2008년도 대한전기학회 하계학술대회 논문집 2008. 7. 16 - 18

Critical Peak Pricing 요금제 적용을 위한 소비자 부하 패턴 분류

주지영, **권상혁**, 안상호, 윤용태
서울대학교 전기.컴퓨터공학부

Categorization of End-Users' Load Patterns Applied to Dynamically-Administered Critical Peak Pricing

Jhi-Young Joo, Sang Hyeok Kwon, Sang-Ho Ahn, Yong Tae Yoon
School of Electrical and Computer Engineering, Seoul National University

Abstract - 지난 논문 "Critical Peak Pricing 요금제를 이용한 일반 수용가 대상 수요관리의 방법" 및 그 후속 연구에서는 일반 수용가를 대상으로 한 효율적인 수요관리의 한 방법으로써 Critical Peak Pricing 요금제를 제안하였다[1]. 또한 이 요금제에서 핵심이 되는 최적 critical peak 시점을 푸는 하위 문제들 및 방법론을 제시하였는데, 이 논문에서는 그 하위 문제들 중 수용가의 부하를 예측하는 문제를 다룬다. 우리는 energy service provider(ESP)가 관리해야 할 수용가의 수가 매우 많다는 점에 주목하여, 각 수용가의 1일 부하 사용량 패턴을 몇 개의 그룹으로 나누어 각 그룹에 대해 critical peak 최적 시점을 결정하는 연구를 수행하였다. 이러한 수용가 부하량 패턴 그룹화를 위해 인공 지능의 여러 기법 중 하나인 self-organizing map(SOM)을 사용하였다..

1. 서 론

지난 연구에서 제안된 이후로 Dynamically-Administered Critical Peak Pricing(DA-CPP)로 새로이 명명된 이 CPP 제도는 전력 시장의 실시간 가격에 대응하여 부하 사용량의 조절이 이루어지는, dynamic pricing을 통한 수요 관리의 한 방법이다[1]. DA-CPP는 특히, 일반 주거용 소비자는 시장의 실시간 가격에 따라 부하 사용량을 적극적으로 조절하기가 힘들다는 점에 착안하여, 자동화된 미터링 및 부하 차단 시스템을 갖추고, 시장에서 부하 통합 관리자(load aggregator)의 역할을 하는 ESP가 부하를 차단할 시점, 즉 critical peak 시점에 자동으로 제한된 짧은 시간만 부하를 차단할 수 있도록 CPP를 좀 더 발전시킨 형태로 고안 되었다. 물론 여기에는 수용가의 편의를 위하여, 원할 때는 전력 차단 신호를 받고도 전력을 차단하지 않는 대신 평상시보다 매우 높은 요금을 내는 등의 옵션도 있다. 또한 전력 차단 시점 및 차단 시간에도 제한을 두도록 하였다.

이러한 DA-CPP는 위에도 언급한 바와 같이, 소규모 부하를 통합하여 전력 시장에서 거래할 수 있는 ESP에 의해 실행되는 것이 가장 적합하다고 가정하였다. 그리하였을 때, DA-CPP에 대한 ESP의 인센티브는 DA-CPP를 시행함으로써 생기는 이윤이 된다. 그러므로 DA-CPP의 critical peak 발생 최적 시점을 결정하는 문제를 푸는 것은 곧, DA-CPP를 실행할 때 발생하는 ESP의 이윤을 최대화하는 시점을 푸는 것과 같은 것이 되며, 이 최적화 방정식은 다음과 같다[1].

$$\pi = \sum_{n=d_j}^{N_{CPP}} R_{d_j} - \sum_{k=1}^{24\times 30} \rho^{DA}[k]\cdot Q_{mkt}[k] - \sum_{k=1}^{10\times 24\times 30} \rho^{RT}(t)\cdot Q_{mkt}(t)$$

$$\text{where } R_{d_j} = \sum_{k=1}^{24\times 30} \rho^{non\text{-}CP}[k]\cdot Q_{d_j}[k] + \sum_{t=1}^{10\times 24\times 30} \rho^{CP}(t)\cdot Q_{d_j}(t)$$

이 최적화 방정식을 풀기 위해서는, 세 가지 하위 문제(subproblem)의 방법론이 필요하다. 먼저 시장 가격의 예측이 필요하고, 수용가의 부하 예측이 필요하며, 이 예측 가격 및 부하량을 통해 critical peak를 발생할 최적 시점을 결정하는 문제가 있다. 앞선 연구에서 시장 가격 예측은 3가지 금융 공학적 모델 random walk, mean reversion, jump diffusion을 따랐으며, 최적 결정 시점을 푸는 문제에는 스윙 옵션(swing option)의 가치 평가 방법을 응용한 동적 계획법(dynamic programming)을 이용하였다[1]. 이 논문에서는 이 세 가지 하위 문제 중, 수용가 부하를 예측하는 문제를 논한다.

2. 본 론

2.1 수용가 부하 예측 방법

최적 critical peak 시점을 구하는 식에서, 우리는 시장 가격이 높고 수용가의 부하가 높은 시점에서 목적 함수가 커짐을 알 수 있다. 이는 계통 상의 수요 관리 필요 시점과도 일치하는 것으로, 계통에 과부하가 걸리거나 상정 사고 등으로 인한 수급 불균형으로 실시간 가격이 치솟을 때 수용가의 부하가 삭감될 필요가 있다.

그런데 시간에 따른 부하량은 소비자마다 각각의 특성을 지니므로, ESP가 가지고 있는 전체 부하량에 따라 최적 CP 시점을 결정하여 모든 수용가에게 같은 시점에서 CP를 발생하는 것보다는, 각 수용가의 부하량에 대해 개별적으로 수요 관리를 하는 것이 더 효율적일 것이다. 하지만 ESP가 관리하는 수용가의 수만큼 각각 최적화 문제를 푸는 것은 비용과 시간 면에서 비경제적이므로, 우리는 각 수용가의 부하 사용량을 일일 패턴으로 파악하여 전체 수용가의 부하 사용량 패턴을 몇 개의 그룹으로 나누어 최적화 문제에 적용하는 방식을 사용하였다.

2.2 수용가 부하 패턴 분류와 Self-Organizing Map(SOM)

Kohonen이 개발한 unsupervised artificial neural network architecture[2]이다. 출력이 주로 2차원의 도면(grid) 상에 시각적으로 표현된다는 점이 특징이다. 또한, 입력 값과 출력 노드(output node) 사이의 유클리드 거리(Euclidean distance)가 가장 작은 최적합 벡터(best-matching unit) 뿐만 아니라 그 주변의 이웃 노드까지 업데이트하여 학습시킨다. SOM은 공학 분야 뿐만 아니라 사회 과학 분야에도 널리 응용되고 있으며, 특히 전력 공학 분야에서는 시스템 부하의 일일 패턴을 주중/주말/휴가철 등의 일별 종류(day type)로 나누는 연구가 진행되기도 하였다[3-5].

우리의 연구에서는 전체 시스템의 일일 부하량 패턴을 day type으로 나누는 대신, 각 수용가의 일일 부하량 패턴을 수용가 수만큼 얻어낸 다음, 이를 몇 가지 대표될 만한 그룹으로 나누는 작업을 하였다.

2.2.1 SOM의 기본 알고리즘[2]

입력 값으로 수용가의 일일 부하량 패턴 값들을 받아 읽어들인다. 그리고 필요한 초기 사용자값들을 설정해 준다. 입력 값과 출력 값인 2차원의 도면의 관계를 나타내는 값을 '연결 가중치(connection weight)'라 하는데 이 값을 초기화 해준다. 그리고 이 알고리즘의 연산에 의해 구해지는 출력 노드의 일정한 범위 내의 이웃 노드의 범위를 'neighborhood'라고 하는데, 그 주변의 어느 이웃 노드까지 업데이트 할지 설정해 준다. 그리고 연결 가중치를 총 몇 번 업데이트 할 것인지 정한다[2].

초기값 설정을 마친 후, 하나의 입력 패턴을 이용하여 연결 가중치를 업데이트 하는 연산을 반복한다. 이 연산은 각 노드에 대해, 입력으로 받은 패턴과 연결가중치의 곱으로 정의되는 'activation value'를 구한다. 즉,

$$a_j = \sum_{i=1}^{N} w_{ij} x_i$$

여기서, w_{ij}는 연결가중치, x_i는 입력패턴, i는 1일동안 N개의 부하, j는 출력 노드이다. 이 중 가장 큰 activation value를 가지는 노드를 최적합 벡터라 한다.

그 출력 노드와 'neighborhood'범위의 node들에 대해서 연결가중치를 입력 값과 출력 노드와의 관계를 실제 입력 패턴과 더욱 연관성을 높이는 값으로 변경하는 '업데이트'를 수행한다. 이러한 과정을 모든 패턴에 대하여 연결 가중치를 업데이트 한 후, 연결가중치와 패턴과의 관계를 더욱 극대화 시키는 값으로 변화시키기 위해 위에서 정한 횟수만큼 반복하는 '연결가중치 훈련' 과정을 거친다. 그리고 neighborhood 범위를 한 단계씩 줄여가며 업데이트를 실시한다.

위의 과정을 통해 '훈련'된 '연결가중치'를 이용하면, 격자 형태로 된 출력 도면을 보면 입력한 여러 개의 패턴들이 몇 개의 그

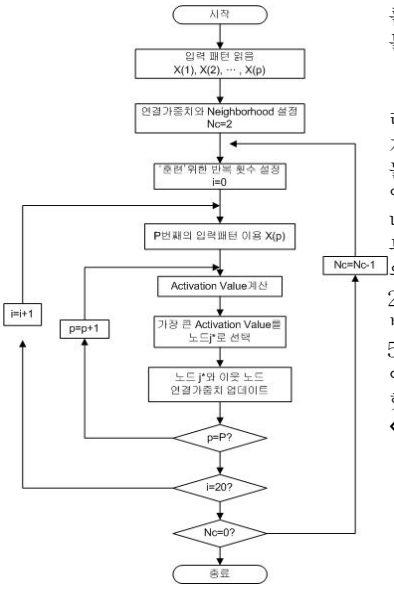

<그림 1> 수용가 일일 부하량 패턴 분류 알고리즘 순서도

룹으로 분류되는 모습을 볼 수 있다.

2.3 시뮬레이션 및 결과

우리 연구에서는 시뮬레이션을 위해 소비자에게서 얻어진 50명 수용가들의 일일 부하량 패턴을 입력으로 이용하였다. 하나의 패턴은 1일 동안의 부하 사용량 값을 6분 단위의 시간 순서로 읽은 240개의 값으로 구성된 벡터이다. 이 입력 값들은 5개의 패턴 중 하나에 노이즈를 더한 값으로 구성했다. 이 5가지 패턴을 **<그림 2>**에 나타내었다.

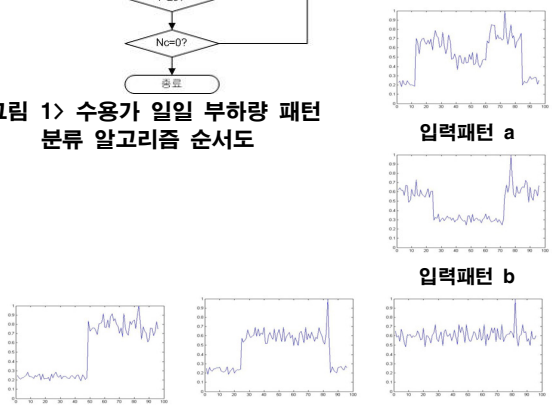

입력패턴 a

입력패턴 b

입력패턴 c 입력패턴 d 입력패턴 e

<그림 2> 시뮬레이션에 사용된 다섯 가지 입력 패턴

입력받은 데이터는 C언어에서 구현을 하기 위해서 배열변수 x[240hours][50days]에 저장한다. 그 값들은 1일치 값들의 크기가 각각 1이 되도록 아래의 식을 이용하여 정규화(normalize) 시킨다.

$$x_i = x'_i / (\sum_{i=1}^{240} x'^2_i)^{1/2}$$

그리고 연결가중치의 행렬을 구하기 위해서, $w_{ij} = (x_i(1), x_i(2), ..., x_i(50))$의평균, $i = 1, \dots, 240$의 값을 구한 다음, -0.5에서 0.5사이의 균일분포(uniform distribution)를 갖는 임의의 값들에 5배 한 후, 입력 값들의 분산을 곱한 값을 위에서 구한 결과 값에 더한다.

$$w_{ij} = w_{ij} + [5r \times (X(1), X(2), ..., X(50))\text{의분산}]$$

여기서, r은 -0.5에서 0.5사이의 값을 갖는 정규 확률 분포이다. 그리고 $Wj = W''_j / (\sum_{i=1}^{240} w''^2_{ij})^{1/2}$을 이용하여 각 열 벡터 크기들이 각각 1이 되도록 다시 정규화 해주면 최종적인 연결가중치가 계산된다.

그런 후 앞에서 구한 연결가중치와 정규화된 입력 값을 이용하여, 패턴 분류에 사용되는 activation value를 계산한다.

$$\begin{bmatrix} node1 \\ node2 \\ . \\ . \\ node64 \end{bmatrix} = \begin{bmatrix} w_{node1,time1} & w_{node1,time2} & \cdots & w_{node1,time240} \\ w_{node2,time1} & w_{node2,time2} & \cdots & w_{node2,time240} \\ \vdots & \vdots & \ddots & \vdots \\ w_{node64,time1} & w_{node64,time2} & \cdots & w_{node64,time240} \end{bmatrix} \times \begin{bmatrix} x_{time1,day} \\ x_{time2,day} \\ \vdots \\ x_{time240,day} \end{bmatrix}$$

결과 값으로 나온 왼쪽의 수치들 중에서 가장 큰 값이 입력 x로 쓰였던 1일 치의 출력 노드가 된다. 그 결과 값으로 나온 출력 노드의, 사용자가 지정한 neighbourhood 범위 안에 들어있는 주변 노드들의 가중치 값들을 아래의 식을 이용하여 업데이트를 수행한다.

$$w_{ij,update} = w_{ij} + \mu(x_i - w_{ij})$$

여기서, w는 가중치, μ는 업데이트를 위한 임의의 스텝 사이즈이다. 이 논문의 시뮬레이션을 위해서, Neighborhood가 2일 때의 $\mu_0 = 0.008$, 그 다음 범위가 한 단계씩 줄었을 때는 각각 $\mu_1 = 0.005$, $\mu_2 = 0.002$의 값을 사용하였다.

위의 과정을 50일의 입력 값들을 이용하여 업데이트를 하며 연산한다. 이러한 반복적인 과정을 사용자가 지정한 횟수만큼 반복한다. 이 시뮬레이션에서는 반복 횟수를 20번으로 설정하였다. 그런 후, 마지막으로 업데이트를 수행할 때, neighborhood 범위를 1씩 줄여가며 위의 반복연산을 수행한다. 우리 연구에서는 초기 설정에서 neighborhood 범위를 2로 지정하였다.

업데이트를 모두 마친 후 가중치와 입력 값의 행렬 곱의 결과 값으로 나온 출력 노드가 같으면 같은 패턴 그룹으로 분류를 하였다. 즉, 입력의 연산을 통해서 50일 별로 각각 출력 노드가 같은 패턴일 경우 같은 출력 노드로 표시되게 된다.

같은 출력 노드를 가지는 패턴들을 묶어서 평균을 계산해본 결과 5개의 패턴으로 나눠지는 것을 볼 수 있었다. 입력 값으로 이용되었던 **<그림 2>**의 패턴 a는 **<그림 3>**의 패턴 a로 분류되었고, **<그림 2>**의 b는 **<그림 3>**의 패턴 c, **<그림 2>**의 c는 **<그림 3>**의 패턴 b, 그리고 **<그림 2>**의 d는 **<그림 3>**의 패턴 e, 마지막으로 **<그림 2>**의 e는 **<그림 3>**의 패턴 d 그룹으로 분류 되었다. 임의로 선택한 5개의 입력 값 이외에 다른 값들의 결과 값 또한 정확히 나눠지는 결과를 얻을 수 있었다.

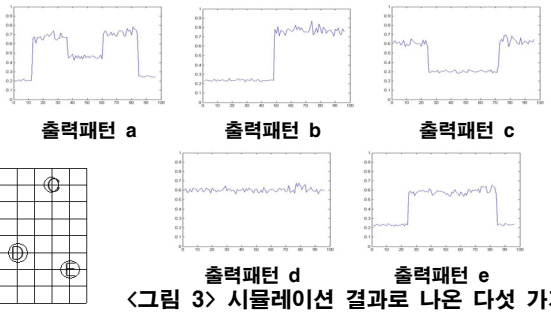

출력패턴 a 출력패턴 b 출력패턴 c

출력패턴 d 출력패턴 e

<그림 3> 시뮬레이션 결과로 나온 다섯 가지 출력 패턴

<그림 4> 출력 도면

출력 노드를 관찰하였을 때, 정확히 5개의 노드만 출력이 분포 되어 있었다. **<그림 4>**의 a의 패턴은 A의 출력을, **<그림 4>**의 b 패턴은 B의 출력을, **<그림 4>**의 c 패턴은 C의 출력을, **<그림 4>**의 d 패턴은 D의 출력을, **<그림 4>**의 e 패턴은 E의 출력을 나타낸다.

3. 결 론

일반 수용가를 대상으로 하는 효율적인 수요관리의 전체적인 방법론은 앞선 연구에서 수행하였고 그 최적화 문제를 풀어보았다. 최적 critical peak 시점을 결정하는 데에는 수용가의 부하 사용량을 예측해야 할 필요가 있는데, 한 ESP가 관리해야 할 수용가의 수는 매우 많고, 이들의 부하 사용량 패턴도 제각기 다르다. 따라서 이 부하 사용량 패턴을 몇 가지의 그룹으로 평균화할 필요가 있으며, 이를 위해 SOM이 사용되었다. 그 결과, 몇 가지의 일정한 패턴을 따르면서 임의의 잡음을 가지는 수용가의 부하 사용량 패턴을 나누었을 때, 이 패턴들이 유효하게 구분됨을 확인할 수 있었다. 이를 최적 critical peak 시점을 결정하는 문제에도 활용하여 지난 연구보다 더 완성도 높은 결과를 얻어낼 수 있었다.

[참 고 문 헌]

[1] 주지영, 안상호, 윤용태 "Critical Peak Pricing 요금제를 이용한 일반 수용가 대상 수요관리의 방법", 2007년도 대한전기학회 하계학술대회 논문집, 2007

[2] T. Kohonen, "The Self-Organizing Map", Proceedings of The IEEE, Vol. 78, No. 9, pp. 1464-1480, 1990

[3] Y.-Y. Hsu, C.-C. Yang, "Design of artificial neural networks for short-term load forecasting. Part I: Self-organising feature maps for day type identification", IEE Proceedings-C. Vol. 138, No. 5, pp. 407-413, 1991

[4] G. Chicco, R. Napoli, F. Piglione, "Load pattern clustering for short-term load forecasting of anomalous days", IEEE Power Tech Proceedings, Vol. 2, 2001

[5] S.V. Verdu, M.O. Garcia, C. Senabre, A.G. Marin, F.J.G. Franco, "Classification, Filtering, and Identification of Electrical Customer Load Patterns Through the Use of Self-Organizing Maps", IEEE Transactions on Power Systems, Vol. 21 No. 4, pp. 1672-1682, 2006