

미검침 고객의 가상 부하패턴 생성을 위한 고객 속성 정보를 이용한 고객 분류 기법

논 문
59-10-2

Customer Classification Method Using Customer Attribute Information to Generate the Virtual Load Profile of non-Automatic Meter Reading Customer

김 영 일[†] · 고 중 민^{*} · 송 재 주^{**} · 최 훈^{***}
(Young-Il Kim · Jong-Min Ko · Jae-Ju Song · Hoon Choi)

Abstract - To analyze the load of distribution line, real LPs (Load Profile) of AMR (Automatic Meter Reading) customers and VLPs (Virtual Load Profile) of non-AMR customers are required. Accuracy of VLP is an important factor to improve the analysis performance. There are 2 kinds of methods to generate the VLP; one is using ALP (Average Load Profile) per each industrial code and PNN (Probability neural networks) algorithm; the other is using LSI (Load Shape Index) and C5.0 algorithm. In this paper, existing researches are studied, and new method is suggested. Each methods are compared the performance with same LP data of real high voltage customers.

Key Words : Customer classification, Virtual load profile, K-means, PNN, C5.0

1. 서 론

전력회사에서는 전자식 전력량계를 설치하여 고객의 15분 단위 전력사용량을 자동으로 검침하고 있다. 초기의 자동검침 데이터는 각 고객의 최대부하를 측정하거나 전력사용 패턴을 파악하는데 사용되었다. 최근 들어 IT기술이 발전하면서 자동검침 데이터를 이용하여 배전선로의 부하분석과 노후설비의 수명예측 등에 활용하는 연구가 진행되고 있다 [1][2]. 배전선로의 15분 단위의 부하는 선로를 통해 전력을 공급받는 모든 고객의 부하의 합과 같다. 따라서 해당 선로에 연결된 모든 자동검침 고객의 15분 단위 부하와 모든 미검침 고객의 15분 단위 부하를 합할 경우 해당 선로의 15분 단위 부하를 예측할 수 있게 된다. 이를 위해 자동검침 고객의 데이터를 부하사용 패턴이 유사한 고객들로 군집화하여 군집의 대표 부하패턴(TLP: Typical Load Profile)을 생성하고, 미검침 고객의 정보를 이용하여 미검침 고객이 속한 군집을 예측하여 해당 군집의 대표 부하패턴에 미검침 고객의 월 사용량을 대입하여 가상 부하패턴(VLP: Virtual Load Profile)을 구하는 방식이 연구되고 있다.

가상 부하패턴을 생성하기 위해서는 자동검침 고객의 데이터를 이용한 군집화와[3], 자동검침 고객의 데이터를 이용한 고객 분류를 위한 훈련, 미검침 고객의 데이터를 이용한 분류를 통한 예측 기법이 필요하다[4][5]. 특히 고객을 분류하는 방법은 미검침 고객의 정보 중에서 어떠한 정보를 이

용하여 분류할 것인가에 따라 가상 부하패턴의 정확도 및 오차에 많은 영향을 주게 된다.

본 연구에서는 가상 부하패턴을 이용한 부하분석 방법과 가상 부하패턴을 생성하기 위해 사용되는 군집화 및 분류 기법에 대해 살펴보고, 각 방식의 단점을 개선하기 위한 방법으로 고객 속성정보를 이용한 분류방법을 제안하였다.

본 논문의 구성은 다음과 같다. 2장에서는 가상 부하패턴을 이용하여 부하를 분석하는 기본 개념에 대해서 설명하고 있으며, 3장에서는 군집화를 이용하여 대표 부하패턴을 생성하고 분류 알고리즘을 이용하여 가상 부하패턴을 생성하는 방법에 대한 설명과 기존에 연구된 군집화 및 분류 알고리즘을 이용한 방법과 본 논문에서 제안하는 방법을 설명하고 있다. 4장에서는 동일한 데이터를 이용하여 기존의 방법과 제안된 방법을 실험하여 비교 분석한 내용을 보여주고 있으며, 마지막으로 5장에는 본 논문의 결론을 보여주고 있다.

2. 가상 부하패턴을 이용한 부하분석

배전선로에서 공급되는 전력량은 전력 공급시 발생하는 손실을 고려하지 않을 경우 해당 선로와 연결된 모든 고객들의 전력사용량의 합과 같다. 따라서 해당 선로에 연결된 모든 고객의 15분 단위 부하패턴을 알 경우에는 이를 이용하여 해당 선로에 추가적인 검침장비를 설치하지 않고도 해당 선로의 15분 단위 부하를 예측할 수 있게 된다. 그러나 이러한 방법은 해당 선로와 연결된 모든 고객의 15분 단위 전력 사용량을 알아야만 적용이 가능한 문제점이 있다. 따라서 이를 보완하기 위해 이미 전자식 전력량계가 설치된 고객의 15분 단위 부하패턴을 이용하여 미검침 고객의 15분 단위의 가상 부하패턴을 생성하여 부하를 예측하는 방법이 연구되고 있다.

미검침 고객에 대한 일일 가상 부하패턴은 유사한 전력사용 형태를 갖는 고객의 실제 일일 부하 패턴에 미검침 고객

† 교신저자, 정회원 : 한국전력공사 전력연구원

E-mail : yikim@kepeco.co.kr

* 정 회 원 : 한국전력공사 전력연구원

** 정 회 원 : 한국전력공사 전력연구원

*** 준 회 원 : 충남대학교 컴퓨터공학과

접수일자 : 2010년 7월 6일

최종완료 : 2010년 9월 16일

의 일일 사용량을 대입하여 생성할 수 있다. 예를 들어 그림 1과 같이 매장 규모가 각각 1,000m², 500m²인 대형마트 A (자동검침 고객), B(미검침 고객)가 있을 경우 각각의 월 전력사용량이 10,000kWh, 5,000kWh라고 할 경우에 두 매장은 다른 업종의 고객에 비해 전력을 사용하는 형태가 유사할 가능성이 높게 된다. 따라서 마트 B의 전력사용량이 마트 A의 절반이므로 마트 A의 실제 부하곡선을 절반으로 크기를 줄이면 마트 B의 실제 부하곡선과 유사한 가상의 부하곡선을 생성할 수 있게 된다.

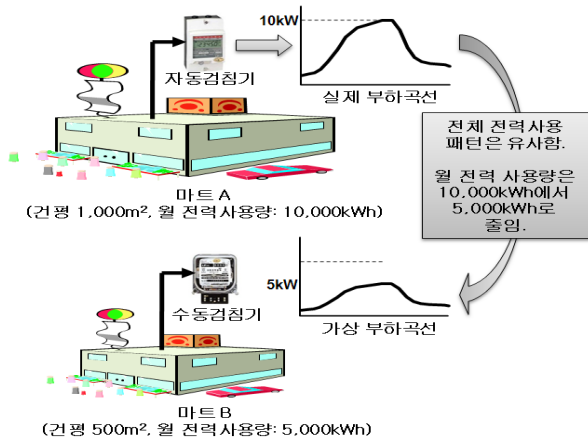


그림 1 부하패턴이 유사한 고객의 실제 부하곡선을 이용한 가상 부하곡선 생성의 예

Fig. 1 Example of virtual load profile generation using real load profile of the customer who has similar load pattern

3. 대표 부하패턴을 이용한 가상 부하패턴 생성

앞에서 살펴본 바와 같이 기존의 자동검침 고객의 실제 부하곡선을 이용하여 미검침 고객의 가상 부하곡선을 예측하기 위해서는 각각의 미검침 고객에 대해서 어떤 부하패턴을 유사한 부하패턴으로 결정할 것인가에 대한 문제를 해결해야 한다. 이러한 문제를 해결하기 위해 군집화 및 분류 기법을 이용하게 된다.

3.1 산업코드를 이용한 가상 부하패턴 생성 방법

고객의 가상 부하패턴을 생성하기 위한 가장 단순한 접근 방법은 자동검침 고객과 미검침 고객 모두가 갖고 있는 산업분류를 이용하여 가상 부하패턴을 생성하는 방법으로 그림 2와 같다.

산업코드를 이용한 방법의 초기 단계에는 자동검침 고객의 15분 단위 검침데이터를 수집(collect)한 후, 수집시 데이터가 빠진 부분이 있는 고객이나, 비정상적인(abnormal) 데이터가 수집된 고객을 제외시키는 전처리 작업을 수행하게 된다. 전처리 작업을 통해 정제된(refine) 고객을 대상으로 각 고객의 15분 단위 검침 데이터 중에서 최대 전력사용량이 1이 되도록 정규화(normalization)를 수행한다. 정규화를 수행하면 대표 부하 프로파일이 항상 0과 1사이의 값으로 이루어져서 패턴에 대한 분석이 용이하고, 가상 부하 프로파일을 생성시에도 빠르게 계산할 수 있는 장점이 있다. 정규화된 데이터는 별도의 군집화 알고리즘을 사용하지 않고, 산

업분류 별로 각 산업분류에 속한 자동검침 고객의 일일 부하패턴의 평균을 계산하고 이를 각 산업코드에 대한 일일 대표 부하패턴으로 정의한다. 각각의 미검침 고객은 별도의 분류 알고리즘을 사용하지 않고 자신의 산업코드에 속한 대표 부하패턴을 할당받아서 고객의 일일 사용량을 대입하여 가상 부하패턴을 생성하게 된다. 이 방법은 복잡한 군집화 및 분류 알고리즘을 사용하지 않아 구현이 쉬운 장점이 있으나, 동일한 산업코드를 갖는 고객이라 하더라도 부하곡선이 상이한 고객이 많을 경우 가상 부하패턴의 정확도(accuracy)가 떨어지는 단점이 있다.

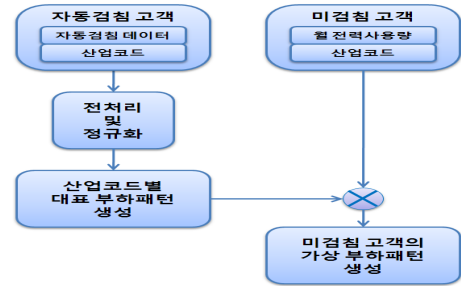


그림 2 산업코드를 이용한 가상 부하패턴 생성 방법

Fig. 2 Virtual load profile generation method using industrial code

3.2 군집화 및 분류 알고리즘을 이용한 가상 부하패턴 생성

최근 들어 패턴분석 기법중의 하나인 군집화 및 분류 알고리즘을 이용하여 고객의 가상 부하패턴의 정확도를 높이는 방법이 연구되고 있다. 그림 3은 군집화 및 분류 알고리즘을 이용한 가상 부하패턴의 생성 단계를 나타낸다.

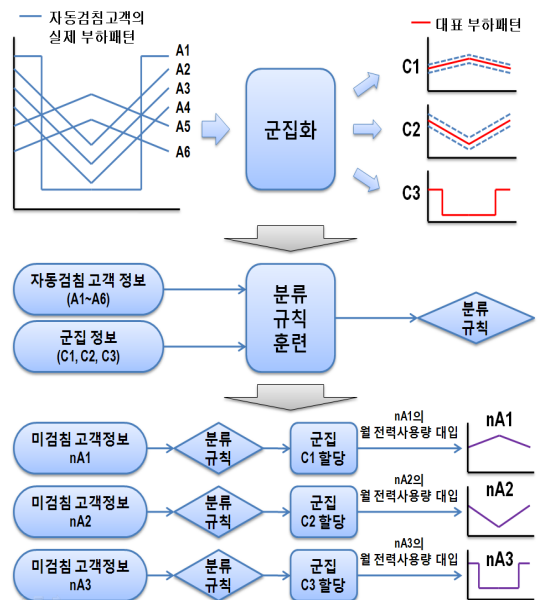


그림 3 군집화 및 분류 알고리즘을 이용한 가상 부하패턴 생성 방법

Fig. 3 Virtual load profile generation method using clustering and classification algorithm

군집화 단계는 자동검침 고객의 부하곡선을 이용하여 몇 개의 군집을 만들고, 각 군집에 속한 고객들의 부하곡선의 평균값 등을 이용하여 대표 부하패턴을 생성하는 것을 말한다. 분류 단계는 각각의 미검침 고객을 군집화에서 생성된 군집들 중에서 미검침 고객과 가장 유사한 부하형태를 가질 것으로 예상되는 군집에 할당하는 것을 말한다. 분류 단계는 자동검침 고객의 데이터와 고객의 군집번호를 이용하여 분류 규칙을 생성하는 훈련 단계와, 생성된 분류 규칙을 이용하여 미검침 고객에게 군집을 할당하는 적용 단계로 나누어진다. 분류를 통해 미검침 고객의 군집이 정해지면, 해당 군집의 대표 부하패턴에 미검침 고객의 월 전기사용량을 대입하여 가상 부하패턴을 생성하게 된다.

3.3 산업코드와 PNN 알고리즘을 이용한 분류 방법

연구논문 [4]에서는 그림 4와 같이 산업코드와 Probability neural networks(PNN)[6] 알고리즘을 이용하여 미검침 고객을 분류하였다.

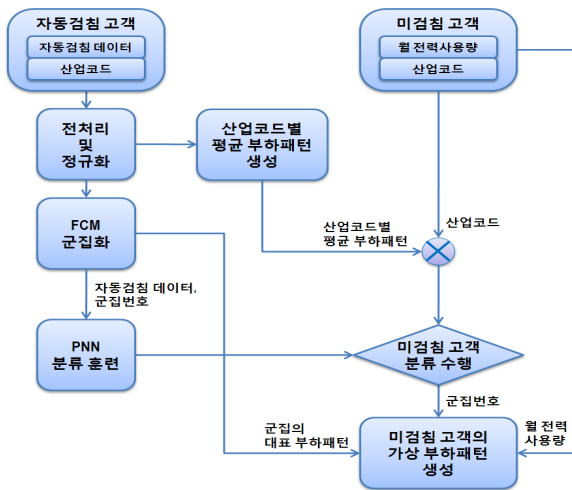


그림 4 산업코드와 PNN 알고리즘을 이용한 가상 부하패턴 생성 방법
Fig. 4 Virtual load profile generation method using industrial code and PNN algorithm

전처리와 정규화 과정을 거쳐 생성된 자동검침 고객의 15분 단위 부하곡선을 이용하여 산업코드 별로 평균 부하패턴을 생성하고, Fuzzy C-Means (FCM)[7] 알고리즘으로 자동검침 고객들의 부하곡선을 부하패턴이 유사한 군집으로 묶고 일일 대표 부하패턴을 생성하였다. 군집화를 수행한 이후에는 자동검침 고객의 일일 96개로 이루어진 15분 단위 부하량과 FCM으로 부여된 고객의 군집번호를 PNN 알고리즘에 입력하여 분류를 위한 신경망(neural network)을 훈련하였다. 미검침 고객을 PNN으로 분류하여 군집번호를 찾기 위해서는 입력에 사용된 96개의 부하값과 동일한 형태의 입력 값이 필요하다. 연구논문 [4]에서는 미검침 고객의 분류를 위한 입력으로 사용될 96개 부하량을 얻기 위해 해당 고객이 속한 산업코드의 평균 부하패턴의 96개 부하량을 사용하여 분류를 수행하였다. 최종적으로 미검침 고객의 가상 부하패턴은 PNN을 이용하여 분류된 해당 고객의 군집번호에

해당하는 대표 부하패턴에 고객의 일일 전력사용량을 대입하여 생성하게 된다.

3.4 부하형태 인덱스와 C5.0 알고리즘을 이용한 분류 방법

연구논문 [5]에서는 그림 5와 같이 부하형태 인덱스와 C5.0 알고리즘을 이용하여 미검침 고객을 분류하였다. 전처리 및 정규화를 거친 자동검침 데이터를 k-means[8] 알고리즘을 이용하여 부하 곡선의 형태가 유사한 군집으로 묶고, 각 군집별로 일일 대표 부하패턴을 생성하였다. 군집화를 수행한 이후에는 분류를 위해 사용될 부하형태 인덱스 (Load Shape Index, LSI)[9]를 계산한다. 부하형태 인덱스는 고객의 일일 부하를 수치로 표현한 load factor(d1)과 저녁 11시부터 새벽 7시까지의 8시간 동안을 표현한 night impact(d3), 12에서 15시까지의 3시간 동안을 표현한 lunch impact로 정의되며 이는 고객의 일일 부하에서 저녁과 점심 시간대의 부하비율이 어떻게 되는가를 나타내는 인덱스가 된다.

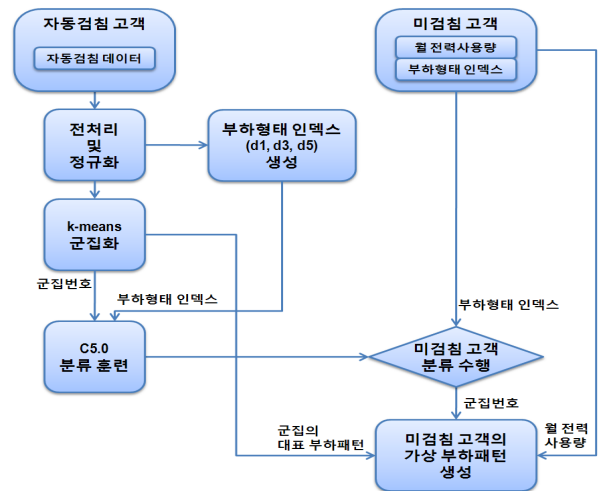


그림 5 부하형태 인덱스와 C5.0 알고리즘을 이용한 가상 부하패턴 생성 방법
Fig. 5 Virtual load profile generation method using load shape index and C5.0 algorithm

연구논문 [5]에서는 자동검침 고객의 부하형태 인덱스를 입력값으로 하여 C5.0[10] 알고리즘을 이용하여 분류를 위한 훈련을 수행하고 미검침 고객의 부하형태 인덱스를 입력값으로 하여 군집번호를 선택하게 된다. 이러한 방식은 고객의 부하곡선과 연관성이 높은 부하형태 인덱스를 사용하므로 자동검침 고객의 경우에는 검침 데이터를 이용하여 LSI를 계산할 수 있어 분류 정확도가 높은 장점이 있으나, 미 검침 고객의 경우에는 LSI를 계산하기 위한 데이터베이스가 구축되어 있지 않은 경우에는 적용할 수 없는 단점이 있다.

3.5 고객 속성정보와 C5.0 알고리즘을 이용한 분류 방법 제안

본 논문에서는 기존의 미 검침 고객의 분류방법에 대한 문제점을 해결하기 위한 방법으로 고객의 다양한 속성정보를 이용한 분류 방법을 제시하고자 한다. 앞에서 살펴보았듯

이 산업코드를 이용한 미검침 고객 분류 방법은 동일한 산업분류에 속한 고객이라고 하더라도 부하 곡선이 상이한 경우가 많이 있으므로 고객의 산업코드 하나만을 이용하여 고객을 분류하는 방식은 분류과정에서 많은 오차를 갖게 된다. 분류를 위해 부하형태 인덱스를 이용하는 방법은 고객의 점심 시간대와 저녁 시간대의 부하 특성을 이용하여 분류하게 되므로 산업코드를 이용한 방법에 비해 높은 분류 성능을 보이게 된다. 그러나 자동 검침 고객의 경우에는 검침값을 이용하여 부하형태 인덱스를 계산할 수 있으나, 미 검침 고객의 경우에는 부하형태 인덱스 값을 알 수가 없기 때문에 고객 조사 등을 통해 각 고객의 부하 특성을 조사하여 데이터베이스를 구축해야만 적용이 가능한 단점을 갖게 된다.

본 논문에서는 미검침 고객의 분류를 위해 이미 전력회사의 고객 데이터베이스에 구축된 고객 속성 정보들 중에서 계약종류, 전기사용 용도, 계약전력량, 산업분류 코드, 전기공급방식을 이용하여 분류하는 방법을 제안하고자 한다. 분류를 위한 입력으로 다양한 속성정보를 사용할 경우에는 산업코드만을 이용하는 방법에 비해 오차를 줄일 수 있으며, 부하형태 인덱스에 대한 데이터베이스를 구축하는 비용과 시간을 소비하지 않고 바로 현장에 적용할 수 있게 된다.

4. 분류 방법에 대한 실험 및 성능 분석

4.1 실험 방법

분류 방법에 대한 실험을 위해 KEPCO의 고압 자동검침 고객 데이터를 수집하여 전처리 및 정규화 과정을 거쳐 3183명의 자동검침 고객을 선정하였다. 실험은 앞에서 소개한 세 가지 방법과 본 논문에서 제안한 방법에 대한 성능을 비교하기 위해 그림 6과 같이 수행하였다.

본 논문에서는 분류 방법의 정확도를 비교하는 것을 목적으로 하기 때문에 군집화 방법에 있어서는 모든 방법에 동

일하게 k-mean 알고리즘을 적용하였다. 군집화가 끝나면 분류 방법의 정확도를 검증하기 위해 전체 데이터의 90%를 훈련용으로 사용하고 10%를 테스트용으로 사용하여 각기 다른 테스트 셋으로 10회를 수행하는 10 fold cross-validation [11] 방식으로 각각의 분류 알고리즘을 수행하였다.

분류 방법 실험을 위해 훈련용 데이터를 이용하여 산업코드만을 이용하는 방법과 산업코드와 PNN 알고리즘을 이용한 방법, 부하형태 인덱스와 C5.0을 이용한 방법, 고객 속성정보와 C5.0을 이용한 방법으로 분류 규칙을 생성하였다. 분류 규칙이 생성되면 각각의 분류 알고리즘을 이용하여 테스트용 데이터를 분류하여 군집번호를 부여받아 실제 군집번호와 부여받은 군집번호를 비교하여 정확도를 계산하였다. 또한 부여받은 군집번호의 대표 부하패턴에 테스트용 데이터의 월 전력사용량을 대입하여 가상 부하패턴을 생성하고 테스트용 데이터의 실제 부하패턴과 비교하여 평균 오차를 계산하였다.

4.2 분류 방법 성능 분석

고객의 부하곡선을 k-means 알고리즘으로 군집화 하기 위해서는 적절한 군집의 개수인 k 값을 선정하는 작업이 필요하다. 일반적으로 k값이 높아질수록 각 그룹 내에서의 평균 오차는 작아지고, k값이 증가할수록 연산시간은 증가하게 된다. 본 연구에서는 최대 k값을 20으로 정하고 제한된 범위 내에서 k 값에 증가에 따른 군집의 대표부하패턴과 고객의 실제 부하패턴간의 오차를 계산하여 각 k 값에 따른 전체 평균 오차를 계산하였다. 최종 k 값의 선정에 위해 이전 k 값의 평균 오차와 현재 k 값의 평균 오차간의 차이를 계산하여 차이 값이 더 이상 줄어들지 않는 지점을 최종 k 값으로 선정하였다. 표 1은 k 값에 따른 평균 오차와 평균 오차간의 차이 값을 나타내며, 본 논문에서는 차이 값이 0.00051에서 0.00052로 더 이상 줄어들지 않는 14를 최종 k 값으로 선정하였다.

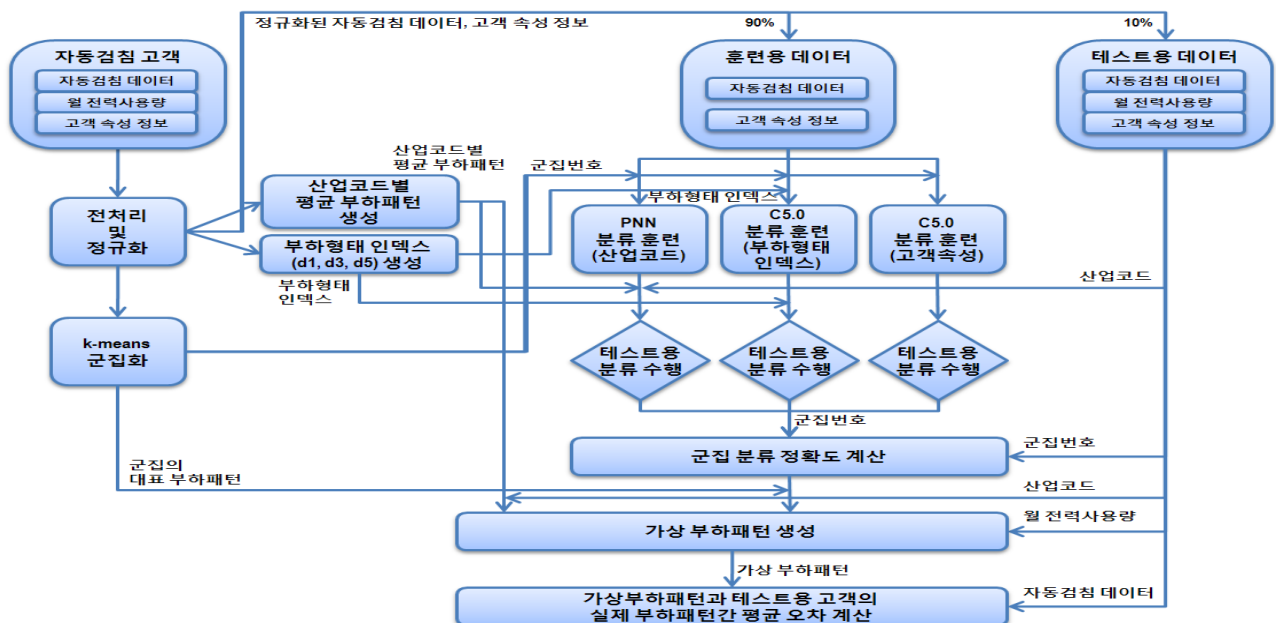


그림 6 분류 방법에 따른 가상 부하패턴 생성 실험 절차

Fig. 6 Experiment process of virtual profile generation for each classification method

표 1 k 값에 따른 평균 오차 및 평균 오차의 차이값

Table 1 Average error and difference for each k value

k 값 (군집수)	평균 오차	평균오차의 차이값	k 값 (군집수)	평균 오차	평균오차의 차이값
1	0.10399		11	0.02601	0.00077
2	0.06291	0.04109	12	0.02535	0.00066
3	0.04678	0.01613	13	0.02477	0.00058
4	0.03890	0.00788	14	0.02426	0.00051
5	0.03539	0.00351	15	0.02373	0.00052
6	0.03234	0.00305	16	0.02332	0.00041
7	0.03056	0.00177	17	0.02290	0.00043
8	0.02917	0.00139	18	0.02263	0.00026
9	0.02791	0.00127	19	0.02226	0.00038
10	0.02678	0.00113	20	0.02171	0.00054

K-means 알고리즘을 통해 생성된 14개의 군집의 대표 부하패턴은 그림 7과 같다. 그림에서 대표 부하패턴은 굵은 선으로 표시되었으며, 회색 실선은 각 군집에 속한 고객의 부하패턴을 나타낸다.




그림 7 14개 군집의 대표 부하패턴
Fig. 7 Typical load profile of 14 clusters

분류 방법의 정확도를 검증하기 위해 전체 데이터를 10등분하여 10 fold cross-validation 방식으로 기존의 방법들과 본 논문에서 제안한 방법을 실험하였다. 표 2는 각각의 분류 방법에 따른 분류 정확도 및 군집의 대표 부하패턴과 고객의 실제 부하패턴 간의 평균 오차를 나타낸다. 정확도는 이미 고객의 군집번호를 알고 있는 테스트용 고객을 분류 방법을 통해 군집을 예측하였을 때 동일한 군집번호를 예측할 확률을 나타내며, 표 2의 10회 평균 정확도를 살펴보면 부하형태 인덱스를 이용하는 방식이 0.752로 가장 우수하며

본 연구에서 제안한 고객속성 정보를 이용한 방식이 0.358로 두 번째 인 것을 알 수 있다. 10회 평균 오차의 경우에도 부하형태 인덱스를 이용하는 방식이 0.118로 가장 오차가 적으며 본 연구에서 제안한 고객속성 정보를 이용한 방식이 0.211로 두 번째로 오차가 적은 것을 알 수 있다. 부하형태 인덱스를 이용하는 방식은 고객 데이터베이스에 미검침 고객의 부하형태 인덱스 값이 미리 조사되어 구축되어 있어야 현장에서 운영이 가능한 단점을 갖고 있어 시스템적으로 운영하기에는 어려운 점이 있다. 따라서 전력사에서는 별도의 고객에 대한 부하형태 조사 없이 기존에 구축된 고객 속성 정보만을 이용하여 효과적으로 미 검침 고객에 대한 가상 부하 프로파일을 계산하는 방법인 본 논문에서 제안한 방식을 이용하여 보다 높은 정확도로 고객을 분류할 수 있게 된다.

표 2 분류 방법에 따른 분류 정확도 및 평균 오차

Table 2 Classification accuracy and average error for each classification method

횟수	산업코드 만		산업코드, PNN		부하형태인덱스, C5.0		고객속성정보, C5.0 (제안)	
	정확도	평균 오차	정확도	평균 오차	정확도	평균 오차	정확도	평균 오차
1	-	0.269	0.258	0.270	0.796	0.120	0.550	0.191
2	-	0.299	0.132	0.247	0.890	0.094	0.475	0.210
3	-	0.227	0.154	0.263	0.733	0.124	0.311	0.222
4	-	0.255	0.503	0.168	0.821	0.089	0.362	0.181
5	-	0.218	0.223	0.229	0.676	0.118	0.333	0.196
6	-	0.217	0.211	0.234	0.723	0.131	0.314	0.237
7	-	0.227	0.138	0.248	0.761	0.126	0.242	0.235
8	-	0.222	0.186	0.220	0.695	0.119	0.289	0.215
9	-	0.227	0.267	0.217	0.686	0.129	0.283	0.227
10	-	0.257	0.204	0.236	0.736	0.127	0.418	0.200
평균	-	0.242	0.228	0.233	0.752	0.118	0.358	0.211

5. 결 론

미 검침 고객에 대한 가상 부하패턴을 계산하는 방법은 배전선로의 부하분석과 노후설비의 수명예측 등에 있어서 중요한 역할을 한다. 본 논문에서는 기존에 제안된 고객 분류 방식의 문제점을 살펴보고, 이를 해결하기 위한 방법으로 고객의 속성 정보들을 이용한 분류 방법을 제안하였다. 본 논문에서 언급된 네 가지 고객 분류 방법을 동일한 데이터를 이용하여 적용하고 각각의 분류 방법의 분류 정확도와 분류된 고객의 실제 부하패턴과 가상 부하패턴의 평균 오차를 계산하여 성능을 평가하였다. 본 논문에서 제안된 방법은 산업코드를 이용하는 방법에 비해 정확도나 평균 오차의 관점에서 나은 성능을 보였다. 고객의 부하 형태를 나타내는 부하형태 인덱스를 이용하는 방법에 비해서는 성능에 낮았으나, 부하형태 인덱스를 이용하는 방법은 미 검침 고객에 대한 부하형태 인덱스를 미리 알고 있다는 가정을 만족시켜야 하므로, 전력사가 고객 조사를 통해 부하형태 인덱스를

데이터베이스로 구축해야 하므로 실제 시스템에 적용하기에는 비용 측면에서의 부담이 크게 된다. 따라서 본 논문에서 제안한 방법을 통해 기존의 고객 속성 정보를 활용하여 보다 정확한 가상 부하 프로파일을 계산할 수 있어 배전선로의 부하 예측에 많은 기여를 할 것으로 생각된다.

감사의 글

본 연구는 지식경제부에서 시행한 전력산업연구개발사업인 “대수용가 서비스 모델 및 시장전략 개발, 시범사업 수행” 과제를 통해 수행되었습니다.

참 고 문 헌

[1] 김영일, 신진호, 이봉재, 양일권, “자동검침 고객의 부하 패턴을 이용한 일일 대표 부하패턴 생성“, 대한전기학회논문지, 2008, 제57권, 9호, pp. 1516-1521.

[2] 윤상윤, 김재철, “수용가 전력 소비 패턴을 고려한 배전용 변압기 과부하 판정기준“, 대한전기학회논문지, 2004, 제53권 9호, pp. 513-520.

[3] 김영일, 송재주, 오도은, 정남준, 양일권, “일일 대표 부하패턴의 분별력을 높이기 위한 반복적인 소규모 군집화를 이용한 고객 군집화 방법“, 대한전기학회논문지, 2009, 제58권, 11호, pp. 2269-2274.

[4] David Gerbec, Samo Gasperic, Ivan Smon, and Ferdinand Gubina, “Allocation of the Load Profiles to Consumers Using Probabilistic Neural Networks”, IEEE Transactions on Power Systems, Vol. 20, No. 2, May 2005, pp. 548-555.

[5] Vera Figueiredo, Fatima Rodrigues, Zita Vale, and Joaquim Borges Gouveia, “An Electric Energy Consumer Characterization Framework Based on Data Mining Techniques”, IEEE Transactions on Power Systems, Vol. 20, No 2, May 2005, pp. 596-602.

[6] H. Demuth and M. Beale, Neural Network Toolbox for Use With MATLAB. Natick, MA: MathWorks, Jun. 2001.

[7] R. N. Davé and R. Krishnapuram, “Robust clustering methods: a unified view,” IEEE Transactions on Fuzzy Systems, vol. 5, no. 2, May 1997, pp. 270 - 293.

[8] Jain A. K. and Dubes R.C., 1988. “Algorithms for Clustering Data,” Englewood Cliffs, NJ: Prentice-Hall.

[9] M. Ernoult and F. Meslier, “Analysis and forecast of electrical energy demand,” Revue Général d'Electricité, no. 4, 1982.

[10] R. Quinlan, The Book C4.5: Programs for Machine Learning. San Mateo, CA: Morgan Kaufmann, 1993.

[11] I. Witthen and E. Frank, Data Mining – Practical Machine Learning Tools and Techniques With Java Implementations. New York and San Mateo, CA: Morgan Kaufmann Publishers, Academic Press, 2000.

저 자 소 개




김 영 일 (金 榮 一)

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




고 종 민 (高 種 旻)

1967년 11월 30일생
 1993년 충남대 전산학과 졸업
 2004년 충남대 컴퓨터공학과 졸업(석사)
 현재 한국전력공사 전력연구원 근무
 E-mail : kojim@kepco.co.kr



송 재 주 (宋 在 周)

1967년 5월 25일생
 1991년 충북대 전산통계학과 졸업
 2004년 충북대 전자계산학과 졸업(석사)
 현재 한국전력공사 전력연구원 근무
 E-mail : jjsong@kepco.co.kr



최 훈 (崔 薰)

1960년 5월 19일생
 1983년 서울대 전자계산기공학과 졸업
 1993년 미국 Duke대 컴퓨터과학과 (박사)
 현재 충남대학교 컴퓨터공학과 근무
 E-mail : hc@cnu.ac.kr