

기둥축소량 보정을 위한 기둥의 최적그룹핑기법

The Optimal Column Grouping Technique for the Compensation of Column Shortening

김 영 민*
Kim, Yeong-Min

요 지

본 논문에서는 기둥축소량 보정의 효율성을 증진시키기 위한 방안으로서 유사한 축소 경향을 보이는 기둥들을 동일 그룹으로 묶는 기둥의 최적그룹핑기법에 대하여 연구하였다. 기둥의 최적그룹핑은 무감독학습에 의해 입력데이터의 패턴을 스스로 분류할 수 있는 코호넨의 자기조직화 형상지도 알고리즘을 이용하였다. 본 연구에 적용된 코호넨 네트워크는 두 개의 입력뉴런과 분류할 기둥그룹 개수만큼의 출력뉴런으로 구성된다. 입력뉴런에는 기둥축소량의 정규화된 평균과 표준편차가 입력되며, 출력뉴런에는 각 기둥이 속하게 될 기둥그룹이 출력된다. 제안된 알고리즘을 실제 축소량 해석이 수행된 두 개의 건물에 적용하여 그 적용성을 평가하였다. 적용결과 동일 그룹으로 분류된 기둥들은 서로 인접하고 있으며 서로 다른 기둥그룹끼리는 교차하지 않는 등 유사한 축소 경향을 보였다. 이로부터 본 연구의 기둥축소량의 최적그룹핑 알고리즘은 충분한 실무적용성이 있음을 확인하였다.

핵심용어 : 기둥축소량, 기둥의 최적그룹핑, 코호넨 네트워크, 자기조직화 형상지도 알고리즘

Abstract

This study presents the optimal grouping technique of columns which groups together columns of similar shortening trends to improve the efficiency of column shortening compensation. Here, Kohonen's self-organizing feature map which can classify patterns of input data by itself with unsupervised learning was used as the optimal grouping algorithm. The Kohonen network applied in this study is composed of two input neurons and variable output neurons, here the number of output neuron is equal to the column groups to be classified. In input neurons the normalized mean and standard deviation of shortening of each columns are inputted and in the output neurons the classified column groups are presented. The applicability of the proposed algorithm was evaluated by applying it to the two buildings where column shortening analyses had already been performed. The proposed algorithm was able to classify columns with similar shortening trends as one group, and from this we were able to ascertain the field-applicability of the proposed algorithm as the optimal grouping of column shortening.

Keywords : column shortening, optimal column grouping, Kohonen network, self-organizing feature map

1. 서 론

건물이 고층화될수록 저층 건물에서는 크게 문제되지 않았던 사용성의 영향이 증대한다. 이 중 기둥축소량은 진동에 의한 가속도의 영향(이상현, 2007; 조강표 등, 2007)과 더불어 초고층 건물을 설계함에 있어서 반드시 해결해야 할 선결요건 중의 하나가 되고 있다.

기둥축소량은 크게 탄성축소량과 비탄성축소량으로 구성되

는데, 구조 및 사용성 관점에서 문제가 되는 부분은 축소량 그 자체가 아니라 기둥간의 축소량 차이에 의한 부등축소량이다. 이 중 슬래브를 타설하기 이전에 발생하는 축소량은 시공과정에서 어느 정도 보정할 수 있지만, 슬래브 타설 이후의 추가하중과 비탄성축소에 의해 발생하는 축소량은 시공 이후에는 보정이 어려우므로 미리 그 값을 예측하여 보정을 해야 한다.

기둥축소량의 보정은 시공단계와 작용하중, 그리고 재료의

* 책임저자, 정회원 · 명지대학교 건축학부 조교수
Tel: 031-330-6490 ; Fax: 031-330-6487
E-mail: ymkim@mju.ac.kr

• 이 논문에 대한 토론을 2011년 6월 30일까지 본 학회에 보내주시면 2011년 8월호에 그 결과를 게재하겠습니다.

물성치를 이용하여 기동의 예측되는 축소량을 해석적으로 구하고 이를 바탕으로 성능 및 시공상의 제약조건을 만족하도록 최적의 보정량을 산정해야 한다. 각 기동들은 작용하중과 단면크기 및 시공이력이 다르므로 예측되는 축소량과 필요한 보정량이 각각 다르다. 각 기동마다 층별로 보정하는 것이 부동축소량을 최소화할 수 있는 가장 이상적인 방법이지만, 시공성을 감안하여 구조 및 사용상 문제가 없는 범위에서 최대한 보정을 단순화 할 필요가 있다. 즉, 평면상으로는 축소량이 비슷한 기동들을 하나의 그룹으로 묶고, 여러 층에서 발생하는 누적축소량을 특정 층에서 보정할 필요가 있다(김영민, 2008).

기동축소량 보정에 대한 기존의 연구는 두 개의 기동그룹에 대한 연구(Park, 2003)와 세 개 이상의 기동그룹에 대한 연구(김영민, 2008)가 대표적이다. 이들 연구에서는 최적화기법을 이용하여 각 기동그룹에 대한 최적의 보정위치와 이때의 보정량을 산출하였다. 그러나 이들 연구에서는 미리 정해진 기동그룹에 대한 최적의 보정위치와 보정량을 산출하는데 중점을 두었으며, 이의 선행과정으로서 요구되는 기동그룹을 어떻게 구성하는가에 대한 연구는 이루어지지 않았다. 다만 기동축소량 보정의 효율을 높이기 위해서 초기 기동그룹의 적절한 산정이 필요함이 언급되었을 뿐이다(김영민, 2010).

기동축소량 보정에서 동일하게 보정을 수행할 기동들을 하나의 그룹으로 묶는 기동의 그룹핑 결과에 따라 축소량의 보정개소와 보정위치 등 보정의 효율성이 크게 좌우된다. 그룹핑이 적절하지 못한 경우 거더의 기울기 조건을 비롯한 성능 및 시공상의 여러 제약조건을 만족하는 보정량 산출이 불가능한 경우도 있다. 이에 본 연구에서는 기동축소량 보정의 효율성을 증진시키기 위한 방안으로서 기동축소량 해석을 통해 구한 기동들의 층별 축소량 결과로부터 유사한 축소경향을 보이는 기동들을 동일 그룹으로 묶는 기동의 최적그룹핑 기법에 대하여 연구하였다.

2. 자기조직화 형상지도 알고리즘

자기조직화(self-organizing)란 주어진 입력패턴에 대하여 정확한 해답을 미리 주지 않고 자기 스스로 학습할 수 있는 능력을 말한다(김대수, 1998). 코호넨이 제안한 자기조직화 형상지도 알고리즘(self-organizing feature map)은 패턴을 인식하여 분류하는데 매우 유용하다(Kohonen, 1982). 코호넨 네트워크라 불리는 이 알고리즘은 입력층, 은닉층, 출력층이라는 3개의 층으로 이루어진 일반적인 신경망인 백프로파게이션(back-propagation) 알고리즘과는 달리 그림 1에서 보




그림 1 코호넨 네트워크의 구조

는 바와 같이 입력층과 경쟁층이라는 2개의 층으로 이루어져 있다. 그리고 뉴런의 모든 연결들은 입력층에서 경쟁층 방향으로만 되어 있다. 이러한 특징으로 인해 본 알고리즘은 연속적인 학습이 가능하다. 이는 입력 데이터의 통계적 분포가 시간에 따라 변할 때 자동적으로 이러한 변화에 적응할 수 있다는 것을 의미한다.

코호넨 네트워크는 입력패턴에 대해 신경망의 출력형태를 지정하는 목적패턴이 없는 즉, 외부로부터의 가르침이 없는 무감독학습을 한다. 무감독학습은 주어지는 입력패턴에 대해 자주 자극되는 연결강도 벡터(weight vector)를 자극의 크기와 같아지도록 조절함으로써 해당 입력패턴에 반응하도록 한다. 결국 무감독학습을 하는 신경망은 주어진 입력패턴들로부터 스스로 특징을 찾아내고, 다른 특징에 대해서는 서로 다른 뉴런들이 반응하도록 경쟁하게 함으로써 입력패턴들을 분류할 수 있다(Hagan, 1996).

코호넨 네트워크에서 각 뉴런은 연결강도 벡터와 입력벡터가 기하학적으로 얼마나 가까운가로 경쟁한다. 이 중 가장 가까운 거리에 있는 뉴런이 승리하게 되는데, 이 승자 뉴런과 그의 이웃한 뉴런들이 식 (1)과 같은 학습규칙으로 연결강도를 조정해 가면서 학습을 한다(Chester, 1993).

$$w_{ij}(t+1) = w_{ij}(t) + \alpha(x_i(t) - w_{ij}(t)) \quad (1)$$

여기서,

$w_{ij}(t)$: 뉴런 i, j 사이의 조정되기 전의 연결강도

$w_{ij}(t+1)$: 뉴런 i, j 사이의 조정된 후의 연결강도

$x_i(t)$: 뉴런 i 의 활성화값 또는 뉴런 i 의 입력패턴

α : 학습률 ($0 < \alpha \leq 1$)

식 (1)의 연결강도 조정으로 그림 2에서 보는 바와 같이 승자 뉴런과 이와 이웃한 뉴런들의 연결강도 벡터는 입력벡터에 가까가게 된다. 또 다른 입력벡터가 들어오면 새로운 승자 뉴런이 선택되고 승자 뉴런과 이의 이웃한 뉴런들의 연결강도는 조정된다. 이러한 과정은 모든 입력벡터가 제시될 때까지 반복되고, 이러한 반복과정은 모든 학습이 끝날 때까지




그림 2 코호넨 네트워크에서의 연결강도 조정

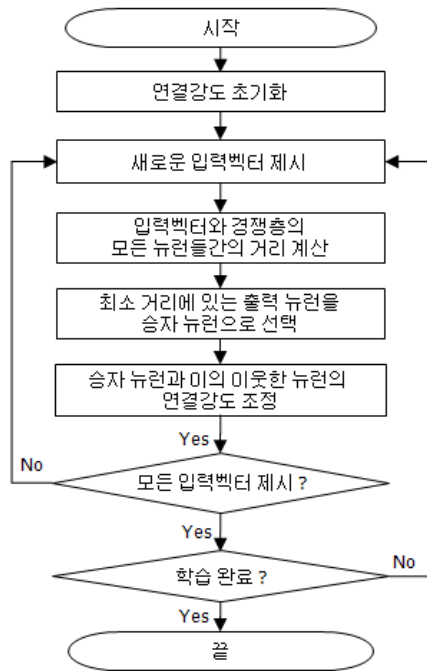


그림 3 코호넨의 자기조직화 형상지도 알고리즘

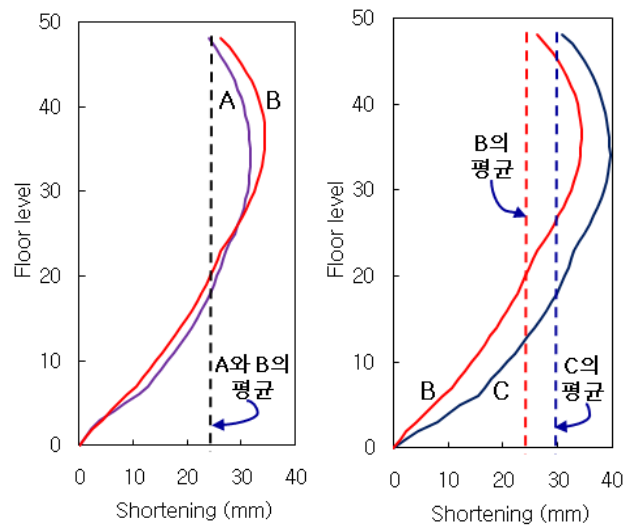
지 반복된다. 한편, 학습이 진행될수록 학습률 α 는 점점 그 값을 줄여 나가는 것이 일반적이다. 코호넨의 자기조직화 형상지도 알고리즘을 순서도로 나타내면 그림 3과 같다.

코호넨 네트워크의 경쟁 매카니즘은 승자 뉴런을 결정하는 역할 뿐만 아니라, 아주 약한 자극에 대해서도 뉴런들이 반응할 수 있도록 해주고, 이웃한 뉴런들끼리 서로 비슷한 입력패턴에 반응할 수 있도록 해준다(이상원, 1995). 코호넨 네트워크가 잘 작동하기 위해서는 층내 뉴런의 연결강도 벡터가 임의값을 가지면서 적절하게 초기화되어야 하고, 연결강도 벡터와 입력벡터가 통상 0에서 1사이로 정규화되어야 한다는 두 가지 조건이 충족되어야 한다.

3. 기둥축소량 보정을 위한 기둥의 최적그룹핑기법

3.1 기둥의 최적그룹핑 개요

기둥축소량 보정을 위한 기둥그룹의 산정은 기둥별 축소량 해석을 통하여 각 층별 축소량의 경향을 구하고 이를 바탕으로



(a) 평균은 유사하지만 표준편차의 차이가 큰 경우
(b) 표준편차는 유사하지만 평균의 차이가 큰 경우

그림 4 평균과 표준편차에 따른 축소량 그래프 비교

표 1 사례 기둥들의 평균과 표준편차 비교

	기둥 A	기둥 B	기둥 C	A와 B 차이(%)	B와 C 차이(%)
평균(mm)	23.58	23.97	29.68	1.63	19.24
표준편차(mm)	8.55	9.80	10.12	12.76	3.16

로 비슷한 축소 경향을 보이는 기둥들을 동일 그룹으로 산정하며, 이후 시공상 및 구조상 특별하게 고려해야 할 필요가 있는 기둥들에 대해서 부가적으로 기둥그룹을 조정하는 것이 가장 합리적인 방법이라 할 수 있다.

이를 위해 본 연구에서는 축소량 해석으로 구한 각 사례 건물들의 층별 축소량을 그래프로 나타내고, 이로부터 각 기둥들의 축소량 경향을 대표하는 값으로서 층별 축소량의 평균과 표준편차를 이용하였다. 일반적으로 기둥축소량의 평균과 표준편차는 비례관계를 가지나, 그림 4(a)와 같이 평균은 유사하지만 표준편차의 차이가 큰 경우와, 그림 4(b)와 같이 표준편차는 유사하지만 평균의 차이가 큰 경우가 나타날 수 있다. 이는 축소량 해석에서 종종 나타나는 현상이므로 축소량 경향을 대표하는 값으로 평균과 표준편차를 모두 고려해야 하는 이유이다. 표 1은 그림 4의 세 기둥에 대해 축소량의 평균과 표준편차 및 이의 차이를 비교하여 나타낸 것이다.

3.2 자기조직화 형상지도 알고리즘을 이용한 기둥의 최적그룹핑기법

코호넨의 자기조직화 형상지도 알고리즘을 이용한 기둥의 최적그룹핑 과정은 그림 5와 같으며, 이 과정을 자세히 설명하면 다음과 같다.

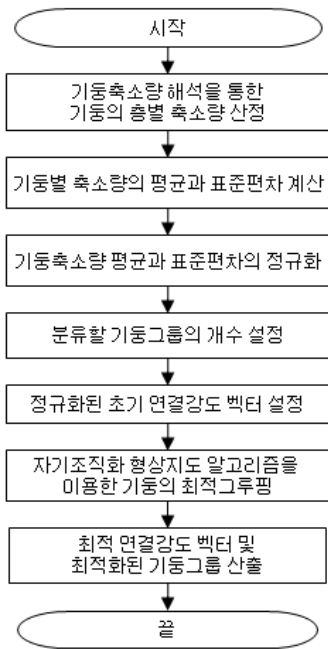


그림 5 기둥의 최적그룹핑 순서도

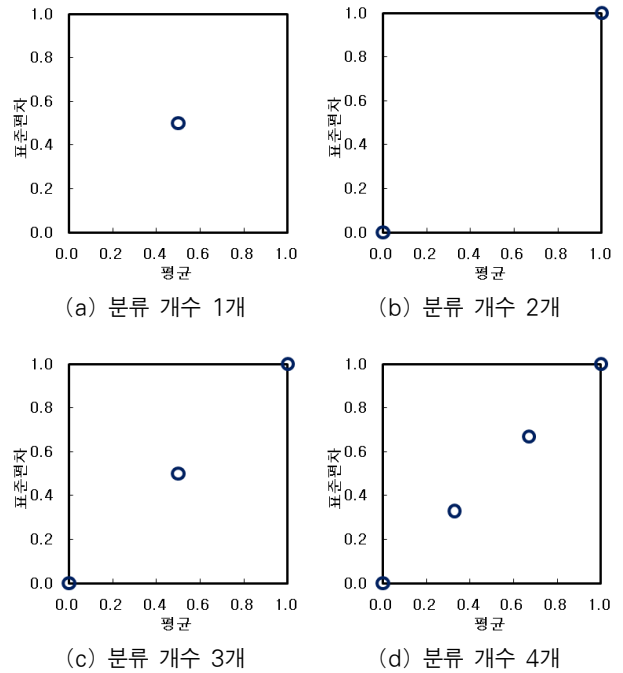



그림 7 분류 개수에 따른 초기 연결강도 벡터의 위치



(a) 각 기둥의 층별 기둥축소량 (b) 기둥축소량의 정규화된 평균과 표준편차

그림 6 기둥그룹 분류를 위한 기둥축소량의 정규화

먼저 기둥축소량 해석을 통하여 각 기둥의 층별 축소량을 구한다. 다음으로 각 기둥별로 전체 층에 걸친 기둥축소량의 평균과 표준편차를 구한다. 여기서 구한 평균과 표준편차의 최대값과 최소값을 이용하여 각 기둥의 평균과 표준편차를 식 (2)에 따라 정규화하고 정규화된 결과를 평균과 표준편차로 구성된 2차원 평면에 나타낸다. 예를 들어 어떤 건물에서 각 기둥의 층별 기둥축소량의 분포가 그림 6(a)와 같다면, 각 기둥의 축소량의 평균과 표준편차를 정규화하여 나타내면 그림 6(b)와 같다.

$$m_n = \frac{m - m_{\min}}{m_{\max} - m_{\min}} \quad (2)$$

여기서,

- m_n : 정규화값
- m : 대상값
- m_{\min} : 최소값
- m_{\max} : 최대값

그 다음, 분류할 기둥그룹의 개수를 설정하고, 입력뉴런과 출력뉴런 사이의 연결강도 벡터를 초기화한다. 최적 그룹핑을 위한 초기 연결강도 벡터는 일반적으로 임의의 값을 사용한다. 그러나 초기 연결강도 벡터들이 서로 인접해 있으면 기둥그룹을 분류하는 과정에서 인접한 연결강도 벡터들이 통합되어 하나의 기둥그룹으로 분류될 수 있으므로, 초기에 계획한 개수만큼 기둥그룹을 분류하기 위해서는 초기 연결강도 벡터들을 서로 인접하지 않도록 설정할 필요가 있다. 본 연구에서는 이를 고려하여 초기 연결강도 벡터를 식 (2)에서 구한 축소량의 평균과 표준편차의 정규화된 값의 최소값과 최대값을 연결하는 직선위에 등간격으로 분포되도록 설정하였다. 즉, 분류할 기둥그룹의 개수에 따른 연결강도 벡터의 초기값은 식 (3)으로 구하며, 이에 따른 초기값의 위치를 도시하면 그림 7과 같다.

$$w_{ij} = 0.5 \quad : \text{if } n = 1 \quad (3)$$

$$w_{ij} = \frac{j-1}{n-1} \quad (j=1, \dots, n) \quad : \text{if } n \geq 2$$




그림 8 기동그룹 분류를 위한 코호넨 네트워크의 구조

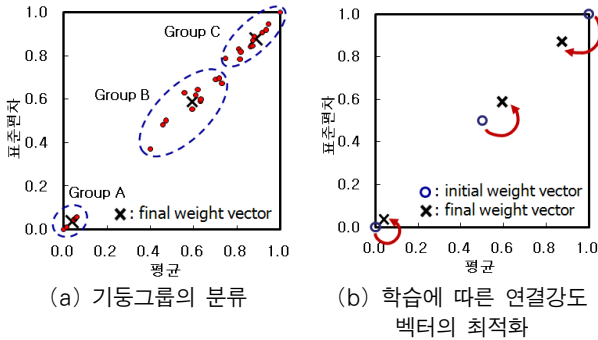


그림 9 기동그룹의 분류 및 연결강도 벡터의 최적화

여기서,

- w_{ij} : 입력뉴런 i 와 출력뉴런 j 사이의 연결강도
- n : 분류할 기동그룹의 개수

모든 입력값과 연결강도 벡터를 설정한 이후에는 코호넨의 자기조직화 형상지도 알고리즘을 이용하여 기동그룹을 분류한다. 이때 적용된 네트워크의 구조는 그림 8과 같다. 입력 뉴런은 두 개로 구성되어 있으며 각각 기동축소량의 정규화된 평균과 표준편차가 입력된다. 출력뉴런은 분류하고자 하는 기동그룹의 개수만큼으로 구성된다.

본 연구에서는 코호넨의 자기조직화 형상지도 알고리즘을 적용함에 있어 승자 뉴런의 연결강도 벡터만 조정하였고, 이와 이웃한 뉴런의 연결강도 벡터는 조정하지 않았다. 이는 대체로 분류할 기동그룹의 개수가 그리 많지 않기 때문에 승자 뉴런과 이웃한 뉴런의 개수도 많지 않고 이로 인해 또 이웃 뉴런의 연결강도를 조정하는 실익이 거의 없기 때문이다.

본 연구에서는 학습률 α 를 학습이 진행될수록 식 (4)에 의하여 줄여 나갔다. 여기서 t 는 학습회수로서, 모든 입력벡터가 한 번씩 제시될 때마다 1씩 증가한다.

$$\alpha(t) = 0.1 \times \left(1 - \frac{t}{10^4} \right), \quad (t \leq 10,000) \quad (4)$$


그림 6(b)와 같이 나타낸 기동축소량의 평균과 표준편차의 정규화된 값에 대하여 자기조직화 형상지도 알고리즘을 이용하면 유사한 축소량 특징을 가지는 기동들이 그림 9(a)

와 같이 동일 그룹으로 분류된다. 여기서는 분류할 기동그룹을 3개로 설정한 경우이다. 동일 그룹으로 분류된 기동들은 서로 인접하고 있으며 서로 다른 기동그룹끼리는 교차하지 않는다. 그림 9(a)에서 X로 표시된 것은 각 기동그룹의 최적화된 연결강도 벡터이다. 연결강도 벡터는 그림 9(b)에서 보는 바와 같이 학습이 진행될수록 그 위치가 변화하며 최적값은 동일 그룹으로 분류된 기동들의 중심에 위치한다. 여기서 중심은 동일 기동그룹에 속한 각 기동들로부터 거리의 합이 최소가 되는 위치를 나타낸다.

4. 사례 적용 및 적용성 평가

본 장에서는 제안된 최적기동그룹 산정 알고리즘을 실제 건물에 적용하여 그 적용성을 평가하였다. 대상 건물은 그림 10에서 보는 두 개의 건물이다. 이들은 실제로 기동축소량 해석이 수행되어 사용성을 초과하는 부동축소량이 보정된 건물로서(마이더스아이티, 2004; 2005), 이전의 기동축소량 최적보정시스템 개발에 대한 연구(김영민, 2010)에서 적용성 평가 사례로 사용된 건물들이다. 두 사례 건물은 모두 철근콘크리트조 건물로 사례 A는 지상 61층 지하 3층, 사례 B는 지상 42층 지하 3층 건물이다. 각 사례 건물들의 기준층 평면은 그림 11과 같다.

실무에서는 기동그룹을 일반적으로 하중분담면적과 기동의 강성 및 단면크기를 기준으로 분류하고 있으며, 이에 의거하여 앞에서 제시한 2개의 사례 건물에 대해 실무에서 직접 분류하여 축소량 보정을 수행한 기동그룹을 나타내면 그림 11과 같다. 사례 건물 A, B는 각각 3, 6 개의 기동그룹으로 분류되었다. 여기서, 사례 건물 A는 좌우 대칭형상으로 대칭



(a) 사례 A

(b) 사례 B

그림 10 최적기동그룹 산정을 위한 사례 건물의 형상

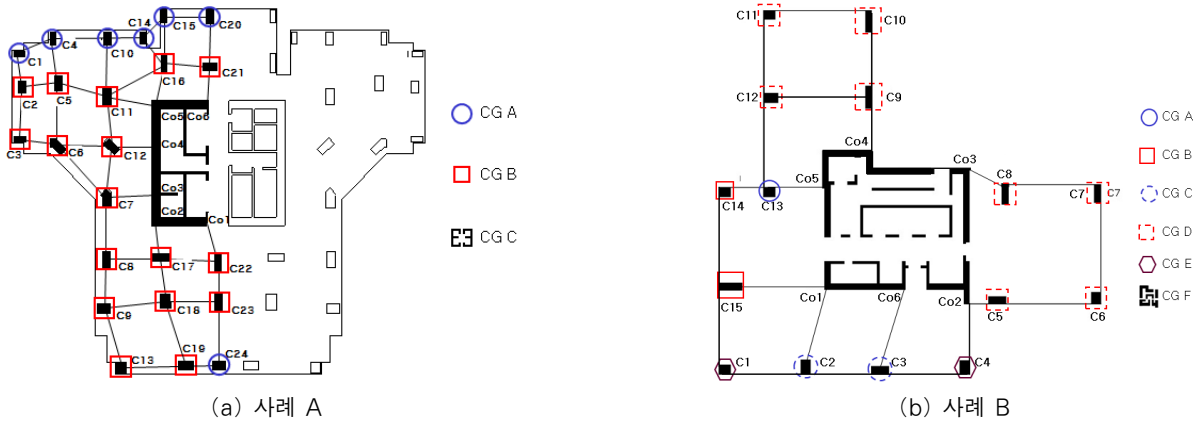


그림 11 각 사례 건물의 평면 및 초기기둥그룹

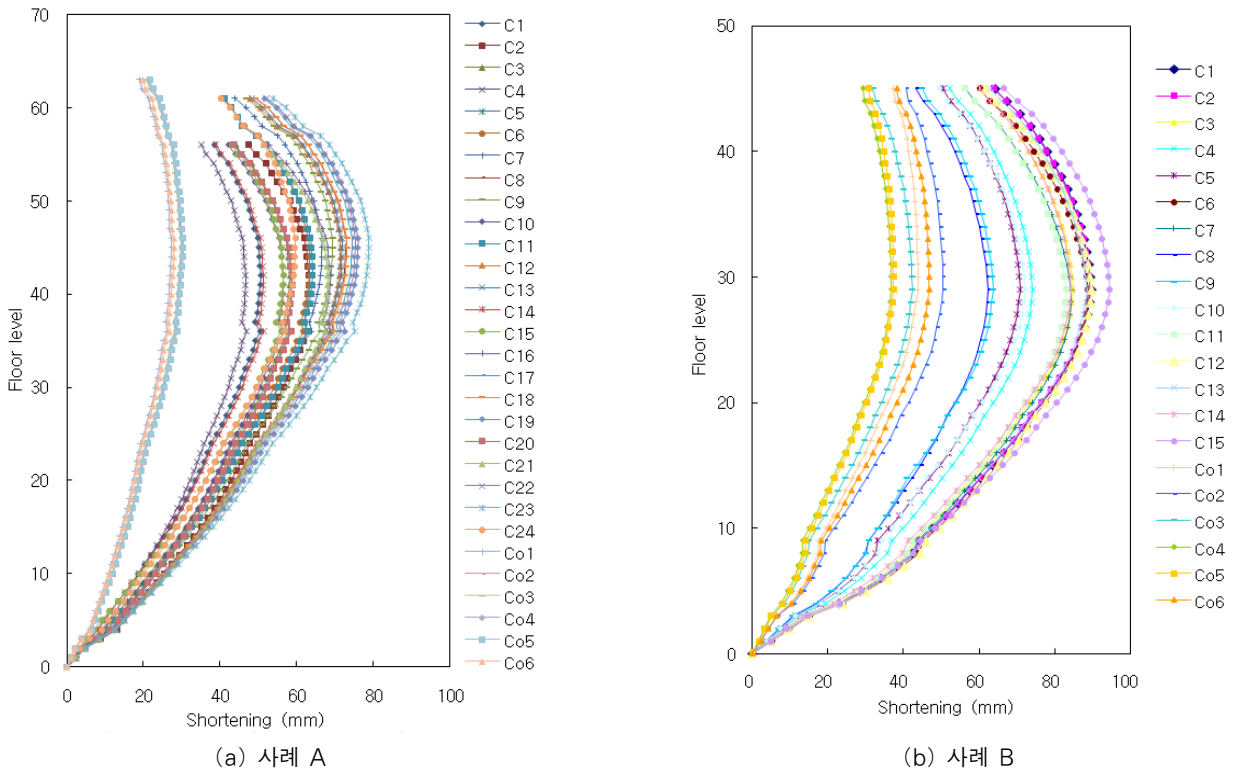


그림 12 각 사례 건물들의 높이에 따른 기동축소량 그래프




그림 13 기동축소량의 정규화된 분포 및 초기기둥그룹

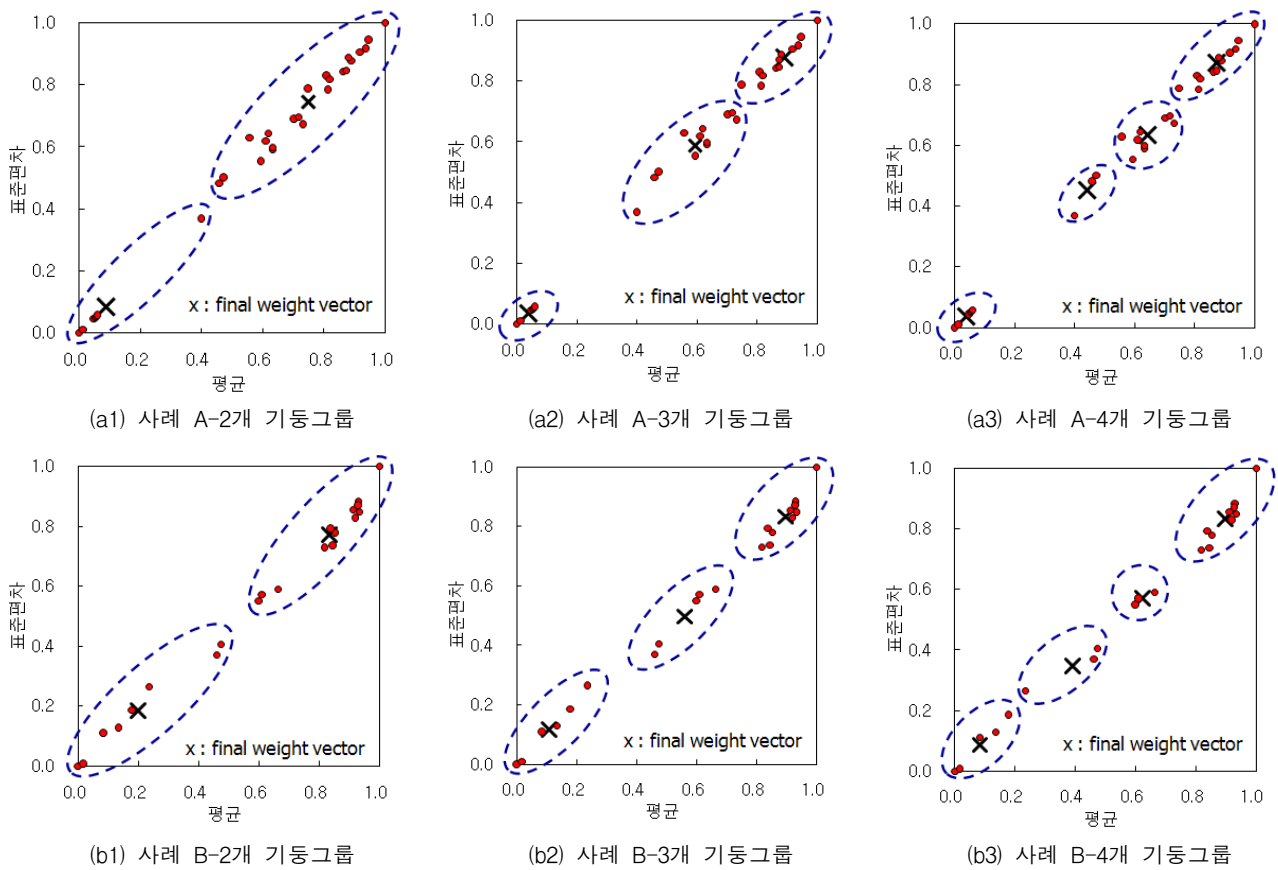


그림 14 기둥그룹의 개수에 따라 최적화된 각 사례 건물의 최적기둥그룹

인 왼쪽 반에 대해서만 기둥축소량 해석이 수행되었다.

그림 12는 각 사례건물에 대해 시공단계와 구조부재의 물성치를 바탕으로 축소량 해석을 수행하여 산출된 각 기둥별 층별 축소예측량이다. 축소량 보정의 대상이 되는 슬래브 타설 후 축소량은 최저층에서 0의 값을 가지고 높이에 따라 점차적으로 증가하다가 대략 전체 높이의 2/3 지점에서 최대값이 나타나며, 그 이상의 층에서는 하부층과는 반대로 점차적으로 줄어드는 경향을 보인다.

그림 13에서는 각 사례 건물에 대해 기둥축소량의 평균과 표준편차를 정규화하여 나타내었으며, 여기에 실무 설계사무소에서 기둥축소량 보정을 위해 분류한 기둥그룹을 기호로 표시하였다. 실무에서 설정한 기둥그룹은 대체로 각 영역이 적절히 분류되어 있으나, 일부 기둥그룹끼리는 서로 영역이 교차하거나 심지어 사례 B와 같이 일부 영역에서 세 개 이상의 기둥그룹이 교차하는 경우도 있음을 확인할 수 있다.

그림 14는 본 연구에서 제안한 최적그루핑기법을 이용하여 각 사례건물의 기둥을 각각 2, 3, 4개의 기둥그룹으로 분류한 결과이다. 여기서 분류된 각 기둥 기둥그룹은 점선의 폐곡선으로 나타내었으며, X로 표시된 것은 최적으로 분류된 각 기둥그룹의 중심 위치를 나타낸다.

본 연구에서 제안하는 그루핑기법을 통해 분류된 기둥그룹들은 각각 유사한 축소 경향을 보이는 기둥들로 구성되어 있으며, 분류된 기둥그룹의 영역들끼리는 서로 교차하지 않는 것을 확인할 수 있다. 이로부터 본 연구에서 제안하는 최적 그루핑기법은 유사한 축소경향을 보이는 기둥들을 의미있게 분류하고 있으며, 충분한 실무적용 가능성을 보이고 있음을 확인할 수 있다.

5. 결 론

기둥축소량 보정을 효과적이고 효율적으로 수행하기 위한 선결요건으로서 적절한 기둥의 그루핑이 필요하다. 본 논문에서는 이를 위해 유사한 축소경향을 보이는 기둥들을 동일 그룹으로 묶는 기둥의 최적그루핑기법에 대하여 연구하였다. 본 연구를 통하여 얻은 결론은 다음과 같다.

- 1) 본 연구에서는 기둥의 최적그루핑기법으로 외부 감독 없이 입력 데이터의 패턴을 스스로 인식하여 분류할 수 있는 코호넨의 자기조직화 형상지도 알고리즘을 이용하였다.
- 2) 코호넨 네트워크로 표현되는 자기조직화 형상지도 알고

리즘은 입력층과 경쟁층으로 구성된다. 본 연구에서는 두 개의 입력뉴런과 분류할 기동개수 만큼의 출력 뉴런으로 네트워크를 구성하였고 이 사이를 연결강도 벡터로 연결하였다.

- 3) 입력뉴런에 제시되는 입력패턴은 축소량 경향을 대표하는 값으로서 각 기동의 층별 축소량의 평균과 표준편차를 이용하였다. 이 때, 입력패턴의 특징을 균등히 반영하기 위하여 평균과 표준편차는 0과 1사이의 값으로 정규화하여 사용하였다.
- 4) 초기 연결강도 벡터는 서로 인접하지 않도록 축소량의 평균과 표준편차의 정규화된 값의 최소값과 최대값을 연결하는 직선위에 등간격으로 분포되도록 설정하여 초기에 계획한 개수만큼 정확하게 기동그룹을 분류할 수 있었다.
- 5) 제안된 최적기동그룹 산정 알고리즘을 실제 건물에 적용하여 그 적용성을 평가한 결과, 분류된 기동그룹들은 각각 유사한 축소 경향을 보이는 기동들로 구성되었으며, 기동그룹의 각 영역끼리는 서로 교차하지 않았다. 이로부터 본 연구에서 제안하는 최적기동그룹 산정 알고리즘은 충분한 실무적용 가능성이 있음을 확인할 수 있었다.

감사의 글

이 논문은 2009년도 명지대학교 교내연구비 지원사업에 의하여 연구되었음. (주)마이다스아이티의 실무 데이터 제공에도 감사드립니다.

참 고 문 헌

김대수 (1998) 신경망 이론과 응용(I), 하이테크정보, 서울, p.364.
 김영민 (2008) 고층건물의 멀티 기동그룹에 대한 부동기동축소량의 최적보정기법, 한국전산구조공학회 논문집, 21(2),

pp.189~197.
 김영민 (2010) 현장 적용성을 고려한 기동축소량의 최적보정 시스템 개발, 한국전산구조공학회 논문집, 23(2), pp.189~197.
 마이다스아이티 (2004) 더 샵 스타시티 기동축소량 계측 및 보정 본해석 보고서, (주)마이다스아이티, p.420.
 마이다스아이티 (2005) 영등포 SK Leader's View 기동축소량 계측 및 보정 본해석 보고서, (주)마이다스아이티, p.200.
 이상원 (1995) 학습하는 기계 신경망, Ohm사, 서울, p.466.
 이상현 (2007) 비선형 구조물에 대한 수정 슬라이딩모드 제어 알고리즘 성능 평가, 한국전산구조공학회 논문집, 20(2), pp.147~155.
 조강표, 신성우, 정승환, 조수연 (2007) 고층 건축물의 수평진동에 대한 거주자의 지각임계기속도, 한국전산구조공학회 논문집, 20(3), pp.371~377.
 Chester M. (1993) Neural Networks : a Tutorial, Prentice Hall, Englewood Cliffs, p.182.
 Hagan M.T., Demuth H.B., Beale M. (1996) Neural Network Design, PWS Publishing Co., Boston, p.712.
 Kohonen T. (1982) Self-Organized Formation of Topologically Correct Feature Maps, *Biological Cybernetics*, 43, pp.59~69.
 Park H.S. (2003) Optimal Compensation of Differential Column Shortening in High-Rise Buildings, *The Structural Design of Tall and Special Buildings*, 12(1), pp.49~66.

- 논문접수일 2010년 9월 1일
- 논문심사일 1차 2010년 9월 3일
2차 2010년 12월 20일
- 게재확정일 2011년 1월 2일