

신경망을 이용한 CIM 데이터베이스의 효율적인 처리 방법

김 선희^{*}, 김 국보^{**}, 정 환목^{*}
^{*} 대구효성기톨릭대학교 천지정보공학부
^{**} 대진대학교 컴퓨터 공학과

An Efficient Approach for Computer Integrated Manufacturing Database Using Neural Network

Kim Sun Hee^{*}, Kim Guk Boh^{**}, Chung Hwan Mook^{*}

^{*}Faculty of Electronic & Info. Engineering, Catholic Univ. of Taegu Hyosung
^{**}Department of Computer Engineering, DaeJin University

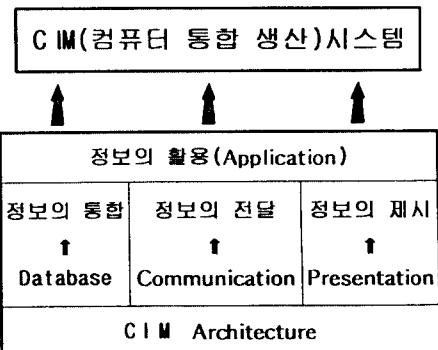
Abstract

One of the consideration issue in implementation and maintanence of CIM(Computer Integrated Manufacturing) database is exchange and sharing of information between heterogeneous databases. For efficient operating of SIM systems, it must be able to organize and to manage the information. In this paper, we propose method that can make enhance the efficiency of CIM database, classfying the data in database using self organize neural network to each database systems, and computing between classfied heterogeneous database using extended operator that is defined.

1. 서 론

시장과 수요의 다양화에 따라 단품종 중·소량 생산 체제로 전환된 현대의 생산 방식은 여러 면에서 매우 복잡한 양상을 나타내고 있다. 특히, 급격하게 발달한 컴퓨터 기술은 생산 시스템에도 큰 영향을 미쳤고, 이에 따라 컴퓨터 통합 생산(CIM)이라는 새로운 생산 방식이 등장하게 되었다.

CIM 시스템이란, [그림 1]에서와 같이 궁극적으로 수요 예측에서 생산 및 판매까지의 제반 기업 업무를 컴퓨터 정보 네트워크로 일체화시키는 것을 의미한다. 즉 제품 주기상의 모든 활동 사항을 포함하는 것으로 신제품의 설계, 기획, 생산 등에 관련된 모든 종류의 자료들이 CIM 데이터베이스의 구성 요소가 되는 것이다. 따라서 성능



[그림 1] CIM의 정의

좋은 로봇이나 공작 기계만으로는 CIM 본래의 의미인 일체화를 달성하기가 어렵다. CIM 시스템

전체를 일체화 시켜주는 데는 “정보”라는 핵심적인 매개체가 존재한다.

CIM 시스템의 효율적인 운용을 위해서는, 방대한 양의 정보를 효과적으로 조작, 관리 및 처리할 수 있는 정보시스템을 필요로 한다. 제품의 생산과 관련된 정보들은 매우 복잡한 특성을 가지고 있기 때문에, 특별히 이와 같은 정보를 다루기 위한 생산정보시스템의 필요성이 증대되고 있다. 생산정보시스템은 다양하고 이질적인 특성을 가진 데이터베이스로부터 경영 및 제조 공정상의 의사 결정에 도움을 주는 정보를 창출해 내는 시스템으로 다양한 종류의 데이터베이스를 이용하여 구축된다. 따라서 생산정보시스템의 효율을 향상시키기 위하여 특별 데이터 및 지식 등의 정보를 효율적으로 처리할 수 있어야 한다.

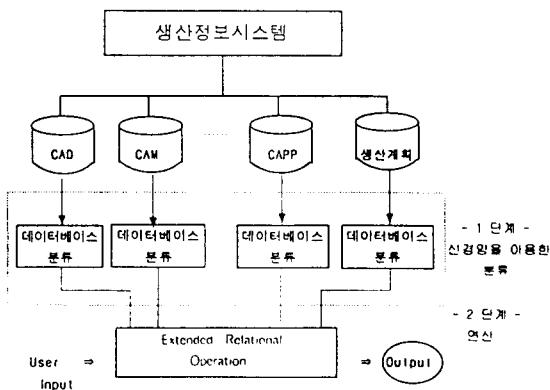
본 논문에서는, 데이터베이스 시스템에 자기조직화 신경회로망을 이용하여 데이터베이스를 분류하고 분류된 데이터베이스 간에 확장 연산자를 도입하여 연산을 수행함으로써 CIM의 다양한 데이터베이스들을 통합하여 관리하고 처리함으로써 시스템의 효율을 향상시킨다.

2. 신경망을 이용한 CIM 데이터베이스

2.1 신경회로망을 이용한

CIM 데이터베이스 구성

본 논문에서 제안하고 있는 신경회로망을 이용한 CIM 데이터베이스의 전체적인 시스템 구성은 [그림 2]와 같다.



[그림 2]. 신경망을 이용한 CIM 데이터베이스 구성

2.2 데이터베이스 분류를 위한

개선된 벡터 양자화법

데이터베이스를 분류하기 위한 개선된 벡터 양자화법을 제안한다.

입력벡터 x 가 속하는 카테고리를 $\Omega(x)$ 로 하고, 그 카테고리에 속하는 참조벡터 중에서 x 에 가장 가까운 참조벡터를 w_1 로 하고, 그 사이의 거리를 d_1 로 한다. 마찬가지로 $\Omega(x)$ 이외의 카테고리에 속하는 참조벡터 중에서 x 에 가장 가까운 참조벡터를 w_2 로 하고 그 사이의 거리를 d_2 로 한다. 입력벡터와 참조벡터와의 거리 계산에는 일반적으로 어떠한 거리를 사용해도 관계없지만 여기서는 간단히 하기 위하여 유clidean 거리를 사용한다.

LVQ에서는 2층의 각각의 뉴런이 자신의 영역을 가지고 있다. 입력벡터는 첫 번째 층과 두 번째 층 사이의 가중치에 의해 어느 쪽으로든 분류되는 것이다. 개선된 LVQ 학습 알고리즘은 다음과 같다.

【단계 1】 네트워크의 초기화

입력층과 출력층 사이의 가중치의 초기값을 난수를 사용하여 작은 값으로 설정한다.

【단계 2】 입력벡터의 입력

우선 입력층에 입력벡터,

$$x = \{x_1, x_2, x_3, \dots, x_n\} \text{ 을 입력}$$

【단계 3】 출력층에서 입력벡터와의 거리 계산

$$\begin{cases} d_1 = |x - w_1| & \text{for } \Omega(w_1) = \Omega(x) \\ d_2 = |x - w_2| & \text{for } \Omega(w_1) \neq \Omega(x) \end{cases}$$

【단계 4】 입력벡터와 그것이 속한 카테고리와의 거리를 계산한다.

$$\mu(x) = \frac{d_1 - d_2}{d_1 + d_2}$$

$\mu(x)$ 는 $-1 \sim +1$ 의 값을 가지며 이 값에 따라 데이터가 분류된다.

【단계 5】 가중치 벡터와의 거리가 최소가 되는 뉴런을 선택한다.

본 논문에서는 $f(\mu)$ 의 비선형성을 간략화하여 다음 조건을 만족하는 입력 벡터 x 에 대해서만, $\mu(x)$ 를 감소시키도록 한다.

$$-\eta < \mu(x) < \varepsilon$$

여기서, $-\eta$, ε 은 양의 실수이다.

[단계 6] 가중치의 학습

조건을 만족하는 입력벡터 x 에 대하여 다음과 같이 참조벡터를 생성한다.

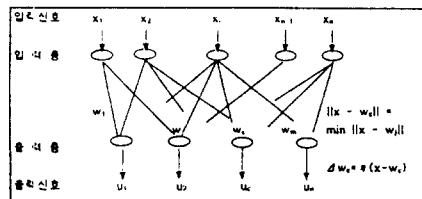
$$\begin{cases} \Delta w_1 = +\alpha(t)(x - w_1) \\ \Delta w_2 = -\alpha(t)(x - w_2) \end{cases}$$

이때, $\alpha(t)$ 는 양의 실수이다. 즉, w_1 을 x 에 가깝도록 하고, w_2 를 x 로부터 멀어지도록 한다.

[단계 7] 단계 2로 되돌아 간다.

2.3 네트워크 구성

LVQ 네트워크의 구성은 자기조직화 특징 맵과 마찬가지로 2층 구조의 신경회로망이다. LVQ 네트워크는 정보 압축이나 패턴 인식이 목적이기 때문에 첫 번째층 보다 두 번째 층의 뉴런의 수가 적은 것이 보통이다. 같은 층의 뉴런 사이에는 결합이 없다.



[그림 3] LVQ 네트워크

[그림 3]에 입력층 뉴런 수 n_i , 출력층 뉴런 수 n_o 는 식별하고자 하는 카테고리 수와 같다. 학습에 이용하는 입력벡터를 x , 시냅스 가중치를 w_{ij} ($i = 1, 2, \dots, n_i$, $j = 1, 2, \dots, n_o$)으로 한다. 여기서 x_m 은 m 번째의 카테고리에 속하는 입력벡터의 집합이다. 또한 시냅스 가중치 w_{ij} 를 구성하는 n 개의 벡터 w_i (w_1, w_2, \dots, w_n)는 참조벡터이다.

3. 응용 예

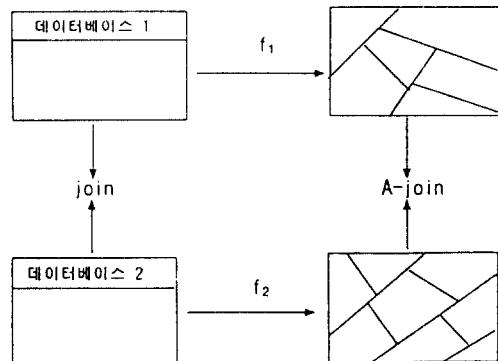
3.1 분류된 데이터베이스들 간의 연산

[표 1]과 같이 5개의 요소를 가진 자동차라는 분류된 리스트가 있다고 가정하자

[표 1] 자동차

이름	연도	가격	용도	수입여부
밴츠	'90	\$50,000	레저용	수입
포르세	'88	\$20,000	레저용	수입
크라이슬러	'90	\$25,000	비즈니스용	수입
그랜저	'95	\$10,000	비즈니스용	국산

join은 많은 유형으로 분류되지만, 근사 join에만 초점을 맞춘다. 각각 N 개의 요소를 가진 두 개의 관계형 데이터베이스간의 join 연산은 $O(n^2)$ 단계를 가지고, H/W 가속은 실시간 응용에서 큰 규모의 데이터베이스에서 요구된다. 그림 20에서 A-join은 참조 데이터 집합들(벡터)간의 join이며, $O(k^2)$ 단계를 가지는데 k 는 본 시스템에서 64~256으로 제한된 참조 데이터(벡터)의 최대 수이고 n 에 대해서 변하지 않는다. 수학적으로 k 는 동등 클래스("유사성"에 근거하여)의 수이고 원래의 집합인 데이터(벡터)의 수인 n 으로부터 상당히 단축된다.



[그림 4] Join 연산

[표 2]는 A-join을 설명하기 위한 고객이라는

새로운 리스트를 소개한다.

[표 2] 고객

고객	사용연도	최대가격	용도	수입여부
고객 1	> '95	< \$10,000	비즈니스용	국산
고객 2	> '87	< \$18,000	레저용	수입

분명히, 고객 1은 join이 두 리스트간에 적용되므로 USED CARS에서 단지 그랜저을 사도록 추천된다. 두 리스트간의 정확한 join은 적용될 수 없지만 A-join은 가능하다. 실제로 포르세와 고객 2는 USED CARS와 고객간의 A-join의 경우이다. 위와 같이 설명된 각 리스트는 참조 데이터(벡터)의 리스트로 보아야 한다.

4. 결론

컴퓨터 통합생산 시스템(CIM : Computer Integrated Manufacturing)에서 중요한 부분을 차지하는 생산정보시스템은 다양한 이종(heterogeneous)의 데이터베이스들로 구성되어 있다. 본 논문에서는 각각의 데이터베이스 내에 자기조직화 신경회로망을 도입하여 데이터를 분류하고, 확장 연산자를 이용하여 연산을 수행하여 신속하게 처리함으로써 생산정보시스템의 효율을 향상시킬 수 있었다.

그러나, 이런 복잡한 시스템을 표현하기 위해서는 상태를 가진 신경회로망을 위한 새로운 알고리즘이 필요하며, 신경망이 근본적으로 가지고 있는 문제점을 해결해야 할 것이다.

참 고 문 헌

- [1] PANEL, : Are Neural Networks a Tool for AI?", Proc, 1991 IEEE Int. Conf. on Tools for AI, San Jose, Nov. 1991.
- [2] S. Nishio, "Knowledge Discovery in Very Large Database", Proc. IPSJ, vol.34, no 3, pp 343-350, 1993.
- [3] Scheer, A. -W. and Alexandar Hars, "From

CIM to enterprise-wide data modeling", ICCIM '91 Conf. Proc., 1991.

[4] D. E. Rumelhart, J. L. McIlroy and the PDP Peserch Group : "Parallel Distributed Processig", I, MIT Press, pp 318-362, 1986.

[5] L. Cooper, "Adaptive pattern recognition", Tutorial in IJCNN '89, 1989.

[6] R. O. Duda and P. E. Hart, Pattern Calssification and Scene Analysis, Wiley-Interscience, pp 44-84, 1973.

[7] T. Kohonen, Self-Organization and Associative Memory, (3rd ed.), Springer, Berlin-Heidelberg-New York-Tokyo, 1989.

[8] A. SATO, J. TSUKUMO, "Improved Vector Quantization and Its Application to Character Recognition", 信學技報, NC93-60, 1993

[9] T. Ichikawa, M. Hirakaw, "ARES : A Relational Database with the Capability of Performing Flexible Interpretation of Queries", IEEE Trans. on Software Engineering, vol.SE-12, no.5, pp 624-634, 1986.

[10] C. Stanfill, D. Waltz, "Toward Memory-Based Resoning", C. ACM, vol.29, no.12, pp 1213-1228, 1993.