

Development of ELM based Load Modeling Method for Residential Loads

정 영 택* · 지 평 식*

(Young-Taek Jung · Pyeong-Shik Ji)

Abstract - Due to the increasing of nonlinear loads such as converters and inverters connected to the electric power distribution system, and extensive application of harmonic generation sources with power electronic devices, disturbance of the electric power system and its influences on industries have been continuously increasing. Thus, it is difficult to construct accurate load model for active and reactive power in environments with harmonics. In this research, we develop a load modeling method based on Extreme Learning Machine(ELM) with fast learning procedure for residential loads. Using data sets acquired from various residential loads, the proposed method has been intensively tested. As the experimental results, we confirm that the proposed method makes it possible to effectively estimate active and reactive powers than conventional methods.

Key Words : Load modeling, ELM, Residential loads, Harmonics, Neural networks

1. 서 론

신뢰성 높은 부하모델링 기법은 안정적이고 경제적으로 전력계통을 운용하는데 필요한 기본요소이다. 이를 위해 다양한 부하모델링 기법이 제안 및 적용되고 있으나, 모선의 전압 및 주파수에 의해 부하모델은 다양한 특성을 나타냄으로 기존 방법들을 적용하여 정확한 부하를 모델링 하는 데는 한계가 있다. 특히, 최소자승법에 근거한 대표적인 부하 모델링 기법인 다항식 방법은 선형부하모델에는 효과적인 것으로 나타났으나, 전력변환기기 등이 포함된 비선형 부하 모델에는 부정확한 결과치를 산출하는 것으로 보고되고 있다. 특히, 최근에 비선형 부하의 증가에 따라 증가추세에 있는 고조파가 존재하였을 경우 다항식 방법은 추정능력이 저하되는 것으로 보고되고 있다[1-3].

부하모델에 관한 연구를 살펴보면, 개별부하 및 집단부하에 대하여 정특성 실험을 실시하고 주거용 및 상업용, 산업용 부하에 대한 시간별 부하구성비를 추정하여 부하모델의 효용성을 입증한 방법이 제안되었다[4]. 또한, 신경회로망 등을 이용한 부하모델링 기법 및 계통 적용 방법에 관한 방법론을 제시한 연구도 수행되었다[5]. 이외에도, 전력계통 안정도 정밀해석을 위한 적정부하모델의 개발방법과 적용 기법[6], 부하 역률모델 개발 기초연구[7], 다층 신경회로망을 이용하여 동태부하를 모델링하고 하는 방법[8], 재귀 신경회로망을 이용하여 부하를 표현하고 전압안정도에 적용한 바 있

으며[9], 부하의 정태 및 동태모델의 파라미터를 확률론적 방법으로 표현한 연구도 시도되었다[10]. 최근에 Keyhani 등은 신경회로망을 이용하여 선형 및 비선형으로 구성된 집단 모델에 대한 부하모델을 개발하였으나, 인버터 구동 유도전 동기의 부하모델을 개발하는데 한정되어 있다[11]. 또한 전력계통의 불확실성에 따른 동적 부하모델의 오차 범위를 정량적으로 제시한 방법[12]과 신경회로망과 다중곡선 식별기법을 각각 이용하여 과도상태의 동적모델에 제안하고 실증 데이터를 이용하여 타당성을 검증한 연구도 진행되고 있다[13][14]. 그러나 기존의 기법들은 고조파를 고려하지 않고 부하를 모델링함으로써 고조파가 존재하는 환경 하에서는 신뢰성 높은 모델을 제공하지 못하는 단점이 있다[15].

따라서 본 연구에서는 학습처리속도가 매우 우수한 ELM(Extreme Learning Machine)을 이용하여 고조파가 존재하는 환경 하에서도 성능이 우수한 부하모델링 기법을 제안한다. 개발된 부하모델은 입력으로서 기본 주파수와 기본 전압 외에 고조파 성분도 고려하였으며, 기존에 널리 사용되는 IEEE 이차식과 다층 신경회로망 기법들과 비교함으로써 제안방법의 타당성을 입증하고자 한다.

2. ELM을 이용한 부하 모델링 기법

그림 1에서는 본 연구에서 개발한 고조파 성분을 고려한 ELM 모델을 나타냈다. 그림 1에서 보는 바와 같이 ELM 모델은 Huang등에 의하여 제안된 방법으로[16][17], 구조는 입력층, 은닉층, 출력층으로 되어 있으며 은닉층의 노드 수는 사용자에 의해 결정된다. 은닉층과 출력층 사이에는 서로를 연결해 주는 가중치 W 가 존재하며 입력벡터 X 를 출력값 Y 로 대응시켜주는 비선형 함수의 역할을 한다. 은닉층에 사용되는 기저함수로는 일반적으로 sigmod 함수를 주

* 정 회 원 : 한국전력공사 이천지사

† 교신저자, 시니어회원 : 한국교통대학교 전기공학과 교수

E-mail : psji@ut.ac.kr

접수일자 : 2012년 1월 30일

최종완료 : 2012년 2월 20일

로 사용한다. 최급경사법(gradient descent method)에 기반한 일반적인 신경 회로망의 학습은 좋은 성능을 얻기 위해 많은 반복 학습을 필요로 하며, 적절하지 못한 학습에 의하여 낮은 적응성을 보이거나 종종 국부 최소해(local minimum)에 수렴하는 단점을 가지고 있다. 그러나 ELM에서 출력 가중치들은 반복적인 학습 구조 대신에 모어-페로스의 일반화된 역행렬(Moore-Penrose generalized inverse)에 의해 분석적으로 계산되어짐으로 반복학습이 이루어지지 않는다.

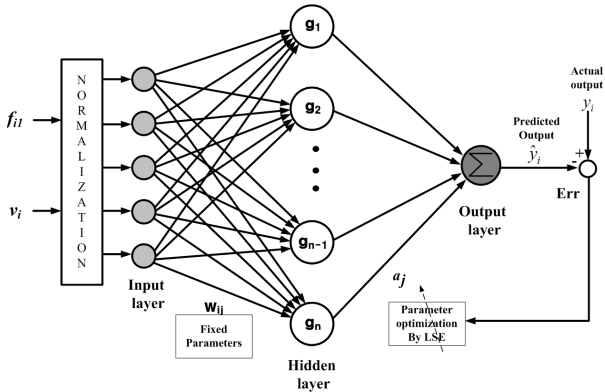


그림 1 ELM을 이용한 부하 모델링 기법
Fig. 1 Proposed load modeling method by ELM

그림 2에서는 본 논문에서 사용된 ELM의 학습과정을 나타냈다. ELM의 학습과정을 설명하기 위해 m 개의 데이터 $\{(\mathbf{x}_i, y_i), i = 1, 2, \dots, m\}$ 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 식 (2)과 같이 나타낼 수 있다.

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

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, $\mathbf{a} = [a_1, a_2, \dots, a_N]^T$ 은 은닉노드들과 출력노드를 연결하는 가중치 벡터이다. $\mathbf{w}_j \cdot \mathbf{x}_i$ 는 \mathbf{w}_j 와 \mathbf{x}_i 의 내적을 의미한다.

식 (2)는 식 (3)과 같이 간결하게 표현될 수 있다.

$$\mathbf{G}\mathbf{a} = \mathbf{y} \quad (3)$$

여기서

$$\mathbf{G}(\mathbf{w}_1, \mathbf{w}_2, \dots, \mathbf{w}_N, \mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_m) = \begin{bmatrix} \mathbf{g}(\mathbf{w}_1 \cdot \mathbf{x}_1) & \dots & \mathbf{g}(\mathbf{w}_N \cdot \mathbf{x}_1) \\ \vdots & & \vdots \\ \mathbf{g}(\mathbf{w}_1 \cdot \mathbf{x}_m) & \dots & \mathbf{g}(\mathbf{w}_N \cdot \mathbf{x}_m) \end{bmatrix} \quad \mathbf{y} = \begin{bmatrix} y_1 \\ \vdots \\ y_m \end{bmatrix}_{m \times 1} \quad (4)$$

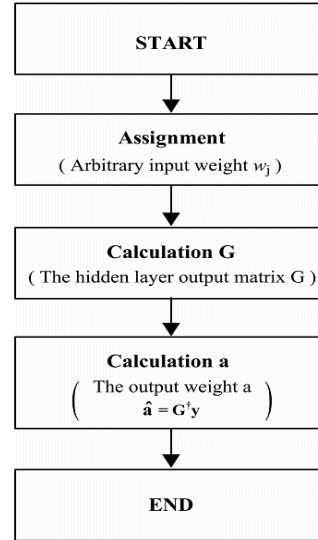


그림 2 ELM의 학습과정
Fig. 2 Learning process of ELM

\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, 식 (5)와 같이 최소자승법에 의하여 출력 가중치 $\hat{\mathbf{a}}$ 을 구한다.

$$\hat{\mathbf{a}} = \mathbf{G}^\dagger \mathbf{y} \quad (5)$$

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 역행렬[18]은 식 (6)과 같으며, 최종 모델링 결과는 식 (7)과 같다.

$$\mathbf{G}^\dagger = (\mathbf{G}^T \mathbf{G})^{-1} \mathbf{G}^T \quad (6)$$

$$\hat{\mathbf{y}} = \hat{\mathbf{G}} \hat{\mathbf{a}} \quad (7)$$

따라서, 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 최적의 해를 얻는 경향이 있다는 점이다. 특히, 경사 기반 학습 방법들이 국부최소(local minimum), 오버피팅과 같은 문제점이 있는 반면에 ELM은 한 번의 학습으로 최적의 해에 직접적으로 도달한다.

3. 사례연구

3.1 실험장치의 구성 및 데이터 취득

본 연구에서 고조파를 고려한 ELM 기반의 부하모델링 기법의 타당성을 입증하기 위해 대표적으로 사용되는 주거용 부하를 이용하여 표 1에서 보는 바와 같이 8개의 부하를 선정하였다. 부하모델링을 위한 개별부하 실험은 입력전압과 주파수를 변화시키면서 부하가 소비한 유효전력과 무효전력

을 취득한다. 이렇게 취득된 입력정보(전압, 주파수)와 출력정보(유효전력 또는 무효전력)를 이용하여 개별부하특성을 모델링 한다.

표 1 실험에 사용된 주거용 개별 부하기기
Table 1 Individual residential load used in experiment

항 목	정격전압[V]	정격소비전력[W]	대수
선풍기	220	60	1
형광등	220	20	1
백열등	220	100	1
전기히터	220	970	1
전기로	220	1000	1
전기밥솥	220	1100	1
헤어드라이기	220	1200	1
TV	220	60	1

고조파에 따른 부하의 특성을 효과적으로 모델링할 수 있는 기법을 개발하기 위해 기본정보인 전압과 주파수 정보 외에 고조파성분을 추가로 부하에 인가하여 유효전력과 무효전력을 취득하였다. 데이터 취득은 그림 3에서 보는 바와 같이 부하에 입력전압, 주파수, 및 고조파 유무 조건에 따라 부하의 유효전력과 무효전력을 측정하였다. 우선, 입력전압은 180[V]에서 235[V]까지 1[V]씩 총 56개의 전압변동에 따른 유효전력과 무효전력을 측정하였다. 또한 입력주파수는 58[Hz], 60[Hz], 62[Hz] 로 변동시키면서 실험하였다. 마지막으로 계통의 고조파 유무를 가정하여 입력파형을 고조파가 없는 정현파와 다수의 고조파가 포함된 구형파를 설정된 전압과 주파수를 고려하여 인가하였다. 이와 같은 조건은 정현파일 때는 고조파가 존재하지 않고, 구형파일 때는 기수파의 고조파가 다수 존재하는 것에 기초를 하고 있다.

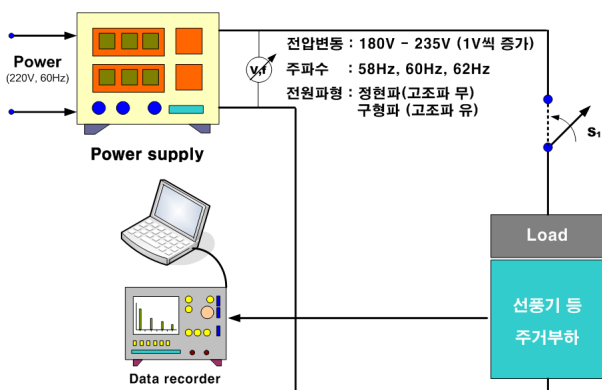


그림 3 주거용 개별부하실험 방법
Fig. 3 Experiments for individual residential loads

부하에 인가되는 전원의 파형, 전압과 주파수 변환을 위해 고조파 전원인가 장치 4500LS(California Instruments)를 사용하였고, 데이터 취득과 고조파 분석을 위해 DT9834 A/D변환모듈과 DEWE Soft 6.3 프로그램을 이용하였다. 그

림 4에서는 본 연구에서 사용된 데이터 취득 시스템 구성도를 나타냈다.

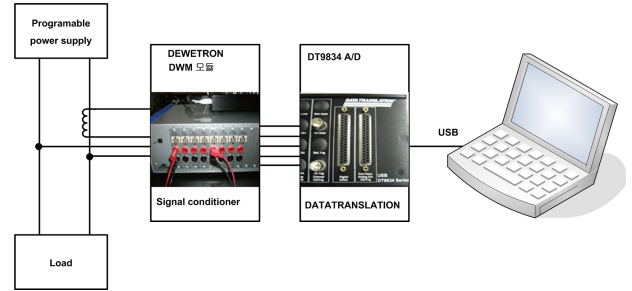


그림 4 데이터 취득 시스템 구성도
Fig. 4 Structure of data acquisition system

3.2 부하모델링 결과

본 연구에서는 고조파를 고려한 부하모델을 개발하고자 하며, 개발된 부하모델의 성능을 검증하기 위하여 입력전압과 주파수를 변동시키면서 다양한 데이터를 취득하였다. 즉, 입력전압은 180[V]에서 235[V]까지 1[V]씩 총 56개의 전압변동에 따른 유효전력과 무효전력을 측정하였고, 주파수는 58[Hz], 60[Hz], 65[Hz]로 총 3개의 주파수 변동에 따른 유효전력과 무효전력을 측정하였다. 또한, 각각의 경우에 대해서 고조파가 존재하는 경우와 존재하지 않는 경우에 대한 유효전력과 무효전력을 구하였다. 따라서 취득한 데이터는 총 336개((전압변동 56 × 고조파 유·무 2)×주파수변동 3)를 구하였다. 취득한 데이터 중에서 부하모델 학습을 위해 180[V]에서 235[V]의 입력 전압값 중에서 짝수에 해당하는 168개를 학습데이터로 사용하였고, 나머지 홀수에 해당하는 168개를 검증데이터로 사용하여 부하모델의 성능을 평가하였다.

표 2에서는 부하모델링 결과를 나타냈다. 여기서, 성능지표는 평균자승오차근인 RMSE (Root mean square error)을 기준으로 하였다. 표 5에서 기존 방법으로 사용된 다항식 모델링 기법은 식 (8) 및 식 (9)에 의해 유효전력 $\hat{P}(t)$ 와 $\hat{Q}(t)$ 을 추정한다. 이 때 관련된 파라미터들은 최소자승법에 의해 결정된다. 또한, MLP의 은닉층은 15로 설정하여 모델링을 수행하였다.

$$\hat{P}(t) = P_0 [p_1 V(t)^2 + p_2 V(t) + p_3] (1 + K_{pf} \Delta f(t)) \quad (8)$$

$$\hat{Q}(t) = Q_0 [q_1 V(t)^2 + q_2 V(t) + q_3] (1 + K_{qf} \Delta f(t)) \quad (9)$$

표 2에서는 선정된 개별부하에 대하여 IEEE 2차식, 다층형신경회로망(MLP), ELM, 제안된 방법 등에 대하여 유효전력에 대한 모델링 오차와 무효전력에 대한 모델링 오차를 나타내었다. 우선, 유효전력에 대한 결과를 살펴보면, 고조파 성분을 고려하지 않은 기존 모델링 기법의 경우 고조파 성분에 의해 변동이 심한 가정용 기기인 “TV”, “전기히터”, “선풍기”, “형광등” 순으로 모델링 오차가 크게 발생하였다. 그러나 제안된 고조파 성분을 고려한 제안방법의 경우 일관되게 우수한 모델링 오차를 보임을 확인할 수 있다. 무효전력에 대한 결과를 살펴보면, 고조파 성분을 고려하지 않은

표 2 개별부하의 모델링 오차

Table 2 Modeling error for individual residential loads

(a) 유효전력에 대한 평균 모델링 오차

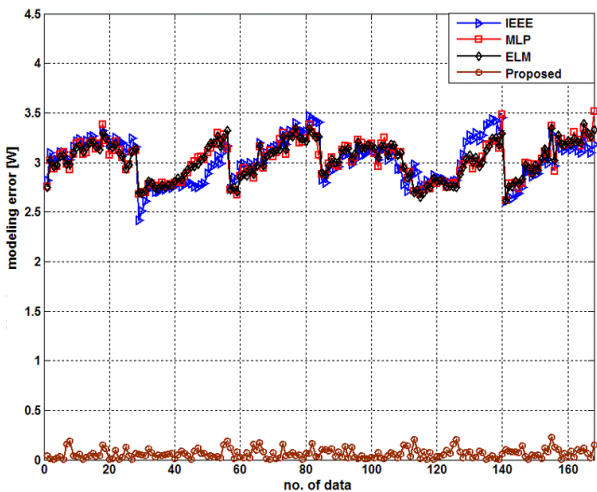
[%]

부하	학습 데이터				검증 데이터			
	IEEE이차식	MLPN	ELM	Proposed	IEEE이차식	MLPN	ELM	Proposed
선풍기	3.038	3.035	3.035	0.058	3.033	3.032	3.031	0.071
형광등	2.098	2.093	2.093	0.086	2.101	2.096	2.096	0.123
백열등	0.341	0.326	0.327	0.099	0.343	0.332	0.330	0.128
전기히터	3.139	2.983	2.905	0.872	3.146	3.045	2.911	1.082
전기로	1.007	1.176	0.981	0.051	1.064	1.440	1.052	0.081
전기밥솥	1.511	1.886	1.380	0.104	1.549	2.047	1.419	0.120
헤어드라이기	1.896	1.836	1.861	0.588	1.818	1.988	1.894	0.830
TV	9.094	9.091	9.091	0.116	9.128	9.126	9.126	0.153

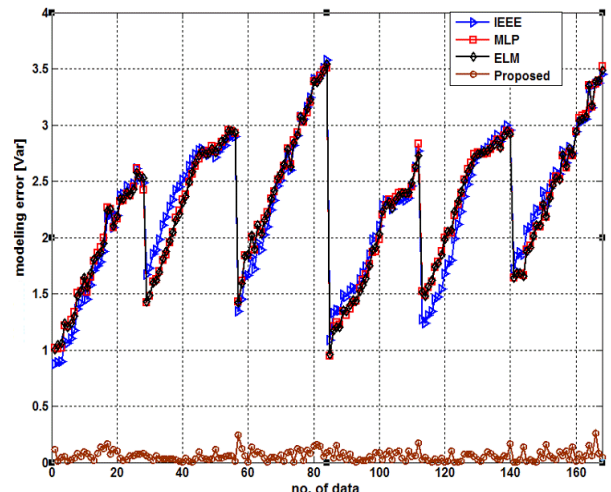
(b) 무효전력에 대한 평균 모델링 오차

[%]

부하	학습 데이터				검증 데이터			
	IEEE이차식	MLPN	ELM	Proposed	IEEE이차식	MLPN	RBFN	Proposed
선풍기	2.318	2.314	2.313	0.051	2.346	2.342	2.342	0.075
형광등	3.876	3.868	3.868	0.097	3.908	3.901	3.900	0.123
백열등	0.284	0.269	0.271	0.098	0.282	0.268	0.271	0.123
전기히터	2.832	2.829	2.829	0.092	2.847	2.845	2.845	0.107
전기로	3.266	3.261	3.260	0.048	3.294	3.289	3.289	0.075
전기밥솥	2.870	2.867	2.867	0.078	2.901	2.900	2.899	0.108
헤어드라이기	83.510	83.482	83.496	0.852	84.478	84.571	84.512	1.483
TV	19.044	19.043	19.042	0.081	19.176	19.176	19.042	0.117



(a) 유효전력



(b) 무효전력

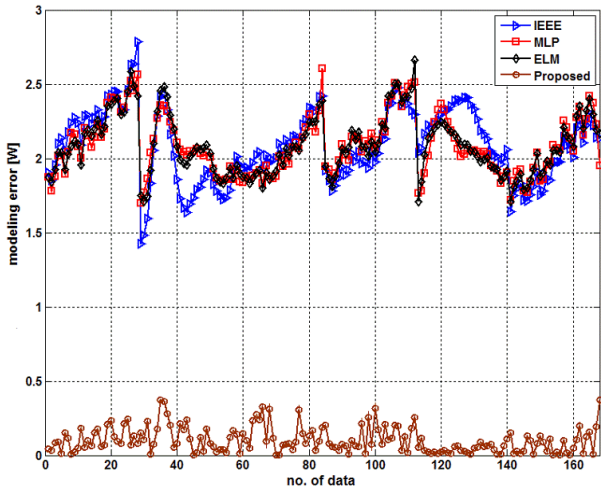
그림 5 선풍기에 대한 모델링 오차

Fig. 5 Modeling error for a fan

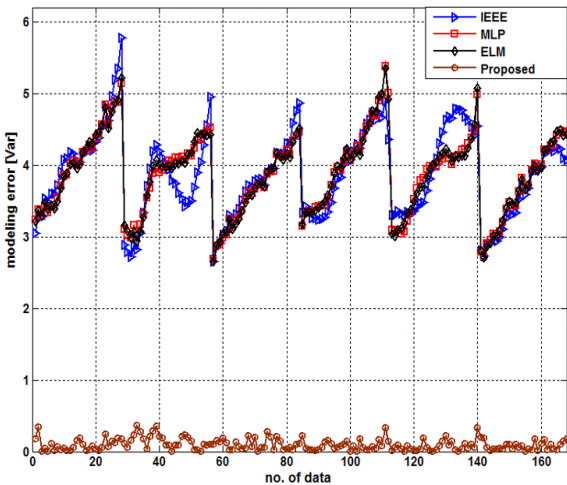
모델링 기법의 경우 “헤어드라이기”가 가장 큰 모델링 오차를 나타냈다. 이는 “헤어드라이기”가 고조파 성분에 따라 무효전력의 변동이 크게 발생하기 때문이라 분석된다. 다음으로 “TV”, “전기로” 순으로 모델링 오차가 큰 것으로 나타

났다. 그림 5와 그림 6에서는 선풍기와 형광등에 대한 모델링 오차를 나타냈다. 그림 5 및 6에서 보는 바와 같이 제안된 고조파 성분을 고려한 제안방법의 경우 일관되게 우수한 모델링 오차를 보임을 확인할 수 있다.

참 고 문 헌



(a) 유효전력



(b) 무효전력

그림 6 형광등에 대한 모델링 결과

Fig. 6 Modeling error for a fluorescent lamp

4. 결 론

전력계통에 연결되어 있는 컨버터와 인버터와 같은 비선형 부하의 증가와 전력전자 소자로 구성된 고조파 발생원의 광범위한 적용으로 인하여 계통의 외란과 그에 따른 산업체에서의 영향은 지속적으로 증대되고 있다. 따라서 다양한 고조파가 존재하는 환경하에서 유효전력과 무효전력 모델을 정확하게 구축하는데 어려움이 있다. 이러한 무효전력 모델을 효과적으로 구축하기 위해서는 고조파에 따른 인가전압의 특성을 고려할 필요가 있다.

본 연구에서는 학습처리속도가 매우 우수한 ELM을 이용하여 주거용 부하의 유효전력 및 무효전력을 추정하는 부하 모델링 기법을 개발하였다. 실험결과 고려 대상의 모든 주거용 부하에 대해 효과적으로 유효전력과 무효전력을 추정함을 확인할 수 있었다. 향후 추정된 기법을 실계통의 다양한 주거용 부하에 적용하여 그 유용성을 검토할 필요성이 있다.

- [1] Mau Teng Au and J. V. Milanovic, "Development of Stochastic Aggregate Harmonic Load Model Based on Field Measurements," IEEE Trans. on Power Delivery, Vol. 22, pp. 323-330, 2007.
- [2] Hsiung Cheng Lin, "Intelligent Neural Network-Based Fast Power System Harmonic Detection," IEEE Trans. on Industrial Electronics, Vol. 54, pp. 43-52, 2007.
- [3] Huaiwei Liao, "Power System Harmonic State Estimation and Observability Analysis via Sparsity Maximization," IEEE Trans. on Power Systems, Vol. 22, pp. 15-23, 2007.
- [4] 한국전력공사 기술연구원, "전력계통 안정도 해석을 위한 적정부하 모델에 관한 연구" KRC-88S-J02, 1989.
- [5] 지평식, "신경회로망에 의한 부하모델링과 계통해석에 관한 연구", 충북대학교 대학원 박사학위 논문, 1998.
- [6] 김정훈 외, "전력계통 안정도 정밀해석을 위한 적정부하모델에 대한 연구" 한국전력공사 전력연구원 연구보고서, 2000.
- [7] 이병하, 김정훈, "전력산업구조개편하에서 전력계통 운용과 계획을 위한 부하역률모델 개발에 관한 연구", 기초전력연구원 연구보고서, 2004.
- [8] D.M. Vilathgamuwa, Wijekoon, H.M, "Representation of Power System Load Dynamics with ANN for Real-time application," Power Engineering Society General Meeting, Vol. 3, pp. 13-17, 2003.
- [9] Dingguo Chen, Ronald R. Mohler, "Neural-Network-Based Load Modeling and Its Use in Voltage Stability Analysis," IEEE Trans. on Control Systems Technology, Vol. 11, No. 11, pp. 460-470, 2003.
- [10] V. Knyazkin, C. A. Canizares, L. H. Soder, "On the Parameter Estimation and Modeling of Aggregate Power System Load," IEEE Trans. on Power System, Vol. 19, No. 2, pp. 0123-1031, 2004.
- [11] A. Keyhani, W. Wu, G. T. Heydt, "Composite Neural Network Load Models for Power System Stability Analysis," IEEE PES 2004, Vol. 2, pp. 1159 - 1163, 2004.
- [12] I. A. Hiskens, J. Alseddiqui, "Sensitivity, Approximation, and Uncertainty in Power System Dynamic Simulation," IEEE Trans. on Power Systems, Vol. 21, pp. 1808-1820, 2006.
- [13] Qian Ai, Danzhen Gu, Chen Chen, "New Load Modeling Approach Based on Field Tests for Fast Transient Stability Calculation," IEEE Trans. on Power Systems, Vol. 21, pp. 1864-1873, 2006.
- [14] He Renmu, Ma Jin, David J. Hill, "Composite Load Modeling via Measurement Approach," IEEE Trans. on Power Systems, Vol. 21, pp. 663-672, 2006.
- [15] 지평식, 고조파를 고려한 부하축약 적용 알고리즘 개발, 지식경제 기술혁신사업 보고서, 2011.

- [16] 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.
- [17] 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.
- [18] D. Serre, Matrices : Theory and Application, New York, Springer-Verlag, 2002.

저 자 소 개



정 영 택 (鄭 榮 澤)

1960년 4월 5일생. 2008년 한국교통대학교 전기공학과 졸업(공학사), 2010년 2월 동 대학교 전기공학과 석사과정 졸업(공학석사), 현재 한국전력공사 이천지사 전력공급팀 근무

E-mail : kepc60@hanmail.net



지 평 식 (池 平 植)

1964년 3월 5일생. 1989년 2월 한밭대학교 전기공학과 졸, 1994년 충북대학교 대학원 전기공학과 석사과정 졸업(석사), 1998년 동대학원 전기공학과 박사과정 졸업(박사), 현재 국립 한국교통대학교 전기공학과 교수

Tel : 043-841-5152

E-mail : psji@ut.ac.kr