

## 수정 LVQ법을 이용한 배전계통의 전압/무효전력 제어에 관한 연구\*

김광원 · 김종일  
전기 · 전자 및 자동화 공학부

### <요약>

본 논문에서는 코호넨 신경회로망을 이용한 배전시스템의 전압 및 무효전력 실시간 제어 기법을 제안하였다. 본 논문에서의 제어 목적은 모든 모선의 전압을 한계값 이내로 유지하면서 배전시스템의  $I^2R$  손실을 최소화하는 병렬 캐패시터 뱅크와 선로전압조정기의 최적 상태를 결정하는 것이다. 이와 같은 이산적인(discrete) 상태를 취급하기에는 코호넨 신경회로망이 적합하지만, 코호넨 신경회로망의 일반적인 학습법인 LVQ는 분류대상 그룹수가 많은 경우에 기준벡터가 feasible 영역에서 벗어나는 현상이 발생한다. 이에 본 논문에서는 수정 LVQ법을 고안하여 코호넨 신경회로망을 학습하였으며, 5개의 on-off 캐패시터와 1개의 선로전압조정기로 구성된 30모선 배전시스템의 전압/무효전력 제어에 제안한 기법을 적용하여 그 타당성을 검증하였다.

## A Study on the Voltage/Var Control of Distribution System Using Modified Learning Vector Quantization

Kim, Gwang-Won · Kim, Jong-Il  
School of Electrical and Electronic Engineering

### <Abstract>

This paper proposes a modified Learning Vector Quantization (LVQ) to control shunt

\* 이 논문은 1998학년도 울산대학교 학술연구조성비에 의하여 연구되었음.

capacitor banks and feeder voltage regulators in an electric distribution system. The proposed modified LVQ is utilized to training Kohonen Neural Network (KNN). The objective of the KNN is on-line decision of the optimal state of shunt capacitor banks and feeder voltage regulators which minimize losses of the distribution system while maintaining all the bus voltages within the limits. The KNN is tested on a distribution system with 30 buses, 5 on-off switchable capacitor banks and a nine tap line voltage regulator.

## 1. 서 론

변전소 및 배전계통의 전압/무효전력은 보통 병렬 캐패시터와 선로전압조정기(line voltage regulator)에 의해 제어된다. 따라서, 캐패시터와 선로전압조정기의 상태를 적절히 조절함으로써 전압을 허용 범위 내로 유지하면서도 배전계통을 경제적으로 운용할 수 있으므로, 기기의 추가적 설치 없이 보다 양질의 전력을 경제적으로 공급하기 위해서는 캐패시터와 선로전압조정기의 상태를 실시간으로 제어할 필요가 있다. 과거에는 해석적 방법[1], 동적계획법[2], 비선형 프로그래밍[3]으로 배전계통의 전압/무효전력 제어를 수행하였으나, 최적해의 결정에 많은 시간이 소요되었다. 따라서 비교적 최근에는 퍼지 논리[4], 유전 알고리즘[5], 인공 신경회로망[6,7] 등의 인공지능기법을 이용하여 이러한 문제를 해결하고자 하는 연구가 많이 진행되고 있다. 특히, 인공 신경회로망을 이용한 방법은 과거의 경험을 바탕으로 현재 배전계통에 적절한 캐패시터와 선로전압조정기의 상태를 신속히 결정하므로 배전계통 실시간 전압/무효전력 제어에 적합하다고 할 수 있다.

인공 신경회로망은 최적화 문제에 적합한 흡필드(Hopfield)형, 함수 학습에 적합한 Perceptron형, 데이터 양자화(quantization)에 적합한 코호넨(Kohonen)형 등 다양한 형태가 있으며, 각각의 학습 방법 또한 다양하므로 응용분야에 맞는 신경회로망 형태와 학습방법의 선택이 중요하다. 배전계통의 전압/무효전력 제어는 연속적인 함수를 다루는 문제가 아니며, 단지 현재의 배전계통의 상태에 따른 캐패시터와 선로전압조정기의 상태 결정 문제이므로, 본 논문에서는 주어진 문제를 패턴 분류(classification)의 문제로 보고, 문제의 해결에 코호넨 신경회로망을 이용하였다. 코호넨 신경회로망을 이용한 패턴 분류는 nearest neighbor를 그 분류 기준으로 하며, 코호넨 신경회로망의 학습은 nearest neighbor를 찾는데 사용되는 기준벡터(codebook vector)를 생성하는 과정이다. 그 대표적인 학습 방법에는 SOFM(Self Organizing Feature Map)과 LVQ가 있다[8].

SOFM과 LVQ는 두 방법 모두 경쟁학습(competitive learning)을 근간으로 하지만, SOFM은 비지도학습(unsupervised training)인 반면에 LVQ는 지도학습(supervised training)이다. 한편, 전압/무효전력제어는 학습 입, 출력쌍을 알고 있는 지도학습 문제이므로 본 논문의 목적에는 LVQ가 부합된다. 그러나, 실험 결과, 기존 LVQ는 분류대상 그룹의 수가 많은 경우에 기준벡터가 feasible 영역에서 벗어나게 되는 경우가 발생하므로 본 논문에서는 기존 LVQ를 다소 변형한 수정 LVQ법을 고안하여 코호넨 신경회로망의 학습에 적용하였고 제안한 방법을 타 논문에서 빈번히 인용된[3,6,7] 30모션 배전계통의 전압/무효전력 제어에 적용하였다.

## 2. 수정 LVQ

### 2-1 코호넨 신경회로망

코호넨 신경회로망의 구성은 그림 1과 같고 각 기호의 의미는 다음과 같다.

$x_i$  : 입력벡터의  $i$ 번째 원소

$w_{ij}$  : 입력벡터의  $i$ 번째 원소와  $j$  번째 노드간의 가중치(weight)

$\theta_i$  :  $i$ 번째 노드의 문턱값(threshold)

$\eta_i$  :  $i$ 번째 노드에서 MAXNET으로의 입력

$y_i$  : 코호넨 신경회로망의  $i$ 번째 노드 출력

$n$  : 입력벡터의 차수

$N$  : 노드 수 (기준벡터 수)

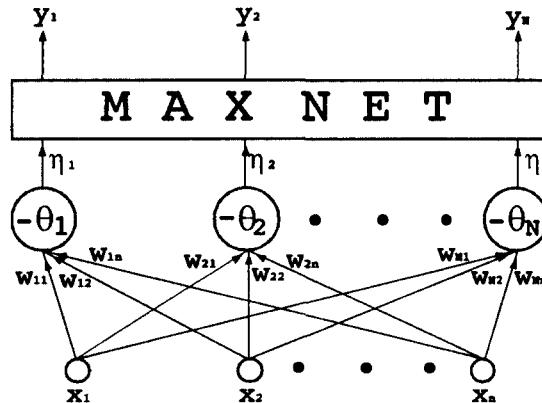


그림 1 코호넨 신경회로망의 구조

그림 1에서 가중치와 문턱값을 적절히 설정하면  $\eta_i$ 는 입력벡터와  $i$ 번째 노드의 기준벡터간의 거리에 반비례하는 값을 가지게 된다. 즉, 입력벡터와 가장 가까운 기준벡터를 가지는 노드의  $\eta$ 값이 가장 크다. 한편 MAXNET은 입력 중에서 가장 큰 값을 '1'로 하고 나머지 값을 '0'으로 조정하는 역할을 수행하므로, 코호넨 신경회로망의 최종 출력  $y$ 는 입력벡터와 가장 가까운 기준벡터를 가지는 노드(winner 노드)의 경우에 '1', 그 외의 노드의 경우에는 '0'이 된다.

### 2-2 기존 LVQ

기존 LVQ의 절차는 다음과 같다.

- 절차 1 : 각 노드의 기준벡터를 임의의 작은 값 또는 학습데이터의 일부로 초기화한다.
- 절차 2 : 현재의 코호넨 신경회로망에 학습 데이터를 입력하여 winner 노드를 결정한다.
- 절차 3 : winner 노드의 소속 그룹이 학습 데이터의 소속 그룹과 같으면 (1)을 이용해서, 다르면 (2)를 이용해서 winner 노드의 기준벡터를 개선한다. 한편, winner 노드의 소속 그룹이 할당되어 있지 않은 경우에는 현재의 학습 데이터의 소속 그룹을 winner node의 소속 그룹으로 할당한다.

$$R(t+1) = R(t) + \alpha(t) \{ X(t) - R(t) \} \quad (1)$$

$$R(t+1) = R(t) - \alpha(t) \{ X(t) - R(t) \} \quad (2)$$

위에서,  $R(t)$  :  $t$ 에서 winner 노드의 기준벡터  
 $X(t)$  :  $t$ 에서 학습데이터 벡터  
 $\alpha(t)$  :  $t$ 에서 학습률

절차 4 : 절차 2, 3을 모든 학습데이터에 대해 반복 수행한다.

LVQ의 학습 절차를 살펴보면 winner 노드와 학습 데이터의 소속 그룹이 같은 경우에는 winner 노드의 기준벡터를 학습데이터 벡터 방향으로 이동하고, 다른 경우에는 학습데이터 벡터의 반대 방향으로 이동함으로써 코호넨 신경회로망의 기준벡터들과 학습데이터 벡터들이 비슷한 분포를 가지게끔 코호넨 신경회로망을 학습한다. 위에서 학습률은 winner 노드의 학습시 이동정도를 결정한다. 즉, 학습률이 1이면 winner 노드의 기준벡터를 학습데이터 벡터와 동일하게 만들며, 0이면 전혀 학습이 이루어지지 않는다. 학습률은 0과 1사이의 값을 가지며 일반적으로 학습초기에는 1근처의 값으로 하여 급격한 학습을 수행하고 그 값을 단조 감소시켜서 학습이 진행됨에 따라 세밀한 학습을 수행한다. 또한 일반적으로 동일한 학습데이터로써 위의 절차 1~절차 4를 최소 수십 차례 이상 반복 수행한다.

### 2-3 수정 LVQ

분류 대상 그룹 수가 많을 때, 기존 LVQ는 (2)에 의한 학습의 수가 증가하게 되어 기준 벡터가 feasible 영역 밖으로 밀려 나가는 경우가 발생할 수 있다. 예를 들어, 본 논문의 사례연구에서는 분류 대상 그룹 수가 최대 288개나 되며 기존 LVQ로 학습한 결과 상기한 문제가 발생하여 효율적인 학습을 할 수 없었다. 이에 본 논문에서는 다음과 같은 수정 LVQ를 고안하여 사용하였다.

- 절차 1 : 각 노드의 기준벡터를 임의의 작은 값 또는 학습데이터의 일부로 초기화한다.
- 절차 2 : 현재의 코호넨 신경회로망에 학습 데이터를 입력하여 winner 노드를 결정한다.
- 절차 3 : 학습 데이터의 소속 그룹을 winner 노드의 소속 그룹으로 할당하고 (1)를 이용해서 winner 노드의 기준벡터를 개선한다.
- 절차 4 : 절차 2, 3을 모든 학습데이터에 대해 반복 수행한다.

수정 LVQ와 기존 LVQ는 절차 3에서만 차이가 있으며, 수정 LVQ에서는 winner 노드의 기준 벡터를 항상 학습데이터 벡터의 방향으로 이동하고 소속 그룹을 학습 데이터의 소속 그룹으로 변경함으로써 전술한 기존 LVQ의 문제점을 해결하였다.

### 3. 사례 연구

#### 3-1 문제의 정의

본 사례연구에서 배전계통의 전압/무효전력 제어 목적은 부하변동에 적절히 대응하여 각 모선의 전압을 한계값 내로 유지하면서 배전선로에서의 손실을 최소로 하는 캐패시터와 선로전압조정기 상태를 결정하는 것이다. 본 사례연구의 목적함수는 다음과 같은 수식으로 표현 가능하다.

$$\arg \min_{\mathbf{T}} \sum_{i=1}^M [ |I_i(\mathbf{T})|^2 R_i ] \quad (3)$$

단,  $V_i \in (V_{\min}, V_{\max})$ ,  $i = 1, \dots, N$

위에서,  $R_i$  : 선로  $i$ 의 저항성분

$I_i$  : 선로  $i$ 의 선전류

$V_i$  : 모선  $i$ 의 전압 크기

(3)에서  $M, N$ 은 각각 선로와 모선의 수이며,  $\mathbf{T}$ 는 캐패시터와 선로전압조정기의 상태를 나타내는 벡터로, (3)을 만족하는  $\mathbf{T}$ 가 시작  $t$ 에서 캐패시터와 선로전압조정기의 최적 상태이다. 아울러, 본 사례연구에서는 다음과 같은 조건을 부가함으로써 문제를 간략화 또는 구체화하였다.

조건 1 : 배전계통의 상태는 배전계통에 설치된 전압·전력 측정장치로부터 얻는다.

조건 2 : 각 캐패시터는 하나의 뱅크로만 구성되어 on-off 상태만을 가진다.

조건 3 : 모선 전압의 허용 범위는 0.95~1.05 p.u.이다.

조건 4 : 캐패시터와 선로전압조정기의 용량과 위치는 결정되어 있다.

조건 5 : 전압과 전력의 측정값은 측정과 동시에 전송된다.

조건 6 : 캐패시터와 선로전압조정기의 스위칭 수에는 제한을 두지 않는다.

조건 7 : 각 모선 부하의 시간적 변동 비율은 비슷하다.

위에서 조건 1~3은 각각 신경회로망의 입력변수 종류, 분류 대상 그룹, 최적해의 조건에 영향을 끼칠 뿐 이론의 전개에는 아무런 영향이 없다. 조건 5는 실시간 제어를 위한 가정이며, 캐패시터의 수명과 surge의 발생 등을 고려하면 가능한 한 스위칭의 수가 적어야 하지만, 본 사례연구에서는 조건 6을 둘로써 문제를 간략히 하여 (3)의 만족 여부에 초점을 두었다. 조건 4와 7은 많은 배전계통에 실재하므로 큰 제약이라고 할 수는 없다.

### 3-2 코호넨 신경 회로망의 구성

코호넨 신경회로망을 이용하여 배전계통의 전압/무효전력을 제어할 때, 결정하여야 할 사항은 입력변수 종류, 구분 대상 그룹, 기준벡터이다. 이 중에서 기준벡터는 수정 LVQ 법에 의해 구성한다. 입력 변수로 사용되는 특징변수는 해당 문제를 가장 잘 대표하면서도 사용 가능한 것이어야 한다. 본 사례연구에서는 각 모선의 부하량을 측정하지 않으므로 배전계통에 설치된 전압·전력측정장치의 출력, 즉, 전압의 크기와 유효, 무효전력량을 입력변수로 선택하였다. 다음에 나오는 대상계통을 보면 측정장치가 6곳에 있으므로 본 논문에서 코호넨 신경회로망의 입력은 18차 벡터이다. 한편, 구분 대상 그룹은 모든 캐패시터와 선로전압조정기의 조합 상태를 하나의 그룹으로 정의하였다. 본 사례연구에서는 on-off 캐패시터가 5곳에 위치하고 하나의 9탭 선로전압조정기가 있으므로  $2^5 \times 9$ 가지, 즉, 288가지의 그룹이 있다.

### 3-3 대상 배전계통 및 학습데이터의 생성

본 사례연구에서 채택한 적용 대상 배전계통은 타 논문에서 빈번히 이용되었던 그림 2의 23kV, 30모선 배전계통으로 선로 및 부하데이터는 표 1에 수록하였다.

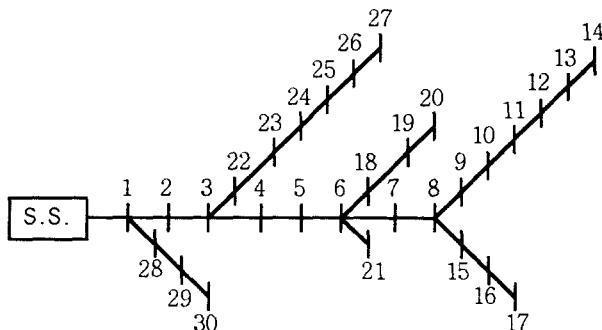


그림 2 23kV 대상 배전계통

대상 배전계통에는 13, 15, 19, 23, 25번 모선에 각각 800, 1000, 400, 1600, 2000[kVar]의 on-off 조작만이 가능한 전력용 캐패시터가 설치되어 있고, 9개의 등간격 템으로 변압비를 1:1~1:1.1 범위 내에서 조절 가능한 선로 전압조정기가 4, 5번 모선 사이에 설치되어 있다. 0(변전소)-1, 3-4, 7-8, 8-9, 18-19, 3-22 모선 사이의 6곳에는 전압·전력 측정기가 설치되어 있다.

위와 같은 배전계통에서 캐패시터와 선로전압조정기의 최적 상태는 각 모선의 부하와 변전소 모선의 전압 크기에 따라 결정된다. 본 사례연구에서는 코호넨 신경회로망의 전압/무효전력 제어기를 KNN제어기라 명명하고 다음과 같은 조건하에 KNN 제어기를 학습하였다.

조건 1 : 변전소 모선의 전압을 1.0 p.u.로 고정한다.

조건 2 : 각 모선 부하는 표 1에 표기된 최대부하량의 20~100[%]내에서 동일하게 변동한다.

본 사례연구 KNN 제어기의 학습데이터는 다음의 절차로 생성하였다.

절차 1 : 현재의 부하수준을 표 1에 나타난 최대부하의 20%~100% 사이에서 가정한다

절차 2 : 절차 1의 부하수준과 캐패시터/선로전압조정기의 288 상태에 대해 조류계산을 수행한다.

절차 3 : 절차 2의 결과로부터 최적의 조합을 찾는다.

표 1 배전계통 데이터

| 모선  | 모선  | 선로 임피던스          | 최대부하(모선 $j$ )    |                |                  |
|-----|-----|------------------|------------------|----------------|------------------|
| $i$ | $j$ | $r_{ij}(\Omega)$ | $x_{ij}(\Omega)$ | $P(\text{kW})$ | $Q(\text{kVar})$ |
| 0   | 1   | 0.196            | 0.655            | -              | -                |
| 1   | 2   | 0.279            | 0.015            | 522            | 174              |
| 2   | 3   | 0.444            | 0.439            | -              | -                |
| 3   | 4   | 0.864            | 0.751            | 936            | 312              |
| 4   | 5   | 0.864            | 0.751            | -              | -                |
| 5   | 6   | 1.374            | 0.774            | -              | -                |
| 6   | 7   | 1.374            | 0.774            | -              | -                |
| 7   | 8   | 1.374            | 0.774            | -              | -                |
| 8   | 9   | 1.374            | 0.774            | 189            | 63               |
| 9   | 10  | 1.374            | 0.774            | -              | -                |
| 10  | 11  | 1.374            | 0.774            | 336            | 112              |
| 11  | 12  | 1.374            | 0.774            | 657            | 219              |
| 12  | 13  | 1.374            | 0.774            | 783            | 261              |
| 13  | 14  | 1.374            | 0.774            | 729            | 243              |
| 8   | 15  | 0.864            | 0.751            | 477            | 159              |
| 15  | 16  | 1.374            | 0.774            | 549            | 183              |
| 16  | 17  | 1.374            | 0.774            | 477            | 159              |
| 6   | 18  | 0.864            | 0.751            | 432            | 144              |
| 18  | 19  | 0.864            | 0.751            | 672            | 224              |
| 19  | 20  | 1.374            | 0.774            | 495            | 165              |
| 6   | 21  | 0.864            | 0.751            | 207            | 69               |
| 3   | 22  | 0.444            | 0.439            | 522            | 174              |
| 22  | 23  | 0.444            | 0.439            | 1917           | 639              |
| 23  | 24  | 0.864            | 0.751            | -              | -                |
| 24  | 25  | 0.864            | 0.751            | 1116           | 372              |
| 25  | 26  | 0.864            | 0.751            | 549            | 183              |
| 26  | 27  | 1.374            | 0.774            | 792            | 264              |
| 1   | 28  | 0.279            | 0.015            | 882            | 294              |
| 28  | 29  | 1.374            | 0.774            | -              | -                |
| 29  | 30  | 1.374            | 0.774            | 882            | 294              |

한편, 동일한 부하수준에 대해서도 캐패시터/선로전압조정기의 상태에 따라 전압·전력

측정장치의 측정값이 다르므로 KNN 제어기의 입력벡터가 상이하다. 따라서, 위의 절차 1~절차 3에 의해 각 부하수준마다 288개의 학습데이터를 얻을 수 있다. 본 논문에서는 161가지의 부하수준을 0.2~1.0사이에서 등간격으로 설정하여 모두 46368개의 학습데이터를 얻었으며, 기준벡터의 수가 학습데이터 수의 12.5% (5796개), 25% (11592개), 33.3% (15456개)인 경우에 대하여 각각 수정 LVQ로 KNN 제어기를 구성하였다.

### 3-4 전압/무효전력 제어 결과

수정 LVQ로 구성한 KNN 제어기의 성능 평가를 위해 0.2~1.0사이에서 난수를 100개 발생하여 부하수준으로 하고, 각 경우마다 캐패시터/선로전압조정기의 최적상태를 구하여 테스트데이터를 생성하였다. 본 경우에도 학습데이터의 경우와 마찬가지로 28800개의 테스트데이터가 얻어지지만, 결과 분석을 간단히 하기 위하여 각 부하수준마다 하나의 테스트데이터를 선별하여 모두 100개의 테스트데이터를 형성하였다. 테스트 결과는 표 2, 3, 4와 같다.

표 2 KNN 제어기의 오분류 내역

| 기준벡터 수<br>내역 \ | 5796 | 11592 | 15456 |
|----------------|------|-------|-------|
| 오분류 수          | 62   | 64    | 31    |
| 전압조건 위배 수      | 27   | 19    | 21    |
| 손실증가 수         | 35   | 45    | 10    |

표 2에서 오분류(misclassification)의 경우는 전압조건을 위배했거나 최적제어에 비하여 배전계통의 손실이 증가한 경우이며 배전계통의 특성상 두 경우가 중복되어 나타나지는 않는다. 한편, 오분류가 아닌 경우는 최적제어기와 KNN 제어기의 출력이 동일함을 의미한다. 다음의 표 3, 4는 오분류인 경우에 KNN 제어기의 성능을 보여주고 있다.

표 3 전압조건 위배시 KNN 제어기의 5번 모션 전압 [p.u.]

| 기준벡터 수<br>내역 \ | 5796    | 11592   | 15456   |
|----------------|---------|---------|---------|
| 평균             | 1.05480 | 1.05554 | 1.05236 |
| 최대값            | 1.06900 | 1.06900 | 1.06900 |
| 표준편차           | 0.00515 | 0.00557 | 0.00405 |

표 4 손실증가시 KNN 제어기의 손실 증가율 [%]

| 기준벡터 수<br>내역 | 5796  | 11592  | 15456  |
|--------------|-------|--------|--------|
| 평균           | 2.193 | 2.527  | 1.856  |
| 최대값          | 8.392 | 13.476 | 10.474 |
| 표준편차         | 2.035 | 2.642  | 3.150  |

방사상 구조의 배전계통의 저항 손실은 각 모선의 전압을 높게 유지할수록 적어진다. 따라서, 본 사례연구의 배전계통에서는 선로전압조정기 2차측인 5번 모선의 전압크기가 가장 크고, 4번 또는 14번 모선의 전압 크기가 가장 낮게 된다. 따라서, 5, 4, 14번 모선의 전압 크기가 허용치 내에 있으면 타 모선의 전압크기도 전압조건을 위배하지 않는다고 할 수 있다. 그리고 사례연구 배전계통을 분석한 결과 전압 상한치의 위배만이 문제가 되므로 표 3에서는 5번 모선의 전압크기를 분석 대상으로 하였다.

표 3은 전압조건을 위배한 경우의 위배 정도를 나타내며, 표 4는 최적해에 비해 배전계통 손실이 큰 경우의 손실 증가율을 나타낸다. 표 3과 4를 보면 오분류의 경우에도 KNN 제어기가 근사 최적해를 제공함을 알 수 있다. 예를 들어 기준벡터의 수가 15456개인 경우에 표 3의 평균과 표준편차로부터 전압조건을 위배하더라도 그 값이 1.05409내에 있을 가능성이 95%임을 알 수 있고, 표 4로부터는 최적해에 비해 배전계통 손실이 큰 경우에도 그 손실 증가율이 3.8% 이내일 확률이 95%임을 알 수 있다.

또한, 표 2, 3, 4를 종합할 때, 기준벡터의 수가 5796, 11592개인 경우에는 KNN 제어기가 비슷한 성능을 보여주었으나, 기준벡터의 수가 15456개인 경우에는 그 성능 향상이 두드러짐을 알 수 있다. 이는 기준벡터의 수가 어느 정도 이상 되어야 KNN 제어기의 신뢰도가 유지됨을 의미한다. 그러나, 그 적절한 수의 결정은 불가능하므로 이 후의 사례연구에서는 기준벡터의 수를 학습데이터 수의 1/3 수준인 15456개로 고정하였다.

다음으로, 대상 배전계통에서 표 1의 최대부하대비 일간부하변동곡선을 그림 3과 같은 정현파로 가정하고 KNN 제어기를 이용하여 전압/무효전력 제어를 수행하였다.

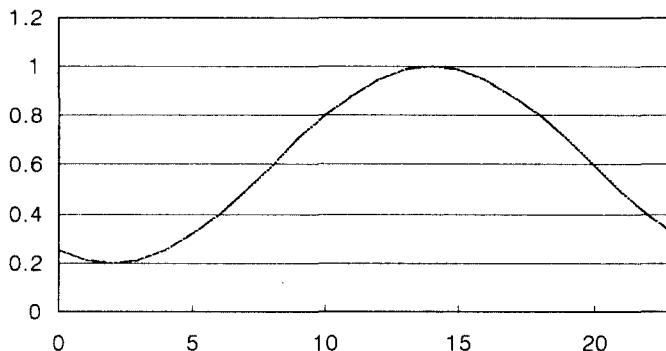


그림 3 일간 부하곡선 (x축: 시간, y축: 부하수준)

그림 4는 캐패시터와 선로전압조정기를 고정한 상태로 관찰한 일간전압변동곡선으로, 중부하시 전압 조건을 만족시키려다보니 경부하시에 5번, 14번 모선의 전압이 상한치인 1.05 p.u.보다 매우 높이 올라감을 알 수 있다.

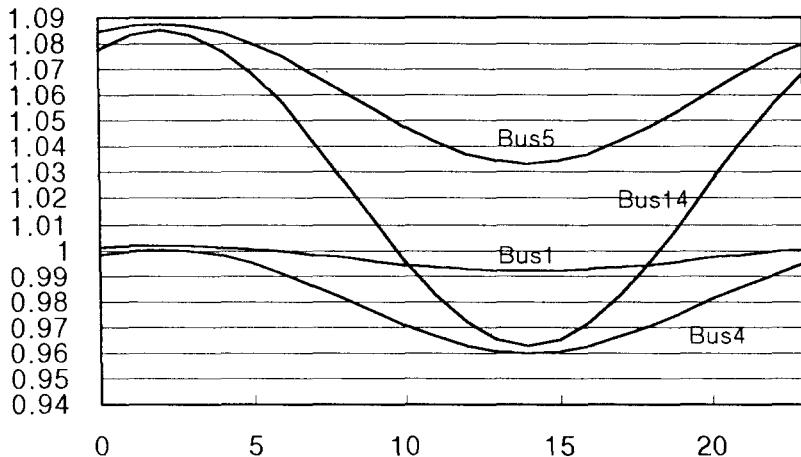


그림 4 일간 전압변동곡선 1 (x축: 시간, y축: 전압수준)

그림 5는 이미 학습한 KNN제어기로 매시간마다 제어한 결과로서, KNN제어기가 부하가 증가하는 시기에는 손실을 줄이기 위하여 배전계통의 전압을 상승시키고 부하가 감소하는 시기에는 전압조건을 위배하지 않기 위하여 배전계통의 전압을 강하시키고 있다.

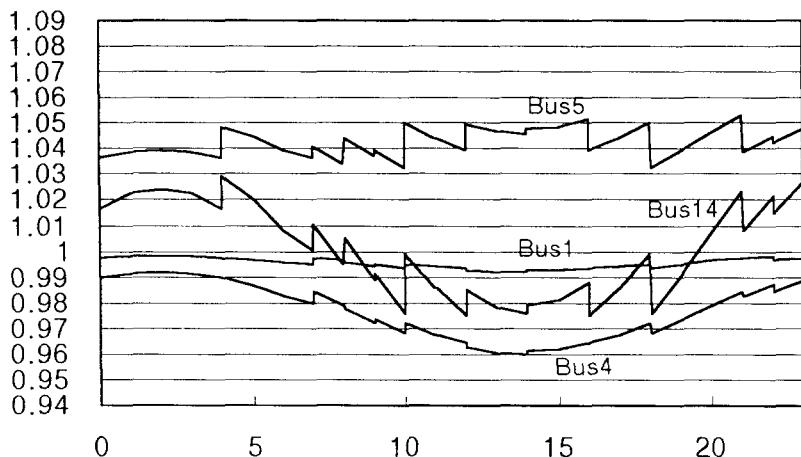


그림 5 일간 전압변동곡선 2 (x축: 시간, y축: 전압수준)

그러나, 그림 5를 보면, 매시간 제어를 하여도 부하가 감소하는 시기에 5번 모선 전압이 전압조건을 위배하는 경우가 간혹 발생한다. 이는 KNN제어기가 최적제어가 아닌 근사최

적 제어를 하기 때문이기도 하고, 제어가 한시간 간격으로 이루어지므로 KNN 제어기가 부하 변동에 즉각적으로 대응할 수 없기 때문이기도 하다. 이에, 모선 전압 조건을 0.95~1.04 p.u.로 강화하여 KNN 제어기를 재학습하였다. 이는 상기한 근사최적제어와 부하변동에 따른 전압제어 오차를 수용하고자 KNN 제어기에 0.01 p.u.만큼의 제어 여유를 두었음을 의미한다. 재학습한 KNN 제어기의 매시간 제어 결과는 그림 6과 같다.

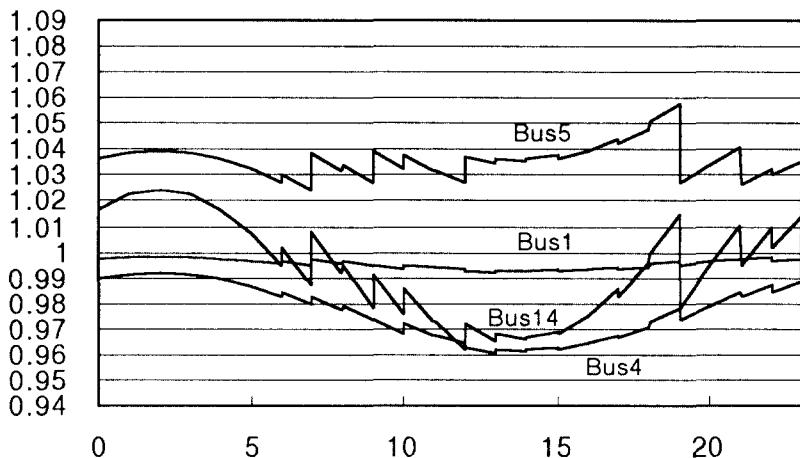


그림 6 일간 전압변동곡선 3 (x축: 시간, y축: 전압수준)

그림 6은 그림 5에 비하여 전체적인 전압 수준이 감소하였으므로 배전계통의 손실은 다소 증가하였으나, 전압조건은 반드시 만족해야 하므로 그림 6의 전압변동곡선이 그림 5의 전압변동곡선 보다 바람직하다고 할 수 있다. 한편, 그림 7은 재학습한 KNN 제어기로 30분 간격으로 제어한 결과이다.

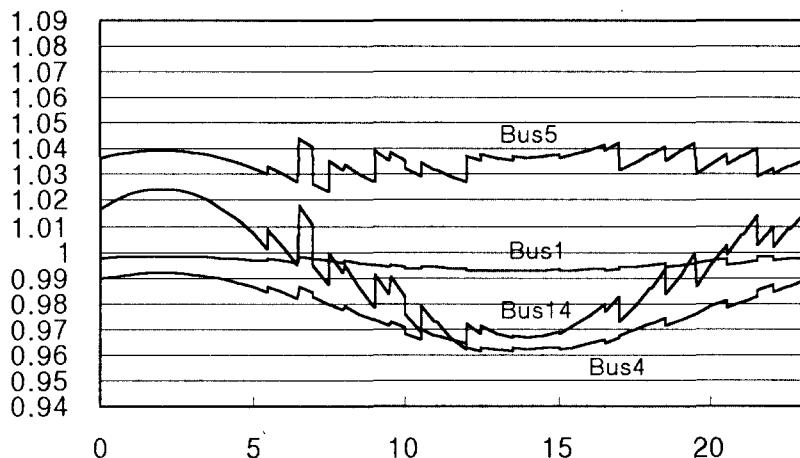


그림 7 일간 전압변동곡선 4 (x축: 시간, y축: 전압수준)

그림 6에는 18시 부근에서 전압조건의 위배가 발생하였으나, 그림 7에서는 제어 시점사 이의 부하변동 폭이 적기 때문에 전압조건의 위배가 전혀 없음을 알 수 있다. 즉, KNN 제어기의 제어주기를 짧게 할수록 제어 결과는 우수하지만 캐페시터와 선로전압조정기의 스위칭 수가 많을수록 보상기기의 수명이 짧아지고 surge가 발생하므로 제어주기와 제어성 능간의 적절한 trade-off가 있어야 하겠다.

#### 4. 결 론

본 논문에서는 배전계통의 실시간 전압/무효전력 제어를 위하여 인공 신경회로망을 도입하였으며 대상문제를 패턴 구분의 측면에서 조망하여 코호넨 신경회로망을 이용하였다. 또한, 코호넨 신경회로망의 대표적인 학습법인 기존 LVQ는 분류 대상 그룹이 많은 경우에 문제가 발생하므로 본 논문에서는 수정 LVQ법을 고안하여 코호넨 신경회로망의 학습에 이용하였다. 제안한 방법을 30모선 배전계통 전압/무효전력 제어에 적용한 결과 코호넨 신경회로망은 전압조건을 만족시키면서도 배전계통의 손실을 최적제어 수준으로 유지함으로써 근사최적제어를 수행함을 확인하였다.

그러나, 본 논문의 사례연구는 변전소 모선 전압을 고정하고 배전계통 각 모선의 부하변동 비율을 동일하게 취급하는 등의 한계를 지니고 있으며, 추후 이러한 한계의 극복을 위한 연구가 뒤따라야 하겠다.

#### 참고 문헌

- [1] M. Kaplan, "Optimization of Number, Location, Size, Control Type and Control Setting of Shunt Capacitors on Radial Distribution Feeders," *IEEE Trans. on PAS*, vol.103, no.9, pp.2659-2665, September 1984.
- [2] Y. Y. Hsu and H. C. Kuo, "Dispatch of Capacitor on Distribution System Using Dynamic Programming," *IEEE Proceedings Part C*, vol.140, no.6, pp.433-438, November 1993.
- [3] S. Civanlar and J. J. Grainger, "Volt/Var Control on Distribution Systems with Lateral Branches Using Shunt Capacitors and Voltage Regulators : Part I, II, and III," *IEEE Trans. on PAS*, vol.104, no.11, November 1985, pp.3278-3297.
- [4] F.-C. Lu and Y.-Y. Hsu, "Fuzzy Dynamic Programming Approach to Reactive Power/Voltage Control in a Distribution Substation," *IEEE Trans. on Power System*, vol.12, on.2, May 1997, pp.681-688
- [5] S. Sundhararajan and A. Pahwa, "Optimal Selection of Substation of Capacitors for Radial Distribution Systems Using a Genetic Algorithm," *IEEE Trans. on power Systems*, vol.9, no.3, pp.1449-1507, August 1994.
- [6] Z. Gu and D. T. Rizy, "Neural Networks for combined Control of Capacitor Banks and Voltage Regulators in Distribution Systems," *IEEE Trans. on Power*

*Delivery*, vol.11, no.4, pp.1921-1928, October 1996.

- [7] N. I. Santoso and O. T. Tan, "Neural-Net Based Real-Time Control of Capacitors Installed on Distribution Systems," *IEEE Trans. on Power Delivery*, vol.5, no.1, pp.266-272, January 1990.
- [8] T. Kohonen, *The Self-Organizing Maps*, Berlin, Germany : Springer-Verlag, 1995.