

PCA 기법에 의한 회귀분석 신경망의 성능개선

조용현, 박용수^o

대구가톨릭대학교 공과대학 컴퓨터정보통신공학부

Performance Improvement of Regression Neural Networks by Using PCA

Yong-Hyun Cho, Yong-Soo Park^o

School of Computer and Information Communications Eng., Catholic University of Taegu

요약

본 논문에서는 주요성분분석 기법을 도입하여 회귀분석을 위한 신경망의 성능 개선 방안을 제안하였다. 이는 대용량의 입력 데이터를 통계적으로 독립인 특징들의 집합으로 변환시키는 주요성분분석 기법의 속성을 살려 학습데이터의 차원을 감소시킴으로써 고차원의 학습데이터에 따른 신경망의 학습성능 의존성을 줄이기 위함이다. 제안된 기법의 신경망을 10개의 독립변수 패턴을 가진 자동차 연비문제에 적용하여 시뮬레이션한 결과, 기존의 학습데이터를 그대로 이용하는 신경망보다 우수한 학습성능과 회귀성능이 있음을 확인할 수 있었다.

1. 서론

회귀분석은 하나의 종속변수가 다른 독립변수들에 의해 어떻게 설명 또는 예측되는지를 알아보기 위해 적절한 함수로 표현하여 자료분석을 하는 통계적인 기법이다^[1-5]. 이러한 회귀분석은 모수 추정을 포함한 관계의 기술이나 새로운 것에 대한 예측, 그리고 통계적 제어 등에 널리 이용되고 있다.

기존의 수치적인 기법에 기초한 회귀분석에는 독립변수의 개수나 종속변수와 독립변수들의 관계에 따라 여러 가지 회귀기법들로 나누어진다^[1-2]. 일반적으로 다항회귀 (polynomial regression)와 다중선형회귀분석 (multiple linear regression)이 많이 이용되고 있다. 이들 기법들에서는 주어진 자료들로부터 독립변수와 종속변수의 상관관계에 대한 사전지식을 통하여 회귀분석 방정식의 모델을 설정하고 회귀계수들의 값은 통계적으로 결정하였다. 하지만 문제에 따라서는 이러한 모델의 설정이나 계수들의 결정이 매우 힘든 제약들은 여전히 존재한다.

기존 수치적 기법들이 가지는 제약들을 해결하기 위해서 입력과 출력간의 사상을 가능하게 하며, 대규모 분산병렬처리와 학습, 그리고 일반화 등의 속성을 가지는 신경망이 널리 이용되고 있다^[3-8]. 신경망을 이용하는 기법 중에서 입력층과 출력층 사이에 은닉층을 가지는 다층전향신경망은 입력층 데이터 내에 포함된 어떤 비선형 연속함수도 근사화하거나 재구성할 수 있어 대단히 일반적이면서도 융통성 있는 속성을 가지고 있다. 이러한 신경망에는 일반회귀신경망 (general regression neural network : GRNN)과 역전파 (backpropagation : BP) 알고리즘의 다층신경망 (multilayer perceptron : MLP)이 이용된다^[5-8].

GRNN^[3,4]은 입력층간 확률밀도함수의 추정에 기반을 둔 memory-based 전향신경망으로 학습알고리즘이 대단히 간단하고 구현이 용이하며, 학습시간이 요구되지 않는 매우 빠르면서도 고신뢰성을 가지는 회귀분석 신경망이다. 그러나 여기에도 독립변수 패턴의 고차원 문제, 최적의 평활요소 및 중앙값 설정, 회귀분석을 위한 데이터 내 변화를 정확하게 측정하기 위한 많은 학습패턴 요구 등의 제약들이 있다.

한편, MLP는 충분한 뉴런을 가지고 있을 때 어떤 임의의 함수도 근사화할 수 있다고 알려져 있지만 유용한 모델을 얻기 위해서는 많은 학습데이터와 시험데이터가 요구된다. 특히, 기물기하강의 속성을 이용하는 역전파 알고리즘은 학습파라미터의 설정에 따라 수렴속도와 건설성 중 하나 이상의 제약을 가지며, 전역최적해로의 수렴이 보장되어 있지 않다. 이러한 문제를 해결하기 위한 여러 방법들이 연구되어 왔다^[6]. 특히 MLP 학습에 이용된 독립변수 패턴의 고차원은 학습시간의 증가와 함께 회귀분석 성능의 저하를 유발하게 된다^[1-5]. 이를 해결하기 위해 기존의 방법들에서는 다중공선성 분석이나 변수변환 등의 방법들이 이용되고 있다^[1,2]. 그러나 척도들을 계산하는 데는 표본의 평균과 표준편차, 독립변수 행렬의 고유벡터와 고유값 등의 계산이 요구되며, 그 계산 또한 매우 복잡하여 계산시간이 오래 걸린다.

본 연구에서는 수치적인 데이터 집합의 차원을 해석하여 이를 감소시키는 것으로 널리 알려진 적응적 주요성분분석 (principal component analysis : PCA) 기법^[6-9]으로 독립변수 벡터의 특징을 추출한 다음, 추출된 특징을 입력으로 하는 역전파 알고리즘의 신경망을 이용한 회귀분석 모델을 제안한다. 제안된 회귀분석 신경망을 10개의 독립변수 패턴을 가진 자동차 연비문제^[2]에 각각 적용하여 시뮬레이션하고

그 타당성을 확인하였으며, 기존의 PCA를 이용하지 않은 MLP와 그 성능을 비교 고찰하였다.

2. 다중신경망을 이용한 회귀분석

회귀분석 모형으로는 종속변수와 독립변수들 상호간에 선형적 함수관계로 표현되는 다중선형회귀 모형이 주로 이용된다. 이는 선형의 함수관계로 표현되지만 독립변수들 내의 비선형 관계를 다소 나타낼 수 있기 때문에 일반적인 표현식은 다음과 같다. 즉,

$$y = X\beta + \epsilon \quad (1)$$

이다. 여기서 종속변수 벡터 $y = [y_1, y_2, \dots, y_n]^T$, $\epsilon = [\epsilon_1, \epsilon_2, \dots, \epsilon_n]^T$, $\beta = [\beta_0, \beta_1, \dots, \beta_p]^T$ 이며, 독립변수 X 는 $n \times (p+1)$ 의 행렬이다. 개개의 오차 ϵ_i 는 정규분포를 따르며 ϵ 은 기대값 0과 분산 σ^2 을 가진다. 식으로부터 추정계수 벡터 β 를 구해야 하며, 이를 위해서 직접적인 방법과 반복적인 방법이 이용될 수 있다. β 를 구하는 방법으로 오차를 최소화하는 최소제곱추정법은 직접적인 계산방법으로 지금까지 많은 연구에서 주로 이용되고 있다^[1]. 이 방법으로 구해지는 회귀계수 β^* 와 오차 ϵ 은 각각

$$\begin{aligned} \beta^* &= (X^T X)^{-1} X^T y \\ \epsilon &= y - X\beta^* = (I - X(X^T X)^{-1} X^T)y \end{aligned} \quad (2)$$

와 같이 표현된다. 그러나 이 식은 행렬을 이용한 식으로 독립변수 행렬 X 가 역행렬로 표현될 수 있어야 한다는 조건이 선행되어야 한다. 조건이 만족될 경우 회귀계수 β 를 구하는 수치적인 방법들을 이용하여 다소 정확한 해는 구할 수 있으나 독립변수의 차원이 높을 경우 수학적 계산이 매우 복잡하여 계산시간이 오래 걸리는 제약이 있다. 이러한 제약을 줄이기 위해 고차원의 다항식을 이용한 Polynomial regression 방법^[2]도 소개되었으나 이 방법 역시 어떤 차원의 다항식을 이용하는가에 따라 그 정확도가 달라지는 단점이 있다.

한편 회귀계수 β 를 구하기 위해 반복적인 방법의 수치적인 기법들이 이용된다. 이 방법들은 유한시간 내에 직접적인 방법보다 더 정확한 해는 구할 수 없으나 역행렬 계산이 요구되지 않아 상대적으로 계산양도 적으며 중간 결과들을 저장하기 위한 기억장소도 적게 요구되는 장점을 가져 많이 이용되고 있다. 이 기법들도 순차적인 알고리즘을 이용하는 것으로 반복수행에 따른 계산시간은 여전히 제약으로 남아 있다. 따라서 기존의 수치적인 기법에 의한 다중선형 회귀분석에서 계산량에 따른 계산시간을 줄이면서도 입력인 독립변수가 종속변수에 대해 가지는 비선형 속성도 잘 반영할 수 있는 새로운 방법이 요구된다.

대규모 분산병렬처리와 학습, 일반화 등의 속성을 가지는 신경망은 수치적인 기법에 의한 다중선형 회귀분석에 대한 하나의 대안이 될 수 있을 것이다. 이는 다중신경망의 통계적인 속성은 비모수적이면서도 입출력 사이의 비선형관계를 잘 표현하기 때문이다. 그림 1은 입력인 독립변수 A와 B, 출력인 종속변수 y, 입력층과 출력층의 연결가중치가 각각 $\alpha_0, \alpha_1, \alpha_2, \alpha_3$ 및 β_0 와 β_1 인 3층 신경망을 나타낸 것이다. 그림에서 출력 y는 출력층 연결가중치와 은닉층 뉴런 출력 V_0 와 V_1 에 의해서 결정되며, 함수관계식은

$$y = \beta_0 V_0 + \beta_1 V_1 = \beta_0 f(\alpha_0 A + \alpha_2 B) + \beta_1 f(\alpha_1 A + \alpha_3 B) \quad (3)$$




그림 1. 3층 신경망

와 같다. 식에서 f 는 비선형 단조증가함수로 s-자 형 함수가 널리 이용된다. 식 (3)은 식 (1)의 다중선형 회귀분석 모형과 동일한 형태로 신경망이 이에 적용될 수 있을 것이다. 즉 신경망에서 연결가중치들을 결정하기 위한 학습은 수치적 방법에서 반복적인 과정에 의해서 해를 얻는 과정이며, 그 연결가중치는 다중선형 회귀분석 모형에서의 회귀계수와 동일하다. 따라서 다중회귀분석은 다중신경망을 이용하여 이루어 질 수 있으며, 신경망이 가지는 우수한 비선형 관계 추출 특성을 더욱 더 잘 살릴 수만 있다면 신뢰성 높은 예측이 가능하게 된다.

3. 적응적 특징추출을 위한 PCA

PCA는 n차원 입력공간의 데이터를 m차원 출력공간의 데이터로 투영시키는 것이다. 여기서 $m < n$ 이며, 이는 입력데이터 벡터의 대부분 내부정보를 유지하도록 차원의 감소를 얻는 것이다. 자기상관행렬 $R_{xx} = \langle xx^T \rangle$ 를 가진 평균이 영인 입력벡터 $x = [x_1, x_2, \dots, x_n]^T$ 에 대해서 생각해 보자. 여기서 $\langle x \rangle$ 는 기대치를 나타낸다. w_1, w_2, \dots, w_m 이 R_{xx} 의 고유벡터와 직교되는 연결가중치 벡터라 할 때, $w_1 = [w_{11}, w_{12}, \dots, w_{1n}]^T$ 는 가장 큰 고유치 λ_1 과 일치하며, $w_2 = [w_{21}, w_{22}, \dots, w_{2n}]^T$ 는 두 번째로 큰 고유치 λ_2 와 $w_n = [w_{n1}, w_{n2}, \dots, w_{nm}]^T$ 는 가장 작은 고유치 λ_n 과 각각 일치한다. 이상의 관계를 행렬방정식으로 나타내면

$$R_{xx} w_j = \lambda_j w_j \quad (j = 1, 2, \dots, n) \quad (4)$$

이며, $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_n \geq 0$ 이다.

주어진 입력벡터 x 를 위한 첫 번째 m개의 주요 특징벡터 y 는 다음의 선형변환식으로 나타낼 수 있다. 즉,

$$y = W x \quad (5)$$

이다. 여기서 $W = [w_1, w_2, \dots, w_m]^T \in \mathbb{R}^{m \times n}$ 이며, T는 전치를 나타낸다. 이 식은 행렬 W의 행이 가장 큰 고유치와 일치하는 상관행렬 R_{xx} 의 고유벡터임을 의미한다. 결국 PCA는 $\langle \|w_j^T x\|^2 \rangle$ 가 최대한 고유벡터 w_1, w_2, \dots, w_m 의 방향을 찾는 것이다.

한편, 입력되는 데이터의 주요특징들을 추출하기 위한 기존의 수치적 기법에 의한 PCA 방법들은 먼저 자기상관행렬 R_{xx} 를 계산한 다음 그것과 일치하는 고유벡터를 계산하였다. 그러나 입력데이터 벡터가 대규모의 차원을 가진다면, 상관행렬은 대단히 크게 되어 요구되는 고유벡터를 찾는 것도 매우 복잡한 일이다. 이를 해결하기 위한 대안으로 상관행렬의 고유벡터를 실시간으로 추정하기 위하여 신경망을 이용하는 방법들이 제안되었다^[6-8]. 여기서는 입력벡터로부터 직접 고유벡터를 추정할 수 있기 때문에 상관행렬의

추정과정의 요구되지 않는다. 이때 이용되는 신경망은 주로 입력층과 출력층으로 구성된 단층구조이다.

Oja^[6]는 정규화된 헤비안규칙의 적응학습 방법을 이용한 간단한 뉴런모델을 제안하여 정상입력벡터 계열의 주요 특징으로 연결가중치 벡터가 수렴됨을 증명하였다. Sanger 등^[6]은 일반화된 헤비안규칙을 이용함으로써 정상과정의 m개의 가장 중요한 주요특징들을 계산하기 위한 다중 뉴런모델을 제안하였다. 한편, Foldiak^[7,8]은 망의 입력과 출력사이의 연결가중치 경신에는 정규화된 헤비안규칙을 이용하고, 망의 출력사이의 측면연결 가중치 경신에는 반 헤비안규칙을 함께 이용한 학습알고리즘을 제안하였다. 일반적으로 Sanger등에 의해 제안된 학습규칙보다는 Foldiak 에 의해 제안된 학습규칙이 수렴속도 면에서 더 우수한 것으로 알려졌다^[8].

n개의 입력뉴런과 m개의 출력뉴런으로 구성된 입력과 출력뉴런간 및 출력뉴런 상호간의 측면연결을 가진 단층신경망에서 입력과 출력의 관계를 나타내면

$$y_i = \sum_{j=1}^n w_{ij} x_j + \sum_{h=1}^m u_{ih} y_h \quad (i=1,2,\dots,m) \quad (6)$$

이다. 여기서 w_{ij} 는 입력뉴런과 출력뉴런을 연결하는 연결가중치이고, u_{ih} 는 출력뉴런 상호간의 측면연결 가중치이다. 이때 출력뉴런 간의 상호연결을 보면 뉴런 i는 다만 h<i인 뉴런에만 연결된다. 입력과 출력뉴런 간의 연결가중치 경신에는 정규화된 헤비안규칙을 이용하고 출력뉴런 간의 측면연결가중치 경신에는 반 헤비안규칙을 이용하는 Foldiak의 학습알고리즘에서 입출력 뉴런간의 연결가중치 w_{ij} 의 경신규칙은

$$w_{ij}(t+1) = w_{ij}(t) + \eta [y_i(t)x_j(t) - w_{ij}(t)y_i(t)^2], \quad (i = 1,2,\dots,m, j = 1,2,\dots,n) \quad (7)$$

이고, 출력뉴런 간의 측면 연결가중치 u_{ih} 의 경신규칙은

$$u_{ih}(t+1) = u_{ih}(t) + \rho y_i(t)y_h(t), \quad (i>h) \quad (8)$$

이다. 식 (7)의 η 와 (8)의 ρ 는 학습율이다. 따라서 식 (7)과 (8)을 이용하여 입력과 출력뉴런 간의 연결가중치 및 출력뉴런 상호간의 측면 연결가중치를 각각 경신시켜 식 (6)에 대입하면 m개의 주요특징들을 추출할 수 있다.

결국 PCA는 높은 차원의 입력공간을 더 낮은 차원의 표현공간으로 사상시켜 입력데이터가 가지는 두드러진 특징들을 추출하는 기법이다. 따라서 학습데이터의 독립변수 패턴 각각에 적응적 PCA를 이용하여 특징을 구한 다음 이를 회귀분석 다층신경망의 입력으로 이용한다. 이렇게 하면 다층신경망의 입력층 뉴런개수가 줄어들어 학습시간이 감소되며, 학습데이터의 고차원에 따른 독립변수들 상호 간의 다중공선성 등으로 인한 회귀성능의 저하도 해결할 수 있다.

4. 시뮬레이션 결과 및 분석

제안된 기법의 PCA가 도입된 회귀분석 다층신경망의 성능을 평가하기 위하여 Foldiak 학습알고리즘의 단층신경망과 3층 전향신경망을 각각 구성하였다. 이용된 단층신경망 및 다층신경망의 각 뉴런층 사이의 초기 연결가중치는 -1에서 +1 사이의 임의의 값으로 설정하였다. 학습은 전체 반복회

표 1. 자동차 연비자료

패턴수	입력조건										출력 독성 y
	x ₁	x ₂	x ₃	x ₄	x ₅	x ₆	x ₇	x ₈	x ₉	x ₁₀	
1	6	160	110	3.9	2.62	16.46	0	1	4	4	21
2	6	160	110	3.9	2.875	17.02	0	1	4	4	21
24	8	350	245	3.73	3.84	17.05	0	0	3	4	13.3
25	8	400	175	3.08	3.845	18.9	0	0	3	2	19.2
32	4	121	109	4.11	2.78	18.6	1	1	4	2	21.4

수가 20,000 이상이거나 전체 오차값이 허용치 10^{-4} 이하일 때 종료되도록 하였다. 제안된 기법의 신경망을 32개의 패턴(10개 독립변수)을 가진 자동차 연비문제를 대상으로 펜티엄III-700 컴퓨터를 이용하여 시뮬레이션한 후 그 타당성을 확인하였으며, 기존의 독립변수를 그대로 이용하는 신경망과 그 성능을 각각 비교 고찰하였다.

자동차 연비문제는 10개의 독립변수에 대하여 1개의 종속변수를 가진 회귀분석 문제이다. 이 문제는 실린더 수(x₁), 입방인치 단위의 배기량(x₂), 마력(x₃), 최종기어비인 최종구동장치비(x₄), 자동차 무게(x₅), 순간가속도(x₆), V자형(0)이나 직선형(1)의 엔진형태(x₇), 자동(0)이나 수동(1)이나의 기어의 종류(x₈), 기어속도의 수(x₉), 그리고 기화기의 밸브수(x₁₀)에 대한 자동차 연비(y)와의 관계를 나타낸 것이다. 본 실험에서는 32개의 패턴데이터 중에서 25개는 학습패턴으로 나머지 7개는 시험패턴으로 이용하였다. 이용된 MLP에서 입력층 뉴런수는 독립변수의 개수와 동일하게 하고, 은닉층과 출력층 뉴런수는 각각 10개와 1개로 구성하였다. 다음의 표 1은 실험에 이용된 자료의 일부를 나타낸 것이다. 한편 실험에서는 임·출력 조건을 각각 최대값으로 나누어 1이하의 값으로 정규화하였다.

표 2는 학습율 $\eta=0.3$ 및 모멘트 $\alpha=0.7$ 로 32개 학습패턴 중에서 25개의 학습패턴에 대해 독립변수 개수 N을 조정하면서 학습한 후 학습반복수 N_l와 학습에 소요된 CPU 시간 t_{cpu}, 그리고 25개의 학습패턴에 대한 재생오차 T_o를 각각 나타낸 것이다. 표에서 독립변수 10은 원래의 입력조건 개수 9에 주요성분분석 기법이 적용되지 않은 경우이며, 나머지 9에서 2까지는 독립변수에 대한 특징을 추출하여 이를 입력조건으로 학습한 경우이다. 표에서 보면 독립변수가 10개인 경우는 학습조건을 만족하지 못하였으며, 학습패턴을 이용한 재생에서도 많은 오차가 있음을 알 수 있다. 그러나 10개의 입력조건으로부터 주요성분분석 기법을 이용하여 추출한 특징들을 이용하는 경우에 학습반복수나 학습시간에서 우수한 성능이 있음을 알 수 있으며, 또한 재생오차

표 2. 독립변수에 따른 학습성능과 회귀오차 변화

독립변수, N	10	9	8	7	6	5	4	3	2
학습반복수, N _l	20000	9789	2606	1836	2017	14333	18987	20000	20000
학습시간, t _{cpu}	53	24	7	3	4	37	43	44	42
재생오차, T _o	2.972 644	1.815 138	1.140 125	1.065 362	1.084 632	1.570 381	1.908 828	2.213 878	0.915 217

도 더욱 작음을 알 수 있다. 이는 독립변수 상호간의 의존성에 따라 학습성능의 저하뿐만 아니라 회귀성능도 떨어짐을 확인할 수 있다. 특히 추출된 특징의 수인 독립변수의 개수가 8개에서 5개 사이는 학습성능과 재생성능이 상대적으로 우수하지만 독립변수가 4개 이하인 경우는 나쁜 성능을 가진다. 이는 전체 10개의 입력조건이 가지는 속성이 추출한 4개 이하의 독립변수에는 충분히 반영되지 않음으로 추측된다. 따라서 제안된 기법은 각 독립변수 상호간에 많은 다중공선성을 가지는 회귀분석 문제에서는 우수한 성능이 있음을 추측할 수 있으며, 특히 입력조건 상호간에 선형적 연관성이 많을수록 더욱 더 우수한 성능이 있을 것으로 추측된다. 이는 제안된 기법은 데이터 상호간의 선형성을 바탕으로 주요성분인 특징을 추출하는 PCA 기법에 기반을 두고 있기 때문이다.




그림 2. 독립변수 N에 따른 전체오차 E의 변화

그림 2는 원 문제의 10개 독립변수와 제안된 방법으로 추출된 특징들을 9개에서 2개의 입력조건으로 각각 이용할 때 전체오차의 변화를 나타낸 결과이다. 여기서 회귀오차는 25개의 패턴으로 학습한 후 학습패턴 25개 및 시험패턴 7개의 재생에 따른 오차이며, 이들의 합인 32개 패턴 전체의 오차도 함께 나타내었다. 그림에서 보면 제안된 기법에 의해 구해진 9개에서 4개의 특징들을 독립변수로 각각 이용하는 경우 10개의 독립변수를 입력조건으로 이용하는 경우보다 학습패턴에 대한 회귀오차와 시험패턴에 대한 회귀오차가 더 적어 개선된 성능이 있음을 알 수 있다. 또한 입력조건을 감소시킬 경우에 전체오차가 상대적으로 줄어드는 것도 확인할 수 있다. 하지만 특징 3개 이하를 입력조건으로 이용할 경우는 상대적으로 더욱 더 큰 전체오차를 보여 이는 지나치게 입력변수를 줄일 경우 추출된 특징들이 독립변수들 각각의 속성을 충분히 잘 반영하지 못하기 때문이다. 여기서도 표 2에서와 유사한 특성을 나타내며, 특히 학습시키지 않은 시험패턴에 대한 회귀성능도 제안된 기법이 기존의 기법보다 우수함을 확인할 수 있다.

5. 결론

본 논문에서는 주요성분분석 기법을 도입하여 회귀분석을 위한 신경망의 성능 개선 방안을 제안하였다. 이는 대용량의 입력 데이터를 통계적으로 독립인 특징들의 집합으로 변환시키는 주요성분분석 기법의 속성을 살려 학습데이터의 차원을 감소시킴으로서 고차원의 학습데이터에 따른 신경망의 학습성능 의존성을 줄이기 위함이다.

제안된 기법의 다중신경망을 10개의 독립변수를 가진 32개 학습패턴의 자동차 연비문제에 적용하여 시뮬레이션한 결과, 기존의 PCA를 이용하지 않는 다중신경망에 의한 결과와 비교할 때 학습시간과 절대오차로 나타나는 회귀성능에서 더욱 우수함을 확인할 수 있었다.

향후 제안된 기법의 신경망을 좀 다양한 회귀분석 문제에 적용하고 다중공선성과 같은 회귀검증도 함께 고려되는 연구가 계속되어야 할 것이다. 또한 효율적인 응용을 위해서는 제안된 기법의 다중신경망에서 다른 성능결정 요소들에 대한 연구도 뒤따라야 할 것이다.

참고문헌

- [1] 허명희 외1, 'SAS 회귀분석,' 자유아카데미, 1996
- [2] 강명욱 외 3, '회귀분석: 모형개발과 진단,' 육곡출판사, 1997
- [3] D.F. Specht, "A General Regression Neural Network," IEEE Trans. on Neural Networks, vol.2, no.6, pp.568-576, Nov. 1991
- [4] T. Masters, 'Advanced Algorithms for Neural Networks: A C++ Sourcebook', John Wiley & Sons, Inc., New York, 1995
- [5] Y. Chtioui, S. Panigrahi, and L. Francl, "A Generalized Regression Neural Network and Its Application for Leaf Wetness Prediction to Forecast Plant Disease," Elsevier, Chemometrics and Intelligent Laboratory Systems, vol.48, pp.47-58, 1999
- [6] A. Cichock and R. Unbehauen, 'Neural Networks for Optimization and Signal Processing', John Wiley & Sons., New York, 1993
- [7] P. Foldiak, "Adaptive Network for Optimal Linear Feature Extraction," International Joint Conference on Neural Networks, Washington D.C., vol.1, pp.401-406, June 1989
- [8] K.I. Diamantaras and S.Y. Kung, 'Principal Component Neural Networks :Theory and Applications, Adaptive and Learning Systems for Signal Processing, Communications and Control', John Wiley & Sons, Inc., 1996