

ELM(Extreme Learning Machine)기반의 단기 물 수요예측 알고리즘

신강욱*, 홍성택*

한국수자원공사 K-water연구원

The short-term water forecasting based on ELM model

Gang Wook Shin, Sung Tack Hong
K-water Corporation K-water Institute

Abstract - 본 연구에서는 안정적인 물 공급과 에너지의 효율적 사용을 위한 단기 물 수요예측알고리즘 개발에 있어서, 지방 소도시 지역의 물 공급패턴에 대한 영향인자를 도출하기 위하여 기상환경인자와 과거 물 공급량에 대한 상관성 분석을 실시하였다. 그리고, 신경회로망 이론 중 ELM알고리즘을 적용한 단기 물 수요예측알고리즘을 개발하여 현장 적용성을 검토하고자 한다

1. 서 론

수요예측 분야는 경제, 경영, 시스템, 안전 등 다양한 분야에서 응용되는 분야로 산업발전의 근간이 되어왔다. 수요예측에 대한 많은 응용분야 가운데에서 물 수요예측분야는 두 가지 중요 상관인자에 의하여 특히 의존성이 높다할 수 있다. 하나는 낮과 밤 동안의 인간 사회활동과 습관에 의한 것, 그리고 나머지 하나는 날씨 조건에 따른 영향을 나타낸다. 따라서, 지금까지 이러한 두 가지 중요 인자에 대한 조사를 통하여 다양한 물 수요예측알고리즘을 개발하려는 시도가 있어 왔다. 또한, 물 수요예측을 기간별로 크게 구분하면, 장기예측과 단기예측으로 나눌 수 있다. 장래의 수도시설의 건설 혹은 확장계획 등의 년간 계획을 결정하는 일을 목적으로한 물 수요예측을 장기예측으로 한다. 한편, 수도시설의 합리적인 물 운용과 유지관리계획을 목적으로 하루 또는 시간계획의 물 수요예측을 단기 물 수요예측이라 한다. 특히 안정적인 물 공급과 에너지의 효율적 사용을 위한 일별 및 시간별 단기 물 수요예측에 대한 연구는 간헐적으로 진행되었고, 지금까지 단기 물 수요예측을 위하여 ARIMA 모델을 비롯한 다양한 시도가 있었다[1-3]. 그러나, 다양한 알고리즘이 개발되었으나 실제 적용할 수 있는 수준의 알고리즘 적용이 미흡한 실정이다. 이는 각 지역별 혹은 각 공급계통 특성에 따른 데이터의 다양성에 따라 일률적인 알고리즘 적용의 문제를 도출한 것으로 판단된다. 따라서, 본 연구에서는 지방 소도시의 단기 물 수요예측의 적용성을 높이기 위하여 신경회로망 이론중 ELM알고리즘을 적용하여 단기 물 수요예측방안을 제안하고자 한다.

2. 본 론


2.1 ELM기반의 예측모델

ELM(Extreme Learning Machine)은 단일 은닉층을 가지는 전방향 신경망으로 최근 Huang[4-5]등에 의하여 제안되었다. 최경경사법에 기반한 신경 회로망의 학습은 일반적으로 좋은 성능을 얻기 위해 많은 반복 학습을 필요로 하며, 적절하지 못한 학습에 의하여 낮은 적용성을 보이거나 종종 국부 최소해에 수렴하는 단점을 가지고 있다. ELM에서 출력가중치들은 반복적인 학습 구조 대신에 모어-페로스의 일반화된 역행렬에 의해 분석적으로 계산되어진다.


그림 1은 ELM의 학습 절차와 구조를 보여준다. 그림 1(a)를 통하여 알 수 있는 바와 같이 ELM은 단일 은닉층을 가지는 전방향 신경 회로망(SLFNs: Single-hidden Layer Feedforward Networks)으로 이루어진다. ELM의 주된 특징은 다른 신경회로망의 학습방법과 달리 반복학습을 하지 않기 때문에 전형적인 반복 학습 방법들에 비하여 매우 빠른 학습이 가능하다는 점과 ELM은 작은 학습 오차값을 가질 뿐만 아니라 가중치들의 가장 작은해를 얻는 경향이 있다는 점이다. 특히, 경사 기반 학습방법들이 국부최소, 과잉적합과 같은 문제점이 있는 반면에 ELM은 한 번의 학습으로 최적의 해에 직접적으로 도달하는 경향이 있다.

m 개의 데이터 $\{(x_i, y_i), i = 1, 2, \dots, m\}$ 와 한개의 출력노드를 가지고 N 개의 은닉노드들을 가지는 전방향 신경 회로망의 학습을 고려해보자. 여기서, 입력 $\mathbf{x}_i = [x_{i1}, x_{i2}, \dots, x_{in}]^T \in R^n$ 이고, $y_i \in R$ 이며, N 개의 은닉노드들의 활성화 함수 $g(x)$ 에 의한 전방향 신경 회로망의 출력은 다음과 같이 나타낼 수 있다.

$$\mathbf{g}(\mathbf{w}_j \cdot \mathbf{x}_i) \cdot \mathbf{a} = y_i, \quad i = 1, 2, \dots, m \quad (1)$$



(a) ELM의 구조



(b) ELM의 학습 과정

<그림 1> ELM 구조와 학습과정

여기서, $\mathbf{w}_j = [w_{j1}, w_{j2}, \dots, w_{jn}]^T, j = 1, 2, \dots, N$ 은 j 번째 은닉노드와 입력노드들을 연결하는 가중치 벡터로 임의의 값으로 초기화 되며, $\mathbf{a} = [a_1, a_2, \dots, a_N]^T$ 는 은닉노드들과 출력노드를 연결하는 가중치 벡터이다. $\mathbf{w}_j \cdot \mathbf{x}_i$ 는 \mathbf{w}_j 와 \mathbf{x}_i 의 내적을 의미한다. 식 (1)은 다음과 같이 간결하게 표현될 수 있다.

$$\mathbf{G}\mathbf{a} = \mathbf{y} \quad (2)$$

여기서,

$$\mathbf{G}(\mathbf{w}_1, \mathbf{w}_2, \dots, \mathbf{w}_N; \mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_m) = \begin{bmatrix} \mathbf{g}(\mathbf{w}_1 \cdot \mathbf{x}_1) & \dots & \mathbf{g}(\mathbf{w}_N \cdot \mathbf{x}_1) \\ \vdots & & \vdots \\ \mathbf{g}(\mathbf{w}_1 \cdot \mathbf{x}_m) & \dots & \mathbf{g}(\mathbf{w}_N \cdot \mathbf{x}_m) \end{bmatrix} \quad \mathbf{y} = \begin{bmatrix} y_1 \\ \vdots \\ y_m \end{bmatrix}_{m \times 1} \quad (3)$$

\mathbf{G} 는 전방향 신경 회로망에서 은닉층의 출력으로 \mathbf{G} 의 i 번째 열은 입력 $\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_m$ 과 관련된 i 번째 은닉노드들의 출력 벡터이다. 최종적으로, 다음과 같이 최소자승법에 의하여 출력 가중치 $\hat{\mathbf{a}}$ 을 구한다.

$$\hat{\mathbf{a}} = \mathbf{G}^\dagger \mathbf{y} \quad (4)$$

여기서 \mathbf{G}^\dagger 는 은닉층의 출력 \mathbf{G} 의 모어-페로스의 일반화된 역행렬이다. 만일 $\mathbf{G}^T \mathbf{G}$ 가 비정칙인 경우, \mathbf{G} 의 모어-페로스의 일반화된 역행렬은 다음과 같이 얻어진다.

$$\mathbf{G}^\dagger = (\mathbf{G}^T \mathbf{G})^{-1} \mathbf{G}^T \quad (5)$$

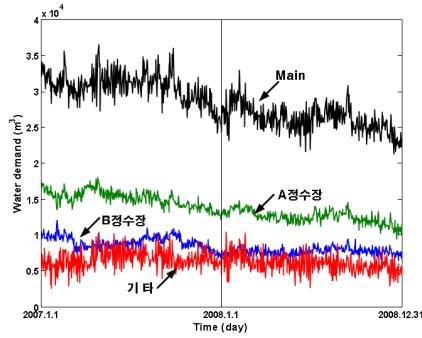
최종 예측은 다음과 같이 얻어진다.

$$\hat{\mathbf{y}} = \mathbf{G}\hat{\mathbf{a}} \quad (6)$$

2.2 대상 사업장 분석

그림 2에서는 2007년도와 2008년도의 물 공급계통의 공급량을 나타냈다. 그림에서 보는 바와 같이 전체 공급되는 물은 주로 A정수장과 B정

수장으로 유입되며 기타 6개의 지역으로 공급되는 물 공급량의 합계는 전체 공급량의 약 20%로 A정수장과 B정수장에 비하여 상대적으로 적음을 알 수 있다.



〈그림 2〉 주 계통 물 공급량

표 1에서는 주 계통에서 공급된 일일 물 수요량의 연도별 상관계수 분석결과를 나타냈다. 상관성분석은 2007년도, 2008년도 및 2007-2008년도 데이터로 각각 구분하여 분석을 하였다. 상관성은 크게 월, 일, 일타입, 계절타입, 기온 등의 외부인자와 1일전~6일전의 과거 물 수요량으로 표현되는 시간인자로 구분하여 실험을 하였다. 외부 인자에서 일 타입은 ① 월요일, ② 화요일, 수요일, 목요일, ③ 금요일, ④ 토요일, ⑤ 일요일, ⑥ 공휴일 전일, ⑦ 공휴일(구경, 추석 연휴만 적용), ⑧ 공휴일 다음날 등으로 총 8개의 타입으로 구분하였다. 계절타입은 봄(3월, 4월, 5월), 여름(6월, 7월, 8월), 가을(9월, 10월, 11월), 겨울(12월, 1월, 2월) 등으로 4단계로 구분하여 실험하였다.

A 정수장에서 공급된 일일 물 수요량의 연도별 상관계수 분석결과를 나타냈다. 우선, 외부 인자에서는 월, 계절타입, 기온이 일, 일타입에 비하여 상관성이 높은 것으로 나타났다. 특히 2007년도 물 수요 데이터는 월에 대해 부의 상관성이 높은 것으로 나타났다. 시간특성에서는 과거 1일전과 2일전의 과거 물 수요량이 현재의 물 수요량과 상관성이 높은 것으로 나타났다.

B 정수장의 경우, 외부 인자에서는 월, 계절, 기온이 일, 일타입에 비하여 상관성이 높은 것으로 나타났으나 상관계수값이 낮아 물 수요량과 연관성이 적은 것으로 분석된다. 시간특성에서는 과거 1일전, 2일전 및 3일전의 과거 물 수요량이 현재의 물 수요량과 상관성이 높은 것으로 나타났다.

〈표 1〉 주 계통의 연도별 상관계수 분석

구분		2007	2008	2007-2008
외부 인자	월	-0.4304	-0.4875	-0.2991
	일	-0.0598	-0.1385	-0.0652
	일타입	0.0728	0.0317	0.0447
	계절타입	-0.2546	0.0131	-0.0857
	기온	0.3649	0.0105	0.1209
시간 인자	1일전	0.5356	0.4771	0.7868
	2일전	0.5367	0.5139	0.7947
	3일전	0.4727	0.4964	0.7768
	4일전	0.4930	0.5744	0.7963
	5일전	0.4694	0.4153	0.7622
	6일전	0.4250	0.4129	0.7528


2.3 실험 및 검증

그림 3과 4에서는 주 계통에서 입력층과 규칙수에 따른 물수요량 예측을 위해 처리속도가 매우 우수한 ELM에 의한 실험결과를 나타냈다. 실험결과 일반적으로 m 이 증가하고 규칙수가 증가할수록 예측 성능이 우수한 것으로 나타났다. 학습데이터는 $m=6$ 이고 규칙수가 38일 때 MAPE는 3.73%로 가장 우수하게 나타났으며, 이 때 검증 데이터의 성능은 6.24%를 나타냈다. 한편 검증데이터는 $m=5$ 이고 규칙수가 10일 때 MAPE는 4.82%로 가장 우수하게 나타났으며 이 때 훈련 데이터의 성능은 3.93%로 나타났다. 검증 데이터가 가장 우수할 때 훈련데이터와 검증 데이터간의 MAPE는 약 0.89%의 차이를 나타냈다.


그림 5에서는 A정수장에 대한 실험결과를 나타냈다. A정수장에서 훈련 데이터의 성능이 가장 우수한 때는 $m=6$ 이고 규칙수가 4인 경우이며 이 때 MAPE는 3.02%로 나타났다. 한편 검증데이터는 $m=6$ 이고 규칙수가 12일 때 MAPE는 3.81%로 가장 우수하게 나타났다.

그림 6에서는 B정수장에 대한 실험결과를 나타냈다. B정수장에서 훈련


데이터의 성능이 가장 우수한 때는 $m=5$ 이고 규칙수가 40인 경우이며 이 때 MAPE는 4.21%로 나타났다. 한편 검증데이터는 $m=6$ 이고 규칙수가 14일 때 MAPE는 5.17%로 가장 우수하게 나타났다.




(a) 학습 데이터 (b) 검증 데이터
〈그림 3〉 주 계통의 입력층과 은닉층의 수에 따른 예측오차



(a) 학습 데이터 (b) 검증 데이터
〈그림 4〉 주 계통의 성능 비교



(a) 학습 데이터 (b) 검증 데이터
〈그림 5〉 A정수장 성능 비교



(a) 학습 데이터 (b) 검증 데이터
〈그림 6〉 B정수장 성능 비교

3. 결 론

본 연구를 통하여 지방 중소지역에서의 주 계통 뿐만 아니라 계통내 정수장에서의 물 공급에 대한 특성을 분석하였다. 이를 통하여 신경회로 망중 ELM 모델을 예측알고리즘으로 적용하였다. 이의 결과로서 주 계통에서의 예측결과 MAPE 4.82%, A 정수장에서의 결과는 3.81%, B 정수장에서의 결과는 5.17%를 각각 얻었다. 또한, 본 연구를 통하여 향후 주 계통 예측알고리즘의 적용성을 높여야할 것으로 분석되었다.

[참 고 문 헌]

- [1] 최기선, 신강욱, 임상희, 전명근 "데이터 마이닝과 칼만필터링에 기반한 단기 물 수요예측 알고리즘", 제어·로봇·시스템학회, Vol. 15, NO. 10, pp. 1056-1061, 2009.
- [2] H.M. Al-Hama, S.A. Soliman, "Short-term electric load forecasting based on Kalman filtering algorithm with moving window weather and load model", Electric power systems research, No. 68, pp. 47-59, 2004.
- [3] J. L. Torres, A. Garcia, M. De Blas, and A. De Francisco, "Forecast of hourly average wind speed with ARMA models in Navarre(Spain)", Solar Energy, 79, pp. 65-77, 2005.
- [4] G. B. Huang, Q. Y. Zhu, and C. K. Siew, "Extreme learning machine: a new learning scheme of feedforward neural networks," in Proc. 2004 IEEE Int. Conf. Neural Networks, Vol. 2, pp. 985-990, 2004.
- [5] G. B. Huang, Q. Y. Zhu, and C. K. Siew, "Extreme learning machine: theory and applications," Neurocomputing, Vol. 70, No. 1-3, pp. 489-501, 2006.