 한 은닉 유닛의 생성을 위하여, 후보유닛(candidate unit)이 학습할 수 있는 시그널은 네트워크의 모든 입력과 이미 존재하고 있는 모든 은닉 유닛들과의 연결들을 통하여 전달된다. 여기에서 이 후보 유닛의 출력은 아직 네트워크와는 연결되지 않은 상태이다. 네트워크는 주어진 패턴들에 대하여 한번의 학습 후에 후보유닛들의 입력가중치(input weight)를 수정한다. Si의 극대화를 위한 수정은 다음과 같이 정의한다: Si는 한 후보유닛 i에서 생성된 값 c와 모든 출력유닛 o에서 측정된 잔여출력오차 Eo의 상호관계(correlation)의 합계로 나타낸다.

$$S_i = \sum_o \left| \sum_p (c_{pi} - \bar{c}_i)(E_{po} - \bar{E}_o) \right| \dots\dots\dots (1)$$

식 (1)에서 E<sub>po</sub>는 패턴 p에 대한 출력유닛 o에서의 오차이고 c<sub>pi</sub>는 패턴 p에 대한 후보유닛 i의 출력이다.  $\bar{c}_i$ 는 모든 패턴들에 대한 후보유닛 i의 평균출력이고  $\bar{E}_o$ 는 모든 패턴들에 대한 출력유닛 o에서의 평균오차이다.

후보유닛 i의 입력을 위한 연결에서의 가중치 w<sub>ij</sub>에 대한 Si의 편미분의 유도식은 다음과 같다:

$$\begin{aligned} \frac{\partial S_i}{\partial w_{ij}} &= \sum_o \frac{\partial}{\partial w_{ij}} \left| \sum_p (c_{pi} - \bar{c}_i)(E_{po} - \bar{E}_o) \right| \\ &= \sum_o \left( \text{sign} \left[ \sum_p (c_{pi} - \bar{c}_i)(E_{po} - \bar{E}_o) \right] \right. \\ &\quad \left. \sum_p \frac{\partial}{\partial w_{ij}} [(c_{pi} - \bar{c}_i)(E_{po} - \bar{E}_o)] \right) \\ &= \sum_o \left( \text{sign} \left( \sum_p (c_{pi} - \bar{c}_i)(E_{po} - \bar{E}_o) \right) \right. \\ &\quad \left. \sum_p \frac{\partial c_{pi}}{\partial w_{ij}} (E_{po} - \bar{E}_o) \right) \dots\dots\dots (2) \end{aligned}$$

$\sigma_o$ 를 다음과 같이 정의하면

$$\sigma_o = \text{sign} \left( \sum_p (c_{pi} - \bar{c}_i)(E_{po} - \bar{E}_o) \right)$$

식 (2)는 다음과 같이 쓸 수 있다.

$$\frac{\partial S_i}{\partial w_{ij}} = \sum_o \sum_p \sigma_o \frac{\partial}{\partial \text{net}_{pi}} f_p(\text{net}_{pi}) \frac{\partial \text{net}_{pi}}{\partial w_{ij}} (E_{po} - \bar{E}_o)$$

따라서 Si의 편미분은 다음과 같다:

$$\frac{\partial S_i}{\partial w_{ij}} = \sum_o \sum_p \sigma_o f'_p I_{pi} (E_{po} - \bar{E}_o) \dots\dots\dots (3)$$

식 (3)에서  $\sigma_o$ 는 후보유닛 i에서 패턴 p에 대한 출력 c<sub>pi</sub>와 출력유닛 o에서 패턴 p에 대한 오차 E<sub>po</sub>와의 상호관계 값의 부호를 나타낸다.  $f'_p$ 는  $\text{net}_{pi}$ 에 대한 후보유닛 i의 활성화함수의 미분이고  $I_{pi}$ 는 패턴 p에 대한 후보유닛 i의 입력을 의미한다.

Si의 극대화를 위한 후보유닛의 학습과 오차수정을 위한 출력뉴런의 학습은 quickpropagation 알고리즘[2]을 이용한다.

캐스케이드 코릴레이션 학습 알고리즘의 특성:

- 1) 알고리즘은 네트워크의 크기와 형태(즉 은닉층과 은닉 유닛의 수 그리고 그에 따른 연결)를 스스로 형성한다.
- 2) 학습과정에서 각 유닛들의 연결을 통해 시그널은 전진 전달(forward propagation)만 하므로 오차의 후진전달(backward propagation)은 필요로 하지 않는다.
- 3) 여러 후보유닛들이 풀(pool)을 형성하여 병렬로 학습할 수 있다.
- 4) 알고리즘은 오직 네트워크의 한 층과 관계된 가중치들만 학습 한다 (즉 한 그룹에 속한 후보유닛들과). 네트워크의 나머지 부분은 변경되지 않는다. 그에 따른 유닛의 활성화 값과 네트워크의 오차 값은 각 학습단계마다 저장되어 다시 사용 된다.
- 5) 새로운 유닛은 각 층에 한 유닛만 첨가되므로 학습과정 동안 매우 깊은 네트워크를 형성하고 이는 은닉유닛의 높은 fan-in의 요인이 된다.

6) 캐스케이드 코릴레이션 알고리즘은 증기학습(incremental learning)에 속하므로 이미 학습한 네트워크의 새로운 패턴들과 함께 다시 학습할 수 있다.

그림 3은 캐스케이드 코릴레이션 알고리즘의 학습 중에 네트워크가 성장하는 과정을 보여준다. 그림에서 사각형으로 표시된 연결들은 고정되고(한번 선택된 가중치는 다음 학습단계에서도 수정 없이 계속 사용된다), x와 함께 표시된 연결들은 반복해서 학습한다(각 학습단계마다 가중치는 다시 수정된다).

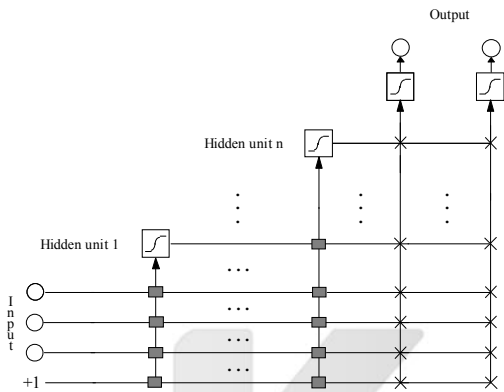


그림 3: (a) 캐스케이드 코릴레이션의 설계, Fig. 3. Cascade-Correlation architecture

### III. 코스가우스 함수


코스가우스 함수의 정의와 그의 미분은 다음과 같다.

$$f_{act}(x) = e^{-\beta_{\mu}(x-\theta_{\mu})^2} \cos(\gamma_{\mu}(x-\theta_{\mu}))$$


$$f'_{act}(x) = -2\beta_{\mu}(x-\theta_{\mu})e^{-\beta_{\mu}(x-\theta_{\mu})^2} \cos(\gamma_{\mu}(x-\theta_{\mu})) - \gamma_{\mu}e^{-\beta_{\mu}(x-\theta_{\mu})^2} \sin(\gamma_{\mu}(x-\theta_{\mu}))$$

함수에서  $\beta_{\mu}$ 는 가우스함수의 기울기를 나타내고  $\theta_{\mu}$ 는 하이퍼플레인(hyperplane)의 위치를 결정한다. 코스가우스 함수의 최대값은 항상 하나이고  $\gamma_{\mu}$ 는 주기의 길이를 제어한다. x축(x-axis)의 정의된 구간에서 등성이의 수는 파라미터  $\gamma_{\mu}$ 와  $\beta_{\mu}$ 의 값에 의존한다.


함수에서 파라미터  $\gamma_{\mu}$ ,  $\beta_{\mu}$ 와  $\theta_{\mu}$ 의 관계를 설명하기 위하여 함수의 2차원적인 경우(two-dimensional case)를 예로 든다. 그림 4에서 (a)는 코스가우스 함수의 파라미터가  $\beta_{\mu}=1$  그리고  $\gamma_{\mu}=16$ 인 경우를 나타내고, 그림 4의 (b)는 같은 함수가 오른쪽으로 2만큼 이동한 경우를 보여준다. 그림 4의 (c)는 코스가우스 함수의 파라미터 값이  $\beta_{\mu}=0.5$ 이고  $\gamma_{\mu}=16$ 인 경우를 나타내고, 그림 4의 (d)는 코스가우스 함수의 파라미터 값이  $\beta_{\mu}=0.3$ 이고  $\gamma_{\mu}=4$ 일 때 그의 미분 함수를 보여준다.



(b)  $e^{-(x-2)^2} \cos(16(x-2))$



(c)  $e^{-0.5x^2} \cos(16x)$



(d) 파라미터  $\beta_\mu=0.3$ 와  $\gamma_\mu=4$ 인 코스가우스 함수의 미분 함수

그림 4. (a): 코스가우스 함수 및 파라미터  $\beta_\mu=1$  그리고  $\gamma_\mu=16$ , (b): 코스가우스 함수의  $\theta_\mu=2$  만큼 이동, (c): 코스가우스 함수 및  $\beta_\mu=0.5$  그리고  $\gamma_\mu=16$ , (d): 코스가우스의 미분 함수 및  $\beta_\mu=0.3$  그리고  $\gamma_\mu=4$ .

Fig 4. (a): CosGauss function with parameters  $\beta_\mu=1$  and  $\gamma_\mu=16$ , (b): Shifting the CosGauss function by  $\theta_\mu=2$ , (c): CosGauss function with  $\beta_\mu=0.5$  and  $\gamma_\mu=16$ , and (d) a derivative function of the CosGauss function with  $\beta_\mu=0.3$  and  $\gamma_\mu=4$ .

그림 5는 파라미터  $\beta_\mu=0.2$ 와  $\gamma_\mu=8$ 의 코스가우스 함수의 3차원 표현(three dimensional representation)을 보여주고 그림 6은 한 쌍의 함수로 구성 된 등성이들의 교차 (intersecting ridges)를 나타낸다. 그림 7과 그림 8은 같은 함수이지만 기준평면(ground plane) 0과 1에서 도식하였다.




그림 5. 코스가우스 함수의 3차원 표현 및  $\beta_\mu=0.2$  그리고  $\gamma_\mu=8$ .  
Fig 5. Three-dimensional representation of CosGauss function with  $\beta_\mu=0.2$  and  $\gamma_\mu=8$ .




그림 6. 한 쌍의 코스가우스 함수 및  $\beta_\mu=0.2$  그리고  $\gamma_\mu=8$ .  
Fig 6. A pair of CosGauss functions  $\beta_\mu=0.2$  and  $\gamma_\mu=8$ .




그림 7. 그림 5와 같은 함수로써 기준 평면 0.  
Fig 7. Same as figure 5, but ground plane set at 0.




그림 8. 그림 5와 같은 함수로써 기준 평면 1.  
Fig 8. Same as figure 5, but ground plane lifted by 1.

#### IV. 파라미터 값 결정을 위한 실험

본 논문에서 제안하는 새로운 코스가우스 함수는 캐스케이드 코릴레이션 네트워크를 이용하여 중요한 벤치마크 문제인 이중 나선 문제를 해결하기 위하여 학습하였다[1]. 시그모이드 함수를 네트워크의 출력 유닛(output units)에

사용하고 코스가우스 함수를 후보자 유닛(candidate units)에 사용하였다. 코스가우스 함수의 파라미터는  $\beta_{\mu}=1$ 과  $\theta_{\mu}=0$ 을 사용하였고  $\gamma_{\mu}$ 의 값을 1부터 50까지 변화시키면서 실험하여 그림 9의 y축은 학습에 필요한 에폭스(epochs), 그리고 그림 10의 y축은 생성된 은닉 유닛(hidden units)의 수를 나타냈다. 두 그림에서 x축은  $\gamma_{\mu}$ 의 값은 의미한다. 캐스케이드 코릴레이션 알고리즘에서는 패턴 공간에서 패턴인식을 위한 수렴을 빨리해야하기 때문에 학습 완료에 필요한 에폭스의 수와 은닉 유닛의 수는 적을수록 좋다. 따라서 네트워크 성능을 가름하는 중요한 기준이 된다.




그림 9. 파라미터  $\gamma_{\mu}$ 에 대한 에폭스의 수  
Fig 9. Number of epochs against parameter  $\gamma_{\mu}$ .




그림 10. 파라미터  $\gamma_{\mu}$ 에 대한 생성된 은닉 유닛 수  
Fig 10. Number of new produced hidden units against parameter  $\gamma_{\mu}$ .

아래의 그림 11과 그림 12는 코스가우스 함수의 파라미터 값을  $\gamma_{\mu}=19$ 을 설정하고  $\theta_{\mu}=0$ 의 값을 유지하면서  $\beta_{\mu}$  값의 변화에 따른 학습에서 학습 완료 후에 에폭스의 수와 새로이 생성된 은닉 유닛의 수를 나타낸다.




그림 11. 코스가우스 함수의 파라미터  $\gamma_{\mu}=19$ 와  $\theta_{\mu}=0$ 에서  $\beta_{\mu}$  값의 변화에 따른 에폭스의 수  
Fig 11. Number of epochs with varying parameters  $\beta_{\mu}$ ,  $\gamma_{\mu}=19$  and  $\theta_{\mu}=0$  of the CosGauss function.




그림 12. 코스가우스 함수의 파라미터  $\gamma_{\mu}=19$ 와  $\theta_{\mu}=0$ 에서  $\beta_{\mu}$  값의 변화에 따른 생성된 은닉 유닛의 수  
Fig 12. Number of new produced hidden units with varying parameters  $\beta_{\mu}$ ,  $\gamma_{\mu}=19$  and  $\theta_{\mu}=0$  of the CosGauss function.

위의 실험 결과에 의하면 파라미터  $\beta_{\mu}$ 의 값이 0.00001으로 선택되었을 때 에폭스의 수가 492, 생성 은닉 유닛의 수가 7개로 최소값을 형성하였으므로 앞으로의 실험에 이 값을  $\beta_{\mu}$ 의 파라미터 값으로 사용한다.

## V. 선택된 파라미터 값을 갖는 코스가우스 함수의 시각화 및 실험

실험을 위한 파라미터는  $\gamma_{\mu}=19$ 와  $\beta_{\mu}=0.00001$ 을 사용하고 캐스케이드 코릴레이션 네트워크의 학습을 통하여 이중 나선 문제(two spirals problem)를 해결한다. 이중 나선 문제에서의 입력은 범위가  $-6.5$ 에서  $6.5$ 까지의 x축과 y축의 값에 의해서 구성되기 때문에 한 쌍의 코스가우스 함수는 구간  $-6.5 \leq x \leq 6.5$ 와  $-6.5 \leq y \leq 6.5$ 에서 선택한 값을 가지고

예를 들어 설명한다. 이 함수는 가우스함수의 감쇄율이 매우 작기 때문에 많은 등성이를 생성한다. 그림 13은 이중나선 문제를 위한 패턴 공간(pattern space)에서 트레이닝 포인트(training points)를 보여준다. 그림 14의 (a), (b), (c)는 다양한 구간에서 코스가우스 함수의 지역 구릉(local hills)을 나타낸다. 그리고 코스가우스 함수는 대칭적이다.







그림 13. 이중 나선 문제의 트레이닝 포인트  
Fig 13. Training points for the two spirals problem



(a):  $-0.4 \leq x \leq 0.1$  and  $-0.1 \leq y \leq 0.4$



(b):  $2.6 \leq x \leq 3.1$  and  $-3.1 \leq y \leq -2.6$



(c):  $5.9 \leq x \leq 6.4$  and  $-0.1 \leq y \leq 0.4$

그림 14. 파라미터  $\beta_{\mu} = 0.0001$ ,  $\gamma_{\mu} = 19$ 를 갖고 있는 코스가우스 함수의 지역 구릉  
Fig 14. Local hills of the CosGauss function with parameters  $\beta_{\mu} = 0.0001$ ,  $\gamma_{\mu} = 19$ .

학습 성능을 비교하기 위해서 코스가우스 함수를 활성화 함수로 사용하여 다른 활성화 함수의 결과 값과 비교한다. 그림 14에서 선택된 값을 사용하여 10회 실험한 값을 나타냈다. 일반적인 활성화 함수로서 가우스(gaussian), 하이퍼볼릭 탄젠트(hyperbolic tangent), 시그모이드(sigmoid), 대칭 시그모이드(symsigmoid)를 사용하였다. 그림 15에서는 학습 후의 에폭스의 수를 그림 16에서는 생성된 은닉 유닛의 수를 그래프로 나타내었다. 그림 15와 그림 16의 맨 오른쪽은 결과의 평균값을 의미한다. 그리고 Symsigmoid 함수는 대칭 시그모이드(symmetric sigmoidal) 함수를 의미한다. 에폭스의 수와 생성된 은닉 유닛의 수는 10회 실험한 평균값을 표 1에 나타냈다.

표 1. 코스가우스와 다른 활성화 함수를 사용한 실험의 평균 값  
Table 1. Listing of the average values using CosGauss and other activation functions

Activation functions	Epochs	Units
CosGauss: $\beta_{\mu} = 0.0001$ and $\gamma_{\mu} = 19$	653.3	8.9
Gaussian	2067.8	17.5
Symsigmoid	2086.3	13.3
Sigmoid	2585.1	15.4
Tanh	1870.2	12.9




그림 15. 코스기우스와 다른 활성화 함수를 사용한 에폭스의 수 비교. 코스기우스 함수:  $\beta_{\mu}=0.0001$ 과  $\gamma_{\mu}=19$ .  
 Fig 15. Comparison of the number of epochs using the CosGauss and other activation functions. CosGauss function:  $\beta_{\mu}=0.0001$  and  $\gamma_{\mu}=19$ .




그림 16. 코스기우스와 다른 활성화 함수를 사용하여 새로이 생성된 은닉 유닛의 수 비교.  
 코스기우스 함수:  $\beta_{\mu}=0.0001$ 과  $\gamma_{\mu}=19$ .  
 Fig 16. Comparison of the number of new produced hidden units using CosGauss- and other activation functions.  
 CosGauss function:  $\beta_{\mu}=0.0001$  and  $\gamma_{\mu}=19$ .

테스트 결과에 의하면 학습 속도 판단의 기준이 될 수 있는 에폭스의 수는 다른 활성화 함수에 비해서 약 3배 이상 적게 기록하였으므로 3배 이상으로 빠르게 학습하는 것을 확인할 수 있다. 또한 학습 완료 후에도 다른 활성화 함수에 비해서 상당히 적은 은닉 유닛이 사용되어 작은 네트워크를 형성 하였다.

아래 그림 17은 코스기우스 함수를 사용하여 학습 완료 후에 패턴 공간에서 인식한 이중 나선을 보여준다.




그림 17. 코스기우스 함수를 사용하여 패턴 공간에서 인식 된 이중 나선  
 Fig 17. recognized two spirals in pattern space using CosGauss function



그림 18은 시그모이드 함수를 사용한 후에 패턴 공간을 보여준다.

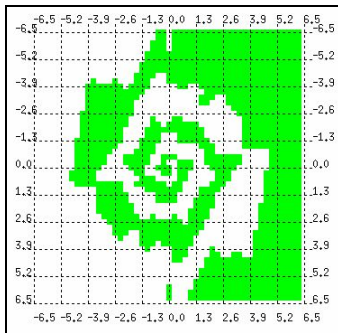


그림 18. 시그모이드 함수를 사용하여 패턴 공간에서 인식 된 이중 나선

Fig 18. recognized two spirals in pattern space using sigmoid function

## VI. 결론 및 향후 과제

새로운 활성화 함수인 코스가우스 함수를 활성화 함수로 사용함으로써 캐스케이드 코릴레이션 학습 알고리즘의 패턴 인식 실험을 통해서 학습 능력이 상당히 향상되었음을 확인 하였다. 코스가우스 활성화 함수의 최적화된 파라미터 값을 찾기 위해서 다양한 값으로 10회의 실험을 진행하였고 그 결과를 갖고 그중에서 가장 좋은 값을 선택하였다. 향후에는 일반적인 패턴 인식 등의 문제를 해결하기 위하여 유전자 알고리즘(genetic algorithm) 등을 이용하여 학습능력을 최적화 시킬 수 있는 가장 좋은 코스가우스 함수의 파라미터 값을 찾는 것이다.

### 참고문헌

[1] Fahlman, S. E. and Lebiere, C., "The cascade-correlation learning architecture", S. Touretzky, Editor, *Advances in Neural Information Processing Systems 2*, Morgan Kaufmann, 1990.

[2] Fahlman, S. E., "Faster-learning variations on back-propagation: An empirical study", *Proceedings of the 1988 Connectionist Models Summer School*. Morgan Kaufmann, 1988.

[3] Lee, S. W., "Verallgemeinerte Neuronale Netze mit kaskadierter Korrelations-Architektur", 16. Workshop Interdisziplinäre Methoden in der Informatik, Haus Nordhelle, Meinerzhagen Valbert. Fakultät für Informatik, Universität Dortmund, Germany, 16-19. 08 2000.

[4] 강경아, 이기준, 정채영, "은닉노드의 특징 값을 기반으로 한 최적신경망 구조의 BPN성능분석", *한국컴퓨터정보학회논문지*, 1598-849X, 제5권2호, pp. 30-36, 2000.

[5] 김성완, "MLP 신경망을 위한 시공간 병렬처리모델", *한국컴퓨터정보학회논문지*, 1598-849X, 제10권 5호, pp.95-102, 2005.

[6] 정진구, "신경회로망을 이용한 시스템의 실시간 고장 감지 및 진단 방법", *한국컴퓨터정보학회논문지*, 1598-849X, 제3권2호, pp. 147-154, 1998.

### 저자 소개



#### 이상화

1998년 11월 : University of Dortmund (Germany) 컴퓨터공학박사  
 2000. 2 ~ 2002. 8 : 한국전자통신연구원(ETRI) 선임연구원  
 2002. 9 ~ 현재 : 서원대학교 컴퓨터정보통신공학부 교수  
 관심분야: 지능형 시스템, 인공지능, 광통신, 데이터통신



#### 송해상

2000년 8월 : 한국과학기술원 컴퓨터공학박사  
 1999.1 ~ 2000.8 고등기술연구원  
 2000. 9 ~ 2002. 8 : (주) 스페이스네트 연구소장  
 2002. 9 ~ 현재 : 서원대학교 컴퓨터정보통신공학부 교수  
 관심분야: 이산사건 시스템 모델링 & 해석, 소프트웨어공학, 임베디드시스템, 데이터통신