

신경망을 이용한 기상예측시스템에서 망구조 최적화를 위한 Pruning 알고리즘

이 기 준[†] · 강 명 아[†] · 정 채 영^{††}

요 약

최근, 기존의 통계적 분석방법과는 달리 시계열 데이터를 이용하여 미래의 연속적인 지배의 법칙을 예측하기 위한 신경 회로망 연구가 진행되고 있다. 본 논문에서는 빠르고 정확한 기상예측을 위하여 초기 임의 설계된 신경회로망의 은닉층중 과(過)설계된 은닉노드를 제거하는 Pruning 알고리즘을 제안하며, 이 제안한 알고리즘의 효율성을 증명하기 위하여 1987년부터 1996년까지의 수집된 기상데이터 22080건을 이용하여 기상예측 실험을 실행하였다. 실험을 통하여 초기 임의 구성된 $26 \times 50 \times 1$ 의 신경망은 제안된 pruning 알고리즘을 통하여 $26 \times 2 \times 1$ 구조로 최적화 되었고, 최적화된 신경망($26 \times 2 \times 1$)의 경우 오차온도 $\pm 0.5^\circ\text{C}$ 의 경우 평균 33.55%, $\pm 1^\circ\text{C}$ 의 경우 61.57%로 임의 설계된 구조($26 \times 50 \times 1$)의 29.31%, 54.47%에 비하여 우수하게 나타났고, 또한 계산횟수에서도 임의구성 신경망에 비하여 최고 25배이상 계산횟수를 줄일 수 있었다.

A Pruning Algorithm for Network Structure Optimization in the Forecasting Climate System Using Neural Network

Kee-Jun Lee[†] · Myung-A Kang[†] · Chai-Yeoung Jung^{††}

ABSTRACT

Recently, neural network research for forecasting the consecutive controlling rules of the future is being progressed, using the series data which are different from the traditional statistical analysis methods. In this paper, we suggest the pruning algorithm for the fast and exact weather forecast that excludes the hidden layer of the early optional designed neural network. There are perform the weather forecast experiments using the 22080 kinds of weather data gathered from 1987 to 1996 for proving the efficiency of this suggested algorithm. Through the experiments, the early optional composed $26 \times 50 \times 1$ neural network became the most suitable $26 \times 2 \times 1$ structure through the pruning algorithm suggested, in the optimum neural network $26 \times 2 \times 1$, in the case of the error temperature $\pm 0.5^\circ\text{C}$, the average was 33.55%, in the case of $\pm 1^\circ\text{C}$, the average was 61.57%, they showed more superior than the average 29.31% and 54.47% of the optional designed structure, also, we can reduce the calculation frequency more than maximum 25 times as compared with the optional structure neural network in the calculation frequencies.

† 정 회 원 : 조선대학교 대학원 전산통계학과
†† 종신회원 : 조선대학교 수학과 전산통계학부 교수
논문접수 : 1999년 8월 23일, 심사완료 : 2000년 1월 24일

1. 서 론

계절적 변화에 따른 기후의 특색은 인간의 사회적, 자연적 생활을 영위함에 있어 많은 영향을 미치고 있다. 특히 이상기후나 태풍, 홍수와 가뭄등 자연적 현상들은 인간의 사회전반적인 활동에 커다란 영향을 미치고 있으므로 이에 대한 정확한 예보와 대비가 절실히 필요하다[1].

그러나 기상변화에 대한 정확한 예측은 변동의 요인이 되는 주 인자들의 명확한 규정과 함께 기존의 데이터를 통한 예측 변동의 차를 최소화해야 가능하다. 하지만 현재의 기상예측기술로는 변동의 요인을 정확히 결정짓기가 어렵고, 문제의 성격상 기존의 예측방법으로는 정확한 기상예측을 기대한다는 것은 어려운 일이다[2].

최근에는 기존의 시계열 예측분야의 통계적인 방법보다 예측결과가 우수한 신경망 모델을 이용하는 방법이 널리 연구되고 있다[1-4]

신경망은 가중치를 갖는 연결을 이용하여 상호 작용을 하는 PE(Processing Elements)가 병렬로 구성된 시스템이다. 이러한 생물학적인 뉴런 기능을 단순화시킨 PE로 구성된 신경망은 고도의 병렬 처리, 적응성, 학습에 의한 일반화 능력, 결합허용, Robustness, 학습 능력 등의 강한 잇점을 보이고 있다[5, 6]. 그러나 대부분의 신경망을 이용한 문제들은 패턴 인식과 같은 방대한 데이터를 신속하게 처리 해야하기 때문에 학습에 소요되는 시간보다는 학습된 네트워크를 사용하여 실시간 환경에서 처리하고자 하는 문제를 해결하는데 걸리는 시간이 훨씬 중요하다.

따라서 다층 신경망 구조를 설계할 때 은닉층의 수와 은닉층 노드수를 결정하는 문제는 매우 중요하다. 일반적으로 은닉노드 수가 너무 적게 지정되면 주어진 입력패턴을 충분히 구분할 수 없게 되어 완전한 학습이 이루어지지 않는 반면, 너무 많이 지정하면 불필요한 연산의 실행과 기억장소의 낭비로 과적응(overfitting)이 일어나 일반성이 떨어져 인식율이 낮아지는 결과를 초래한다. 따라서 주어진 문제에 적합한 최적의 은닉노드 수로 구성된 신경망 구조가 인식성능에 가장 큰 영향을 주는 요인이 되고 있다.

최근에 이와 관련한 연구들이 제안되었고, Resampling Method나 Information Criteria를 이용한 최적화 알고

리즘이 제안되었다. 그러나 이러한 알고리즘은 계산량의 감소나 네트워크의 실질적인 수렴에 대한 만족도를 충분히 반영 못하고, Hiroaki의 Pruning 알고리즘의 경우 은닉노드의 특징값 결정시 노드의 가중치와 Offset에 대한 고려를 하지 않아 출력노드에 대한 영향력을 절대적으로 평가하기 어렵다[7].

본 논문에서는 대량의 기상 데이터를 처리하여야할 신경망 기상예측 시스템에서 최적의 신경망 구조를 결정할 수 있는 Pruning 알고리즘을 제안하고자 한다. 제안하는 알고리즘은 은닉노드의 연결강도와 offset 그리고 은닉층의 출력값을 이용하여 은닉층의 특징정보를 구하고, 이 특징정보를 은닉노드를 제거하기 위한 평가치로 사용하여 과다하게 구성된 은닉노드를 삭제함으로써 신경망 학습속도를 개선하고자 한다.

본 논문의 구성은 2장에서 기존의 Pruning 알고리즘을 기술하고 3장에서 제안한 Pruning 알고리즘을 소개한다. 4장에서 제안한 Pruning 알고리즘을 적용한 기상예측시스템을 소개하고 5장에서 실험을 통하여 제안한 방법의 타당성을 검증한 후 6장에서 결론을 맺는다.

2. 기존 연구동향

최적의 신경망 구조 설계를 위한 다양한 연구가 진행되었는데, 먼저 유전자 알고리즘을 이용하여 신경망의 노드수를 결정하는 방법과 유전자 알고리즘을 이용하여 신경망 노드를 제거하는(pruning)방법, 그리고 신경망의 학습을 수행하는 동안 역전파되거나 전전파된 정보값의 오류함을 이용하여 은닉층 노드를 결정하는 방법으로 크게 분류할 수 있다.

2.1 유전자 알고리즘을 이용한 신경망의 노드수 결정[8]

이 방법은 집단수준 진화능력의 유전자 알고리즘과 개체 수준의 탐색인 신경망 학습 능력을 병합한 방법으로 기존의 역전파 알고리즘 학습보다 성능이 향상된 결과를 나타내었다. 그러나 이 방법은 신경망을 유전자로 표현할 때 가중치 정보를 포함하지 않으면 새로운 구조가 형성될 때마다 가중치를 생성해야 한다. 유전자 알고리즘으로만 탐색하는 경우, 가중치를 2진화하면 가중치 개수가 작은 경우에는 가능하나, 개수가 증가하면 조기 수렴하거나, 탐색에 걸리는 시간이 많

아진다. 더욱이 문제의 특성에 따라 가중치를 실수로 부호화한 경우에는 가중치의 개수가 작은 경우에도 탐색이 잘 되지 않는 단점이 있다.

2.2 유전자 알고리즘을 이용한

신경망 노드 제거(Pruning)[9]

초기의 완전한 MLP 구조는 수렴되기 전에 일정 세대 동안 유전자 알고리즘을 이용하여 신경망 구조를 학습시키고 그 결과로 생성된 개체를 MLP 구조 축소 방법에 적용한다. 축소된 MLP 구조 중에서 가장 바람직한 MLP 구조를 결정하고 이 MLP 구조를 바탕으로 전체 값을 재 초기화 한다.

신경망의 필요없는 은닉노드를 pruning하는 방법이 기 때문에 수렴속도를 높이는대는 좋지만 역시 유전자 알고리즘을 이용한 학습방법을 사용하기 때문에 위에서 제시되었던 문제점이 해결되지는 못한다.

2.3 신경망의 학습수행중 오류함을 이용한

은닉노드수 결정

이 방법은 신경망의 학습을 수행하는 동안 역전파되거나 전전파된 정보값의 오류 함을 이용하여 은닉층 노드 수를 결정하는 것이다. 이것은 완벽한 학습을 수행한 후 노드의 제거 작업을 수행하고, 한 개의 노드를 제거하기 위하여 반복학습을 수행해야 한다. 따라서, 급격한 학습횟수의 감소는 최적화된 은닉층 노드 수를 결정함으로써 얻을 수 있다. 그러나 이 방법은 은닉노드를 제거하는데 은닉층의 출력값만을 사용하기 때문에 유효한 은닉노드까지 제거하는 단점이 있다.

기존의 연구들에서도 보여지듯이 신경망의 성능은 학습 알고리즘의 매개 변수에 의해 좌우되고 특히 가중치와 은닉층의 개수 및 노드의 개수에 큰 영향을 받는다는 것을 알 수 있다. 따라서, 본 논문에서는 학습 알고리즘의 매개변수로 구성된 특징정보를 가지고 신경망 노드 수를 결정하는 방법을 제안한다. 이 방법은 연결강도와 offset 그리고 은닉층의 출력값을 이용하여 은닉층의 특징정보를 구하고, 이 특징정보를 은닉노드를 제거하기 위한 평가치로 사용한다. 구해진 특징값 중 최대값을 갖는 노드를 감소대상에서 제외하고 나머지 은닉노드 특징값의 평균과 각 은닉노드의 특징값을 비교하여 평균보다 작은 특징값을 갖는 은닉노드를 pruning 시킴으로서 다층 신경망의 최적 구조를 결정한다.

3. 제안한 Pruning 알고리즘

단층 신경망으로부터 발전된 다층 신경망은 입력층, 1개 이상의 은닉층, 그리고 출력층으로 구성된 신경망으로써 일반적으로 다층 신경망의 학습 알고리즘으로 백 프로퍼게이션 학습 알고리즘이 널리 사용되고있다. 백 프로퍼게이션 학습방법은 식 (1)의 에러함수를 통하여 목표값에 접근되어간다.

$$E = \frac{1}{2}(d_k - y_k)^2 \tag{1}$$

이때 y_k 는 패턴에 대한 출력층 k 번째 노드의 출력값이고 d_k 는 교사데이터의 값이다. 식(1)은 가중치를 변경하여 에러를 최소화하는 최적의 가중치를 결정한다. 이때 식 (2)를 이용하여 가중치를 변경한다.

$$w_{ji}^{t+1} = w_{ji}^t + \alpha \delta x^k + \beta \Delta w^{k-1} \tag{2}$$

위 식 (2)에서 w_{ji}^t 은 뉴런 i 에서 뉴런 j 로의 가중치이고 α 는 학습율, δ 는 출력노드의 오차신호 x^k 는 은닉노드의 출력값, β 는 모멘텀, t 는 반복횟수를 나타내고 $\beta \Delta w^{k-1}$ 은 모멘텀항이다.

각층의 뉴런은 입력총합을 활성화함수에 적용시켜 각 노드의 출력값을 정한다. 이때 사용하는 활성화함수로는 식 (3)의 양극성 시그모이드 함수를 사용하며 -1(음) 또는 1(양)의 값에 근사하게 되는 출력값을 갖도록 조정한다.

$$x_j = \frac{1 - \exp(-\sum_i x_{ji})}{1 + \exp(-\sum_i x_{ji})} \tag{3}$$

먼저, 설계된 신경망 구조를 이용하여 백 프로퍼게이션 학습알고리즘을 수행하여 학습이 수렴되면 식 (4)를 이용하여 은닉노드의 특징값을 구한다. 여기서 C_j 는 j 번째 은닉노드의 특징값이며, w_{ji} 는 i 번째 입력노드에서 j 번째 은닉노드의 가중치, H_j 는 j 번째 은닉노드의 출력값, θ_j 는 j 번째 은닉노드의 옵셋값이다.

$$C_j = w_{ji} * H_j * \theta_j \tag{4}$$

특징값 C_j 가 클수록 ($|x_j| \approx 1$) 특징값이 작을때 ($|x_j| \approx 0$)에 비하여 출력노드에 강한 역할을 수행한다고 할 수 있다. 제안된 은닉노드 감소 알고리즘은

학습 수렴시 사용되지 않은 은닉노드를 감소시킨다. 식 (5)에서처럼 먼저 구해진 은닉노드의 특징값 중 최대크기를 가지는 은닉노드를 감소대상에서 제외시키고 나머지 은닉노드의 특징값을 평균하여 각 은닉노드의 절대값과 비교, 이보다 작은 경우 축소대상 노드로 삼고 이 노드를 pruning시킨다.

$$\bar{C} = \sum_{i=0}^N \frac{C_i}{N-1} \quad (5)$$

위 식(5)에서 \bar{C} 는 은닉노드 평균특징값, c_i 는 i 번째 은닉노드의 특징값, N 은 Pruning 과정을 수행중인 은닉노드의 갯수이다.

따라서 제안된 알고리즘을 수행하면 은닉노드의 수는 문제의 특성에 따라 최적의 은닉노드로 수렴될 수 있다. 불필요한 노드가 제거된 신경망을 이용하여 재 학습을 시행하고 또다시 학습이 수렴되는 위의 과정을 반복수행 한다.


신경망 구조를 결정하기 위하여 제안된 특징값을 이용한 노드 제거 과정은 다음과 같다.

```

HNS_Plun_Hnode()
{
  int Hnode, Onode ;
  if (Onode > 1)
  {
    for( Hnode = 0 ; Hnode < NUM_HNODE ; Hnode++)
      if ( abs(Value_Array[j] < GetAvg() )
          {
            if (Temp_Hidden_Num > 2 )
              flag[j] = 0;
            } else
              flag[j] = 1;
            plun_hnode(flag);
          }
          /* if End */
        else
        {
          for ( Hnode = 0 ; Hnode < NUM_HNODE ; Hnode++ )
            {
              for ( Onode = 0 ; Onode < NUM_ONODE ; Onode++ )
                if ( abs(Value_Array[j+NUM_HNODE] < GetAvg_All(Onode) )
                    {
                      if (Temp_Hidden_Num > 2 )
                        flag[j] = 0;
                      } else
                        flag[j] = 1;
                      plun_hnode(flag);
                    }
                    /* for End */
                  /* else End */
                }
            }
    }
}
    
```

<알고리즘 1> 제안한 Pruning 알고리즘

(그림 1)는 본 논문에서 제안한 Pruning 방법과 Hiroaki가 제안한 방법을 가지고 은닉노드를 제거할 때 학습횟수에 따른 수렴율을 나타낸다.




(그림 1) 학습 곡선 비교

4. 제안한 Pruning 알고리즘을 적용한 기상예측 시스템 구성

본 기상 예측 시스템은 과거의 연속적인 기상데이터를 분석함으로써 미래의 기상변화에 대한 예측을 가능케 한다. 모델의 입력데이터로는 1987년도부터 1996년까지의 6, 7, 8월의 22,080건 데이터를 사용하며, 각 데이터는 년(Y), 월(M), 일(D), 시(T), 풍향(A), 풍속(B), 총운량(C), 온도(D), 노점온도(E), CEILING 고도(F), 해면기압(G), 상대습도(H)로, 이 12개 필드로 구성된 레코드단위로 구성되어 있다. 신경회로망의 입력노드 값으로는 한 단위 시간씩 움직여가며 학습패턴을 구성하는 슬라이딩 윈도우기법(Sliding Window Method)을 이용하여, 연결된 두 레코드와 예측일의 년,월,일,시를 사용하였다. 출력노드의 값은 예측일의 해당시간별 온도값으로 설정하였다. 입력력시 사용될 데이터는 0~1 사이의 값으로 정규화되어 계산된다.

초기 구성된 신경망 네트워크는 26개의 입력노드, 50개의 은닉노드 그리고 1개의 출력노드로 구성된 26×50×1 신경망을 사용하고, 각층의 입력총합을 활성화함수에 적용시켜 각 노드의 출력값을 정한다. 이때 사용하는 활성화함수로는 양극성 시그모이드 함수를 사용하며 -1(음) 또는 1(양)의 값에 근사하게 되는 출력값을 갖도록 조정된다.



(그림 2) 기상예측을 위한 신경망 모델

학습시행 후 학습 오차가 수렴오차내에 수렴되면 제안된 pruning 알고리즘을 수행하여 초기 구성된 네트워크의 은닉층 노드 중 과다 설정된 은닉노드를 제거하여 네트워크를 재구성한 후 재 학습을 실행한다.

5. 실험 및 고찰

기상예측 신경망 모델의 초기구조는 입력노드 26개, 은닉노드 50개, 출력노드 1개로 구성된 26×50×1구조로 하였다. 입력노드와 은닉노드사이의 활성화 함수는 양극성 시그모이드 함수를 사용하였고, 각 입력층과 은닉층, 출력층간의 연결은 완전연결 되어있다. 그리고 학습율은 0.4, 모멘텀은 0.7, 반복학습횟수는 1000회로 설정하여 학습오차값이 지정된 오차값 이하로 감소하는 시점에 학습이 완료된 것으로 간주하여 최적화 알고리즘을 수행 후 재 구성된 신경망을 학습시킨다.

5.1 기상예측을 위한 은닉층 노드수 결정과

r.m.s 학습오차


기상예측 실험의 경우 예측된 온도값이 실 측정된 온도값과 정확히 일치되는 경우가 드물기 때문에, 예측된 온도와 실 측정된 온도와의 차가 ±1℃인 경우 수렴된 것으로 간주하였으며, 다른 패턴인식 문제의 경우 학습오차 값을 0.1이하로 지정하지만 기상예측의 경우 문제성격상 학습오차값을 0.4로 상향지정 하였다.

위와 같이 설정된 실험환경하에서 초기 26×50×1 구조의 전방향 다층 신경망은 최적화 알고리즘을 통하여 26×2×1의 구조로 최적화되었다.

<표 1>은 최적화 알고리즘 수행중 학습 횟수별 r.m.s 학습오차와 은닉노드의 감소현황을 보여주고 있고, (그림 3)는 은닉노드 감소곡선과 r.m.s 오차 곡선의 변화 정도를 나타내고 있다.

<표 1> 학습 횟수별 r.m.s 오차와 은닉노드수 비교

학습 횟수	은닉노드 갯 수	r.m.s 학습오차	학습횟수	은닉노드 갯수	r.m.s 학습오차
1	50	0.774	256	6	0.421
24	50	0.777	272	6	0.389
81	50	0.747	273	3	0.487
130	50	0.664	288	3	0.392
144	50	0.598	289	2	0.616
158	50	0.554	300	2	0.472
175	50	0.521	350	2	0.376
203	50	0.503	750	2	0.315
255	50	0.396	1000	2	0.292



(그림 3) 은닉노드 감소곡선과 r.m.s 오차 곡선

<표 1>의 학습진행과정을 보면, 초기 설정된 은닉노드 50개는 학습횟수 256회에 처음 초기화 알고리즘을 수행하여 6개의 은닉노드로 최적화되었으며, 이후 학습횟수 273회에 3개, 289회에 2개의 은닉노드로 최적화 되었다.

최적화 작업 수행 후 재구성된 네트워크의 성능을 살펴보면 최적화 변동이 가장 큰 학습횟수 256회의 경우 이전의 r.m.s 학습오차가 0.396에서, 0.421로 약간 악화되었지만, 학습횟수 272회에서는 오히려 r.m.s 학습오차가 0.389로 향상되었음을 알 수 있다. 또한 지정된 학습범위(1000회)내의 최적화된 신경망 구조(26×2×1)에서도 r.m.s 학습오차값이 0.292로 이전의 다른 구조에 비하여 r.m.s 학습오차는 줄어들며 동시에 계산량별 r.m.s 오차의 성능비 역시 더 우수해짐을 알 수 있다.

(그림 3)에서 은닉노드 감소시 발생하는 오차 곡선 상승폭이 크지 않고 기존값을 유지하거나 약간 증가함을 발견할 수 있는데 이것은 초기 과(過) 설계된 신경망 구조중 학습에 영향을 미치지 않는 은닉노드의 비율이 그 만큼 높다는 것을 알 수 있고 이 과(過) 설계된 은닉노드를 제거하여도 학습결과에 미치는 영향력 또한 작다는 것을 알 수 있다.

5.2 기상예측을 위한 일반성

이 실험에서는 제안된 pruning 알고리즘의 일반화 성능을 실험하기 위하여 최적화 작업을 통해 구성된 신경망(26×2×1)과 사용자 임의구성신경망(26×50×1)을 비교 실험하였다.

학습패턴으로는 1987년, 88년, 89년, 91년 6,7,8월의 총 8832건의 기상패턴을 사용하며, 나머지 패턴(13248건)을 테스트 패턴으로 분리하였다.


구성된 신경망의 수렴도를 측정하기 위하여 먼저 학

습패턴에 대한 학습을 수행한 후 학습패턴(87년, 88년, 89년, 91년)과 테스트 패턴(90년, 92년, 93년, 94년, 95년, 96년)에 대하여 적합도 검사를 실행하였다.

학습 후 예측된 온도의 값과 실제 측정된 오차의 값의 차가 $+1^{\circ}\text{C}$ 이내이면 수렴된 것으로 간주하였고 이때 학습오차가 0.4 이하이면 학습이 완료된 것으로 간주하고 제한한 pruning 알고리즘을 수행한다. 실측온도와 예측온도의 차를 각각 $\pm 0.5^{\circ}\text{C}$ 에서 $\pm 3^{\circ}\text{C}$ 까지 0.5°C 범위로 측정된 결과는 <표 2>와 같고 $\pm 0.5^{\circ}\text{C}$, $\pm 1^{\circ}\text{C}$, $\pm 1.5^{\circ}\text{C}$ 에 대한 최적화 구조 신경망($26 \times 2 \times 1$)과 임의 구성신경망($26 \times 50 \times 1$)에 대한 수렴결과는 (그림 4)와 같다.

<표 2> 오차온도별 수렴율과 수렴횟수(%)

연도	측정오차	수렴율(%)					
		$\pm 0.5^{\circ}\text{C}$	$\pm 1^{\circ}\text{C}$	$\pm 1.5^{\circ}\text{C}$	$\pm 2^{\circ}\text{C}$	$\pm 2.5^{\circ}\text{C}$	$\pm 3^{\circ}\text{C}$
1987년	$26 \times 50 \times 1$	14.56	32.41	53.08	71.39	83.90	92.79
	$26 \times 2 \times 1$	23.93	48.05	69.08	85.13	93.51	97.08
1988년	$26 \times 50 \times 1$	17.54	36.40	54.89	71.39	84.58	90.97
	$26 \times 2 \times 1$	27.51	49.54	70.85	84.17	90.75	96.14
1989년	$26 \times 50 \times 1$	26.11	50.40	69.49	83.36	90.88	95.78
	$26 \times 2 \times 1$	37.53	63.64	81.36	90.02	95.10	97.86
1990년	$26 \times 50 \times 1$	24.47	47.78	67.67	82.50	90.93	95.42
	$26 \times 2 \times 1$	33.86	59.24	78.87	89.21	94.69	97.41
1991년	$26 \times 50 \times 1$	33.90	60.29	79.23	90.97	96.46	98.68
	$26 \times 2 \times 1$	39.02	72.71	88.25	95.14	98.50	99.59
1992년	$26 \times 50 \times 1$	36.53	64.05	82.00	92.29	97.28	99.04
	$26 \times 2 \times 1$	38.57	71.84	86.53	95.78	98.68	99.41
1993년	$26 \times 50 \times 1$	38.44	69.80	87.57	94.96	98.86	99.68
	$26 \times 2 \times 1$	39.07	71.16	88.57	96.01	99.09	99.68
1994년	$26 \times 50 \times 1$	32.13	55.30	74.20	83.86	90.52	94.15
	$26 \times 2 \times 1$	31.45	58.79	75.24	85.49	91.93	95.14
1995년	$26 \times 50 \times 1$	37.44	68.35	84.85	94.19	98.09	99.18
	$26 \times 2 \times 1$	34.99	65.36	83.81	93.01	97.91	99.27
1996년	$26 \times 50 \times 1$	32.00	60.01	78.64	90.43	96.28	98.64
	$26 \times 2 \times 1$	29.60	55.39	76.01	90.66	96.05	98.77



(그림 4) $\pm 0.5^{\circ}\text{C}$, $\pm 1^{\circ}\text{C}$, $\pm 1.5^{\circ}\text{C}$ 에서의 $26 \times 2 \times 1$ 과 $26 \times 50 \times 1$ 의 수렴율 비교

<표 3> $26 \times 2 \times 1$ 과 $26 \times 50 \times 1$ 망의 평균 수렴율(%)

연도	측정오차	수렴율(%)					
		$\pm 0.5^{\circ}\text{C}$	$\pm 1^{\circ}\text{C}$	$\pm 1.5^{\circ}\text{C}$	$\pm 2^{\circ}\text{C}$	$\pm 2.5^{\circ}\text{C}$	$\pm 3^{\circ}\text{C}$
$26 \times 50 \times 1$	학습패턴	23.02	44.87	64.17	79.10	88.95	94.55
	테스트패턴	33.50	60.88	79.15	89.63	95.32	97.44
$26 \times 2 \times 1$	학습패턴	31.99	58.48	77.41	88.61	94.46	97.66
	테스트패턴	34.59	63.62	81.50	91.69	96.26	98.28

위의 <표 2>를 살펴보면, 실생활에서 적용할 수 있는 $\pm 0.5^{\circ}\text{C}$ 와 $\pm 1^{\circ}\text{C}$ 수렴오차의 경우, 제한한 pruning 알고리즘을 수행하여 최적화된 신경망구조($26 \times 2 \times 1$)의 경우 각각 평균 33.55%, 61.57%로 임의 설계된 구조($26 \times 50 \times 1$)의 29.31%, 54.47%에 비하여 우수하게 나타나는 것을 알 수 있고, 또한 <표 3>에서 각 수렴 오차온도별 학습패턴과 테스트패턴에 대한 평균 수렴율 역시 제한한 pruning 알고리즘을 수행하여 최적화된 $26 \times 2 \times 1$ 의 망이 더 우수한 수렴율을 보이는 것을 확인할 수 있다. 이것은 과도하게 설계된 은닉노드에 의한 과(過)학습현상으로 인하여 전체적인 수렴율이 떨어진다는 것으로 해석할 수 있다.

제한된 pruning 알고리즘을 적용한 기상예측시스템은 임의 구성된 신경망에 비하여 미 학습된 학습패턴에 대하여 잘 예측하고 있음을 알 수 있다. 또한 기상예측을 위한 계산소요횟수의 경우 기존 망의 경우 1300회 ($26 \times 50 \times 1$)의 계산이 소요되는데 반하여 최적화 구성된 망의 경우 52회($26 \times 2 \times 1$)의 계산량만으로도 더 정확한 예측을 기대할 수 있다.

그러나 최적화된 신경망과 임의 설계된 신경망의 전체적인 인식율을 살펴볼 때 다른 패턴인식문제에 비하여 많이 뒤져 있는 것을 확인할 수 있다. 이는 기상예측문제의 특성상 온도에 영향을 미치는 변수요인구성에 대한 문제점과 결과에 대한 변동차가 심하기 때문에 정확한 예측이 어렵기 때문이다. 하지만 본 실험에서 예측한 인식율은 기존의 시계열 분석을 통한 예측 방법에 비하여 우수한 성능을 나타냄을 알 수 있었다.

6. 결 론

본 논문에서는 제한한 pruning 알고리즘을 적용하여 기상예측을 위한 최적의 신경망 설계 방법에 대하여 연구하였다. 제한한 pruning 알고리즘은 은닉노드의 출력값과 연결강도, 읍셋값을 이용하여 특징값 C를 구하였고, 이 특징값을 이용하여 은닉노드중 과(過)설

새된 노드를 네트워크에서 제거한다.

제한한 알고리즘을 이용한 기상예측 시스템에서 초기 임의 설계된 $26 \times 50 \times 1$ 의 신경망은 제한한 pruning 알고리즘을 통하여 $26 \times 2 \times 1$ 의 구조로 최적화 되었다.

최적화된 신경망 구조를 이용한 기상예측을 실험결과 실생활에 적용할 수 있는 오차온도 $\pm 0.5^\circ\text{C}$ 의 경우 평균 33.55%, $\pm 1^\circ\text{C}$ 의 경우 61.57%로 임의 설계된 구조($26 \times 50 \times 1$)의 29.31%, 54.47%에 비하여 우수하게 나타나는 것을 알 수 있고, 테스트 패턴에 대한 수렴을 역시 각각 34.59%, 63.62%로 우수하게 나타났다.

또한 최적화 알고리즘을 수행하여 구성된 신경망은 계산횟수에서도 임의구성 신경망에 비하여 최고 25배 이상 계산횟수를 줄일 수 있었다.

향후 연구과제로 학습 초기 단계에서 최적화 알고리즘 수행에 관한 연구와 함께 제안된 pruning 알고리즘을 다른 응용분야에 적용할 때 적용방법의 일반화에 대한 연구가 수행되어야 할 것이다.

참 고 문 헌

- [1] 정재성, "실시간 기상자료와 신경망 이론에 의한 다지점 강우예측 모형연구". 박사학위논문, 전북대학교, 1996.
- [2] 박성진, "신경망을 이용한 태풍진로예측", 석사학위논문, 포항공대, 1996.
- [3] H.-S. Shin, "Regional drought analysis based on neural network in southwestern colorado," ASCE J. of Hydrologic Engineering, accepted, 1998.
- [4] 오남선 외, "신경망 이론에 의한 강우예측에 관한 연구," 한국수자원학회지, 제29권 제4호, pp.109-118, 1996.
- [5] R.Hecht-Nielsen, 'Neurocomputing,' Addison-Wesley Publishing Co., 1989.
- [6] J.Hertz, A. Krogh, and R.G.Palmer, 'Introduction to the theory of neural computation,' Vol.1, Addison-Wesley Publishing Co., 1991.
- [7] M. Hagiwara, "Novel back propagation algorithm for reduction of hidden units and acceleration of convergence using artificial selection," Proc. IJCNN90, Vol.1, pp.739-742, Jan. 1990.
- [8] Zbigniew Michalewicz, "Genetic Algorithms+Data Structure=Evolutionprograms" 3rd, Extended Edition, Springer-Verlag, 1995.

- [9] 조성태, 이기철, 변형태 : "유전자 알고리즘을 이용한 BPN의 최적 은닉계층의 구성 및 학습", 한국정보처리학회 추계학술발표논문집, 제4권 제2호, pp.609-614, 1997.



이 기 준

e-mail : cholee@shinbiro.com

1994년 조선대학교 전산통계학과 (이학사)

1997년 조선대학교 일반대학원 전산통계학과(이학석사)

1998년~현재 조선대학교 일반대학원 전산통계학과 박사과정

1997년~현재 조선대학교 전산통계학과 강사

관심분야 : 신경망, 패턴인식, 인공지능, 분산 에이전트 시스템



강 명 아

e-mail : angelfox386@netsgo.com

1992년 광주대학교 전자계산학과 (이학사)

1995년 조선대학교 일반대학원 전산통계학과 (이학석사)

1999년 조선대학교 일반대학원 전산통계학과 (이학박사)

1999년~현재 순천 청암대학교 전산정보처리과 초빙교수

관심분야 : 신경망, 영상처리, 패턴인식, 유전자알고리즘



정 채 영

e-mail : cyjung@mail.chosun.ac.kr

1983년 조선대학교 컴퓨터공학과 (이학사)

1986년 조선대학교 일반대학원 전자과 전산전공(공학석사)

1989년 조선대학교 일반대학원 전기과 전산전공(공학박사)

1986년~현재 조선대학교 자연과학대학 수학.전산통계학부 부교수

관심분야 : 영상처리, 신경망, 데이터베이스, 멀티미디어 콘텐츠