

신경회로망을 이용한 생산량 예측에 관한 연구

°이오걸*, 송호신**
 동의공업대학*, 부산정보대학**

Production Volume Forecast using Neural Networks

°Lee Oh Keol*, Song Ho Shin**
 DongEui T.C*, Busan L.C**

ABSTRACT - This paper presents a forecasting method for production volume of each model manufactured goods by using Back-Propagation technique of Neural Networks.

As the learning constant and the momentum constant are respectively 0.65 and 0.94, the learning number is the least, and the forecasting accuracy is the highest.

When the learning process is more than 1,000 times, the accurate forecasting was possible regardless of kind of product.

1. 서론

최근 산업체에서 생산하는 량을 그 해의 수요량에 맞추어 보다 안정범위 내의 량을 예측할 수 있도록 노력할 필요가 있다.

최근 들어, 시계열 분석과 회귀분석 모델링 방법을 결합하여 수요 예측을 하려는 연구가 진행 중이다. 그 방법의 한가지로서 신경회로망을 이용한 수요예측이 큰 기대를 걸고 있다.1~2)

본 연구에서는 시계열 정보처리에 많이 적용되는 제어 기법으로 1986년 루멜하트(Rumelhart)에 의해 제안된 교사달린 학습법인 백 퍼퍼게이션(Back Propagation)을 이용하여 과거의 수년간의 수요 변화량을 모델로 하여 향후의 수요에 따른 생산량을 예측할 수 있도록 하고자 한다.3~5)

생산량 예측에 사용한 신경 회로망은 NeuralWare사에서 개발한 Neural Works Professional II and Neural Works Explorer 소프트웨어를 이용하여 예측을 하고자 한다.

따라서 본 논문에서는 물자수급 계획 및 생산시설 확충 계획, 생산인원 확충 계획 등 생산에 기본이 되는 데이터를 예측할 수 있는 기법에 대해 논하고자 한다.

2. 신경회로망의 학습

본 논문에서는 back-propagation (BP:역전파) 학습법을 이용한 신경회로망을 적용하였다.4)

그림 1은 하나의 신경소자를 표현한 것으로 한 뉴런의 출력 Y는 n개의 입력, 즉, X1...Xn과 연결강도 W_i와의 곱의 합 즉, $\sum W_i X_i$ 를 출력함수 f(X)로 변환시킨 것이다. 여기서, 연결강도 W_i는 수행하고자 하는 작업의 성능을 향상시키도록 학습시킨다.




그림 1. 뉴런의 모델
 Fig. 1. Model of neuron

n개의 입력신호(X1...Xn)는 모든 펄스의 크기를 나타내며, 그 강도는 0 또는 1 사이의 실수라고 한다. 그림 1과 같이 일반적인 신경회로망의 학습과정은 그림 2와 같이 먼저 학습횟수를 임의의 오차 이하의 값일 때 학습을 종료할 수 있도록 오차의 한계값을 초기설정을 한 다음 학습의 기울기를 결정하는 학습계수를 임의 설정한다. 그 다음 결합계수를 초기에는 학습상태가 없으므로 랜덤(Random)한 값으로 설정해 둔다. 그리고 이 결합계수에 대해서 학습 데이터(Date)를 입력하고 평가 기준을 참조하여 평가한다. 또한, 평가결과에 기본을 두고 학습상태에 따라 결합계수를 재조정하게 되는 학습과정을 다음에 나타내었다. 신경회로망은 본 논문에서 사용한 중간층 출력함수는 시그모이드 함수로서, 출력이 [0, 1]의 범위 내에서 미분 가능한 단조 증가하는 함수이다. 델타법으로 연결강도를 수정하는 방법을 활용하여 오차를 최소화하였다.

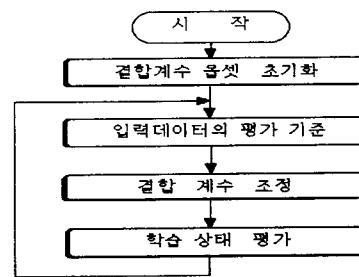


그림 2. 학습 과정
 Fig. 2. Learning process


3. 생산량 예측 시뮬레이션 및 결과 고찰

본 장에서는 과거 몇 년간의 생산량 추이에 대해 앞으로 1년 내지 몇 년 후의 생산량을 예측하기 위한 기법으로 신경회로망을 이용하여 예측하고자 한다.


생산량을 예측하기 위한 데이터는 실제 생산하고 있는 제품으로 과거 몇 년간 매일의 실제 생산하는 4가지 제품을 선정하였다. 1996년 1월1일부터 2000년 12월 31일 까지의 5년간의 데이터 중에서도 각 계절마다 대표 되는 주일을 선택하여 신경회로망의 학습 모델로 삼았다.

3.1 생산량 모델

실제 매년 생산되는 패턴을 알기 위하여 1996년도 부터 1999년 까지 4계절로 나누어 각 계절마다 일요일을 제외한 2주일씩의 실제 생산량을 계수하였다. 다음에 생산패턴을 나타내었다.



(a) A model and B model of winter



(b) C model and D model of winter

그림 3. 1996~1999년 겨울의 생산 패턴

신경 회로망에 사용한 생산량 데이터는 1996년 부터 1998년까지 3년간 각 계절별로 일요일은 거의 휴무가 많으므로 제외한 12일간의 생산량을 모델로 이용하였다. 생산량 선택 시 각 계절별로 2주제를 선택하였으나 생산량의 패턴이 비슷한 것을 선택하기 위하여 공휴일이 있는 주는 그 다음 주를 학습 데이터로 선정 하였다.

매 생산량의 특성 중에서 나타나는 것과 같이 생산량은 자기 상관함수를 지닌다는 것이다. 즉 해마다 같은 계절, 같은 요일의 생산량은 매우 유사한 패턴을 가지고 있으므로 여기서 신경회로망에 의해 학습하기 위한 알고리즘은 다음 식과 같다.

$$P_n(i, t) = [p_{n-1}(i, t) \cdot p_{n-2}(i, t) \cdot p_{n-3}(i, t)]^T \quad (1)$$

- n : 년도 (1996~2000년: 1~5)
- t : 계절 (겨울=1, 봄=2, 여름=3, 가을=4)
- i : 요일 (1~6)
- m : 생산 제품 모델(A, B, C, D)

각 생산량의 선택 일은 표 1과 같다.

표 1. 학습 데이터의 기간

Table 1. Day of learning data

| 년도 | 계절 | | | |
|------|------------|------------|------------|--------------|
| | 겨울 | 봄 | 여름 | 가을 |
| 1996 | 1, 8~1, 13 | 4, 9~4, 14 | 7, 9~7, 14 | 11,12~11, 17 |
| | 1,15~1, 20 | 4,16~4, 21 | 7,16~7, 21 | 11,19~11, 24 |
| 1997 | 1, 7~1, 12 | 4, 7~4, 13 | 7, 7~7, 12 | 11,10~11, 15 |
| | 1,14~7, 19 | 4,14~4, 19 | 7,14~7, 19 | 11,17~11, 22 |
| 1998 | 1, 6~1, 11 | 4, 6~4, 11 | 7, 6~7, 11 | 11, 9~11, 14 |
| | 1,13~1, 18 | 4,13~4, 18 | 7,13~7, 18 | 11,16~11, 21 |
| 1999 | 1,11~1, 16 | 4, 6~4, 11 | 7, 5~7, 10 | 11, 8~11, 13 |
| | 1,18~1, 23 | 4,13~1, 18 | 7,12~7, 17 | 11,15~11, 20 |
| 2000 | 1,10~1, 15 | 4,11~4, 16 | 7,11~7, 16 | 11,14~11, 19 |
| | 1,17~1, 22 | 1,18~1, 23 | 7,18~7, 23 | 11,21~11, 26 |

입력 데이터를 구축하기 위하여 각 모델별 데이터를 $I_m(i, t)$ 로 두고, 이 경우 $I_m(i, t)$ 는 2주일 동안의 매 제품별의 변동량이다.

이 입력 데이터와 신경 회로망의 결합계수 w_m 와의 곱은 다음 식으로 표시할 수 있다.

$$x_m(i, t) = w_m \cdot I_m(i, t) \quad (2)$$

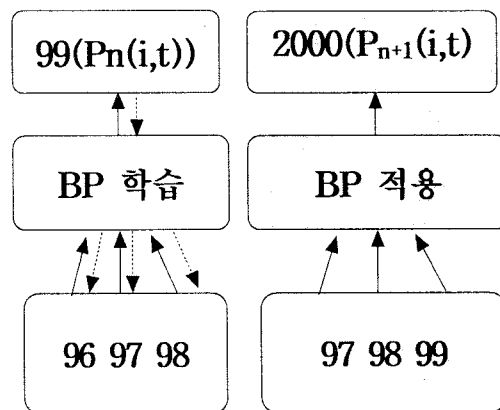
식(2)를 비선 함수 f에 의하여 변형된 함수 $p_n(i, t)$ 는 다음과 같이 된다.

$$P_n(i, t) = F \cdot [x_m(i, t)]^T \quad (3)$$

이 식은 n년에서의 생산량의 변화량을 의미하며 이를 신경회로망의 학습 데이터로 사용하였다.

이상에서 $P_{n+1}(i, t)$ 을 예측하는 식은 다음과 같다.

$$P_{n+1}(i, t) = [p_n(i, t) \cdot p_{n-1}(i, t) \cdot p_{n-2}(i, t)]^T \quad (4)$$



(a) 학습시스템 (b) 예측시스템
그림 3 학습 알고리즘

3.2 결과 고찰

본 생산량 예측에 사용한 신경 회로망은 입력층을 5개로 1996년부터 1998년 까지 과거 3년간의 생산량을 입력하고, 중간층은 입력층의 3배인 15개로 하였으며, 출력층은 1999년의 생산량을 1개로 하여 학습하였다.

학습률 η 와 모멘트 계수 α 를 각각 0.1에서 0.9로 가변시키면서 학습해본 결과 학습계수가 0.62이고 모멘텀항이 0.94일때 가장 빨리 학습하면서도 정확성이 가장 양호하


었다.

그리고, 학습의 정확도는 중간층의 수가 입력층의 수보다 약 3배일 때 가장 학습 정확도가 양호했으며, 중간층의 수가 많을수록 정확도가 더 양호하게 되나 너무 많으면 정확도가 오히려 떨어짐을 알 수 있었다.


2000년도 실제 생산량과 예측치 결과 및 오차를 그림 3에 나타내었다.

표 2에 2000년도 생산량 예측결과의 평균 표준 오차와 오차율을 나타내었다.

이상에서와 같이 1996년부터 1999년도의 생산량 추이를 가지고 2000년도의 생산량을 예측해본 결과 A Model인 경우 평균 표준편차는 34.012779 [set]이고, 평균 오차율은 2.130268[%]이었다. B Model인 경우 평균 표준편차는 34.688643[set]이고, 평균 오차율은 1.996632[%]이었으며, C Model인 경우 평균 표준편차는 42.166586[set] 이고, 평균 오차율은 1.606242[%]이었다. D Model인 경우 평균 표준편차는 31.183467[set]이고, 평균 오차율은 0.979943[%]이었다.



(a) A model and B model of spring



(b) C model and D model of spring

그림 5. A모델의 실적치와 예측치 비교

Fig. 5. Comparison of real values and forecasted values in A model.

표 2 평균 표준 오차와 오차율

Table 2 Forecasted results of average standard percentage error and percentage ratio error

| 구분 | 겨울 | 봄 | 여름 | 가을 | 평균 |
|--------|-----------|-----------|-----------|-----------|-----------|
| A 표준편차 | 18.690260 | 31.584391 | 40.237732 | 45.538734 | 34.012779 |
| 제품 오차율 | 0.656893 | 1.731247 | 2.706871 | 3.426062 | 2.130268 |
| B 표준편차 | 21.493618 | 31.548027 | 40.287418 | 45.425510 | 34.688643 |
| 제품 오차율 | 0.605435 | 1.691449 | 2.514683 | 3.174961 | 1.996632 |
| C 표준편차 | 27.931561 | 38.864468 | 47.985641 | 53.884674 | 42.166586 |
| 제품 오차율 | 0.058221 | 1.546975 | 2.079747 | 2.740025 | 1.606242 |
| D 표준편차 | 20.576046 | 28.030899 | 35.881840 | 40.245083 | 31.183467 |
| 제품 오차율 | 0.171781 | 0.262868 | 1.340204 | 2.144917 | 0.979943 |

겨울철의 생산량 오차율에 비해 가을철 생산량 오차율

이 약 1.15[%] 감소되어 생산량이 선형성이 많을수록 예측이 그만큼 정확하게 할 수 있다는 것을 알 수 있었으며, 생산량의 수량이 아주 비선형으로 급변하는 경우에는 오차가 크게 나타났으나, 1~3[%] 내외로 아주 예측이 잘 됨을 알 수 있었다.

그리고 학습횟수가 약 500회 일 때 부터 오차가 2~3[%] 이내로 감소되었고, 학습횟수가 약 1000회 일 때 원하는 1[%] 이내로 감소하여 정확한 예측이 가능하였다.

4. 결론

본 논문에서는 과거 몇 년간의 생산량 추이를 가지고 신경 회로망에 의해 생산량을 예측하는 것이 본 논문의 목적이었다.

본 생산량 예측에 사용한 신경 회로망은 NeuralWare사에서 개발한 Neural Works Professional II and Neural Works Explorer 소프트웨어를 이용하여 예측을 해본 결과 다음과 같은 것을 알 수 있었다.

1. 학습률 η 와 모멘트 계수 α 를 각각 0.1에서 0.95로 가변시키면서 학습해본 결과 학습계수가 0.65이고 모멘텀항이 0.94일때 가장 빨리 학습하면서도 정확성이 가장 양호하였다.
2. 학습의 정확도는 중간층의 수가 입력층의 수보다 약 3배일때 가장 학습 정확도가 양호했으며, 중간층의 수가 많을수록 정확도가 더 양호하게 되나 너무 많으면 정확도가 오히려 떨어짐을 알 수 있었다.
3. 학습횟수가 약 500회 일때부터 오차가 2~3[%] 이내로 감소되었고, 학습횟수가 약 1000회 일때 원하는 1[%] 이내로 감소하여 정확한 예측이 가능하였다.

참고문헌

- [1] M. Saerens and A. Soquet, "A Neural Controller Based on Backpropagation Algorithm", Proc. of First IEEE Int. Conf. on Artificial Neural Networks, London, pp.211-215, 1989.
- [2] K. J. AstÖm and B. Wittenmark, "Adaptive Control", Addison-Wesley Publishing Company, pp.328-342, 1989
- [3] B. Window and M.A. Lehr "30 years of adaptive neural network Perceptron, madaline and backpropagation." Proc IEEE, Vol 78, pp 1415-1442. Sept, 1990.
- [4] B. Muller and J. Reinhardt, "Neural Networks," Springer-Verlag, 1990.
- [5] C. Klimasauskas, J. Guiver, G. Pelton, "Neural Works Professional and Neural Works Explorer, Vol. I, Neural Computing", Neural Ware, Inc., 1989.