

초기 제품 설계 단계에서 제품군의 근사적 전과정 평가

박지형*(KIST, CAD/CAM 연구센터), 서광규(KIST, CAD/CAM 연구센터)

Approximate Life Cycle Assessment of Product Family in Early Product Design Stage

Ji-Hyung Park(CAD/CAM Research Center, KIST), Kwang-Kyu Seo(CAD/CAM Research Center, KIST)

ABSTRACT

This paper proposes an approximate LCA methodology for the conceptual design stage by grouping products according to their environmental characteristics and by mapping product attributes into impact driver (ID) index. The relationship is statistically verified by exploring the correlation between total impact indicator and energy impact category. Then an artificial neural network model is developed to predict an approximate LCA of grouping products in conceptual design stage. The training is generalized by using identified product attributes for an ID in a group as well as another product attributes for other IDs in other groups. The neural network model with back propagation algorithm is used and the results are compared with those of multiple regression analysis. The proposed approach does not replace the full LCA but it would give an approximate LCA results for design concepts.

Key Words : Approximate Life Cycle Assessment (근사적 전과정 평가), impact driver (환경영향 드라이버), product attribute (제품 속성), artificial neural networks (인공신경망)

1. 서론

환경에 대한 관심이 고조되고 이에 대응하기 위한 국내외의 규제와 무역장벽이 강화되면서 이에 대한 적절한 대응책이 요구되고 있으며, 이에 대한 요구로써 제품의 life cycle 동안의 환경성을 평가하기 위한 개념으로 시작된 방법이 LCA (Life Cycle Assessment; 전과정 평가) 기법이다.

LCA 기법은 제품의 전과정 (life cycle)에 대한 환경영향을 분석하여 매우 유용한 결과를 제공하여 주는 매우 강력한 도구이고 가장 범용적으로 사용되고 있는 방법이다⁽¹⁾. 그러나 LCA 기법은 이러한 장점에도 불구하고, full LCA를 수행하는데 많은 시간과 비용이 소요된다는 단점이 있고 이를 제품설계자 이해하기 어려운 전문적인 환경 지식이다.

기존의 연구들에서는 full LCA 적용을 보다 간단하게 하기 위한 여러 가지 방법론들이 제안되었는데, 이를 위해 수행된 내용중에 가장 대표적인 방법이 단순화 (Streamlining) LCA이다⁽²⁾. 그러나 단순화 LCA는 full LCA 결과와 비교해 보면 정확도가 상대적으로 낮다는 단점을 가지고 있다.

기존의 연구들에서는 LCA를 간단하게 수행하기 위한 다양한 방법론들이 개발되었으나, 제품의 설계초기 단계에서는 LCA 사용하기가 용이하지 않다. 그 이유는 설계초기 단계에서는 아이디어가 다

양하고, 제품특성에 대한 상세정보가 부족하고, 환경영향평가 데이터가 부족하기 때문이다.

따라서, 본 논문에서는 이러한 문제점을 극복하기 위하여 제품을 그 특징 (characteristic)에 따라 그룹핑하여 제품군을 형성하고, 제품군내의 제품들을 대상으로 하여 근사적 (approximate) LCA를 수행하기 위한 방법론을 제안한다. 제안하는 방법론은 제품 설계자가 초기 설계 단계에서 제품의 속성 정의와 이를 통해 제품의 LCA를 평가할 수 있는 새로운 방법론이다.

2. 근사적 LCA 방법론의 overview

본 연구에서 제안하는 새로운 환경영향평가 방법론은 그룹 테크놀로지 (Group Technology; GT) 기법을 이용하여 제품들을 그룹핑 범주 (Grouping Category)에 맞게 분류하여 그룹핑된 제품군 내에서 제품의 근사적인 LCA를 수행하기 위한 방법이다.

본 연구의 주요 연구 내용은 다음과 같다. 먼저 대상제품들을 대상으로 하여 대상제품들을 각각의 목적을 만족시키는 그룹핑 범주 (Grouping Category)별로 제품들을 제품군으로 분류하고, 이렇게 분류된 제품군내의 제품들을 대상으로 제품군의 환경 특성치와 이 환경 특성치를 대표할 수 있는 "환경영향 드라이버 (Impact Driver; ID)"라는 새로

운 인덱스 (index)를 제시하고, ID 와 제품 속성들 (product attributes)간의 관계를 추적 (trace)하여 최종적으로 제품속성들 (product attributes)과 환경 영향 (impact categories)간의 관계를 규명하여, 초기 개념 설계 단계에서 제품의 LCA 를 근사적으로 수행하는 것이다.

본 논문에서 제안하는 방법론을 위한 전체 연구수행 과정은 Fig. 1 과 같고, 구체적인 연구 내용은 Fig. 1 의 단계에 따라 기술하기로 한다.

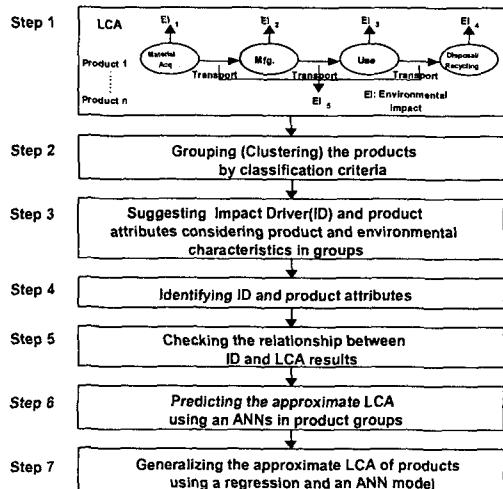


Fig. 1 Procedure of an approximate LCA of classified products

3. 제품군내 제품들을 위한 근사적 LCA 방법론 개발

3.1 그룹핑 방법 (Grouping Approach)

Fig. 1 의 단계 1 과 단계 2 에서는 제품의 특징 (characteristic)에 따라 제품을 그룹핑하는 단계이다. 본 연구의 단계 2 에서는 이미 분석된 제품의 LCA 결과를 이용하여 제품의 특성에 따른 제품군으로 그룹핑하였다. Fig. 1 의 단계 1 에서 보듯이 환경 영향은 크게 다섯 개의 범주 (EI₁~EI₅)로 구분하였다. 제품들의 환경 특성에 의해 그룹핑된 제품군들은 제품군의 환경 특성치와 이 환경 특성치를 대표할 수 있는 “환경 영향 드라이버 (Impact Driver; ID)”라는 새로운 지수 (index)를 유도하는데 사용된다.

본 연구에서 제안된 그룹핑 범주는 다음과 같다^(3,4).

- (1) Ranking the life cycle phase impact indicator
- (2) Top impact indicator class
- (3) Hierarchical clustering attempt
- (4) Preliminary product classification into general categories
- (5) Product classification according to functional properties

본 연구에서는 150 개의 제품을 대상으로 하여 그룹핑을 수행하였다. 예를 들면, 제시한 방법(2)을

적용하여 그룹핑하면, 제품들이 5 개의 제품군으로 분류되고, 그 내용은 다음과 같다.

- 그룹 1: 온실효과 (greenhouse effect)에 가장 많은 영향을 미치는 제품군
- 그룹 2: 에너지(energy) 소모가 가장 많은 제품군
- 그룹 3: 스모그 (winter/summer smog)에 가장 많은 영향을 미치는 제품군
- 그룹 4: 산성화 (acidification)에 가장 많은 영향을 미치는 제품군
- 그룹 5: 오존층 소멸 (ozone depletion)에 가장 많은 영향을 미치는 제품군

마찬가지로 다른 그룹핑 방법을 적용하여도 각각의 그룹핑 범주에 맞는 제품군이 형성된다.

3.2 환경영향 드라이버 (Impact Driver; ID)와 제품 속성 (Product Attributes)의 개발

Fig. 1 의 단계 3 과 4 에서는 분류된 제품군을 대표할 수 있는 환경영향 드라이버 (ID: Impact Driver)를 제시하고 제품 속성들을 개발하는 단계이다. 그리고 단계 5 에서는 제안된 ID 와 상관관계가 있는 제품 속성들(product attributes)을 확인한다.

예를 들면, 그룹핑 방법 (2)를 적용하면 5 개의 제품군이 형성되는데, 제품군 1 (그룹 1)은 온실 효과 영향 범주에 가장 많은 영향을 미치는 제품군이므로, 제품군 1 의 ID 는 ID_{greenhouse} 로 제안할 수 있고, 제품군 2 (그룹 2)는 energy 가 주된 환경영향이므로, 제품군의 ID 는 ID_{energy} 로 제안할 수 있다.

본 연구에서는 ID_{energy} 를 예를 들어 제안한 근사적 LCA 방법론에 대하여 설명하기로 한다. 본 연구에서 150 개의 제품을 대상으로 그룹핑 범주에 의해 그룹핑한 결과 에너지(energy) 소모가 많은 제품군에서 30 개의 제품들이 포함되었고 그 제품들은 가전제품과 자동차였다.

또한, 단계 3 에서는 ID 와 함께, 제품의 초기 설계 단계에서 설계자가 쉽게 이해할 수 있고 의미 있는 제품 속성들 (product attributes)도 제안하고 확인한다. 제안한 ID 와 제품속성들은 다음과 같은 함수로 표현할 수 있다. 예를 들면 위에서 제안한 ID_{energy} 지수 (index)는 다음과 같이 표현할 수 있다.

$$ID_{energy} = f(x_1, x_2, x_3, x_4, x_5) \quad (1)$$

where, x₁: lifetime, x₂: use time, x₃: mode of operation, x₄: in use energy source, and x₅: in use power consumption.

식 (1)에서의 ID_{energy} 를 구성하는 변수들인 x₁, x₂, x₃, x₄, x₅ 는 확인된 제품 속성들 중 에너지 소모와 관계가 있다고 생각된 제품 속성들의 전문가들과의 브레인스토밍 (Brainstorming) 과정을 거쳐서 선정하였다.

여기서 제안한 새로운 ID_{energy} 는 환경영향 범주 (energy)와 연관이 있으며, 새로운 지수 ID_{energy} 는 에너지와 관련이 있는 제품 속성들 (product

attributes)을 변수 (parameter)로 갖는 함수 (function)로 표현된다. 물론 이를 변수들간의 관계는 수리적 혹은 통계적 기법으로 유도될 수 있다.

식 (1)에서 제안된 지수 ID_{energy} 와 이를 구성하는 변수 x_1, x_2, x_3, x_4, x_5 변수들간의 상관관계 규명하기 위하여 본 연구에서는 피어슨 상관계수를 계산하였는데, 그 결과는 Table 1 과 같다. 분석 결과를 살펴보면, 5 개의 변수가 제안된 ID_{energy} 와 상관관계가 있음을 확인할 수 있다.

Table 1. The correlation coefficients and tests between ID_{energy} vs. parameter x_1, x_2, x_3, x_4 , and x_5

The parameters	the coefficient of correlation
x_1	0.43
x_2	-0.24
x_3	-0.27
x_4	0.83
x_5	0.99

다음 단계에서는 변수 변수 x_1, x_2, x_3, x_4, x_5 와 새로운 지수 ID_{energy} 와 선형관계를 유도하고 결정계수 (R^2)를 통한 통계적 검정을 수행한다. Table 2 는 변수 x_1, x_2, x_3, x_4, x_5 와 새로운 지수 ID_{energy} 와 선형관계를 검정하기 위하여 수행한 중회귀 분석 결과를 보여주고 있다.

Table 2. The results of multiple regression analysis between 5 parameters and ID_{energy}

Statistics of regression analysis	
multiple coefficient	0.99
R-squared	0.99
adjusted R-squared	0.99
Obs	30

ANOVA Table				
Source	DF	Sum of Squares	Mean Squares	F value
Model	5	3.19651E+12	6.39302E+11	1234.31
Error	24	12430667565	517944481.9	
Total	29	3.20894E+12		

Table 2 의 중회귀 분석 결과를 보면 결정계수 (R^2)가 0.99 이다. 결정계수(R^2)가 0.99 라는 의미는 변수 x_1, x_2, x_3, x_4, x_5 들이 지수 ID_{energy} 의 변동을 99%로 충분히 설명해 주고 있다는 의미이다. 따라서, $ID_{energy} = f(x_1, x_2, x_3, x_4, x_5)$ 가 의미가 있고, 이 수식이 성립함이 보여준다.

또한 분산분석표 (ANOVA Table)에서 F 값이 1388.59 이므로, 중회귀식의 변수들은 모두 유의하다. 따라서, 새로운 ID 와 변수들 (product attribute)간의 의미가 있음을 통계적으로 확인하였다.

다음 단계에서는 그룹핑된 제품군내에서 본 연구에서 제안한 ID 가 제품군의 환경영향을 대표할 수 있는지를 검증하였다. 이를 위하여 ID_{energy} 와 제품군내의 제품들에 대한 전체 환경영향과 ID_{energy} 간의 관계를 회귀분석을 이용하여 평가하였다. 그룹내 제품들의 ID_{energy} 와 총환경영향간의 관계는 식 (2)와 같이 유도되는데, 이를 이용하면 그룹내 제품들의 ID_{energy} 값으로 제품들의 총 환경영향을 근사적으로 구할 수 있다.

$$TI (\text{Total Impact}) = 74.8 + 1.3 ID_{energy} \quad (2)$$

3.3 인공신경망 (ANNs)을 이용한 제품군의 근사적 LCA

본 절에서는 전술한 중회귀 분석이외에 인공신경망을 적용한 새로운 환경영향 평가 방법론에 대하여 기술한다. 이 단계는 Fig. 1 의 단계 6 에 해당하는데 이 단계에서는 제품군내의 제품들에 대하여 전 단계에서 정의한 제품 속성들과 ID 를 각각 입력값과 출력값으로 하는 인공신경망을 이용하여 새로운 제품 개념의 근사적인 LCA 를 수행하는 것이다. 본 절에서 제안된 인공신경망은 역전파 (Backpropagation) 알고리즘을 가지는 신경망을 채택하였다. 인공신경망을 이용하여 학습시킨 결과를 보면 에너지 소모에 많은 환경영향을 미치는 제품으로 분류된 제품군내의 제품들에 대한 에너지 예측 결과는 매우 좋은 결과를 얻을 수 있었고, 그 결과는 Table 3에 나타내었다. 이 분석 결과는 제품군 내의 제품에 대한 근사적인 LCA 가 가능함을 의미한다.

Table 3. The predicted results of group members by using ANNs

Product	Actual LCA	The results of predicted LCA		Relative error (%)	The results of predicted LCA with 15 neurons	Relative error (%)
		1 hidden layer with 10 neurons	1 hidden layer with 15 neurons			
Vacuum cleaner	5110	3910.68	23.47	3846.30	24.73	
Mini-Vacuum Cleaner	176	130.70	25.74	126.30	28.24	
Radio	207	182.68	11.75	185.43	10.42	
Heater	24800	35498.72	-43.14	36014.56	-45.22	
Coffeemaker	3980	4604.86	-15.7	3995.12	-0.38	
Washing Machine	54500	54036.75	0.85	53786.05	1.31	
Refrigerator (small)	268619	2431.54	9.48	2475.06	7.86	
Refrigerator (large)	18777.79	20165.47	-7.39	18496.12	1.5	
TV	24320.37	24325.23	-0.02	23653.99	2.74	
LCD TV	24813.73	25324.89	-2.06	24625.15	0.76	
Average absolute error			13.96		12.32	
Maximum absolute error			43.14		45.22	

* Training sample size is 30, ** Test sample size is 10

4. 중회귀 분석과 인공신경망 모델을 이용한 제품의 근사적 LCA 방법론의 일반화

본 장에서는 제안된 여러가지 IDs 와의 연관성 평가를 통해 확인된 제품속성을 이용하여 제품군내의 제품뿐만 아니라, 제품군외의 일반 제품들도 초기 설계단계에서 근사적인 LCA 를 평가할 수 있는 새로운 방법론을 제안한다 (Fig. 1 의 단계 7). 본 연구에서는 제품의 LCA 를 평가하기 위하여 확인된 제품속성을 독립변수로 하고 ID 를 종속변수로 하는 중회귀분석과 확인된 제품속성을 입력값으로 하고 ID 를 출력값으로 하는 인공신경망을 이용한 제품의 LCA 평가 결과의 우열을 비교하여 보다 우수한 평가 방법론을 채택하기로 한다.

먼저, 에너지와 관계있는 제품 속성들을 상관분석한 결과 모두 21 개의 제품 속성들이 강한 상관관계가 있었다. 확인된 제품 속성들은 각각 중회귀 분석의 독립변수와 인공신경망의 입력값으로 사용되고 환경영향 범주인 ID_{energy} 는 종속변수와 출력

값으로 사용되었다.

확인된 제품속성들을 독립변수로 하고 ID_{energy} 를 종속변수로 하는 중회귀 모델은 다음과 같이 제안되었다.

$$y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \beta_3 x_3 + \beta_4 x_4 + \dots + \beta_{21} x_{21} + \epsilon \quad (3)$$

where, y : predicted LCA (ID_{energy}), x_1 : normalized mass (kg) of products; x_2 : ceramic (% mass); \dots , x_{20} : serviceability (binary); x_{21} : disassemblability (binary), and β_i ($i=1, 2, \dots, 21$) is coefficient

중회귀 분석은 SAS 통계 패키지를 이용하여 분석하였다. 또한 확인된 제품속성들을 입력값으로 하고 ID_{energy} 를 출력값으로 하는 인공신경망을 개발하였다. 이 인공신경망은 입력층에 21 개의 뉴런을 가지고 있고 1 개의 은닉층에 16 개의 뉴런을 가지고 있고, 출력층에는 1 개의 뉴런을 가지고 있는데 그 구조는 Fig. 2 와 같다.

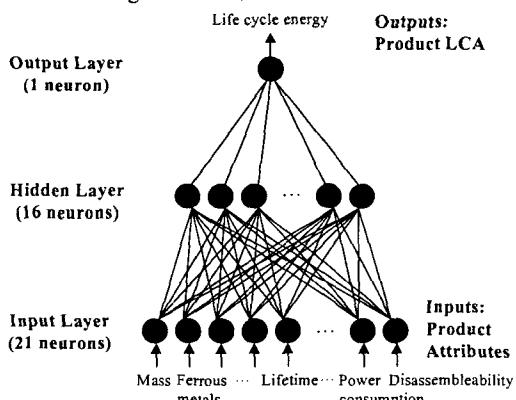


Fig. 2 Structure of the BP neural network to predict the product LCA

제안한 방법을 가지고 제품의 근사적인 LCA 를 평가한 결과를 Table 4 에 나타내었다.

Table 4. Comparison of the predicted results of LCA between the regression and ANN model

Product	Actual LCA	Predicted LCA		Relative error (%)	
		Regression	ANN	Regression	ANN
Vacuum cleaner	5110	4893.85	4686.84	21.38	4.23
Mini-Vacuum Cleaner	176	129.62	122.21	26.35	5.72
Radio	207	170.94	164.53	17.42	3.75
Heater	24800	35235.84	39471.19	-42.08	-12.02
Coffeemaker	3980	4844.85	5097.76	-21.73	-5.22
Washing Machine	54500	49627.70	49682.29	8.94	-0.11
Refrigerator (small)	2686.19	3072.73	3002.98	-14.39	2.27
Refrigerator (large)	18777.79	20762.60	20507.22	-10.57	1.23
TV	24320.37	26047.12	26807.69	-7.1	-2.92
LCD TV	24813.73	24553.19	24430.42	1.05	0.5
Average absolute error				17.1	3.79
Maximum absolute error				42.08	12.02

* Training sample size is 140. ** Test sample size is 10

이 결과를 살펴보면 중회귀분석과 인공신경망 기법 중 인공신경망을 이용하여 LCA 를 평가한 결과가 보다 우수함을 확인할 수 있다. 따라서 향후에는 초기제품을 설계시 인공신경망을 이용한 제품

의 근사적 LCA 평가를 사용하는 것이 더 정확한 예측 결과를 얻을 수 있겠다.

그리고 인공신경망을 이용하여 제품의 LCA 를 평가한 결과를 살펴보면, 일반적으로 제품의 초기 설계단계에서의 LCA 평가 오차는 -30%에서 +30% 의 범위에 있다고 알려져 있는데⁽⁵⁾, 본 연구에서 새롭게 제안한 방법에서는 그 오차 범위가 0.11~12% 로서 그 정확성이 기존의 방법보다 훨씬 더 우수함을 확인할 수 있었다.

5. 결론 및 향후 연구과제

본 연구에서는 제품의 초기 설계 단계에서 설계자가 이해하기 쉬운 제품 속성들을 개발하여 인공 신경망을 기반으로 한 근사적 LCA 방법론을 개발하였다.

먼저, 근사적 LCA 방법론을 위해 제품의 초기 설계 단계에서의 제품의 LCA 예측을 위해, 제품의 속성과 제품의 환경영향 범주를 정의하고 확인하였다. 이를 위해 제품들을 다양한 그룹핑 범주를 적용한 GT 기법을 이용하여 제품군을 분류하였다. 이를 통하여 제품군 내의 환경 특성을 나타내는 환경영향 드라이버 (ID)를 제안하였고, ID 를 제품 속성들의 합수로 나타내고, 이들간의 관계를 규명하여 ID 와 제품 속성간의 관계를 확인하였다.

이렇게 확인된 ID 와 제품 속성을 인공신경망 및 중회귀분석 모델에 적용하여 개념설계 단계에서 제품의 근사적인 LCA 를 수행하였는데, 인공신경망을 이용한 방법이 훨씬 좋은 평가 결과를 보여주었다. 그리고 인공신경망을 이용한 방법은 실제 LCA 값과 예측한 결과값의 절대오차의 범위는 0.11~12%로 매우 우수한 예측값을 얻을 수 있음을 확인할 수 있었고, 제품 속성을 변화시켰을 경우에도 좋은 예측값을 얻을 수 있었다.

향후 연구과제로는 보다 다양한 제품 속성들을 정의가 필요하고, 제품의 특징에 따른 다양한 그룹핑 범주와 이를 적용한 ID 의 확인이 필요하다.

참고문헌

- Curran, M. A., Environmental Life-Cycle Assessment, McGraw-hill, 1996
- SETAC, Streamlined Life-Cycle Assessment: A Final Report from the SETAC North America
- Inês Sousa et al., "Approximate Life-Cycle Assessment of product Concepts Using Learning Systems", Journal of industrial Ecology, pp. 61~81, 2001.
- Hartmut K. and Virginia S., "An approach to simplified environmental assessment by classification of products", Proceeding of 7th CIRP International Seminar on Life Cycle Engineering, pp.163~169, 2000
- Franklin Associates, Ltd., Energy and Environmental Profile Analysis of Children's Disposable and Cloth Diapers. Prairie Village, 1990.