

DEA와 SOM을 이용한 투입 요소 유사성 기반의 벤치마킹 경로 선택 방법에 관한 연구

박재훈¹ · 배혜림^{1*} · 임성묵²

¹부산대학교 산업공학과 / ²고려대학교 경영학부

Method of Benchmarking Route Choice Based on the Input-similarity Using DEA and SOM

Jae Hun Park¹ · Hye Rim Bae¹ · Sung Mook Lim²

¹Department of Industrial Engineering, Pusan National University, Busan, 609-735, Korea

²Division of Business Administration, College of Business and Economic, Korea University, Seoul, 136-701, Korea

DEA(Data Envelopment Analysis) is the relative efficiency measure among homogeneous DMU(Decision-Making Units) which can be used to useful tool to improve performance through efficiency evaluation and benchmarking. However, the general case of DEA was considered as unrealistic since it consists a benchmarking regardless of DMU characteristic by input and output elements and the high efficiency gap in benchmarking for inefficient DMU. To solve this problem, stratification method for benchmarking was suggested, but simply presented benchmarking path in repeatedly applying level. In this paper, we suggest a new method that inefficient DMU can choice the optimal path to benchmark the most efficient DMU base on the similarity among the input elements. For this, we propose a route choice method that combined a stratification benchmarking algorithm and SOM (Self-Organizing Map). An implementation on real environment is also presented.

Keywords: DEA, SOM, Benchmarking, Stratification Benchmarking Model, Variable-benchmarking Model

1. 서론

컴퓨터와 통신 기술의 발달로 기업간의 경쟁은 더욱 치열해지고 프로세스 구조의 복잡화로 인해 비즈니스의 효율성 개선은 기업 생존의 중요한 요소 중의 하나로 여겨지고 있다. 이러한 효율성 개선을 위해 다양한 벤치마킹 방법들이 소개되었고 공공 행정(Ammons, 2002), 생산 및 설계(Grupp, 1990), 경영 관리(Spendolini, 1992; Tata and Motwanu, 2000)등 다양한 분야에서 이에 대한 연구가 진행되어 왔다. 벤치마킹은 어느 특정 분야에서 우수한 상대를 찾아 성과 차이를 분석하고, 이를 바탕으로 내부 활동 및 관리능력을 판단하여 자기 혁신을 추구하는 경영 기법이라 할 수 있다. 이러한 벤치마킹은 다음의 세 단

계로 나뉘어 진행된다. 먼저 가장 우수한 성과 조직(best performer)을 선정하고, 선정된 조직을 모방하기 위한 활동 및 목표를 설정한 후 목표를 달성하기 위한 최적의 모형(best practice)을 구현하게 된다(Donthu *et al.*, 2005). 우수한 성과 조직을 선정하는 것은 벤치마킹을 위한 첫 단계이면서 현실적으로 달성 가능한 목표치가 선택될 수 있도록 정확한 분석을 바탕으로 이루어져야 함으로, 벤치마킹을 위한 단계 중 가장 중요한 부분이라 할 수 있다. 우수한 조직을 선정하기 위해서는 다수의 다른 조직과 효율성을 비교해야 하는데 이러한 효율성을 비교하기 위해서는 조직의 효율성에 영향을 미치는 다양한 투입요소 및 산출요소를 고려해야 한다.

다수의 조직들 간에 투입과 산출 요소를 고려하여 상대적

본 연구 결과물은 교육인적자원부 지정 차세대 물류 IT 기술 연구 사업단 지원을 통해 이루어졌음.

* 연락처 : 배혜림 교수, 609-736 부산광역시 금정구 장전동 부산대학교 산업공학과, Tel : 051-510-2733, Fax : 051-512-7603,

E-mail : hrbae@pusan.ac.kr

2009년 9월 24일 접수; 2009년 2월 11일 수정본 접수; 2010년 2월 22일 게재 확정.

효율성을 비교하고 비효율적인 조직이 벤치마킹 대상을 선정하기 위한 방법으로 DEA(Data Envelopment Analysis)가 유용하게 이용되고 있다(Ross and Droge, 2002). DEA는 다수의 투입물과 산출물을 이용하여 DMU(Decision Making Unit)들 간의 상대적 효율성을 측정하는 방법으로, 효율적인 결과를 내는 최상의 DMU와 상대적으로 비효율적인 DMU간의 효율성 정도와 비효율 발생 요소에 대한 정보를 제공한다. DMU들 간의 효율성 차이는 벤치마킹을 시행하려는 조직이 대상 조직을 벤치마킹하기 위해 개선해야 하는 정도를 의미한다. 일반적인 DEA의 경우 DMU들의 특성과는 무관하게 가장 효율적인 DMU만을 벤치마킹 대상으로 제시함으로써 개선해야 하는 정도가 큰 경우에는 당장의 벤치마킹 대상으로 삼는 것이 현실적으로 어렵다는 지적을 받아 왔다(Cooper *et al.*, 2006). 그러나 벤치마킹에서 가장 합리적인 대상 선택 전략은 투입 및 산출에 의해 규정되는 특성이 유사하면서도 좀 더 효율적인 조직을 벤치마킹 대상으로 하는 것이다(Gonzales and Alvarez, 2001). DEA를 이용한 벤치마킹에서 DMU들의 특성과는 무관하게 효율성 격차가 큰 대상이 선택되는 문제점을 보완하기 위해 효율성을 계층화(stratification)하여 단계적으로 벤치마킹 대상을 선택하는 방법(recursive DEA-based enveloping method)이 제시되었다(Sharma and Yu, 2009). 이는 DMU들을 효율성 기준으로 계층화 한 후 상대적으로 효율성이 낮은 계층에서 효율성이 높은 계층으로 단계적으로 효율성을 개선하는 방법이다.

단계적 벤치마킹 방법에 대한 기존의 연구는 DEA를 반복적으로 실행하여 비효율적인 DMU가 단계적으로 벤치마킹 대상을 찾아가는 방법과 투입 및 산출 요소의 유사성을 기반으로 한 단계적 개선 방법이 있다. Alirezaee and Afsharian(2007)은 투입·산출요소의 측정값에 존재하는 이상치(outliers)로 인해 발생하는 문제점을 해결하기 위한 목적으로 DMU 집단을 효율성 기준으로 계층화하는 계층 측정 모형을 구성하였고, 이를 토대로 비효율적인 DMU가 단계적으로 계층을 거슬러 올라가며 벤치마킹 대상을 선정하는 방법을 제안하였다. Hong *et al.*(1999)은 시스템 통합 프로젝트의 효율성을 평가하기 위해 DEA와 기계 학습(machine learning)을 결합한 방법론을 제안하였는데, 새로운 DMU를 계층으로 분류하는 규칙을 의사결정 나무를 통해 생성하였고 다른 DMU들의 효율성에 미치는 영향을 측정하였으며 이를 바탕으로 비효율적 DMU의 효율성 개선 경로를 구성하였다. Shaneth *et al.*(2009)은 DMU를 대상으로 효율성 분석을 시행하고, 그 결과를 바탕으로 SOM(Self-Organizing Map)과 강화학습(Reinforce Learning)을 이용하여 DMU들 간에 최소 효율성 범위를 만족하는 최단 경로를 찾는 방법을 제시하였다. 해당 방법은 벤치마킹을 시행하려는 DMU의 효율성 값보다 최소 효율성 범위 값 이상을 만족하는 DMU들 중 가장 근접한 거리에 존재하는 DMU를 대상으로 경로를 탐색하는 방법으로서, 효율성을 기준으로 한 계층화를 시도하지 않는다는 점에서 본 논문과 차이가 있다. 또한 Mithun and Song(2009)은 SOM을 이용하여 투입 요소의 유사성 그룹을 도출하여 동일한 그룹에 존재하는 DMU를 대상으로 단계적으로 벤

치마킹하는 방법을 제안하였다. 이는 동일 그룹으로 벤치마킹 범위를 제한한다는 것과 동일 그룹에 소수의 DMU가 존재할 경우 가장 효율적인 DMU를 벤치마킹하기 어렵다는 단점이 있다. 이와 대조적으로 본 논문에서 제안하는 방법은 가장 유사한 그룹을 대상으로 최적의 벤치마킹 DMU를 찾을 때까지 범위를 확장하며 단계적 벤치마킹을 시행한다.

이처럼 DEA의 효율성을 계층화 하여 효율성 격차를 단계적으로 개선하는 벤치마킹 방법은 DMU들의 특성을 고려한 현실적인 효율성 개선이라는 측면에서 일반적인 DEA의 벤치마킹 방법보다 효율적이라 할 수 있다. 그러나 이러한 계층화를 통한 단계적 벤치마킹 방법은 모든 계층의 DMU들을 벤치마킹 하도록 함으로써, 효율성의 차이가 미약한 두 DMU간의 단계적 벤치마킹 경로가 생성되는 경우가 발생한다. 이는 단계적 벤치마킹 수행 횟수를 증가시키는 요인으로 작용하고 이로 인해 벤치마킹을 위한 부가적인 활동들도 증가하는 비효율적인 부분으로 작용한다.

본 논문에서는 앞서 언급한 계층화를 통한 단계적 벤치마킹에서 발생할 수 있는 비효율적 요소를 개선하기 위해 불필요하게 많은 벤치마킹을 피하면서도 적절한 수준에서 벤치마킹 대상을 결정하기 위한 새로운 방법으로 SOM 기법을 조합하여 투입 요소 유사성에 따른 단계적 벤치마킹 경로 선택 방법을 제안한다. 서론에 이어 제 2장에서는 배경 이론과 문제정의에 대해 설명하였고, 제 3장에서는 문제점을 해결하기 위해 본 논문에서 제시하는 투입 요소 유사성 기반의 벤치마킹 대상 선택 방법에 대해 기술하였다. 제 4장에서는 제안한 방법을 실제 동아시아 항만터미널에 적용하여 사례 연구를 진행하였으며, 제 5장은 결론으로써 본 연구의 의의와 추후 연구에 대한 논의가 이루어 졌다.

2. 배경이론 및 문제정의

2.1 DEA

DEA는 투입과 산출의 명확한 인과관계를 밝히기 어려운 DMU들의 상대적 효율성을 평가하기 위해 개발된 방법이며, 여러 종류의 산출물을 생산하기 위해 여러 종류의 투입물을 이용하는 DMU들간의 효율성을 평가하기 위한 선형계획법에 기반한 방법이다(Joe, 2003). DEA의 수리적 모형은 다음과 같다.

$$\begin{aligned} \max & \frac{\sum_{r=1}^s u_r y_{rk}}{\sum_{i=1}^m v_i x_{ik}} \\ s.t & \\ & \frac{\sum_{r=1}^s u_r y_{rj}}{\sum_{i=1}^m v_i x_{ij}} \leq 1; j = 1, 2, \dots, n \end{aligned} \quad (1)$$

$$u_r, v_i \geq 0; r = 1, 2, \dots, s; i = 1, 2, \dots, m$$

식 (1)은 DEA의 기본 모형인 Charnes, Cooper and Rhodes의 CCR 모형(Charnes *et al.*, 1978)으로 u_r 은 r 번째 산출 요소의 가중치, v_i 는 i 번째 투입 요소의 가중치, n 은 DMU의 수, s 는 산출 요소의 수, m 은 투입 요소의 수, k 는 평가하고자 하는 특정 DMU 번호, y_{rj} 는 DMU j 의 r 번째 산출물의 양, x_{ij} 는 DMU j 의 i 번째 투입물의 양을 각각 의미한다. 한편 DEA 모형은 투입요소 초점을 두는가, 산출요소 초점을 두는가에 의해 투입지향(input oriented) 모형과 산출지향(output oriented) 모형으로 구분되는데 투입지향 모형은 최소한의 투입요소를 사용하여 주어진 수준의 산출요소를 생산하는 것을 목적으로 하고, 산출지향 모형은 주어진 투입 요소를 가지고 산출 요소를 최대화하는 것을 목적으로 한다.

식 (1)의 모형은 다음 식 (2)와 같은 선형계획법 모형으로 변형될 수 있다.

$$\begin{aligned} \max_{u,v} & \sum_{r=1}^s u_r y_{rk} \\ \text{s.t.} & \\ & \sum_{i=1}^m v_i x_{ik} = 1 \\ & \sum_{r=1}^s u_r y_{rj} - \sum_{i=1}^m v_i x_{ij} \leq 0, \forall j \\ & v_i, u_r \geq \epsilon, \forall i, r \end{aligned} \quad (2)$$

여기서 y_{rj} 는 DMU j 가 생성하는 산출 요소 r 의 양이 되며, x_{ij} 는 DMU j 가 사용하는 투입 요소 i 의 양이 된다. v_i 는 투입요소 i 에 부과되는 가중치, u_r 은 산출요소 r 에 부과되는 가중치이며, ϵ 는 비아르키메디안 무한소(non-Archimedean infinitesimal)를 의미한다. 목적함수는 평가 대상 DMU의 효율성 값을 나타내게 되는데 효율성 값은 0보다 크고 1보다 작거나 같은 값을 가진다. 각각의 DMU에 대해 효율성 값이 1인 경우 해당 DMU는 효율적이라고 하고, 1보다 작을 경우는 비효율적이라고 한다.

DEA는 DMU들 간의 상대적 효율성 측정 외에 비효율적인 DMU에게 벤치마킹 대상으로 사용될 수 있는 참조집단을 제시함으로써 벤치마킹 도구로도 매우 유용하게 사용될 수 있다. DEA를 이용한 벤치마킹에서는 DEA의 선형계획 모형을 쌍대화(dual)하여 참조집합을 구할 수 있다. 식 (3)은 식 (2)의 DEA 모형을 쌍대화한 포락모형(envelop model)으로 DMU k 에 대하여 모든 DMU들의 투입요소의 가중합이 단위 k 의 투입 요소의 θ 비율 이하인 범위에서 모든 DMU들의 산출요소의 가중합이 단위 k 의 산출요소 이상이 되는 최소비율 θ 를 구하는 모형이다. 여기서 θ 는 효율성을 개선하기 위해 피평가 DMU k 의 모든 투입 요소에 적용된 비례적 감소를 나타내는 변수이고, λ_j 는 각 DMU의 잠재가격(shadow price, 피평가 DMU k 의 참조 대상이 되는 효율적 경계선 상의 가상 DMU를 구성하기 위한

모든 DMU들의 가중치. 이후 가중치로 줄여서 표현함)을 각각 나타낸다.

$$\begin{aligned} \min & \theta \\ \text{s.t.} & \\ & \sum_{j=1}^n \lambda_j x_{ij} \leq \theta x_{ik} \quad (i = 1, 2, \dots, m) \\ & \sum_{j=1}^n \lambda_j y_{rj} \geq y_{rk} \quad (r = 1, 2, \dots, s) \\ & \lambda_j \geq 0 \quad (j = 1, 2, \dots, n) \end{aligned} \quad (3)$$

본 논문에서는 계층화 모델 DEA 시행 이후 벤치마킹을 시행하려는 DMU가 각 계층별 존재하는 DMU들 중 벤치마킹 가능한 DMU들을 선택 할 수 있도록 가변적 벤치마크 모델(variable-benchmark model)(Joe, 2003)을 이용하였다. 가변적 벤치마크 모델은 효율적인 DMU들을 대상으로 새롭게 도입되는 DMU의 상대적인 효율성과 참조집합에 의한 벤치마킹 대상을 구하기 위한 방법으로 본 논문에서는 벤치마킹을 시행하려는 DMU가 계층화 모델 DEA에 의해 단계적으로 구분된 효율적인 DMU 집단을 대상으로 각 계층별로 벤치마킹 가능한 참조집합과 가중치를 산출하기 위한 방법으로 적용하였다. 가변적 벤치마크 모델의 수리적 모형은 다음 식 (4)와 같다.

$$\begin{aligned} \min & \delta \\ \text{s.t.} & \\ & \sum_{j \in E^*} \lambda_j x_{ij} \leq \theta x_i^{org} \quad (i = 1, 2, \dots, m) \\ & \sum_{j \in E^*} \lambda_j y_{rj} \leq y_r^{org} \quad (r = 1, 2, \dots, s) \\ & \lambda_j \geq 0, j \in E^* \quad (j = 1, 2, \dots, n) \end{aligned} \quad (4)$$

식 (4)에서 E^* 는 벤치마킹 대상이 되는 효율적인 집단에 속한 DMU들이 되고 벤치마킹을 시행 하려는 DMU를 DMU^{org} 라고 표기할 때, x_{io}^{org} 와 y_{ro}^{org} 는 DMU^{org} 의 i 번째 투입 요소와 r 번째 산출 요소 값이 된다. $\sum_{j \in E^*} \lambda_j x_{ij}$ 은 효율성 개선을 위한 DMU^{org} 의 i 번째 투입 요소 값이고, $\sum_{j \in E^*} \lambda_j y_{rj}$ 은 효율성 개선을 위해 DMU^{org} 의 r 번째 산출 요소 값을 의미한다.

2.2 계층화 모델(stratification model) DEA

계층화 모델 DEA는 일반적인 DEA방법과 유사하지만 차이점은 가장 효율적인 DMU 집단이 다음 차순위자를 결정할 때는 제외 된다는 점이다. 본 논문은 Joe Zhu(2003)가 제시한 계층화 모델 DEA모형을 사용하여 DMU들을 효율성에 따라 계층화한다. DEA방법에 의거하여 DMU들에 대한 효율성을 분

석할 때 비효율적인 DMU들을 포함하거나 제외시켜도 다른 DMU들의 효율성 수치에는 영향을 미치지 않지만, 효율적인 DMU들을 제거하는 경우에는 다른 DMU들의 효율성수치가 변하게 된다.

아래 식 (5)는 투입 지향 모형의 쌍대모형으로 x_{ik} 와 y_{rk} 는 각각 k 번째 DMU의 i 번째 투입 요소와 r 번째 산출 요소의 값을 의미한다. l 은 계층화 모델 DEA에서 효율적인 DMU 집합들로 구성된 각 계층을 의미하고, k 는 계층 l 에 존재하는 개별 DMU들을 의미한다. J^l 은 계층 l 까지 남아 있는 DMU 집합을 의미하고, $F(J^l)$ 은 J^l 에 속하는 DMU들의 색인(index) 집합을 의미한다.

$$\begin{aligned} \theta^*(l, k) &= \min \theta(l, k) & (5) \\ \text{s.t.} & \\ \sum_{j \in F(J^l)} \lambda_j x_{ij} &\leq \theta(l, k) x_{ik} \\ \sum_{j \in F(J^l)} \lambda_j y_{rj} &\leq y_{rk} \\ \lambda_j &\geq 0, j \in F(J^l) \end{aligned}$$

$E^1 = \{DMU_k \in J^1 | \theta^*(l, k) = 1\}$ 는 $\theta^*(l, k)$ 가 1이고 동시에 제약식의 조건이 모두 등식으로 만족할 때 DMU는 효율적이라 하고 전체 DMU를 대상으로 $\theta^*(l, k)$ 가 1인 효율적인 DMU의 집합으로 표시할 수 있다. E^1 는 전체 DMU들 중에서 효율적인 DMU들의 집합이고, E^2 는 E^1 을 제거한 후 남은 DMU들 중에서 효율적인 DMU들의 집합이다. 다음은 계층화 모델 DEA 방법에서 전체 DMU들을 계층화 하는 일반적인 방법에 대해 설명한다.

- 단계 1 : $l = 1$ 로 두고 J^l 는 전체 DMU들의 집합이다.
- 단계 2 : 식 (5)에 의해 J^l 에 속하는 DMU들을 평가하여, 효율적 DMU 집합 E^l 을 구한다.
- 단계 3 : E^l 에 속한 DMU들은 이후 DEA 평가에서 제외한다. 즉 $J^{l+1} = J^l - E^l$ 로 둔다(만일 $J^{l+1} = \emptyset$ 이면 종료한다).
- 단계 4 : $l = l + 1$ 로 두고 단계 2로 간다.
- 종료 조건: 만일 $J^{l+1} = \emptyset$ 이면 절차를 종료한다.

2.3 SOM

본 논문에서 사용된 SOM은 Kohonen(1988)에 의해 개발된 자율 학습(unsupervised learning) 신경망 모델의 한 종류로서, 유사한 입력 패턴을 같은 군집으로 묶기 위해 스스로 연결 강도를 조절하여 특징지도(feature map)로 자기 조직화하는 방법이다(Haykin, 1999).

SOM은 입력 층과 출력 층, 두 개의 뉴런에 입력 패턴을 배열시키는데, 관측된 데이터 개수만큼의 뉴런을 가지고 있는 입력 층은 각각의 뉴런을 통해 실제 데이터로부터 정보를 받아들이는 역할을 하며, 입력 층에 존재하는 뉴런들은 출력 층에

있는 뉴런 전체와 연결이 되어 있고 각각의 연결선은 연결강도(weight)를 나타낸다. 입력패턴이 출력 층에 투영되면서, 출력 층에 존재하는 뉴런들은 정해진 학습 알고리즘의 규칙인 유사성의 정도를 두고 서로 경쟁을 한다. 이 때 유사성의 척도로는 유클리디안(Euclidean) 거리가 주로 사용되며, 그 결과 입력패턴과 가장 유사한 연결강도(weight)를 갖는 출력 층 뉴런이 선택 되는데 이를 승리(winner)뉴런이라 한다. 승리 뉴런이 결정되면 이 승리 뉴런을 중심으로 반경 r 을 설정하고 이 범위 내의 모든 뉴런들은 출력 층에서 유사한 연결강도를 갖는 입력패턴에 대응되도록 조절된다. 규정된 반복 횟수만큼 학습이 진행되면 반경 r 과 학습률 $a(t)$ 를 감소시킨 후 다음 학습 과정을 반복하게 된다. 이 과정의 반복을 통해 입력패턴들은 상대적으로 큰 유사성을 가지는 것들끼리 스스로 모이게 되고 그 결과 출력 층은 특징적인 형상을 나타내게 된다.

SOM 학습 알고리즘의 일반적인 방법에 대해 설명하면 다음과 같다.

- 단계 1 : N개의 입력 패턴과 M개의 출력뉴런 사이의 가중치를 임의의 작은 값으로 초기화 한다.
- 단계 2 : 새로운 입력패턴을 입력한다.
- 단계 3 : 입력패턴과 각 출력뉴런 j 의 거리 (d_j)를 구한다.

$$d_j = \sum_{i=0}^{N-1} (X_i(t) - w_{ij}(t))^2 \quad (6)$$

$X_i(t)$: 시각 t 에서의 입력

$w_{ij}(t)$: 시각 t 에서의 i 번째 입력패턴과 j 번째 출력 뉴런 사이 연결강도

- 단계 4 : 최소거리를 갖는 출력뉴런(승리뉴런)을 선택한다.
- 단계 5 : 승리뉴런과 그 이웃 반경 내의 뉴런들의 연결강도를 재조정한다.

$$w_{ij}(t+1) = w_{ij}(t) + a(t)m(t)(X_i(t) - w_{ij}(t)) \quad (7)$$

$m(t)$: 이웃

$a(t)$: 학습률(시간이 경과함에 따라 점차 작아짐), $0 < a(t) < 1$

- 단계 6 : 단계 2에서부터 반복한다.

2.4 DEA를 이용한 기존 벤치마킹 방법 적용의 한계점

DEA를 이용한 기존의 벤치마킹 방법을 적용할 경우 발생할 수 있는 한계점을 이해하기 위해 다음 <Table 1>의 예제 데이터를 이용하여 설명한다. <Table 1>의 데이터는 Copper *et al.* (2006)가 제시한 슈퍼마켓의 예제에 본 논문의 방법론에 대한 설명을 용이하게 하기 위하여 데이터를 추가한 것이다.

<Table 1>은 2개의 투입 요소와 1개의 산출 요소를 이용하여 12개 슈퍼마켓의 효율성을 비교하기 위한 데이터들이다. 2개의 투입 요소 x_1, x_2 는 작업자(단위 : 10)와 매장 규모(단위 : 1000 m^2)이고 1개의 산출 요소 y 는 판매 금액(단위 : \$100,000)

을 나타낸다.

Table 1. Supermarket efficiency analysis

Store		A	B	C	D	E	F	G	H	I	J	K	L
Employee	x_1	2	4	8	3	4	5	5	6	7	6	6	7
Floor area	x_2	4	2	1	6	3	2	6	3	3	9	4	7
Sales	y	1	1	1	1	1	1	1	1	1	1	1	1

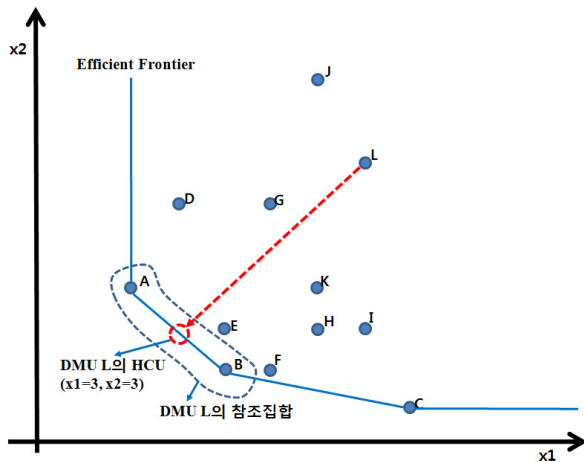


Figure 1. DEA benchmarking

일반적인 DEA를 이용한 벤치마킹의 경우 벤치마킹 대상은 효율성이 가장 높은 집단의 DMU 혹은 HCU(Hypothetical Composite Unit)을 벤치마킹 대상으로 제시한다. 일반적인 DEA를 이용한 벤치마킹 방법을 <Table 1>의 데이터에 적용하면 <Figure 1>와 같다. DMU L은 효율성이 가장 높은 DMU A와 DMU B를 벤치마킹이 가능한 참조집합으로 하고 Efficient Frontier상의 HCU를 가상의 벤치마킹 대상으로 제시 한다. 이는 단번에 가장 효율적인 DMU를 벤치마킹 대상으로 제시함으로써 효율적인 방법일 수 있지만, 효율성의 격차가 큰 경우에는 당장의 벤치마킹 대상이 되는 것이 비합리적일 수 있다. 또한, HCU가 벤치마킹 대상일 경우 실제로 존재하지 않는 가상의 DMU를 벤치마킹 하는 것으로 벤치마킹 대상은 가능하나 실제 벤치마킹에 필요한 추가적인 비교 데이터가 없어 비효과적일 수 있다. DEA를 이용한 벤치마킹에서 효율성 격차가 큰 대상이 선택되는 문제를 해결하기 위해 단계적 벤치마킹 방법이 제시되었으며, 계층화를 통한 방법이 대표적이다.

계층화 모델을 이용하여 Yoon *et al.*(2005)은 공공조직 간의 벤치마킹 정보의 단계적 도출 방법을 제시한 바 있으며 해당 방법론의 개괄적인 도출 방법을 <Table 1>의 데이터에 적용하면 <Figure 2>와 같다. 전체 DMU를 대상으로 5계층으로 계층화 되었고 계층 1이 효율성이 가장 높은 효율적인 경계선(efficient frontier)을 의미하고, 계층 5는 상대적으로 효율성이 가장 낮은 계층을 의미한다. 단계적 벤치마킹에서 계층 5에 존재하는 DMU가 계층 1에 존재하는 DMU를 벤치마킹하기 위해서는

먼저 계층 5보다 상대적으로 효율성이 높은 계층 4에 존재하는 DMU중 가장 효율적인 DMU를 벤치마킹 대상으로 한다. 계층 4의 DMU는 다시 상대적으로 효율성이 높은 계층 3의 DMU들 중 가장 효율성이 높은 DMU를 벤치마킹 대상으로 하고 위와 같은 방법을 반복하여 최종적으로 계층 1에 존재하는 DMU를 벤치마킹 하게 된다. 즉, 계층 5에 존재하는 DMU가 계층 1의 가장 효율적인 DMU를 벤치마킹하기 위해서는 4번의 단계적 벤치마킹을 시행 하게 되는데, 만약 계층의 개수가 많아질 경우 단계적 벤치마킹 횟수도 상대적으로 많아짐을 알 수 있다. 앞서 1장에서 언급한 것처럼 벤치마킹을 위해서는 우수한 상대를 찾는 것 외에 상대의 프로세스 운영 상태 분석, 관리 능력 평가, 최적 모형 구현 등 부가적으로 시행해야 하는 활동들이 많다. 기존의 계층화를 통한 단계적 벤치마킹은 DMU들의 특징을 고려한 효율적인 대상을 찾을 수 있다는 장점이 있지만 반대로 계층이 많이 생성된 경우 벤치마킹의 횟수와 벤치마킹을 위한 부가적인 활동들이 많아지게 되어 과도한 개선 활동을 시행 한다는 비효율성이 존재 한다.




Figure 2. Stratification benchmarking

<Figure 2>의 경우 DMU K와 DMU H, DMU I는 두 개의 투입 요소(Floor Area, Employee)를 기준으로 했을 때 계층은 서로 틀리지만 유사한 위치에 분포하고 있음을 확인할 수 있다. 만약 DMU K와 DMU H가 투입 요소를 고려할 때 서로 유사한 구조를 가진다면 DMU L의 입장에서는 효율성 개선을 위해 DMU K를 대상으로 하는 것과 DMU H를 대상으로 하는 것에 대한 개선 정도의 차이는 크게 없을 것이라 예측할 수 있다. 유사한 투입 요소를 바탕으로 DMU L이 DMU K를 대신하여 DMU H를 벤치마킹 한다면 가장 효율적인 계층에 존재하는 DMU B를 벤치마킹하기 위해 시행해야 하는 벤치마킹 횟수를 줄일 수 있을 것이다. 또한 이는 벤치마킹을 위해 시행하는 부가적인 개선 활동들을 줄일 수 있는 이점으로 작용한다. 이런 측면에서 투입 요소들 간의 유사성을 고려하여 적절한 벤치마킹 대상을 선택할 수 있다면 단계적 개선 및 활동들을 줄일 수 있어 보다 효율적인 벤치마킹 방법이라 판단 할 수 있다. 다음 장

에서는 투입 요소들 간의 유사성을 고려하여 가장 효율적인 집단에 속한 DMU들을 단계적으로 벤치마킹 할 수 있는 경로 선택에 대한 구체적인 방법을 설명한다.

3. 투입 요소 유사성 기반의 벤치마킹 경로 선택 방법

본 장에서는 투입 요소들 간의 유사성을 고려한 단계적 벤치마킹에서 적절한 벤치마킹 대상을 선택하기 위한 개념적인 방법과 구체적인 절차를 설명한다. <Figure 3>는 본 논문에서 제시하는 방법에 대한 개념적인 절차를 나타낸다. 먼저 전체 DMU의 투입 요소를 기반으로 유사한 규모의 DMU들을 그룹화하고 단계적 벤치마킹이 가능하도록 DMU들을 효율성을 기준으로 계층화한다. 다음으로 벤치마킹을 시행하려는 DMU에서 각 계층에 존재하는 DMU들을 대상으로 참조집합과 가중치를 도출한다. 그룹화와 계층화 된 결과를 기반으로 벤치마킹을 시행하려는 DMU에서 가장 근접한 그룹을 선택하고 해당 그룹 내에 존재하는 계층들 중 가장 효율성이 높은 계층의 참조집합을 선택한다. 선택한 참조집합 중 가중치가 가장 높은 DMU를 단계적 벤치마킹의 대상으로 선택하고, 선택된 DMU를 대상으로 다음 최적 경로를 찾기 위해 앞서 설명한 방법으로 효율적 경계선 상의 DMU가 선택될 때까지 반복한다.

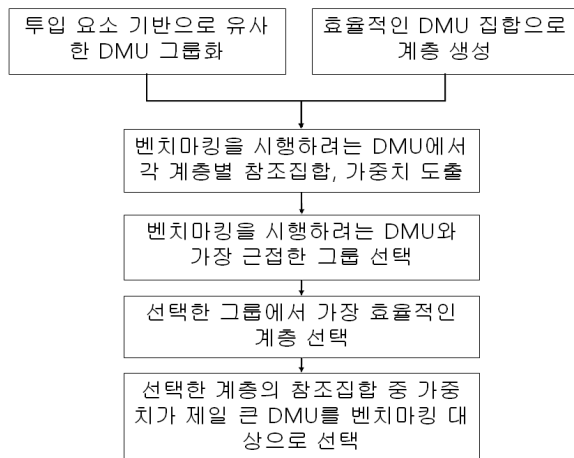


Figure 3. Conceptual procedure of benchmarking method based on the input-similarity

앞서 제시한 방법을 위해 다음과 같은 기법들을 적용하였다. 투입 요소를 기반으로 유사한 DMU들을 그룹화하기 위해 SOM기법을 적용하였고, 계층화 모델 DEA를 적용하여 효율적인 DMU별로 계층을 생성하였다. 각 계층에 존재하는 DMU들을 대상으로 벤치마킹을 시행하려는 DMU에서 벤치마킹 대상이 되는 참조집합과 가중치를 도출하기 위해 가변적 벤치마크 모델을 적용하였다. 본 논문에서 제시하는 방법을 좀 더 구체화 하면 <Figure 4>과 같은 모형이 된다. <Figure 4>는 본 논문에서 제시하는 방법에 대한 흐름을 절차화 한 모형으로, 본

모형에 대한 이해를 돕기 위해 <Table 1>의 데이터를 적용하여 실제 벤치마킹 대상을 찾아보도록 한다. <Figure 4>에 적용되는 기호에 대한 정의는 다음과 같다.

- i = 계층 번호($i = 1, 2, \dots, I, I$: 계층화 DEA에 의해 도출된 총 계층의 수)
- r = 그룹 번호($r = 1, 2, \dots, R, R$: SOM에 의해 생성된 총 그룹의 수)
- j = DMU 번호(DMU_j : j 번째 DMU)
- DMU_{j^*} = 현재 벤치마킹을 시행하려는 DMU
- $lr(DMU_j)$ = DMU_j 가 포함된 계층 번호
- $gr(DMU_j)$ = DMU_j 가 포함된 그룹
- $d(gr(DMU_j), gr(DMU_{j+n}))$ = DMU_j 가 포함된 그룹과 DMU_{j+n} 이 포함된 그룹간의 거리
- Dg_r = r 번째 그룹에 포함된 DMU들의 집합
- Di_i = i 번째 계층에 포함된 DMU들의 집합
- $De_{j^*}^i$ = DMU_{j^*} 가 참조집합으로 가지는 Di_i 에 소속된 DMU 집합
- λ_j^* = DMU_{j^*} 가 DMU_j 를 참조집합으로 가질 때의 가중치 값
- $CE(DMU_{j^*}, DMU_j) = DMU_{j^*}$ 와 DMU_j 의 투입 요소 유사성 평가함수(식 (8) 참조).

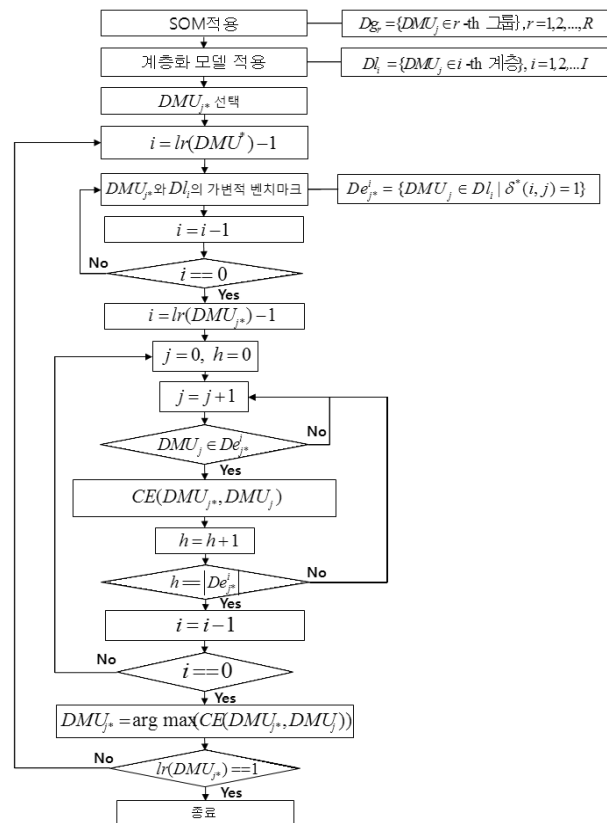


Figure 4. Flowchart of the benchmarking method based on the input-similarity

<Table 1>의 데이터에서 투입 요소를 기준으로 SOM 기법을 시행하면 <Figure 5>와 같이 투입 요소간의 유사성 그룹이 형성된다. 본 논문에서는 SOM을 실행하기 위해 NNclust라는 엑셀 기반의 프로그램을 사용하였고, <Table 1>의 두 개의 투입 요소(Floor Area, Employee)를 입력 변수로 하였다. 관측수(number of observation)는 200, 훈련주기(training cycle)는 100, 학습변수(learning parameter)는 시작을 0.9, 종료를 0.1로 하였고 지도 내 유사성 집단 개수는 4×4모형을 실험 조건으로 하여 시행하였다.

<Figure 5>에서 전체 16개의 그룹 중 5개의 그룹에 DMU들이 분포되어 있음을 확인 할 수 있다. 각 그룹에서 좌측 아래의 숫자는 그룹 번호를 의미하고 둥근 점은 그룹에 분포된 DMU를 의미한다. 각 그룹에 위치하는 DMU들의 집합을 Dg_r 로 나타낼 수 있으며 Dg_r 은 r번째 그룹에 존재하는 DMU의 집합으로 <Figure 4>에서 Dg_1 은 DMU L, Dg_4 은 DMU K, H, I, C의 집합이 된다.

본 논문에서는 각 그룹간의 거리가 멀수록 유사성은 떨어진다는 원칙을 바탕으로 유사성을 수치화하기 위해 같은 그룹은 0.5, 상하좌우 그룹은 거리를 1로 가정하여 계산한다.




Figure 5. Result of SOM

$d(gr(DMU_j), gr(DMU_{j+n}))$ 은 $gr(DMU_j)$ 과 $gr(DMU_{j+n})$ 의 거리로서 <Figure 5>에서 $gr(DMU_j)$ 이 3이고 $gr(DMU_{j+n})$ 이 4일 경우 $d(gr(DMU_j), gr(DMU_{j+n}))$ 은 1이 되고, $gr(DMU_j)$ 이 3이고 $d(gr(DMU_j), gr(DMU_{j+n}))$ 이 8일 경우에는 $d(gr(DMU_j), gr(DMU_{j+n}))$ 은 $\sqrt{2}$ 가 된다.

투입 요소간의 유사성을 기반으로 각 그룹간의 거리를 구한 후 계층화 모델 DEA를 이용하여 DMU들을 계층화 하면 총 1개의 계층으로 계층화가 이루어지는데 <Table 1>의 경우에는 총 5 계층으로 계층화 된다. 각 계층에 분포하고 있는 DMU의 집합은 Dl_i 로 표기할 수 있으며 계층 4에 존재하는 DMU 집합 Dl_4 는 DMU K, DMU I가 된다. 현재 벤치마킹을 시행하려는 DMU_j^* 는 DMU L이라고 할 때 $lr(DMU_j^*)$ 은 계층 5가 되고, 상대적으로 효율성이 높은 단계의 계층을 대상으로 가변적 벤

치마킹 모델을 적용하면 <Figure 6>과 같이 각 계층마다 DMU L의 참조집합과 가중치 값을 구할 수 있다. 각 계층별 참조집합은 De_L^i 로 표기 할 수 있으며, 계층 4의 경우 De_L^4 는 DMU K 이고 계층 3의 De_L^3 은 DMU G와 DMU H, 계층 2의 De_L^2 은 DMU D와 DMU E, 계층 1의 De_L^1 은 DMU A와 DMU B가 된다. 이때 각 계층별 DMU의 가중치 λ_j^* 는 각각 1, 0.75, 0.25, 0.2, 0.75, 0.5, 0.5가 된다.

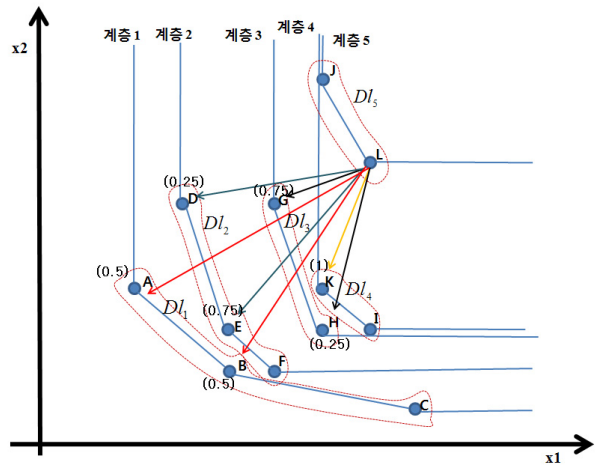


Figure 6. Variable benchmarking model at DMU L

<Figure 7>은 <Figure 6>의 DMU L에서 가변적 벤치마크 모델을 적용하여 도출한 참조집합에 <Figure 5>의 투입 요소 유사성 그룹을 표시한 것이다. <Figure 7>에서 벤치마킹을 시행하려는 DMU L은 그룹 3에 존재하고 이와 가장 근접한 위치에 있는 그룹 4의 DMU K와 DMU H는 DMU L의 참조집합이 된다.

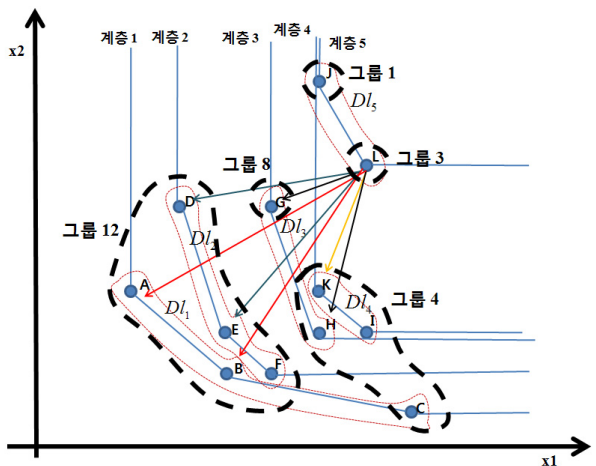


Figure 7. Variable benchmarking model with result of SOM at DMU L

투입 요소의 유사성을 기반으로 최적의 벤치마킹 경로를 구하기 위해 벤치마킹을 시행하려는 DMU에서 상대적으로 효율

성이 높은 계층의 $De_{j^*}^i$ 를 대상으로 식 (8)의 유사성 평가 함수를 계산한다.

$$CE(DMU_{j^*}, DMU_j) = \frac{1}{d(gr(DMU_{j^*}), gr(DMU_j))} + w_1((lr(DMU_{j^*}) - lr(DMU_j)) + \lambda_j^*), \quad w_1 \leq 0.01 \quad (8)$$

$CE(DMU_{j^*}, DMU_j)$ 는 현재 벤치마킹을 시행하려는 DMU_{j^*} 로부터 상대적으로 효율성이 높은 계층의 $De_{j^*}^i$ 를 대상으로 그룹간의 거리와 계층 간의 차이와 가중치 값을 이용하여 벤치마킹 대상을 평가하는 함수이다. 본 함수는 상대적으로 효율성이 높은 계층의 $De_{j^*}^i$ 중 DMU_{j^*} 에서 그룹간의 거리가 가장 가까운 DMU들을 대상으로 DMU_{j^*} 가 존재하는 단계와 가장 멀리 떨어진 단계의 DMU들 중 가중치가 가장 큰 DMU가 가장 높은 값을 가지도록 수식화 되어있다. 투입요소 유사성 평가 함수에서 $\frac{1}{d(gr(DMU_{j^*}), gr(DMU_j))}$ 은 상대적으로 효율성이 높은 계층의 $De_{j^*}^i$ 를 대상으로 가장 가까운 거리에 위치한 유사성 그룹이 큰 값을 가지도록 그룹간의 거리에 역수를 취한 것을 의미하고, $w_1((lr(DMU_{j^*}) - lr(DMU_j)) + \lambda_j^*)$ 은 유사성 그룹간의 거리가 가장 근접한 DMU를 대상으로 상대적으로 효율성이 높은 단계의 DMU들 중 λ_j^* 가 가장 큰 DMU가 선택 되도록 계층 간의 차이 값과 λ_j^* 의 합에 0.01이하의 가중치 값을 곱하는 것을 의미한다. 여기서 $((lr(DMU_{j^*}) - lr(DMU_j)) + \lambda_j^*)$ 를 w_1 로 곱하는 이유는 유사성 그룹간의 거리에는 상대적으로 높은 가중치를 주고 계층 간의 차이와 λ_j^* 값에는 상대적으로 낮은 가중치를 주기 위함이다.

$De_{j^*}^i$ 를 대상으로 $CE(DMU_{j^*}, DMU_j)$ 를 계산한 값 중 가장 큰 값을 가진 DMU_j 를 DMU_{j^*} 의 단계적 벤치마킹의 대상으로 정한다. w_1 을 0.01로 하여 DMU L에서 상대적으로 효율성이 높은 계층의 $De_{j^*}^i$ 를 대상으로 $CE(DMU_{j^*}, DMU_j)$ 를 구하면 <Table 2>와 같다.

Table 2. Result of $CE(DMU_{j^*}, DMU_j)$ at DMU L

계층	4	3	2	1			
DMU	K	G	H	D	E	A	B
결과값	1.020	0.735	1.025	0.480	0.485	0.492	0.492

<Table 2>에서 $CE(DMU_{j^*}, DMU_j)$ 값이 가장 큰 DMU H가 DMU L의 단계적 벤치마킹 대상이 되고, 다음의 단계적 벤치마킹 대상을 구하기 위해 DMU_{j^*} 는 DMU H, $lr(DMU_j)$ 는 계층 3이 된다. 앞서 진행한 방법과 동일하게 DMU_{j^*} 에서 상대적으로 효율성이 높은 계층을 대상으로 단계별 참조집합 $De_{j^*}^i$ 와 가중치 λ_j^* 를 구한다. DMU_{j^*} 에서 상대적으로 효율성이 높

은 계층의 $De_{j^*}^i$ 를 대상으로 $CE(DMU_{j^*}, DMU_j)$ 값 중 DMU B가 최대의 값을 가지게 되어 DMU H의 벤치마킹의 대상이 된다. 여기서 DMU B는 효율성이 가장 높은 계층 1의 DMU이므로 모든 벤치마킹 과정을 종료한다. 앞서 진행한 과정을 종합하여 DMU L에서 투입 요소의 유사성을 고려한 최적의 단계적 벤치마킹 경로는 DMU H와 DMU B를 벤치마킹 하는 것으로 결정 된다.

4. 사례연구

사례연구는 동아시아 항만을 대상으로 하였으며 데이터의 가용성 및 불완전한 정보를 제외한 22개의 항만을 최종 분석 대상으로 선정하였다. 분석에 사용된 자료와 변수는 Containerization International Year book 2005의 내용 중에서 발췌하였으며 투입물은 선석수, 선석길이(m), 수심(m), 부두총면적(m²), G/C 장비(Yard Gantries, Quarry Cranes)를 사용하였으며 산출물은 총 처리물동량(TEU)을 사용하였다. DMU들은 22개의 동아시아 항만이 되며 투입물을 대상으로 SOM을 이용하여 제 3장과 동일한 실험 조건으로 유사성을 분석하면 <Table 3>과 같다. 총 25개의 그룹으로 지도를 구성하였는데 각 DMU들은 10개의 유사한 집단으로 그룹화 되고 각 그룹은 최대 5개의 DMU가 유사한 집단으로 존재함을 확일 할 수 있다. <Table 4>는 전체 DMU를 대상으로 계층화 모델 DEA를 적용하여 DMU들을 계층화 한 결과이다. 총 6계층으로 계층화 되었으며 상대적으로 가장 효율성이 높은 계층 1에는 홍콩, 상하이, 선전, 샤이먼이 존재하고, 상대적으로 가장 효율성인 낮은 계층 6에는 고베, 광양이 존재 한다. 계층 6에 존재하는 광양을 벤치마킹을 시행하려는 DMU로 하여 상대적으로 효율성이 높은 계층을 대상으로 가변적 벤치마크 모델을 적용하면 계층 5에는 오사카, 인천, 계층 4에는 도쿄, 계층 3에는 텐진, 계층 2에는 카오슝, 닝보, 그리고 계층 1에는 선전이 각 계층에 존재하는 참조 집합이 된다. 계층 6의 광양 보다 효율성이 높은 계층에 존재하는 참조집합 DMU들을 대상으로 w_1 을 0.01로 하여 $CE(DMU_{j^*}, DMU_j)$ 값을 구하면 계층 4의 도쿄가 1.0238로 가장 큰 값을 가진다. 즉 광양의 제일 처음 단계적 벤치마킹 대상은 도쿄가 되고, 도쿄를 대상으로 다시 상대적으로 효율성이 높은 계층의 DMU들에 가변적 벤치마크 모델을 적용하면 계층 3에는 칭다오, 텐진, 계층 2에는 카오슝, 닝보, 그리고 계층 1에는 선전이 참조 집합이 된다. 도쿄보다 효율성이 높은 DMU들을 대상으로 $CE(DMU_{j^*}, DMU_j)$ 값을 구하면 계층 2의 닝보가 1.0250로 가장 큰 값을 가진다. 닝보를 대상으로 효율성이 높은 계층의 DMU들에 가변적 벤치마크 모델을 통해 $CE(DMU_{j^*}, DMU_j)$ 값을 구하면 계층 1의 선전이 가장 큰 값을 가지게 된다. 선전은 계층 1에 존재하는 DMU이므로 모든 벤치마킹 과정을 종료하고 최종적으로 광양은 도쿄, 닝보를 거쳐 선전을 단계적으로 벤치마킹 하게 된다. 즉, 이는 투입 요소의 유사성을 기반으로

로 광양이 가장 효율적인 계층에 존재하는 선전을 벤치마킹하기 위해 총 3번의 단계적 벤치마킹을 시행하면 된다는 것을 의미하고 이는 기존의 계층화 방법을 이용한 단계적 벤치마킹에서 5번의 벤치마킹을 시행해야 하는 것에 비해 적은 횟수의 벤치마킹으로 가장 효율적인 DMU를 벤치마킹 할 수 있음을 의미한다.

Table 3. SOM model of east-asia port

선전	부산, 카오슝, 칭다오, 요코하마			홍콩, 상하이
	다롄	광양	광저우, 도쿄, 오사카	닝보, 톈진
			푸저우, 고베, 나고야, 기룡, 타이중	
		레윈강, 인천		
사이먼				

Table 4. Stratification of east-asia port

계층 1	계층 2	계층 3	계층 4	계층 5	계층 6
홍콩 상하이 선전 사이먼	부산 카오슝 닝보	칭다오 톈진 광저우 기룡 레윈강	도쿄 다롄 나고야	요코하마 오사카 타이중 인천 푸저우	고베 광양

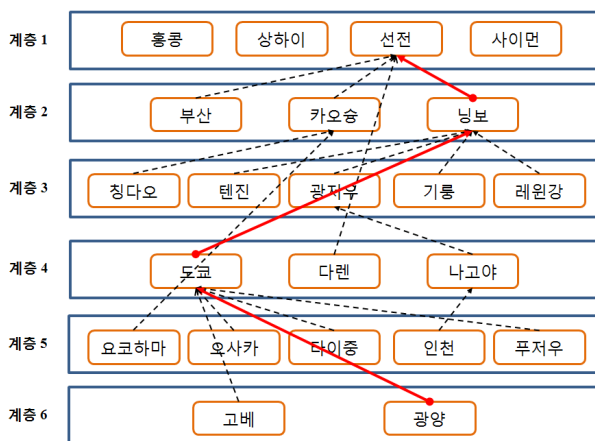


Figure 8. Benchmarking route based on input-similarity of east-asia port

22개의 동아시아 항만의 투입 요소 유사성을 기반으로 한 효

율적인 벤치마킹 경로는 <Figure 8>과 같다. 광양과 함께 가장 효율성이 낮은 고베는 광양과 동일하게 도쿄와 닝보를 거쳐 선전을 벤치마킹 하게 되고, 계층 5의 요코하마의 경우 카오슝을 거쳐 선전을 벤치마킹 하게 된다. 모든 DMU들은 최종적으로 선전을 벤치마킹 대상으로 하게 되는데 이는 단계적 벤치마킹에서 선전이 존재하는 그룹과 가장 근접한 위치에 계층 2의 DMU들이 존재하기 때문에 가장 근접한 유사성을 보이는 선전을 벤치마킹함을 알 수 있다.

5. 결론

본 논문은 계층화를 이용한 단계적 벤치마킹 방법에서 투입 요소의 유사성 기반의 벤치마킹 경로 선택 방법을 제안 하는데 목적이 있다. 이를 위해 SOM 기법을 이용하여 전체 DMU들을 투입요소 유사성을 기반으로 그룹화 하였고, 계층화된 모델에서 가변적 벤치마크 모델을 이용하여 각 계층별로 참조 집합과 가중치를 도출하였다. 투입 요소의 유사성과 계층화에 의한 각 계층별 참조집합을 대상으로 현실적으로 의미를 가지는 유사한 범위 내에서 벤치마킹 대상을 선택 하는 방법을 제시하였고 동아시아 22개의 항만을 대상으로 사례연구를 실시 하였다. 사례연구 결과 가장 효율성이 낮은 계층의 광양이 가장 효율성이 높은 계층의 항만을 벤치마킹하기 위해 도쿄, 닝보, 선전을 대상으로 단계적으로 벤치마킹하게 됨을 알 수 있다. 본 논문에서 제시한 투입 요소 유사성 기반의 단계적 벤치마킹 대상 선택 방법을 통하여 불필요하게 많은 벤치마킹을 피하면서도 적절한 수준에서 벤치마킹 대상이 결정되는 이점이 발생한다. 이로 인해 벤치마킹을 위한 부가적인 활동들을 줄일 수 있어 합리적 대상선정과 목표수립에 유용하리라 판단 된다.

본 논문의 유용성에도 불구하고 향후 투입과 산출을 모두 고려하였을 경우 유사성 기반의 단계적 벤치마킹 횟수를 최적화 하는 방법과 유사성을 위한 다양한 기법을 적용한 연구가 필요하리라 판단된다.

참고문헌

Alirezaee, M. R. and Afsharian, M. (2007), Model improvement for computational difficulties of DEA technique in the presence of special DMUs, *Applied mathematics and Computation*, **186**(2), 1600-1611.
 Ammons, D. N. (2002), Benchmarking as a performance management tool: experiences among municipalities in North Carolina, *European Journal of Operational Research*, **140**, 249-265.
 Charnes, A., Cooper, W. W., and Rhodes, E. (1978), Measuring the efficiency of decision making units, *European Journal of Operational Research*, **2**, 429-444.
 Cooper, William W., Lawrence M. Seiford, and Kaoru Tone (2006), Introduction to Data Envelopment Analysis and Its uses : with DEA solver software and reference, *Interface*.

- Donthu, N., Hershberger, E. K., and Osmonbekov, T. (2005), Benchmarking marketing productivity using data envelopment analysis, *Journal of Business Research*, **58**(11), 1474-1482.
- Gonzales, E. and Alvarez A. (2001), From efficiency measurement to efficiency improvement : The choice if a relevant benchmark, *European Journal of Operational Research*, **133**(3), 512-520.
- Grupp, H. (1990), Technometrics as a missing link in science and technology indicator, *Measuring the Dynamics of Technological Change*, 57-76.
- Hong, H-K., Ha, S-H., Shin, C-K., Park, S-C., and Kim, S-H. (1999), Evaluating the efficiency of system integration projects using data envelopment analysis and machine learning, *Expert System with Applications*, **16**(3), 283-296.
- Haykin S. (1999), Neural networks a comprehensive foundation, *Prentice Hall*, **1-45**, 443-483.
- Joe Zhu (2003), Quantitative models for performance evaluation and benchmarking-Data Envelopment Analysis with Spreadsheets and DEA Excel Solver, *Kluwer Academi Publishers*.
- Kohonen, T. (1988), An introduction to neural computing, *Neural Networks*, **1**, 3-16.
- Ross, A. and Droge, C. (2002), An integrated benchmarking approach to distribution center performance using DEA modeling, *Journal of Operations Management*, **20**, 19-32.
- Sharma, M. J. and Yu, S-J. (2009), Performance based stratification and clustering for benchmarking of container terminals, *Expert System with Application*, **36**, 5016-5022.
- Spendolini, M. J. (1992), The benchmarking book, *America management association*, New York
- Tata, J., Prasad, S., and Motwani, J. (2000), *Benchmarking quality management practices : U.S. Versus Costa Rica*, *Multinational Business Review*, **8**(2), 37-51.
- Shaneth A. E., Hee, S-S., Young, A-K., Su, H-N., and Shin, C-K. (2009), A method of stepwise benchmarking for inefficient DMUs based on the proximity-based target selection, *Expert Systems with Applications*.
- Yoon, K-J., Choe, S-Y., and Kang, J-S. (2005), Using DEA to draw stepwise benchmarking information for public organizations, *The Korean Association For Public Administration*, **39**(2), 233-262.