

자동검침 고객의 부하패턴을 이용한 일일 대표 부하패턴 생성

論文

57-9-5

Typical Daily Load Profile Generation using Load Profile of Automatic Meter Reading Customer

金榮一[†] · 辛鎮浩^{*} · 李俸在^{*} · 梁日權^{*}
(Young-Il Kim · Jin-Ho Shin · Bong-Jae Yi · Il-Kwon Yang)

Abstract – Recently, distribution load analysis using AMR (Automatic Meter Reading) data is researched in electric utilities. Load analysis method based on AMR system generates the typical load profile using load data of AMR customers, estimates the load profile of non-AMR customers, and analyzes the peak load and load profile of the distribution circuits and sectors per every 15 minutes/hour/day/week/month. Typical load profile is generated by the algorithm calculating the average amount of power consumption of each groups having similar load patterns. Traditional customer clustering mechanism uses only contract type code as a key. This mechanism has low accuracy because many customers having same contract code have different load patterns. In this research, We propose a customer clustering mechanism using k-means algorithm with contract type code and AMR data.

Key Words : Typical Load Profile, Clustering, Automatic Meter Reading, AMR

1. 서 론

배전선로의 효율적인 운영은 전력사의 경쟁력을 높이는데 중요한 요소이며, 이를 위한 방법으로 1995년부터 많은 기업들이 자동검침(AMR: Automatic Meter Reading) 시스템을 도입하여 운영하고 있다.

자동검침시스템은 단순한 검침에 대한 비용 절감을 넘어서 고객 서비스 수준을 향상시키고 경쟁력 있는 에너지 가격 정책을 유지하기 위해서 꼭 필요한 기술이다. 이 시스템을 통해 고객의 에너지 사용 효율을 높일 수 있도록 돋기 위해 시간대 별로 구체적인 고객의 전력 사용량을 제공하여 고객의 전력사용 형태를 분석할 수 있으며[1], 시간대별 가격정책과 부하관리[2], 수요자 관리, 배급망 최적화, 배전 자동화[3], 부하 예측[4] 등의 분야에 활용할 수 있게 된다. 원격검침 방식은 초기에는 단순한 검침 이익이 주된 목적 이였으나 최근에는 원격검침을 통해 얻은 데이터를 새로운 응용 소프트웨어를 통해 활용하고 회사와 지사간의 연동을 통해 새로운 고객 서비스와 운영 이익을 창출하고 있다. 특히 부하 및 배전망 최적화 부분에 있어서는 상당한 이익을 창출하고 있으며, 최근에는 실시간 배전 최적화를 위한 응용 프로그램 개발에 대한 연구가 진행되고 있다.

기존의 배전선로의 부하분석을 위한 방식은 변전소를 통해 각 회선으로 제공되는 15분 단위의 전력량을 SOMAS

(Substation Operating results MAnagement System)를 통해 얻을 수 있을 뿐이었다. 자동검침시스템은 회선에 연결된 고객이나 서비스의 15분 단위 전력량을 제공할 수 있어 보다 정확하고 빠른 정보분석 능력을 갖출 수 있게 한다. 그러나 모든 서비스에 자동검침 장비를 설치하여 데이터를 수집하는 방식은 비용적인 측면에서 또 다른 문제점을 발생시킨다.

본 연구에서는 최소한의 서비스에 검침장비를 설치하고 수집된 데이터를 바탕으로 데이터 분석을 통해 각 서비스에 대한 대표 부하패턴을 생성하고 검침장비가 설치되지 않은 서비스의 월 사용량을 대표 부하패턴에 적용하여 가상의 15분 단위 부하패턴을 생성하였다. 현재 한전에서는 신규 고객을 등록할 때 계약종별, 전기사용용도, 고객의 산업종류 및 계약전력량 등과 같은 정보를 입력하여 고객을 분류하고 있으며, 계약종별에 따라 고객의 대표 부하패턴을 생성하여 배전 선로의 부하분석 자료로 사용하고 있다. 그러나 이러한 방식은 고객정보 입력 과정에서 고객에 대한 정확한 분류가 어렵고, 계약종별 코드만으로 생성한 대표 부하패턴의 오차가 커서 분석에 어려움을 갖게 된다. 본 연구에서는 동일한 계약종별 코드를 갖는 자동검침 고객의 부하패턴을 이용하여 k-means 기법을 적용하여 고객을 분류하였다. 고객 분류를 위한 클러스터의 개수(k)는 대표 부하패턴의 오차가 수렴하는 지역에 대한 값으로 설정하였다.

2. 기존의 대표 부하패턴을 이용한 부하분석

2.1 자동검침 개요

배전선로는 그림 1과 같이 변전소에서 여러 개의 회선으로 나누어지고, 회선에서는 여러 구간으로 나누어져 구성된다.

[†] 교신저자, 正會員 : 韓國電力公社 電力研究員

E-mail : yikim@kepco.co.kr

* 正會員 : 韓國電力公社 電力研究員

接受日字 : 2008年 5月 9日

最終完了 : 2008年 7月 23日

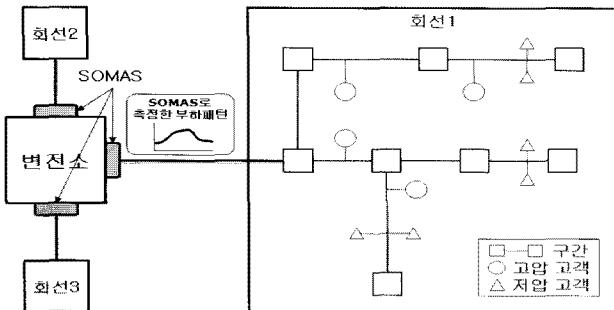


그림 1 배전선로의 구성요소

Fig. 1 Basic component of distribution line

고전적인 배전선로의 운영은 각 회선의 사용전력을 SOMAS를 통해 15분 단위로 검침한 데이터를 바탕으로 이루어졌다. 그러나 SOMAS 데이터만으로는 회선 전체의 개략적인 운영상태는 파악할 수 있지만, 회선 내에 각 구간별, 각 변압기별 운영상태는 파악이 어려우며, 특히 일별, 시간별 사용량에 대한 정보가 부족하여 신뢰할 만한 부하 데이터를 얻기가 어렵게 된다. 이러한 정보를 파악하기 위해서는 구간이나 변압기에 운영정보를 취득할 수 있는 계측장비를 설치하고 이를 통해 수집된 데이터를 분석해야만 가능하다. 자동검침은 배전설비에 15분 단위로 전력량을 계량할 수 있는 장비를 부착하고 이를 PLC와 같은 유선망이나 CDMA와 같은 무선망을 이용하여 중앙 서버로 전송하는 방식으로 운영된다. 15분 단위의 데이터를 활용할 경우 시간대 별로 회선 및 구간에 대한 사용량 및 피크 로드 등의 분석이 가능하게 되며 배전선로의 재구성 및 추후 배전망의 확충을 위한 분석 자료로 활용이 가능하게 된다.

2.2 계약종별 대표 부하패턴 생성

조류계산을 이용하여 구간부하를 분석하기 위해서는 계약종별에 따른 일일 대표 부하패턴을 필요로 하게 된다. 고객 c 에 대한 하루 부하패턴을 L_{day}^c 라고 할 경우,

$$L_{day}^c = [l_1^c, l_2^c, \dots, l_i^c, \dots, l_T^c]$$

L_{day}^c : 고객 c 의 하루 부하패턴

l_i^c : 고객 c 의 i 번째 15분 단위 부하량

i : 15분 단위 부하량에 대한 일련번호

T : 일련번호의 최대값 ($T=4\times24=96$)

로 표현할 수 있다. 기존의 연구에서는 이를 이용하여 n 개의 고객으로 구성된 하나의 계약종별 코드에 대한 일일 대표 부하패턴(TDLP: Typical Daily Load Profile)을 각 고객들의 15분 단위 부하량에 대한 평균을 계산하여 생성하였다.

$$TDLP = \left[\frac{\sum_{c=1}^n l_1^c}{n}, \frac{\sum_{c=1}^n l_2^c}{n}, \dots, \frac{\sum_{c=1}^n l_i^c}{n}, \dots, \frac{\sum_{c=1}^n l_{96}^c}{n} \right]$$

2.3 조류 계산을 이용한 구간 부하 분석

연구논문 [5]에서는 약 10만호의 자동검침 고압고객을 대상으로 15분 단위의 전력 사용량을 수집하여 각 계약종별 일일 대표 부하패턴을 생성하였다.

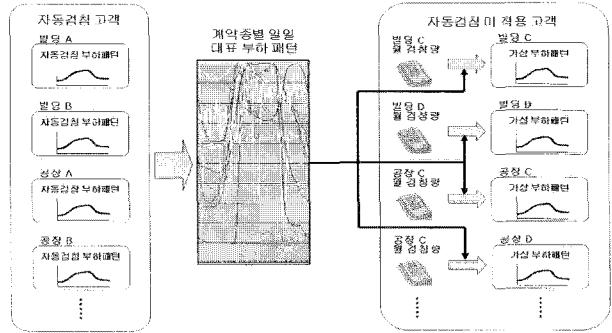


그림 2 자동검침 부하패턴을 이용한 가상 부하패턴 생성방법

Fig. 2 Virtual load pattern generation using AMR load pattern

이를 활용하여 그림 2와 같이 자동검침을 하지 않는 고압고객의 월 검침량을 각 계약종별 대표 부하패턴에 적용하여 15분 단위의 가상 부하패턴을 생성하였다. 자동검침 고객의 부하패턴과 자동검침 미적용 고객의 부하패턴을 이용하여 Forward Sweeping[6] 기법을 적용하면 조류 계산을 통해 회선 및 구간에 대한 15분 단위 부하패턴을 생성할 수 있었다. 이러한 분석 방식을 통해 그림 3과 같이 각 구간에 대하여 15분/시간/일/주/월 단위의 최대부하 및 부하패턴 등을 분석할 수 있었다. 회선이나 구간 단위의 부하패턴을 활용하면 신규 고객이 발생할 경우 인접한 구간들 중에서 부하 사용률이 낮은 구간에 사용자를 연결하여 전체 구간들의 부하 사용률을 평준화 할 수 있으며, 특정 구간에 과도하게 부하가 집중되는 경우에는 스위칭을 통해 부하를 절제하여 부하률이 낮은 구간으로 우회하는 등의 운영이 가능하게 된다. 특히 변압기에 연결된 고객들의 부하패턴을 조합하여 변압기의 부하를 계산할 수 있어, 과부하 판정 알고리즘[7]을 이용하여 변압기의 수명을 예측할 수 있게 된다.

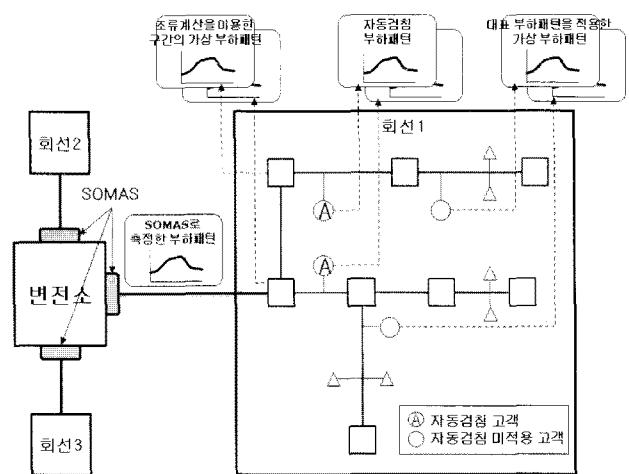


그림 3 조류계산을 이용한 구간의 가상 부하패턴 생성

Fig. 3 Virtual load pattern generation using Forward Sweeping Algorithm

3. 계약종별에 따른 고객분류 방법

본 연구에서는 고객의 계약종별 코드만을 이용하여 고객을 분류하고 대표 부하패턴을 생성하여 부하분석을 수행하

는 방식의 오류를 줄이기 위해 각 계약종별로 고객을 분류하고 해당 분류 내에 존재하는 고객의 자동검침 부하패턴을 이용하여 클러스터링 알고리즘을 통해 고객을 분류하고 대표 부하패턴을 생성하는 방식을 개발하였다. 본 연구에서는 강남지역의 고객에 대한 15분 단위 자동검침 데이터를 이용하여 그림 4와 같이 k-means[8] 알고리즘을 적용하고 대표 부하패턴을 생성하였다.

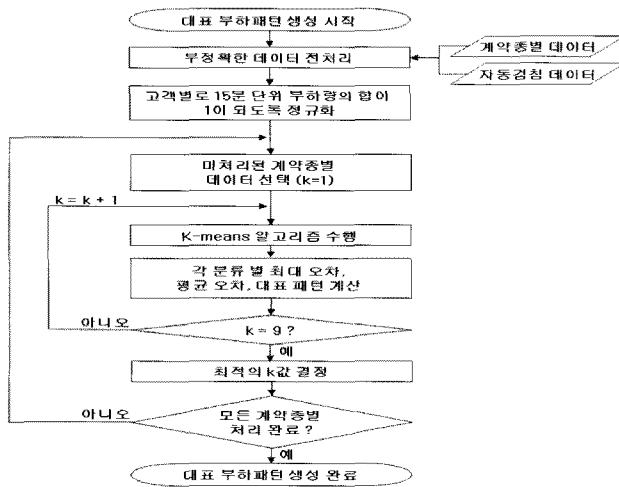


그림 4 K-mean 알고리즘을 이용한 대표 부하패턴 생성 절차
Fig. 4 Flow chart of typical load profile generation procedure

3.1 전처리 및 정규화

대표 부하패턴 생성을 위한 첫 번째 과정으로 전처리 및 정규화를 수행하게 된다. 우선 대표 부하패턴 생성을 위해 고객의 계약종별 데이터와 자동검침 데이터를 추출하고, 전처리 과정을 통해 통신오류 등으로 15분 단위 사용량이 완벽하게 검침되지 않은 부정확한 데이터들을 제거한다. 전처리된 데이터는 각 고객별로 15분 단위 부하량의 합이 1이 되도록 정규화 한다. 이 정규화 방식을 사용하면 총 사용량은 많은 차이가 있다고 하더라도 15분 단위의 사용량의 증감 방식이 유사한 고객들을 같은 그룹으로 분류할 수 있을 뿐 아니라, 정규화된 대표 부하패턴을 생성한 후 각 고객의 총 사용량을 곱하여 손쉽게 15분 단위 부하 값을 계산해 낼 수 있기 때문이다.

3.2 K-means 알고리즘 수행

정규화를 완료하면, 하나의 계약종별 데이터를 선택하여 k 값을 1부터 9까지 증가시키며 k-means 알고리즘을 수행하게 된다. k-means 알고리즘은 공간상에 존재하는 데이터를 서로 가까운 데이터들끼리 묶어서 몇 개의 그룹으로 나누는 분류 방법 중 하나로 데이터가 벡터 공간을 이룬다고 가정하고, 각각의 뮤음에 속하는 점들이 다른 뮤음의 중심에서의 유클리디안 거리보다는 자신이 속한 뮤음까지의 유클리디안 거리가 최소화 되도록 분류하여 뮤음의 분산도를 최소화하는 방식이다. 이것을 식으로 나타내면 다음과 같다.

$$V = \sum_{i=1}^k \sum_{j \in S_i} |x_j - \mu_i|^2$$

S_i : i 개의 뮤음, $i = \{1, 2, \dots, k\}$

μ_i : 각 뮤음의 중심(대표) 값

K-means 알고리즘은 맨 처음 각 점들을 k 개 집합으로 나누어 뮤음 C_i 를 만든 후, 각 C_i 의 중심값 μ_i 를 구한다. 이후, 각각의 점들을 방금 구한 중심 값 중에서 제일 가까운 것에 새롭게 연결하면서 새로운 C_i 를 구성하게 된다. 이 작업을 반복적으로 수행하면서 각각의 뮤음에 위치한 점들이 더 이상 다른 뮤음으로 이동하지 않거나, 중심 값이 바뀌지 않는 상태로 수렴하게 되며, 이때의 중심 값을 해당 뮤음을 대표하는 값으로 결정하게 된다.

본 연구에서는 이러한 k-means 알고리즘을 하나의 점이 아닌 15분 단위의 사용량에 대한 연속적인 데이터에 확장하여 적용하였다. 하나의 계약종별 코드에 존재하는 모든 고객의 15분 단위 부하량 데이터를 이용하여 k 개의 그룹으로 분할하고 각각의 그룹에서의 일일 대표 부하패턴($TDLP^{Ci}$)을 계산하였다. 각 그룹의 대표 부하패턴을 구성하는 15분 단위의 대표 부하량(μ_j^{Ci})은 해당 그룹에 속한 고객의 15분 단위 부하량(l_j^{Cm})의 중심값이 된다.

$$TDLP = \{TDLP^{C1}, TDLP^{C2}, \dots, TDLP^{C3}, \dots, TDLP^{Ck}\}$$

$$TDLP^{Ci} = [\mu_1^{Ci}, \mu_2^{Ci}, \dots, \mu_j^{Ci}, \dots, \mu_{96}^{Ci}]$$

$$\mu_j^{Ci} = \text{Mean}(l_j^{C1}, l_j^{C2}, \dots, l_j^{Cm}, \dots, l_j^{Cn})$$

(단, n 은 Ci 그룹에 속한 고객 수)

3.3 분류별 최대 오차 및 평균 오차 계산

K-means 알고리즘은 k 값을 초기에 사용자가 직접 입력해 주어야 하므로 적정한 k 값을 입력하지 않을 경우 만족 할만한 실행 결과를 얻을 수 없게 된다. 본 연구에서는 계약종별 k 값을 결정하기 위해 k 값의 범위를 1에서 9까지 증가시키며 k-means 알고리즘을 반복수행 하였다.

하나의 계약코드에 대한 최대 오차(E_{max})는 각각의 그룹들의 최대 오차(E_{max}^C) 중에서 최대값이 된다. 각 그룹의 최대 오차는 그룹 내에 존재하는 15분 단위의 최대 오차(d_{maxj}^C) 중에서 최대값이 된다. 15분 단위의 최대 오차는 15분 단위 대표 부하량(μ_j^C)과 해당 그룹에 속한 고객의 15분 단위 부하량들(l_j^{Cm})과의 절대 거리 중 최대값이 된다.

$$E_{max} = \text{Max}(E_{max}^C, E_{max}^{C2}, \dots, E_{max}^{Ck}, \dots, E_{max}^C)$$

$$E_{max}^C = \text{Max}(d_{max1}^C, d_{max2}^C, \dots, d_{maxj}^C, \dots, d_{max96}^C)$$

$$d_{maxj}^C = \text{Max}(d_{\mu_j}^{C1}, d_{\mu_j}^{C2}, \dots, d_{\mu_j}^{Cm}, \dots, d_{\mu_j}^{Cn})$$

$$d_{\mu_j}^{Cm} = |\mu_j^C - l_j^{Cm}|$$

하나의 계약코드에 대한 평균 오차(E_{avg})는 각각의 그룹들의 15분 단위 대표 부하량과 각 그룹에 속한 고객의 15분 단위 부하량들의 절대 거리의 합에 대한 평균값으로 계산된다.

$$E_{avg} = \frac{\sum_{i=1}^k \sum_{j=1}^{96} \sum_{m=1}^n d_{\mu_j}^{Cm}}{\sum_{i=1}^k 96 \times n^{Ci}}$$

(단, n^C 는 Ci 번째 그룹에 속한 고객수)

표 1 계약종별에 따른 클러스터링 처리 결과

Table 1 Clustering result for contract code

계약종류	고객수	오차율	k값에 따른 오차율(%)								
			1	2	3	4	5	6	7	8	9
주택용전력	213	최대	1.015	1.023	0.591	0.596	0.613	0.599	0.599	0.549	0.561
		평균	0.076	0.07	0.068	0.063	0.06	0.058	0.056	0.056	0.054
일반용(갑)고압A	2340	최대	6.629	6.44	6.227	6.075	6.039	6.027	6.009	4.581	4.581
		평균	0.243	0.205	0.188	0.172	0.167	0.161	0.155	0.154	0.151
교육용고압A	90	최대	3.916	3.76	3.573	2.689	2.259	3.328	3.255	1.264	1.277
		평균	0.268	0.226	0.202	0.19	0.179	0.168	0.162	0.158	0.154
일반용(을)고압A	410	최대	1.731	1.574	1.565	1.539	1.364	1.358	1.382	1.398	1.322
		평균	0.168	0.13	0.119	0.11	0.104	0.099	0.095	0.092	0.09
산업용(갑)고압A	18	최대	3.435	3.305	2.528	2.473	2.429	2.429	2.369	2.161	2.161
		평균	0.371	0.328	0.288	0.246	0.209	0.185	0.156	0.131	0.106
심야전력(갑)	10	최대	3.347	3.006	2.711	1.874	1.874	1.703	1.363	0.709	0.435
		평균	0.34	0.258	0.182	0.153	0.123	0.098	0.06	0.037	0.015
심야전력(을)	12	최대	1.774	0.815	0.414	0.385	0.205	0.189	0.194	0.127	0.068
		평균	0.187	0.071	0.054	0.04	0.029	0.022	0.016	0.01	0.006

4. 고객분류 결과 분석

K-means 알고리즘을 이용한 계약코드에 따른 고객분류를 위해 한전 강남지점 3093명의 고객에 대한 자동검침 데이터를 이용하였다. 분류를 위해 k 값을 1부터 9까지 1씩 증가하면서 실험을 수행하였으며, 그 결과는 표 1과 같다. k 값이 1인 경우는 기존의 계약종별로 대표 부하패턴을 생성하는 방식과 동일한 결과를 나타낸다. 각 계약코드에 대한 최대 k값은 9로 선정하였는데, 한전의 경우 약 30여개의 계약종별 코드를 갖고 있으며, 각각의 계약종별 코드에 대하여 하위에 10개 이상의 분류를 생성할 경우 총 300여개가 넘는 대표 부하패턴을 갖게 된다. 이 경우 자나치게 세분화 된 대표 부하패턴으로 인해 배전선로에 대한 부하분석시 과도한 연산 비용이 발생하게 되므로 본 연구에서는 하나의 계약종별에 대하여 최대 9가지 분류만 생성하도록 제안을 두었다.

4.1 계약종별 대표 부하패턴 생성방식 분석

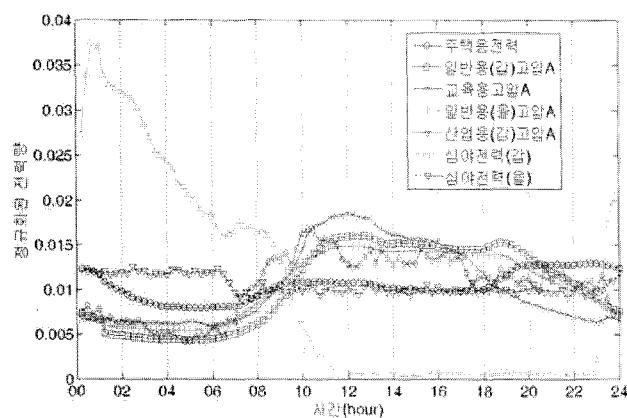


그림 5 계약코드만을 이용한 일일 대표 부하패턴

Fig. 5 Typical daily load profile using contract code

기존의 계약종별 대표 부하패턴 생성방식으로 생성된 대표 부하패턴은 그림 5와 같다. 주택용의 경우에는 주간의 부하보다는 저녁시간의 부하가 높고, 사무용으로 사용되는 일반용의 경우에는 주간의 부하가 높은 것을 볼 수 있다. 또한 심야전력(갑)의 경우에는 주간에는 부하가 거의 없으며 할인이 적용되는 심야에 부하가 급증하는 것을 볼 수 있다.

4.2 평균 오차율을 이용한 k값 선정

다양한 k값 적용을 통해 얻어진 분류결과에서 최적의 k값을 선택하기 위해 계약종별 평균 오차율을 이용하여 k값을 결정하였다. 일반적으로 k값이 높아질수록 각 그룹 내에서의 평균 오차는 작아지게 된다. 그러나 k값이 증가할수록 연산시간이 증가하게 되므로, 본 연구에서는 최대 k값을 9로 정하고 제한된 범위 내에서 평균 오차의 감소 폭이 수렴하는 지점을 찾아서 k값을 결정하는 방식을 사용하였다.

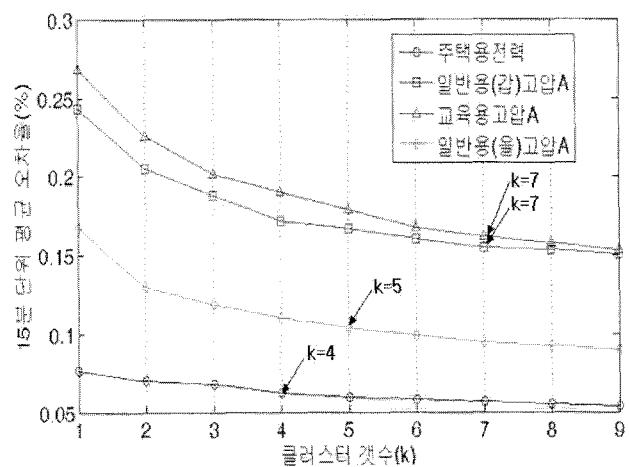


그림 6 K값 증가에 따른 계약종별 평균 오차율 그래프

Fig. 6 Average error rate graph for cluster count(k)

그림 6은 고객의 수가 50명을 초과하는 네 가지 계약코드에 대하여 k 값의 증가에 따른 평균 오차율을 그래프로 나타낸 것이다. 이 그래프에서 기울기는 k 값 증가에 따른 평균 오차의 차이 값을 나타내고 있다. 따라서 기울기 값이 0.005 이하인 경우에는 그라프가 수렴하는 것으로 판단하여 이 때의 k 값을 해당 계약코드에 대한 최적의 그룹 개수로 결정하였다.

4.3 클러스터링을 이용한 고객분류 방식 분석

교육용고압A의 경우 평균 오차의 기울기 비교를 통해 선정된 최적의 k 값은 7이 된다. 표 2는 교육용고압A에 대한 기존의 계약종별 대표 부하패턴 생성 방식과 본 연구에서 제안된 방식의 최대 오차와 평균 오차를 비교한 결과를 보여준다. 표를 살펴보면 교육용고압A의 경우 하나의 대표 부하패턴을 사용하지 않고, 7개의 대표 부하패턴을 생성하여 사용할 경우 15분 단위의 부하량에 대해 평균 오차가 약 40% 정도 줄어든 것을 볼 수 있다.

표 2 두 방식의 최대오차와 평균오차의 비교

Table 2 Comparison of maximum and minimum error rate

구 분	최대오차율	평균오차율
기존방식($k=1$)	3.916	0.268
제안된 방식($k=7$)	3.255	0.162
오차 개선 정도	17%	40%

그림 7은 교육용고압A에 대한 각 그룹별 일일 대표 부하패턴을 보여주고 있다. k 가 1인 기존의 대표 부하패턴과 비교하면 k 가 7인 경우의 그룹별 대표 부하패턴이 고객의 부하패턴을 보다 상세히 표현하고 있는 것을 알 수 있다. 특히 C2와 C5의 경우에는 기존의 대표 부하패턴과 상당히 다른 패턴을 보이고 있어, 이러한 고객들을 구분하여 부하패턴을 적용할 경우 조류분석을 통한 부하분석의 성능을 크게 향상시킬 수 있게 된다. 표 3은 고객의 수가 50명이 넘는 네 가지 계약종별에 대한 분류를 통해 얻어진 각 그룹별 최대 오차율 및 평균 오차율을 나타낸다. 표를 살펴보면 각 그룹별로 비교적 균등한 고객수로 나누어져 있음을 알 수 있다.

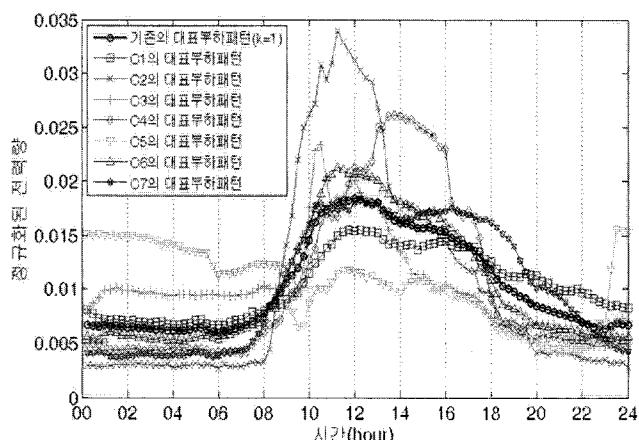


그림 7 교육용고압A에 대한 그룹별 일일 대표 부하패턴

Fig. 7 Typical daily load profiles using clustering algorithm

표 3 그룹별 최대 오차율 및 평균 오차율

Table 3 Maximum and minimum error rate for clusters

계약종류	그룹	고객수	최대오차율	평균오차율
주택용전력	C1	147	0.508	0.024
	C2	2	0.499	0.085
	C3	58	0.596	0.034
	C4	6	0.42	0.058
일반용(감)고압A	C1	501	2.316	0.006
	C2	490	1.496	0.006
	C3	50	2.881	0.013
	C4	510	1.567	0.006
	C5	287	1.713	0.006
	C6	200	6.009	0.009
	C7	302	1.957	0.007
교육용고압A	C1	26	0.749	0.164
	C2	4	1.26	0.186
	C3	7	3.255	0.18
	C4	5	0.996	0.212
	C5	6	1.096	0.191
	C6	23	1.264	0.173
	C7	19	1.009	0.164
일반용(을)고압A	C1	99	0.899	0.024
	C2	47	0.77	0.034
	C3	137	1.019	0.022
	C4	90	1.104	0.024
	C5	37	1.364	0.023

5. 결론 및 향후 연구

전자식 전력량계가 확산 보급되면서 자동검침 데이터를 이용한 배전선로의 부하분석에 대한 연구가 활발히 진행되고 있다. 최근에는 부하분석을 위해 자동검침 고객의 15분 단위 사용량을 이용하여 대표 부하패턴을 생성하고, 이 패턴에 미검침 고객의 월 검침량을 대입하여 미검침 고객에 대한 가상 부하패턴을 생성하는 방식으로 전체 배전선로의 15분 단위의 최대부하 및 부하패턴 등을 분석하는 방법이 많이 연구되고 있다. 본 연구에서는 동일한 계약코드를 갖는 고객들을 k -means 알고리즘을 이용하여 k 개의 그룹으로 분류하는 방식을 제안하였다. 또한 기존의 계약종별 대표 부하패턴을 생성하는 방식과 본 연구에서 제안한 방식의 최대 오차율 및 평균 오차율을 계산하고 이를 비교하였다. 그룹의 수를 결정하는 k 값을 선정하기 위해, 최소 1개에서 최대 9개의 그룹으로 분류하여 그룹이 증가함에 따른 평균 오차율의 감소 비율이 수렴하는 지점을 찾아내는 방식을 이용하였다.

향후에는 미검침 고객의 정보를 이용하여 선정된 대표 부하패턴에 효과적으로 매핑할 수 있는 의사결정 기법에 대한 연구를 진행할 예정이며, 전력 사용량과 밀접한 관계가 있는 날씨 및 온도 등에 상관관계를 반영하여 보다 정확하게 가상 부하패턴을 생성하는 연구를 진행할 예정이다.

감사의 글

본 연구는 지식경제부에서 시행한 전력산업연구개발사업인 “인터넷 GIS 환경의 AMR 시스템 연계 모델” 연구과제를 통해 수행되었습니다.

참 고 문 헌

- [1] 손학식, 김인수, 박용욱, 임상국, 김재철, “수용가 부하곡선을 이용한 국제분쟁시 전력사용 행태분석”, 대한전기학회 학술대회, pp. 165-167, 2004, 7월.
- [2] Koo-Hyung Chung, Chan-Joo Lee, Jin-Ho Kim, Don Hur, Balho H. Kim, and Jong-Bae Park, “Development of Customer Oriented Load Management Software for Saving on Utility Bills in the Electricity Market”, Journal of Electrical Engineering & Technology, Vol. 2, No. 1, pp. 42-49, 2007.
- [3] 하복남, 한용희, 한병성, 이홍호, “배전자동화 투자비 대 경제적 효과분석에 관한 연구”, 대한전기학회논문지 전력기술부문A, 2003, pp. 407-413, 제52권 7호.
- [4] Chongqing Kang, Xu Cheng, Qing Xia, Yonghao Huang, and Feng Gao, “Novel approach considering load-relative factors in short-term load forecasting”, Electric Power Systems Research, Vol. 70, Issue 2, pp. 99-107, July 2004.
- [5] 신진호, 김영일, 송재주, 이봉재, 이정일, “지리정보와 검침데이터를 이용한 배전계통 부하분석모델 개발”, 대한전기학회 학술대회, pp. 2124-2125, 2006, 7월.
- [6] G. W. Chang, S. Y. Chu, and H. L. Wang, “A Simplified Forward and Backward Sweep Approach for Distribution System Load Flow Analysis,” 2006 International Conference on Power System Technology, pp. 1-5.
- [7] 윤상윤, 김재철, “수용가 전력 소비 패턴을 고려한 배전용 변압기 과부하 판정기준”, 대한전기학회논문지 전력기술부문A, 2004, pp. 513-520, 제53권 9호.
- [8] Jain A. K. and Dubes R.C., 1988. "Algorithms for Clustering Data," Englewood Cliffs, NJ: Prentice-Hall.

저 자 소 개



김 영 일 (金 榮 一)

1972년 11월 27일 생
1998년 충남대 컴퓨터공학과 졸업
2000년 충남대 컴퓨터공학과 졸업(석사)
현재 한전 전력연구원 근무
E-mail : yikim@kepco.co.kr



신 진 호 (辛 鎭 浩)

1970년 7월 26일 생
1996년 한밭대 전자계산학과 졸업
2004년 충북대 전자계산학과 졸업(석사)
현재 한국전력공사 전력연구원 근무
E-mail : jinho@kepco.co.kr



이 봉 재 (李 傳 在)

1959년 1월 13일 생
1982년 성균관대 수학과 졸업
1985년 한국전력공사 입사
현재 한전 전력연구원 근무
E-mail : leeboja@kepco.co.kr



양 일 권 (梁 日 權)

1954년 4월 24일 생
1976년 조선대 전기공학과 졸업
1992년 미국 Indiana대 컴퓨터과학과 졸업
현재 전력연구원 정보통신그룹장
E-mail : ikyang@kepri.re.kr