

웨이브렛 변환과 Descending Epsilon 학습방법을 이용한 시계열 예측 system 구현

윤나미*, 정유정*, 이기준*, 정채영*

*조선대학교 전산통계학과

e-mail:cssnami@hanmail.net

Implement of Time Series Forcasting System Using the Wavelet Transform and Descending Epsilon Learning Method

Na-Mi Yun*, Yu-Jeong Jeong*, Kee-Jun Lee*, Chae-Young Chung*

*Dept of Computer Science & Statistics, Chosun University

요약

본 논문에서는 빠르고 정확하게 기후를 예측, 분석하기 위해 웨이브렛 변환을 통해 Data의 특징을 추출하고 이를 신경망의 입력값으로 사용하는 기상예측시스템을 제안하였다. 또한 학습이 잘되지 않는 패턴에 대한 집중적인 학습을 수행할 수 있는 Epsilon Descending 학습방법을 사용하여 정확도를 상승시켰다. 예측실험결과 웨이브렛 변환을 데이터의 전처리 과정에 삽입한 제안 기상예측시스템이 기존의 신경망만을 통한 기상예측시스템에 비해 예측능력면에서 훨씬 더 우수함을 보였다.

1. 서론

1980년 이후 두드러진 지구 온난화(Global Warming)효과, 과거와 다른 갖가지 이상기상현상 출현 등 현재 지구는 과거와 다른 기후 변동 과정을 겪고 있다. 특히 최근 들어 엘리뇨의 강도 강화, 과거의 판축 최고치를 간신히는 이상기상 출현 등이 더욱 두드러짐에 따라 기상 변동 분야에 대한 관심이 확대되고 있다. 또한 다음 세기에 일어날 기상 변동 예측은 전세계적으로 중요한 현안이다. [1]

본 논문에서는 웨이브렛 변환과 신경망을 이용하여 기상변화, 특히 온도변화에 대한 예측을 위해 과거의 연속적인 기상 데이터의 분석을 통하여 미래의 기상변화에 대한 예측모델을 제안하고자 한다.

기존의 신경망만을 이용한 기상예측 시스템은 자료 자체의 방대함 때문에 원하는 학습패턴을 유도해 내는데 많은 계산량과 그에 따른 반복횟수의 증가가 필수적으로 수반되었다.

기상예측과 같이 패턴양상이 불규칙적인 흔히

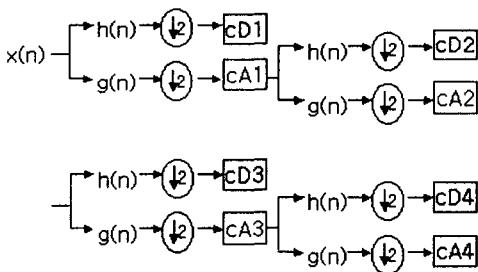
random이나 noise의 패턴을 이용한 예측모형은 학습패턴을 유도하는데 있어 많이 어려움이 따른다.[2] 따라서 본 논문에서는 시계열 자료 패턴에 포함되어 있는 이러한 미세한 값들이 예측에 큰 영향을 끼친다고 판단하여 이들의 특성을 분석하는 방법으로 웨이브렛 이론을 적용하고자 한다. 또한 먼저 학습횟수를 지정하고 학습을 수행하다 예측값이 교사값에 수렴할 때 패턴에 대해서만 집중적으로 학습시키는 Descending Epsilon 학습방법[3]을 이용하여 전체적인 학습횟수를 줄이고 정확도를 높일 수 있는 온도변화예측 시스템을 구현하고자 한다.

본 논문의 구성을 다음과 같다. 2장에서는 전처리 과정에 사용된 웨이브렛 변환과, 학습횟수를 줄이는 데 사용된 Descending Epsilon 학습방법에 대해 살펴보고 3장에서는 본 논문에서 제안하는 기상예측모델을 실험하여 그에 따른 결과를 분석한다.

2. 관련연구

2.1 wavelet을 이용한 다해상도 시스템

웨이브렛 변환은 다해상도 시스템으로 입력된 신호의 샘플링 주파수를 다른 형태의 샘플링 주파수로 변환시켜 다양한 주파수 대역에서 신호를 처리할 수 있는 장점을 가지고 있다. 다중해상도 웨이브렛 변환(multiresolution wavelet transformation)은 웨이브렛 함수를 정규직교기저에서 적용함으로써 주어진 신호의 특성을 분해하여 나타내는 알고리즘이다. 즉 j 를 0부터 $-j$ 까지 적용하여, 해석하고자하는 신호의 근사(approximation)성분 $A(j)$ 와 세부(detail)성분 $D(j)$ 로 나누어 나가는 것이다. 나누어진 성분들은 단계적으로 연속되는 더욱 세밀한 크기와 해상도를 갖게 되는데, 이는 j 값의 변화에 따라서 세부성분은 감소되고, 근사성분들은 계속 유지된다고 볼 수 있는 것이다. 그리고, 이러한 과정을 주파수 영역의 관점에서 보면, 근사성분은 저역필터 $g(n)$ 를 통과한 신호들이 되고 세부성분은 고역필터 $h(n)$ 를 통과한 신호들로 나타나게 됨을 알 수 있다.<그림 1>은 다중해상도 분할 과정을 나타낸다.[4][5]



<그림 1> Wavelet의 다해상도 분할 과정

원신호 $x(n)$ 은 식(1)으로 표현된다.

$$x(n) = A_2[x(n)] + D_2[x(n)], \quad j=1 \quad (1)$$

이때 $A_2[x(n)]$ 은 $j=1$ 일 때의 근사성분을 나타내며, $D_2[x(n)]$ 은 $j=1$ 일 때의 세부성분으로서 원래의 신호 $x(n)$ 와 근사신호 $A_2[x(n)]$ 와의 차이라고 할 수 있다.

웨이브렛 변환은 주어진 신호를 각 scale에서 근사 및 세부성분으로 분해하는 과정이다. scale j 에서의 세부성분은 scale($j-1$)에서의 근사신호와 웨이브렛 필터계수 $h(n)$ 을 상승적분 함으로서 구할 수 있고,

scale j 에서의 근사성분은 scale($j-1$)에서의 근사신호와 scale 필터계수 $g(n)$ 을 상승적분 함으로서 계산되어진다.[6]

본 논문에서는 수집된 기상예측 시계열 자료에 대해 다중해상도 웨이브렛 변환을 적용했으며, 최초의 자료는 저대역필터를 통과한 근사신호(cA1)와 고대역필터를 통과한 세부신호(cD1)로 분할된다. 그리고 다시 저대역, 고대역필터를 거쳐서 cA2와 cD2로 분할되며, 이러한 웨이브렛 과정을 반복 실행하여 4개 대역의 신호들로 나타나게 된다. 따라서, 고대역필터를 통과한 cD1, cD2, cD3, cD4의 값들과 저대역필터를 통과한 cA1, cA2, cA3, cA4으로 저장된다. 본 실험에서는 세부성분인 cD1~cD4 값들과 근사성분인 cA4을 기상예측 시스템의 입력 값으로 사용하게 된다.

2.2 Descending Epsilon 학습방법

신경망 학습알고리즘은 각 출력노드에서 출력값과 교사데이터의 값의 차가 최소화되도록 연결강도의 값을 조절하는 오류 역전파 학습 알고리즘이 주로 사용된다. 기존 방법에 따라 기상자료를 신경망으로 처리할 경우, 자료 자체의 방대함 때문에 원하는 학습 패턴을 유도해내는데 많은 계산량과 그에 따른 반복횟수의 증가가 필수적으로 수반된다. 특히 모든 자료를 고정된 반복횟수로 수렴시킬 경우 최종 오차율은 정해진 범위로 귀결되지만 이 학습패턴이 각각의 예측값에 적용될 때는 큰 편차를 갖게된다.

따라서 본 논문에서는 이러한 문제를 해결하기 위해 먼저 학습횟수를 지정하고 학습을 수행하다 예측 값이 교사값에 수렴할 때 해당 패턴을 학습에서 제외시키고, 수렴되지 않은 패턴에 대해서만 집중적으로 학습시키는 Descending Epsilon 학습방법을 이용한다.

이 학습방법은 학습되지 않은 출력 뉴런만이 오차를 역전파하여 가중치를 조절하는 것으로 학습패턴에 대한 오차의 크기가 학습 중에 허용할 수 있는 오차의 크기인 Epsilon보다 작으면, 그 학습패턴은 학습에 참여시키지 않는다. 따라서 학습이 잘 되지 않은 패턴에 대해서는 집중적인 학습을 수행할 수 있다는 장점을 가지고 있다.

신경망의 학습된 정도를 나타내는 척도로

$$E = \sum_{p=1}^P \sum_{i=1}^N (\text{Number of } |t_i - O_i| > \epsilon) \quad (2)$$

을 사용한다.

Desceding Epsilon 방법의 전체 알고리즘은 <표 1>과 같다. [7]

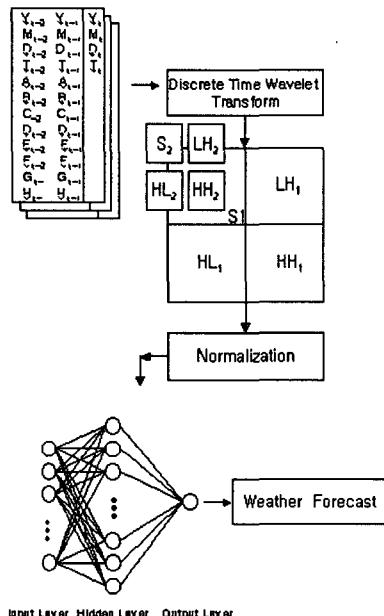
```
int Epsilon()
{
    float Epsilon = 0.0;
    int flag ;
    Label :
    flag = 0;
    for (p=0 ; p<pnum ; p++)
    {
        Error = 1;
        if (value< output_value)
        {
            if (abs<(tpi- opi) > Epsilon)
            {
                Error=(tpi- opi);
                Error=0;
            }
            else
                Error=0;
            if (Error)
                Correct++;
            else
                Backpropagation();
        } // end for;
        if (Epsilon<= F_Epsilon)
            return;
        else
        {
            Epsilon=Epsilon_step;
            Correct++;
        } goto Label;
}
```

<표 1> Epsilon Descending 학습방법

3. 실험 및 결과

본 기후 예측 시스템은 과거의 연속적인 기상데이터를 분석함으로써 미래의 기후변화에 대한 예측을 가능케 한다. 모델의 입력데이터로는 1987년도부터 1996까지의 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 레코드 단위로 구성되어 있다. 신경회망의 입력노드 값으로 기상 데이터의 패턴에 포함되어 있는 미세한 값들의 특성을 웨이브렛을 적용하여 추출하고, 다해상도 웨이브렛을 통하여 입력값으로 사용될 방대한 기상 데이터의 값들에 대해 규칙적인 패턴을 찾기위해 Down Sampling을 시행한 값들을 입력노드 값으로 사용한다. 신경망 학습방법은

Descending Epsilon 학습 알고리즘을 사용하여 미학습 패턴에 대하여 집중적인 학습을 시도하였고 학습율은 0.4, 모멘텀값은 0.7, 학습횟수는 200회로 지정하였다. 또한 출력노드의 값은 예측일의 해당시간별 온도값으로 설정하였다. 입출력시 사용될 데이터는 0과 1 사이의 값으로 정규화되어 계산된다.

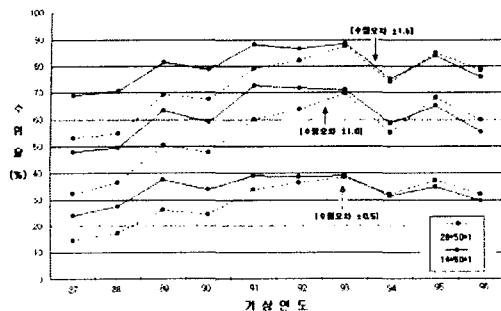


<그림 2> 기후예측을 위한 웨이브렛 신경망 모델

초기 구성된 신경망 네트워크는 14개의 입력노드, 50개의 은닉노드, 그리고 1개의 출력노드로 구성된 $14 \times 50 \times 1$ 신경망을 사용하고, 각층의 입력총합을 활성화함수에 적용시켜 각 노드의 출력값을 정한다. 이때 사용하는 활성화 함수로는 양극성 시그모이드 함수를 사용하며 -1(음) 또는 1(양)의 값에 근사하게 되는 출력값을 갖도록 조정된다.

구성된 신경망의 수렴도를 측정하기 위해 먼저 학습패턴에 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 오차 값의 차가 $\pm 1^{\circ}\text{C}$ 이내이면 수렴된 것으로 간주하였고 이때 학습오차가 0.4 이하이면 학습이 완료된 것으로 간주한다.



<그림 3> 오차온도 $\pm 0.5^{\circ}\text{C}$, $\pm 1^{\circ}\text{C}$, $\pm 1.5^{\circ}\text{C}$ 에서의 $28 \times 50 \times 1$ 망과 $14 \times 50 \times 1$ 망의 수렴율 비교

		측정오차					
		$\pm 0.5^{\circ}\text{C}$	$\pm 1^{\circ}\text{C}$	$\pm 1.5^{\circ}\text{C}$	$\pm 2^{\circ}\text{C}$	$\pm 2.5^{\circ}\text{C}$	$\pm 3^{\circ}\text{C}$
28x50x1	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
$14 \times 50 \times 1$	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

<표 2> $14 \times 50 \times 1$ 과 $28 \times 50 \times 1$ 망의 평균 수렴율(%)

<그림 3> 과<표 2>에서 각 연도별 수렴율과 각 수렴오차온도별 학습패턴과 테스트패턴에 대한 평균 수렴율에서 제안된 $14 \times 50 \times 1$ 의 구조가 $28 \times 50 \times 1$ 의 구조보다 더 우수한 수렴율을 나타낸다는 것을 볼 수 있다. 이것은 웨이브렛 변환과 Descending Epsilon 학습방법을 사용하여 신경망의 구조를 제안한 방법이 기존의 방법보다 미 학습된 학습패턴에 대하여 잘 예측하고 있음을 나타낸다. 또한 제안한 기상예측 시스템은 기존의 신경망 모델에 비해 입력 값이 현저하게 저하되었지만 더욱 빠르고 정확한 기상예측 시스템을 구성할 수 있었다.

4. 결론

본 논문에서는 빠르고 정확하게 기후를 예측, 분석하기 위해 웨이브렛 변환을 통해 데이터의 특징을 추출하고 이를 신경망의 입력 값으로 사용하는 기상 예측시스템을 제안하였다. 제안된 시스템은 기존의 신경망만을 사용한 방법보다 학습패턴과 테스트패턴 모두에서 우수한 수렴율을 보였으며, 전체적인 학습 횟수를 줄이고, 정확도를 높일 수 있는 온도변화예측 시스템을 구현하여, 기존의 방법을 통한 예측시스템과의 비교에서 구현된 시스템의 효율성을 검증하였다. 향후 웨이브렛의 특징추출을 기상예측뿐만 아니라 지리정보시스템, 의료영상데이터 고속전송부

분에 적용시켜 기존의 방법보다 훨씬 정확도를 높여는 방법으로 연구가 수행되어져야한다.

참고문헌

- [1] 서울대학교 기후 역학 실험실.
<http://climate.snu.ac.kr>
- [2] A.N.Edmonds et al "Simulation Prediction of Multiple Financial Estimation," Proceeding of IEEE International Conference on Neural Networks, Vol 1, 1994
- [3] Y.H.Yu, R.F.Simmons, "Descending Epsilon in Back-Propagation : A Technique for Better Generalization", IEEE IJCNN, Vol 3. pp.167-172, 1990.
- [4] Charles K.Chui, Wavelet : A Tutorial in Theory and Applications, Harcourt Brace Jovanovich Publisher, 1992
- [5] C. Sidney Burrus, Ramesh A. Gopinath, Introduction to Wavelets and Wavelet Transforms : A Primer, 1997, Prentic-Hall, Inc.
- [6] 신승원 외, "웨이브렛 변환과 신경망을 이용한 경로통행시간 예측모형 개발", 대한교통학회지, 제16권, 제4호, pp.153-166. 1998.
- [7] 이기준 외, "신경망의 선별학습 집중화를 이용한 효율적 온도변화예측모델 구현", 한국통신학회논문지, Vol.25. pp.1120-1126. 2000.