

인공신경회로망의 LDC 변수 동적이동 능력을 이용한 실시간 ULTC 제어전략

正會員 고 윤 석*, 김 호 용*, 이 기 서**, 배 영 철**

Real-Time ULTC Control Strategy Using the Dynamic Movement Capability of LDC Variables of Artificial Neural Network

Yun-Seok Ko*, Ho-Yong Kim*, Kee-Seo Lee**, Young-Chul Bae** *Regular Members*

요 약

본 연구에서는 인공 신경 회로망을 이용하여 LDC 변수들의 값을 동적으로 변화시킴으로써 보다 개선된 전압 적정유지율을 얻을 수 있는 실시간 ULTC 제어전략이 개발된다. 제안된 전략에서는 수전전압의 변화에 따른 주 변압기 송출전압 변화를 인식하는 ANNs, 그리고 ANNs로부터의 전압레벨과 배전선로들의 시간대별 변화패턴을 인식하여, ULTC의 정정치를 동적으로 결정하는 ANNg를 도입함으로써 보다 개선된 전압보상능력을 얻을 수 있도록 하였다.

개발된 제어전략의 성능을 평가하기 위해서 8개의 피더로 구성되는 시험 배전계통에 대해서 부하가 불규칙적으로 변화하였을때, 그리고 부하가 일정한 시간대별 패턴으로 변화하였을때의 ULTC의 전압 보상 전략이 모의된다. 인공 신경회로망은 Fortran 언어로 구현되며 시험계통에 대한 성능평가에서 유용한 결과를 입증하였다.

ABSTRACT

This study develops the real time ULTC(Under Load Tap Changer) control strategy with LDC setting values moved dynamically using artificial neural networks. The suggested strategy can improve the ULTC voltage compensation capability by building 2 types of neural networks, ANNs and ANNg. ANNs recognizes the uncompensated MTr sending voltage change caused by the receiving voltage variation. And ANNg dynamically determines the most appropriate ULTC setting values by recognizing the voltage level obtained from ANNs, and

* 한국전기연구소

** 광운대학

論文番號: 95338-0929

接受日字: 1995년 9월 29일

the section load pattern for each time period.

In order to evaluate the suggested approach, the ULTC voltage compensation strategy are simulated on a 8 feeder distribution system. Artificial neural networks developed in this study are implemented in FORTRAN language on PC 386.

Key words : Artificial Neural Network, Real-Time, ULTC Control

1. 서 론

배전 시스템은 전력 시스템으로부터 송전되는 수전전압과 서로 다른 부하 특성을 갖는 선로구간 부하들의 변화에 따라 선로 상태, 즉 전압, 전류 값이 변하게 된다. 따라서 배전계통으로부터 전력을 공급받는 일반 수용가의 전압은 시간대별로 다르게 되는데 최근 고도 정밀기기의 보급 확산으로 공급전압의 질에 대한 사회적 관심과 중요성이 대두됨으로서, 일반 수용가에 적절한 전압의 전력을 공급하기 위한 많은 노력들이 요구되고 있다.

따라서 전력회사는 일반 수용가의 공급전압을 적절한 허용 범위내에서 유지함은 물론 매년 그 적정 전압 유지율을 개선하기 위해, 고/저압측 전압강하 개선 공사등을 포함한 다양한 전압관리 개선대책을 계획, 실행하고 있다. 그중에서도 ULTC(Under Load Tap Changer)제어를 통한 주 변압기 2차측 전압 제어 방식은 부하패턴의 변화에 따라 ULTC의 전압보상 능력($\pm 10\%$)을 이용하여 주 변압기 송출 전압을 제어함으로써, 일반 수용가에 공급되는 전압을 가장 경제적인 방법으로 적절하게 유지할 수 있다는 측면에서 그 중요성이 인식되고 있다.

ULTC 제어방법에는 프로그래밍 방식과 전압강하 보상법(LDC: Line Drop Compensation)을 들 수 있는데, 현재 ULTC 제어기법으로는 전압강하 보상법이 채택되고 있다. 전압강하 보상법은 전체 시간대에 가장 적절한 부하중심점과 그 위치에서의 유지전압을 결정한 다음 ULTC가 그 값들을 기준으로 시간대별로 부하전류의 변화에 따라 변화하는 부하중심점까지의 전압강하분을 보상케하여, 부하중심점의 전압이 일정하게 유지되도록 하는 방법이다. 따라서, ULTC를 최적으로 운용하기 위한 LDC 정정치 설정 방법 [1-5]들이 제안되었는데, 이들은 기존의 기계적 매카니즘에 근거하여 하나의 최적 불변 정정치를 결정하

는 방법들이다. 이 접근들은 시간대별 전압강하의 변화가 심한 경우, 경부하와 중부하의 차가 큰 경우 부적절한 전압공급 또는 허용 범위내의 전압이라도 시간대별 전압변동이 심할 수 있는데, 이 문제는 부하중심점을 동적으로 변화시킴으로서 개선될 수 있다.

따라서, 본 연구에서는, 인공 신경 회로망을 이용하여 부하중심점을 동적으로 변화시킴으로써, 전압적 정 유지율을 개선시킬 수 있는 온라인 실시간 ULTC 제어전략이 새롭게 제안된다. 제안된 전략에서는 수전전압의 변화에 따른 주 변압기 송출전압 변화를 인식하는 ANN, 그리고, ANN의 시간대별 전압레벨과 선로 부하패턴을 인식하여, ULTC의 정정치를 동적으로 결정하는 ANN을 도입함으로써, 보다 개선된 ULTC 전압 보상 능력을 얻을 수 있도록 하였다.

개발된 제어전략의 성능을 평가하기 위해서 8개의 피더로 구성되는 시험 배전계통에 대해서 부하가 불규칙적으로 변화하였을때, 그리고 부하가 일정한 시




그림 1. 3층 전향 퍼셉트론 인공 신경 회로망의 구조
Fig. 1 Structure of the three layer feederforward perceptron

간대별 패턴으로 변화하였을때의 ULTC의 전압 보상 전략이 모의된다. 인공 신경 회로망은 Fortran 언어로 구현되며 성능 평가는 PC 386상에서 모의된다.

II. 인공신경회로망(Artificial Neural Network)

지금까지 수개의 인공신경회로망 모델이 발표되었는데[12-13], 그 중 다층 전향 퍼셉트론(multi-layer feedforward machine)은 아날로그/이진 입력처리 능력을 가질뿐만 아니라 은둔 층을 이용하여 복잡하고 극히 비선형적인 입출력간의 관계를 맵핑할 수 있는 능력을 가진다.[6-11]

그림 1은 대표적인 3층 전향 퍼셉트론의 구조를 보인다. 인공신경회로망에 대한 학습과정은 2 단계로 구성된다. 첫번째 단계에서는 입력 패턴의 전향전파 과정이 실행된다. 층 j의 각 유니트들은 식 (1)과 같이 가중된 패턴을 입력으로 받는다.

$$net_j = \sum_{i \in S_j} w_{ji} o_i \quad (1)$$

여기서, S_j 는 패턴들이 다음 층 유니트 j로 전송되는 모든 입력 층 유니트들의 집합이며, w_{ji} 는 입력 층 유니트 i와 다음 층 유니트 j간의 연결부 가중치(weights)이다. 그리고 o_i 유니트 i의 출력을 의미한다. 이때, 유니트 j의 출력은 식 (2)로 표시된다.

$$o_j = f_j(net_j) \quad (2)$$

여기서 f_j 는 유니트 j의 활성화 함수(activation function)이다. 활성화 함수는 일반적으로 비선형적인 맵핑을 위해서는 식 (3)의 S형(sigmoid) 함수를 사용한다.

$$o_j = \frac{1}{1 + \exp\left\{-\left(\sum_{i \in S_j} w_{ji} o_i + \theta_j\right)\right\}} \quad (3)$$

식 (1)에서 (3)의 입력패턴 전향전파 과정을 통해 얻어진 실제출력과 기대출력을 비교하여 허용오차를 초과하는 경우, 두번째 단계로써 EBP 알고리즘을 이용하여 제공되는 p개의 패턴들에 대한 총 오차함수, 식 (14)가 최소화가 되도록 연결부 가중치들과 결정소(thresholds)를 조정한다.

$$Err = (1/2) \sum_{p=1}^P \sum_j (t_{pj} - o_{pj})^2 \quad (4)$$

여기서 t_{pj} , o_{pj} 는 패턴 p에 대한 기대출력과 실제출력이다. 이때, 연결부 가중치들은 식 (5)에 비례하여 변화된다.

$$\Delta w_{ji}^{(n)} = \eta \delta_{pj} o_{pi} \quad (5)$$

여기서 n은 반복 회수이며, η 은 학습률(learning rate)이다. 출력 층의 한 유니트에 대한 에러신호는 식 (6)으로 표시할 수 있다.

$$\delta_{pj} = (t_{pj} - o_{pj}) o_{pj}(1 - o_{pj}) \quad (6)$$

반면에, 은둔 층의 유니트들 j에 대한 에러신호들은 식 (7)로 표시된다.

$$\delta_{pj} = o_{pj}(1 - o_{pj}) \sum_k \delta_{pk} w_{kj} \quad (7)$$

여기서 유니트 j의 활성화 함수의 도함수 $f'_j(net_{pj})$ 는 $o_{pj}(1 - o_{pj})$ 로 표시된다. 학습과정에서 반복적으로 조정되는 연결부 가중치들은 식 (8)로 표시할 수 있다.

$$w_{ji}^{(n+1)} = w_{ji}^{(n)} + \Delta w_{ji}(n) \quad (8)$$

식 (5)는 모멘텀 항을 추가함으로서 식 (9)로 표시된다.

$$\Delta w_{ji}^{(n)} = \eta \delta_{pj} o_{pi} + \alpha \Delta w_{ji}^{(n+1)} \quad (9)$$

인공 신경회로망의 가중치들은 식 (1)에서 식 (8)로 표시되는 2 단계 학습과정을 반복 적용함으로써, Err이 최소화되도록 조정된다. 학습과정에서, Err의 로컬 미니멈 수렴문제는 이득 항(gain term)의 값을 낮추거나, 가중치들의 초기치를 재 설정함으로써 해결할 수 있다. 바이어스(bias) θ_j 는 단위출력을 전송하도록 설계되며, 학습률 η 와 모멘텀 인수 α 는 0에서 1사이에서 경험적으로 결정된다. 그리고, 학습초기에 요구되는 가중치와 결정소 값들은 0에서 1 사이에서 무작위로 결정한다.

Ⅲ. 기존의 ULTC 운용기법

현재, 일반 수용가의 전압을 허용범위내($110 \pm 6V$)에서 유지되도록 하기 위해 가장 직접적이고 효율적인 방법은 ULTC를 이용하여 부하상태에 따라 전압강하를 보상하는 전압강하 보상법이다. 전압강하 보상법은 전체 시간대에 가장 적절한 부하 중심점(U_s : 부하 중심점까지의 저항, U_r : 부하중심점까지의 리액턴스)과 그 위치에서의 유지전압(V_o)을 결정한 다음 ULTC가 그 값들을 기준으로 $\pm 10\%$ 의 전압보상능력 이용하여 시간대별로 부하전류의 변화에 따라 변화하는 부하 중심점까지의 전압강하분을 보상케 하여, 부하중심점의 전압이 일정하게 유지되도록 하는 방법이다. 이 방법에서, LDC 정정치들은 모든 시간대에 대해서 일반 수용가에 전압변동이 적고 허용범위내에 속하는 전압이 공급되도록 최적하게 결정되어야 한다.

LDC 정정치는 전압강하 해석법과 실측 데이터 이용법 의해서 결정될 수 있다. 전압강하 해석법은 선로상에서 최대전압강하/2의 지점을 부하중심점으로 하고 정격전압이 유지되도록 하는 방법이다.

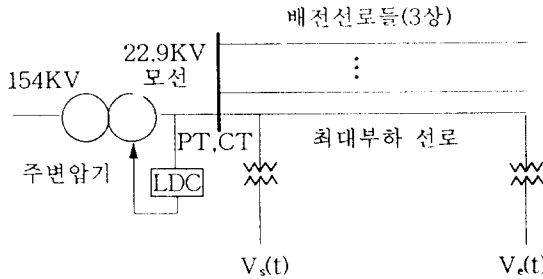


그림 2 전압강하 보상법에 의한 ULTC 제어모
Fig. 2 Digram for ULTC control using line drop compensation

반면에, 실측 데이터 이용방법은 그림 2에 보인바와 같이, 실측된 $V_s(t)$, $V_r(t)$, 그리고 $I(t)$ 를 이용하여 정정치를 결정함으로써 $V_s(t)$ 를 116[V]보다 낮게 그리고 $V_r(t)$ 를 104[V]보다 높게 유지되도록 하는 방법이다. 여기서, $V_s(t)$ 는 선로 인출부의 주상 변압기 2차측 직하 수용가, $V_r(t)$ 는 선로 말단부의 주상 변압기 2차

측 말단 수용가 공급전압, 그리고 $I(t)$ 는 주변압기 부하전류를 나타낸다. 실측 데이터들로부터 최적 ULTC 정정치들을 얻는 방법은 다음과 같다.[5]

먼저, 그림 2에서 가장 심각한 부하조건을 가지는 배전선로를 선택한다. 그리고, $V_s(t)$ 와 $V_r(t)$ 를 근거로 하여 최적 송출전압 $V_{OPT}(t)$ 를 결정하기 위해, 식 (10)과 같이 $V_r(t)$ 를 $V_s(t)$ 측으로 환산하여 하한 경계치 전압을 계산한다.

$$V_s(t)_u = V_{max}$$

$$V_s(t)_l = V_{min} V_s(t) / V_r(t) \quad (10)$$

여기서 $V_s(t)_u$, $V_r(t)_l$ 는 각각 허용전압 상한치와 하한치를 직하전압으로 환산한 값을 나타내며, V_{max} 와 V_{min} 는 각각 허용전압 상한치와 하한치를 의미한다. 따라서, 최적전압 보상율은 식 (11)로 표시된 $G(t)$ 를 최소화하는 문제로 표시된다.

$$G(t) = \left\{ V_s(t)_u - V_s(t) \cdot \frac{X_{TAP}}{R_{TAP}} \right\}^2$$

$$+ \left\{ V_s(t) \cdot \frac{X_{MTR}}{R_{TAP}} - V_s(t)_l \right\}^2 \quad (11)$$

여기서 $G(t)$ 는 시각 t에서의 평가함수, R_{TAP} 는 시각 t에서의 ULTC에 의한 전압 보상률, X_{TAP} 는 1 + ULTC에 의한 최적전압 보상율을 나타낸다. 따라서, X_{TAP} 은 식 (11)을 미분하여 식 (12)와 같이 얻을 수 있다.

$$X_{TAP} = \frac{R_{TAP} (V_s(t)_u + V_s(t)_l)}{2V_s(t)} \quad (12)$$

따라서, 최적 송출전압, $V_{OPT}(t)$ 는 $X_{TAP} \cdot V_s(t)$ 로써 얻을 수 있기 때문에, 식(13)으로 표시된 전압 보상 관계식에서, 부하전류 $I(t)$ 의 변화에 따라 $V_{OPT}(t)$ 와의 편차가 최소가 되도록 V_o 와 Z 를 결정하면 된다. 이때 편차는 실측 데이터 수가 n인 경우 식 (14)로 표시될 수 있다.

$$V_{OPT}(t) = V_o + Z \cdot I(t) \quad (13)$$

여기서, 부하 중심점까지의 임피던스 Z 는 부하전류 비례상수($U_r + jU_s$)를 의미한다.

$$G = \sum_{i=0}^n [V_{OPT}(k) - (V_o + Z \cdot I(k))]^2 \quad (14)$$

따라서, 식 (14)를 최소화하는 V_o 와 Z 는 $\partial G/\partial V_o$, $\partial G/\partial Z$ 를 통해서 식 (15)와 (16)과 같이 얻을 수 있다.

$$Z = \frac{\sum_k V_{OPT}(k) \sum_k I(k) - n \sum_k I(k) V_{OPT}(k)}{(\sum_k I(k))^2 - n \sum_k I(k)^2} \quad (15)$$

$$V_o = \frac{\sum_k I(k) \sum_k V_{OPT}(k) - Z \sum_k I(k)^2}{\sum_k I(k)} \quad (16)$$

일단, 식 (15), (16)에 의해 V_o 와 Z 가 결정되면, LDC 정정치들은 PT, CT비를 고려하여 계산되는데, $V_{LDCo} = V_o/N_n$ 으로 계산되며 U_r , U_x 는 식 (17),(18)에 의해 얻어진다.

$$U_r = \frac{ZN_m/N_n}{(\%x/\%r)\sin \theta + \cos \theta} \quad (17)$$

$$U_x = \frac{ZN_m/N_n}{\sin \theta + (\%x/\%r)\cos \theta} \quad (18)$$

여기서, N_n 는 전압비(주 변압기 직하전압/PT 2차 전압), N_m 는 전류비(주 변압기 부하전류/CT 2차 전류), θ 는 부하 역률각, 그리고, $\%r$, $\%x$ 는 배전선로의 단위길이당 퍼센트 저항과 리액턴스이다.

IV. 인공 신경회로망의 설계

4.1 ULTC 정정치 결정 구조

먼저, 인공신경회로망 ANN_g 가 수전전압, V_{RES} 로부터 ULTC에 의해서 보상되지 않은 주변압기 송출전압 레벨 V_q 를 결정한다. 다음, n 개의 ANN_g 는 ANN_g 로부터의 송출전압 레벨 V_q 와 주변압기 전류 I 그리고 각 선로들로부터 유효전력 $\{P_1, \dots, P_g\}$, 무효전력 $\{Q_1, \dots, Q_g\}$ 를 제공받아 현재의 부하패턴과 학습된 지식에 근거하여 출력신호를 전송한다. 다음, 최대 출력신호를 가지는 유니트의 임피던스 값을 부하중심점 임피던스로 결정한다. 다음, 식 (18-19)로부터 ULTC의 세팅치 U_r' , U_x' 를 결정한다. ULTC는 일단 U_r' , U_x' 가 정정되면 전압강하분, $V_d = I(U_r' + jU_x')$ 을 보




그림 3 인공 신경회로망을 이용한 ULTC 정정치 결정 구조
Fig. 3 Decision structure of ULTC setting values using ANN

상하기 위해, 자동적으로 탭을 변경하게 된다.

여기서, ANN_{gq} 는 전압레벨 V_q 를 입력으로 하는 ANN_g 이다.

4.2 송출전압레벨 결정

일반적으로, 송전전압의 변화는 $\pm 5\%$ 로 제한되므로, 이 제약범위내에서 전압레벨을 구분할 수 있도록 설계되어야 한다. 만약 q 개의 레벨로 구분한 경우 ANN_g 는 q 개의 출력 유니트를 가지도록 설계되는데, 실제 수전전압이 입력되었을때, 입력전압에 가장 유사한 전압레벨에 해당하는 출력 유니트가 1을 그리고 나머지 출력 유니트가 0을 출력하도록 한다.

4.3 부하 중심점 결정

배전 시스템의 일반 수용가 전압은 변전소 수전전압의 변화는 물론 배전계통의 구간부하 변화에 영향을 받는다.

즉, 배전선 부하의 변화에 따라 선로 전압강하가 변화하여 일반 수용가 전압이 변하게 된다.

따라서, 수전전압 변화를 반영하기 위해 q 개의 인공신경회로망들의 그룹 ANN_g 가 설계된다. 그리고

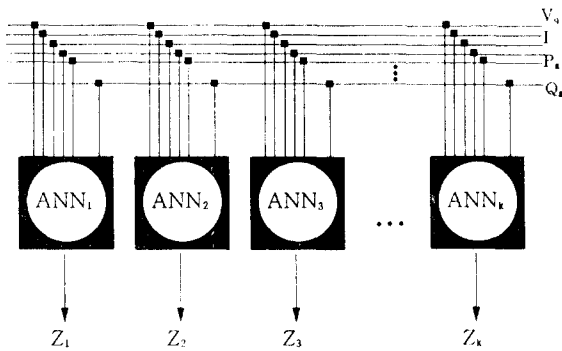


그림 4 부하중심점 결정을 위한 인공 신경회로망
Fig. 4 Artificial neural net. for load center decision

각 ANN_g는 배전 시스템의 부하변화에 따른 전압변화를 반영할 수 있도록 하기위해, q개의 소속 배전선로들의 I, P₁, Q₁, ..., P_g, Q_g를 입력요소로 하여, 적절한 부하중심점에 해당하는 임피던스 Z₁...Z_k를 결정하는 k개의 인공신경회로망으로 구성된다. 이때 k는 최대 임피던스를 근거로 임피던스의 변화를 적절하게 반영할 수 있도록 결정한다. 그림 4는 부하중심점 결정을 위한 인공신경회로망들의 그룹 ANN_{gk}를 보인다. 따라서 만약 임피던스의 값을 k개로 구분한 경우 출력 유니트는 k개로 구성되며 각 인공신경회로망들은 주어진 부하 패턴에 가장 유사한 부하패턴에 해당하는 출력유니트에서 최대신호가 출력함으로써 크기비교를 통해 부하 임피던스를 결정하게 된다.

4.4 교육자료 구축(Training Set Build-Up)

인공 신경 회로망의 교육자료는 학습이 가능한 범위내에서 비교적 적절한 인식능력을 가질 수 있도록, 구간부하의 유형과과 크기를 적절하게 구분해야 한다. 만약, 부하유형과 부하크기 레벨을 각각 W, P로 구분하면 ANN_g의 교육패턴수는 P^W이다. ANN_g에 대한 교육자료 계산 절차는 다음과 같다.

단계 1) 총 q * P^W개의 부하레벨 조합을 시간대별 부하 변화로 가정하며, 각 부하레벨에 대해 조류계산을 실행하여 I, P₁, Q₁, ..., P_g, Q_g, V_s, V_c, 시간대별 V_{OPT}를 계산한다.

단계 2) 기존 최적 ULTC 정정치 선정 기법을 이용하여, 단계 1)에서 계산된 결과를 근거로하여 V_s를 선정

한다.

단계 3) V_{OPT}와 V_s를 입력으로 하여 q * P^W 개의 부하 패턴에 대한 Z를 계산한다.

단계 4) 단계 3)에서 얻어진 Z를 근거로 최대치와 최소치 범위내에서 적절하게 ULTC 정정치가 결정될 수 있도록 k개로 구분한다.

단계 5) 단계 1)에서 얻어지는 값들을 입력 패턴으로 그리고 단계 4)에서 얻어지는 값을 출력패턴으로하는 지식패턴을 구성한다. 이때, 지식패턴들은 ANN_{g1}, ..., ANN_{gk}를 위해 전압레벨에 따라 q개의 교육자료로 구성된다.

V. 설계경험및 평가

그림 5는 인공 신경회로망을 이용한 제어전략의 성능을 평가하기 위한 시험계통을 보인다. 일반적으로, 배전계통은 4-8개의 피더들로 구성된다. 시험계통은 설계의 복잡성을 모의하기 위해 8개의 피더로 구성된다. 배전 시스템은 고압선에서 5%의 전압강하를 허용한다. 따라서 배전선로의 공장이 길어 5%의 전압강하를 초과하는 경우, 5% 초과지점에 해당하는 지역은 주상변압기 탭의 위치를 한단계 내려 5%의 전압을 보상하게 된다.




그림 5 성능평가를 위한 시험 배전 시스템
Fig. 5 Test distribution system for performance evaluation

따라서 V_c(t)는 주상변압기 탭을 달리 사용하는 지역 V_s(t)의 수 만큼 고려될 수 있는데, 배전선로 1, 3,

6, 8상에는 이러한 관점을 고려하기 위해서 2개의 V_e (t)가 설계된다. 표 1은 시험계통에 대한 데이터를 표시한다. 부하타입에서 R은 주거용 C는 상업용 그리고 I는 산업용을 의미한다.

표 1. 시험 배전 시스템의 데이터
Table 1 Distribution system data for test

Feeder Number	From Bus	To Bus	Impedance R(Ω /Km)	X(Ω /Km)	Load Km	Type	P[MW]	Peak Q[MVAR]
1	0	1	0.20242	0.38911	0.55	R	0.78	0.22
1	1	2	0.20242	0.38911	2.75	R	0.75	0.37
1	2	3	0.20242	0.38911	4.16	C	0.65	0.25
1	3	4	0.20242	0.38911	3.56	C	0.76	0.22
1	4	5	0.20242	0.38911	4.15	C	0.54	0.26
1	5	6	0.20242	0.38911	3.88	I	0.65	0.38
1	6	7	0.20242	0.38911	3.90	I	0.45	0.15
1	7	8	0.20242	0.38911	4.14	I	0.55	0.26
2	0	9	0.20242	0.38911	0.55	I	1.22	0.29
3	0	10	0.20242	0.38911	0.55	R	0.65	0.28
3	10	11	0.20242	0.38911	3.75	R	0.78	0.29
3	11	12	0.20242	0.38911	3.45	R	1.45	0.37
3	12	13	0.20242	0.38911	2.85	R	1.08	0.25
3	13	14	0.20242	0.38911	3.25	R	0.75	0.32
3	14	15	0.20242	0.38911	3.56	R	0.75	0.25
3	15	16	0.20242	0.38911	3.78	R	1.25	0.45
4	0	17	0.20242	0.38911	0.55	I	1.10	0.22
4	17	18	0.20242	0.38911	3.35	I	1.32	0.11
4	18	19	0.20242	0.38911	4.20	I	0.65	0.28
4	19	20	0.20242	0.38911	4.45	I	0.85	0.18
4	20	21	0.20242	0.38911	3.55	I	0.44	0.16
4	21	22	0.20242	0.38911	3.45	I	0.96	0.29
5	0	23	0.20242	0.38911	0.55	C	1.25	0.35
5	23	24	0.20242	0.38911	2.25	C	0.98	0.19
5	24	25	0.20242	0.38911	3.15	C	0.45	0.17
5	25	26	0.20242	0.38911	3.25	C	0.88	0.25
5	26	27	0.20242	0.38911	2.55	C	1.10	0.42
6	0	28	0.20242	0.38911	0.65	C	0.65	0.17
6	28	29	0.20242	0.38911	2.45	C	0.86	0.15
6	29	30	0.20242	0.38911	2.15	C	1.45	0.42
6	30	31	0.20242	0.38911	2.55	I	0.65	0.22
6	31	32	0.20242	0.38911	3.10	I	0.65	0.28
6	32	33	0.20242	0.38911	2.25	R	1.30	0.38
6	33	34	0.20242	0.38911	1.78	R	0.64	0.25
6	34	35	0.20242	0.38911	1.85	R	0.85	0.27
7	0	36	0.20242	0.38911	0.45	I	1.42	0.58
7	36	37	0.20242	0.38911	1.75	I	0.58	0.29
7	37	38	0.20242	0.38911	3.15	C	0.82	0.37
7	38	39	0.20242	0.38911	3.45	C	1.08	0.35
7	39	40	0.20242	0.38911	2.55	R	0.68	0.22
7	40	41	0.20242	0.38911	2.65	R	0.75	0.27
8	0	42	0.20242	0.38911	0.56	R	0.98	0.25
8	42	43	0.20242	0.38911	2.75	R	0.45	0.15
8	43	44	0.20242	0.38911	2.16	I	1.28	0.36
8	44	45	0.20242	0.38911	1.85	I	0.65	0.28
8	45	46	0.20242	0.38911	1.95	C	1.10	0.38
8	46	47	0.20242	0.38911	2.85	C	0.54	0.36
8	47	48	0.20242	0.38911	2.25	C	0.45	0.12

5.1 인공 신경회로망 구조 설계

먼저, ANNs가 설계된다. 주 변압기 송출전압 레벨은 154[KV] 수전전압의 $\pm 5\%$ 허용범위를 적절하기 나타낼 수 있도록 22.9[KV] 기준 전압을 근거로 0.955, 0.930, 0.915, 1, 1.015, 1.030, 1.045로 표시되는 7개의 전압레벨로 구분된다. 그리고 입력 유니트 2개, 히든 유니트 10개, 출력 유니트 7(전압레벨들 수)의 구조로 설계된다. ANN_g의 학습은 약 1000번 내외의 반복작

업(presentation)이 요구되었으며, 학습율 α 와 모멘텀 값 η 는 0.3과 0.5이다. Err은 부하 중심점 임피던스에 대한 식 (4)의 값을 의미한다.




그림 6 ANN_g의 학습에러 곡선
Fig. 6 Learning error curve of ANN_g

다음, ANN_g가 ANN_h의 출력 유니트 수 만큼(q개) 설계된다. 부하유형 수 W=3, 부하크기 레벨 수 P=3으로 함으로써 q개의 인공 신경회로망 그룹들에 대한 교육자료는 각각 4³=64개로 구성된다. 먼저, 4.4 설계절차에 의해, V₀=116.43이 계산되며, 다음으로, V₀를 근거로 q개의 교육자료가 작성된다. 그림 6은 ANN_g중 하나의 인공 신경회로망에 대한 학습과정에서 보인 에러 변화를 보인다.

ANN_g의 입력 유니트는 시험계통이 8개의 피더로 구성되기 때문에 I를 포함한 17개의 입력요소수와 동일한 수 즉, 17개가 설계된다. 그리고 은둔 층 유니트는 28개로 결정되며, 출력 유니트는 8개로 설계된다. ANN_g의 학습은 학습율 0.1과 모멘텀 값 0.25를 가지고 약 32000번의 반복작업(presentation)이 요구되었다.

5.2 평가 결과

설계된 인공 신경회로망을 이용한 제어전략의 성능을 평가하기 위해서 시험 배전계통에 대해 2개의 경우가 모의된다. 시험 배전 시스템에서, 기준 수전전압과 주변압기 송출전압은 각각 154[KV], 22.9[KV]이다. PT의 전압비는 154[KV]전압에서 110/154, 그리고 22.9[KV] 레벨에서 110/22.9이다. 또한 CT의 전류비는 5/2000이다.

일반적으로 구간부하는 일정한 패턴을 가지지만 갑작스러운 온도변화와 같은 환경변화등으로 인해 급격한 패턴의 변화를 보일 수 있다. 따라서, 이러한 갑작스러운 부하패턴의 가혹한 변화에 대한 적응능력을 검증하기 위해, 먼저 3개의 부하타입 즉, 주거용, 상업용 그리고 상업용 부하가 일정한 형태를 가지지 않고 피크치를 근거로 10에서 110[%]의 범위내에서 무작위적으로 변한다는 가정하에서 평가를 모의하였다. 그림 7에서 ◆는 이 경우에 대한 인공 신경 회로망들의 응답을 보인다.




그림 7 인공 신경회로망의 응답
Fig. 7 Response of artificial neural net.

그리고 그림 8은 ULTC에 의해서 보상되지 않은 $V_s(t)$, $V_e(t)$ 를 보이는데, 저전압 한계보다 낮은 부정적 전압이 공급됨을 알 수 있다.




그림 8 ULTC에 의해 보상되지 않은 $V_s(t)$ 과 $V_e(t)$
Fig. 8 $V_s(t)$ and $V_e(t)$ uncompensated by ULTC




그림 9 ULTC의 정정치를 고정시켰을때의 $V_s(t)$, $V_e(t)$
Fig. 9 $V_s(t)$, $V_e(t)$ compensated by ULTC with fixed setting values




그림 10 ULTC의 정정치를 동적으로 변화시켰을때의 $V_s(t)$, $V_e(t)$
Fig. 10 $V_s(t)$, $V_e(t)$ compensated by ULTC with dynamic setting values

그림 9는 기존의 방법 즉, ULTC의 정정치를 최적 위치에 놓고 변화시키지 않았을때를 그리고 그림 10은 제안된 인공 신경회로망에 의해서 부하패턴의 변화에 따라 ULTC 정정치를 동적으로 이동하였을때의 결과를 보인다.

다음은 3개의 부하 타입이 시간대별 부하 특성 곡선에 따라 변화하였을때의 모의 결과를 그림 11-13에 보인다. 그림 7에서 ■는 이 경우에 대한 인공 신경회로망의 응답을 보인다. 그림 11은 ULTC에 의해서 보

상되지 않은 수용가 전압 $V_s(t)$ 와 $V_c(t)$ 를 보이는데, 저전압 한계보다 낮은 부적정 전압이 공급됨을 알 수 있다. 그림 12는 기존의 방법 즉, ULTC의 정정치를 최적위치에 놓고 변화시키지 않았을때를 그리고 그림 13은 제안된 인공 신경 회로망에 의해서 부하패턴의 변화에 따라 ULTC 정정치를 동적으로 이동하였을때의 결과를 보인다.




그림 11 ULTC에 의해 보상되지 않은 $V_s(t)$ 과 $V_c(t)$
Fig. 11 $V_s(t)$ and $V_c(t)$ uncompensated by ULTC




그림 12 ULTC의 정정치를 고정시켰을때의 $V_s(t)$, $V_c(t)$
Fig. 12 $V_s(t)$, $V_c(t)$ compensated by ULTC with fixed setting values




그림 13 ULTC의 정정치를 동적으로 변화시켰을때의 $V_s(t)$, $V_c(t)$
Fig. 13 $V_s(t)$, $V_c(t)$ compensated by ULTC with dynamic setting values

그림에서 V_{max} , V_{min} 은 허용전압의 상한치와 하한치를 보인다. 그림 9는 수개의 시간대에서 부적정 전압 즉, 허용전압의 하한치를 초과함을 보인다. 그림 10과 그림 13은 그림 9와 그림 12에 비해 수용가 말단 전압이 훨씬 개선되었으며, 전압 변동도 적음을 보인다. 특히, 그림 9, 그림 13의 고정된 ULTC 정정치를 근거로 한 실험에서 72시간 동안 ULTC가 각각 46번과 21번, 반면에 그림 10, 그림 12의 인공 신경회로망을 이용한 동적 정정치를 근거로 한 실험에서 ULTC가 각각 45번, 24번의 동작횟수를 보임으로써 ULTC의 동작회수는 거의 동일한 수준임을 알 수 있다.

따라서 기존의 방법에 근거한 하나의 불변 최적 정정치를 근거로한 방법(그림 9와 그림 12)에 비해 본 연구에서 제안된 인공신경 회로망을 이용한 ULTC 정정치 동적 보상 제어 전략(그림 10과 그림 13)이 ULTC의 전압 보상 능력을 개선시키며, 수용가 말단의 전압 변동도 줄일 수 있음을 알 수 있다.

V. 결 론

본 연구에서는 인공 신경 회로망을 이용하여 LDC 변수들의 값을 동적으로 변화시킴으로써 보다 개선된 전압 적정유지율을 얻을 수 있는 실시간 ULTC 제어전략이 개발되었다. 주 변압기 송출 전압레벨 결정 그리고 ULTC 정정치 결정을 위한 인공 신경회로망

들이 별도로 설계됨으로서 수전단 전압의 변화는 물론 주변압기 부하 변화에 따라 ULTC 정정치가 적절하게 동적으로 결정되도록 하였다.

주 변압기 송출 전압의 레벨을 7개로 구분하여 전압 변화에 대한 정정치 변화가 고려되도록 하였다. 또한 배전계통 부하타임을 3개로, 각 구간부하의 크기를 4개로 함으로서, 비교적 학습이 가능한 범위내에서 인공 신경 회로망들이 적절한 인식 능력을 가질 수 있도록 7개의 개별 교육자료에 대해 패턴의 수를 $4^3 = 64$ 개로 제한하였다.

제안된 접근의 가능성을 평가하기 위해 하나의 시험계통에 대해 2개의 경우가 모의되었다. 평가 결과를 통해, 3개 타입의 부하가 정해진 부하 패턴으로 변화하였을 때는 물론 불규칙하게 변화하였을 때에도 보다 개선된 그리고 전압 변동이 적은 수송가 전압을 보임으로서 제안된 접근의 유용성을 입증하였다.

참 고 문 헌

1. I. R. E. A. "Voltage Regulator Application on Rural Distribution Systems," REA Bulletin 169-27, January 1973.
2. C. S. Chan, "The Effect of Voltage Control Distribution System(Ph. D. Dissertation," The University of Texas at Arlington, May 1982).
3. A. Baitch and R. A. Barr, "A Tapping Range and Voltage Level Analysis Chart for Tap Changing Transformers," IEEE Trans. Vol. PAS-104, No. 11, pp 3269-3277, November 1985.
4. 배전전압 관리개선을 위한 전압조정장치의 최적 응용연구, 한전연구소보, 1985
5. H. Kim and D. Rho "A Study on the Optimal Operation Method of Voltage Regulator at Distribution Substation," 1989 IFAC Symposium on Power Plant Control, pp. 145-149, 1989.
6. D. J. Sobajic and Yoh-Han Pao, "Artificial Neural-Net Based Dynamic Security Assessment for Electric Power Systems," IEEE Trans. on Power Systems, Vol. 4, No. 1, pp 220-228, February 1989.
7. S. Ebron, D. L. Lubkeman, and M. White, "A Neural Network Approach to the Detection of Incipient Faults on Power Distribution Feeders," IEEE PES Transmission and Distribution Conference, New Orleans, Louisiana, Paper No. 89, TD 377-3 PWRD, April 2-7, 1989.
8. 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.
9. R. K. Hartana and G. G. Richards, "Harmonic Source monitoring and Identification using Neural Networks," IEEE Rans. Power Systems, Vol. 5, No. 1, pp. 1098-1104, November 1990.
10. E. H. P. Chan. "Using Neural Networks to Interpret Multiple Alarms," IEEE Computer Applications in Power, pp. 33-37, April 1990.
11. H. Kim, Y. Ko and K. H. Jung. "Artificial Neural Network based Feeder Reconfiguration for Loss Reduction in Distribution Systems," IEEE PWRD SM-92, Aug. 1992.
12. D. E. Rumelhart, G. E Hinton and R. J. Williams, "Learning internal representations by error propagation," in D. E. Rumelhart and J. L. McClelland(Eds.) Parallel Distributed Processing: Exploration in The Microstructure of Cognition, Vol. 1: Foundations, MIT Press, 1987.
13. R. P. Lippmann, "An introduction to computing with neural Nets," in V. Vemuri(Ed.), Artificial Neural Networks:Theoretical Concepts, IEEE Computer Society, 1988.

고 윤 석(Yun-Seok Ko) 정회원

1965년 2월 10일생

1984년 2월: 광운대학교 공과대학 전기공학과 졸업 (공학사)

1986년 2월: 광운대학교 공과대학 전기공학과 졸업 (공학석사)

1996년 2월: 광운대학교 공과대학 전기공학과 졸업 (공학박사)

1986년 2월~현재: 한국전기연구소 KODAS 사업팀 선임연구원



김 호 영(Ho-Yong Kim) 정회원

1952년 9월 1일생

1979년 2월: 서울대 공과대학교
전기공학과 졸업(공학사)

1985년 2월: 텍사스 오스틴대 전기공학과 졸업(공학박사)

1986년 2월~현재: 한국전기연구소 KODAS 사업팀
책임연구원

이 기 서(Kee-Seo Lee) 정회원

1951년 1월 18일생

1977년 2월: 연세대학교 공과대학 전기공학과 졸업
(공학사)

1979년 2월: 연세대학교 공과대학 전기공학과 졸업
(공학석사)

1986년 2월: 연세대학교 공과대학 전기공학과 졸업
(공학박사)

1988년~1989년: Yale University 교환교수

1981년~현재: 광운대학교 제어계측공학과 교수

배 영 철(Young-Chul Bae)

정회원

1995년 11월호 참조