

실시간 주문 확답을 위한 데이터 마이닝 기반 운용 계획 모델*

한현수** · 오동하***

Applications of Data Mining Techniques to Operations Planning for Real Time Order Confirmation*

Hyun-Soo Han** · Dong-Ha Oh***

■ Abstract ■

In the rapidly propagating Internet based electronic transaction environment, the importance of real time order confirmation has been more emphasized. In this paper, using data mining techniques, we develop intelligent operations decision model to allow real time order confirmation at the time the customer places an order with required delivery terms. Among various operation plannings used for order fulfillment, mill routing is the first interface decision point to link the order receiving at the marketing with the production planning for order fulfillment. Though linear programming based mathematical optimization techniques are mostly used for mill routing problems, some early orders should wait until sufficient orders are gathered for optimization. And that could effect longer order fulfillment lead-time, and prevent instant order confirmation of delivery terms. To cope with this problem, we provide the intelligent decision model to allow instant order based mill routing decisions. Data mining techniques of decision trees and neural networks, which are more popular in marketing and financial applications, are used to develop the model. Through diverse computational trials with the industrial data from the steel company, we have reported that the performance of the proposed approach is effective compared to the present heuristic only mill routing results. Various issues of data mining techniques application to the mill routing problems having linear programming characteristics are also discussed.

Keyword : Data Mining, Linear Programming, Real-Time Order Conformation, Mill Routing Strategy

논문접수일 : 2004년 7월 31일 논문게재확정일 : 2004년 10월 15일

* 이 논문은 2001년도 한양대학교 교내 연구비의 지원에 의하여 연구되었음.

** 한양대학교 정보통신대학

*** 한양대학교 정보통신대학원 정보기술경영 전공

1. 서론

데이터 마이닝은 마케팅, 금융, 보험, 의학 등의 광범위한 분야에서 경영 의사결정 지원 도구로 사용되어 왔고 최근에는 공급사슬관리(SCM, Supply chain management)분야에의 응용 또한 활발해지고 있다[6, 8, 12]. 전통적으로 SCM 분야에서 생산 시스템에 관한 연구는 수요예측, 생산계획, 일정계획, 수송 문제 등의 분야에서 단위 조직이나 업무의 개선을 위해 최적화와 시뮬레이션 등 경영과학 기법 등이 주로 사용되어 왔다. 하지만 계량적 기법들은 정량적 요인과 정성적인 요인이 복합되어 있는 문제 해결에는 효과적이지 못한 단점을 가지고 있으므로 인공지능 분야에서 개발된 기법들을 계량적 기법들과 상호 보완적으로 운용할 필요가 있다. 데이터 속성에 바탕을 둔 데이터 마이닝을 통한 의사결정은 직관이나 추정에 의존하는 의사결정과 정형화된 수리적 최적화 기법의 단점을 보완 할 수 있다[5].

본 논문에서는 복수 공장과 연속 공정 환경에서 주문처리 프로세스의 운용계획과 스케줄링의 출발점이 되는 공장 배분(Mill routing) 문제를 데이터 마이닝 기법과 휴리스틱을 이용하여 접근하였다. 주문이 처리되는 공장의 경로 결정은 판매와 생산의 첫번째 인터페이스가 되는 중요한 의사결정 프로세스이다. 마케팅 혹은 판매 부서에서 주문이 접수되면 주문이 고객이 원하는 납기 내에 생산이 가능한지 혹은 가능한 납기는 언제인가를 고객에게 통보하고 고객과의 합의가 되면 주문 접수 확인이 이루어지며 생산부서로 주문처리 태스크가 넘겨진다. 계획 생산을 통한 재고에 의한 주문충족 경우에는 공장 결정 프로세스가 단순하나 다공정 복수 공장에서의 주문 생산 체계에서의 주문 처리 공장 결정은 생산성 및 납기의 두 가지 성과에 민감한 영향을 준다. 특히 인터넷 기반의 전자상거래의 확산에 따라 주문 접수 프로세스가 웹 상에서 이루어지고 실시간 주문 응답의 중요성이 강조됨에 따라 납기의 즉시 결정과 통보는 고객 만족에 중요한

요소로서 강조되고 있다[23].

복수 공장 다공정을 거쳐 생산되는 주문 생산 체계의 모델은 국내의 대표적인 P제철소의 주문처리 프로세스를 기본으로 하였다[1]. 제철소는 복수 공장과 연속 공정으로 이루어진 대표적인 주문생산 프로세스 모델이며 생산 계획과 스케줄링의 복잡성을 해결하기 위한 다양한 과학적 의사결정 모델 등이 연구되어 왔다[7, 9, 11, 13, 22]. 일반적인 공장 배분 문제는 대부분 정량적 최적화 기법인 선형 계획법(Linear programming)으로 다루어져 왔다 [1, 16, 17]. 그러나 선형계획법에 의한 최적화는 필연적으로 적정량의 주문이 수집된 후 최적화 공장 배분을 하게 되므로 전자상거래 환경에서의 실시간 주문 확답이 어렵고 주문 충족을 위한 리드 타임(Lead time)을 증가시키는 요인이 되어 왔다. 따라서 적절한 주문 배분 시점의 선정에 관한 논의가 계속되어 왔으며 또한 선형계획법을 통한 제철소의 공장 배분 방식은 공정의 복잡성에 의한 복잡한 제약조건과 업무 담당자 경험에 의한 공장 배분의 유연성을 반영하기가 어려워 현업에서의 실제 활용이 저조하였다. 결과적으로 기존의 제철소 공장 배분 문제는 현업 담당자의 직관과 추정에 의존해왔고 이러한 방식은 객관성의 결여와 전문가의 부재, 변경 시에 발생하는 일관성의 상실로 수익성 저하를 가져왔다. 이에 기인하여 본 논문에서는 업무 전문가의 유연성 있는 공장 배분 지식을 기반으로 하여 전자상거래 환경에서 주문 접수 후 즉각적 공장 배분이 가능한 지능형 의사 결정 모델(Intelligent decision model)을 구현하고자 한다.

공장 배분에 기준이 되는 요소들은 품질 및 원가 등에 주문 속성과 공장의 공정 능력 등이 복합적으로 고려된다. 또한 속성에 의한 공장 배분 규칙 등이 업무 전문가의 공장 배분 시 유연하게 적용되므로 규칙기반 전문가 시스템보다는 마케팅과 금융 분야에서 분류와 예측에 좋은 성과를 보인 의사결정나무(Decision Trees)와 신경망(Neural Networks) 등의 데이터 마이닝 기법[2, 3, 6, 21]을 사용하였다. 데이터 마이닝 도구는 SAS E-miner 4.1을 사용하

였으며 제철소의 2003년 실 주문 데이터를 분석하여 모델을 수립하였다. 분석의 용이를 위해 제품은 열연 제품으로 한정하였고 제철소 연속 공정 중 초기 공정인 열연 프로세스에 한정하였다.


다음 2장에서는 공장 배분의 구조와 선형계획법에 의한 접근 방법을 소개하고 이를 바탕으로 본 논문에서 제시하는 지능형 공장 배분 모델을 소개하였다. 다음 3장에서는 다양한 데이터 마이닝 기법을 적용한 결과와 평가를 정리하였고 마지막 4장에서는 연구의 한계점, 개발된 모델의 실적용 및 연구 확장에 대한 시사점을 제시하였다.

2. 지능형 공장 배분 모델

철강 제품은 일반적으로 제강 공정, 열연 공정, 냉연 공정으로 대표되는 세 개의 연속 공정을 통하여 생산되며 각 공정은 다수의 세부 공정으로 구성되어 있다. 일반적으로 냉연 제품은 총 13개의 단위 공정을 거치게 된다. 본 연구 모델이 기반으로 하고 있는 P제철소는 <그림 1>과 같이 1, 2, 3 세 개의 공장을 갖고 있으며 각 공장은 제강, 열연, 냉연 각 3개의 생산 공정으로 구성되어 있다. 1, 2, 3 공장은 각각 상이한 제조 특성을 갖고 있으며 따라서 총 주문의 공장 결정 결과는 각 제품의 품질, 납기 및 생산 원가 등에 영향을 주게 된다.

제강 공정에서 생산된 슬라브는 고온의 상태이며 슬라브의 일부는 냉각 과정을 거치지 않고 바로 열연 공정으로 연계 되어 열연 제품(HR, Hot Rolled Coil)으로 생산되거나 냉각과 재가열 과정을 거쳐 열연 공정을 통과하게 된다. 열연 공정을 통해 생산된 열연제품은 완제품으로 판매되거나 냉각을 거쳐 냉연 및 도금 공정 등을 거쳐 냉연제품으로 출하된다. 같은 공정이라도 공장별 특성에 따라 제품의 품질과 생산 원가가 달라지고 또한 한 주문이 제강, 열연, 냉연 처리 공장이 달라질 경우에는 재공품의 저장 및 공장 간 이송 물류 비용이 발생하게 된다. 철강 공정 특성 상 재공품의 저장과 이송은 많은 물류 비용이 소요되므로 많은

크로스(Cross)재의 발생은 원가 상승과 납기 지연 등의 원인이 된다. 효과적인 공장 배분의 중요성은 크로스재를 줄이는 데도 그 목적이 있다.



<그림 1> 단순화된 제철 공정 및 공장 구조

2.1 공장 배분의 선형계획 모델

공장 배분 의사결정 모델은 주문 주문 $i, i=1, 2, \dots, N$ 가 열연 1, 2, 3 공장 중에서 처리 되는 한 공장의 선택과 연속적으로 냉연 1, 2, 3 공장 중에서 처리 공장의 결정, 그리고 최초로 슬라브를 생산하는 제강 공장 결정으로 구성되어 있다. 냉연 제품일 경우는 주문 당 제강, 열연, 냉연 등 각 공정별 처리 공장을 나타내는 세 개의 의사결정 변수가 존재하며 열연 제품일 경우는 제강 및 열연 공장 배분을 나타내는 두개의 의사결정 변수가 필요하다. 일반적으로 열연제품 경우에는 제강과 열연의 연계 관계를 고려하여 열연 공장 결정을 기준으로 제강 공정을 결정한다.

<표 1> 주문 속성

구분	주문 속성	
입력변수	강종	강종명, 용도, 규격약호, 출강목표, 가능통과 공장
	규격	주문폭, 주문두께, 주문량, 정포장 상한, 정포장 하한,
	제조	슬라브 폭, 열연제조, 1, 2, 3 열연 압연 Max 단중, 주편순질방법
	시점	출강요구일, 제조공기 시작일, 납기 ATP, 조정 ATP
	주문자	수주구분, 최종고객
생성변수	수익성	1, 2, 3 열연 공장 수익성 추정치
출력변수	공장 배분	실제 생산 공장

구체적으로는 각 공장 내 세부 처리 공정이 복수로 존재하고 주문 속성별로 필요한 세부 통과 공정이 차별화 되어 공장결정 문제는 매우 복잡한 구조로 되어 있으며 최적해를 구하는 것은 정교한 알고리즘이 필요하다.

본 논문에서는 공정의 복잡성을 단순화하기 위해 연구 대상을 열연제품(HR, Hot rolled coil)으로 한정했으며 열연 공정 공장 배분을 다룬다.

열연 제품 주문의 공장 결정 의사 결정시 고려되는 요소는 주문의 품질 속성과 공장 특성과의 매칭, 공장 처리 능력 준수, 그리고 수익성이다. 품질 속성에 의한 공장 결정 요소와 공장처리 능력은 선형계획법을 이용한 수리적 모델에서 제약조건이 되며 수익성은 목적 함수로 각각 정형화 된다. 주문 $i=1, 2, \dots, N$ 의 열연 공장 배분 의사 결정을 나타내는 변수를 각각 $x_{i1}, x_{i2}, x_{i3}, i=1, 2, \dots, N$ 로 정의하기로 한다. 즉 주문 i 가 열연 1공장으로 배분될 때 $x_{i1}=1$ 되며 $x_{i2}=x_{i3}=0$ 이 된다.

선형계획법에서 표현 되는 제약조건의 첫번째 범주는 주문의 품질속성과 처리 공장 특성을 매칭시키는 것으로 구성된다. <표 1>에서 정리된 주문 속성 중 공장 배분에 영향을 주는 품질 특성 속성들을 각각 r_1, r_2, \dots, r_R 로 정의한다. 품질 특성을 가장 대표적으로 반영하는 속성은 강종이며 이를 r_1 이라 정의하고 강종의 종류를 나타내는 집합을 $Q_1 = \{m_1, m_2, \dots, m_M\}$ 으로 각각 정의한다. 주문 i 의 강종 속성을 q_{i1} 라 정의 할 때 q_{i1} 는 강종 집합 Q_1 의 한 원소인 m_k 에 해당된다. 또한 열연 공장 j 에서 처리 할 수 있는 강종의 종류를 나타내는 집합을 각각 $Q_j, j=1, 2, 3$ 으로 정의하면 주문 i 가 처리 될 수 있는 가능한 열연 공장 j 는 강종 특성 제약 조건을 고려 할 때 $\{j | Q_j \ni q_{i1}\}$ 로 정의 된다. 따라서 모든 품질 속성 r_1, r_2, \dots, r_R 각각에 대하여 주문 i 가 처리 될 수 있는 가능한 열연 공장 j 의 선택을 제한하는 제약 조건은 $\{j | Q_{jk} \ni q_{ik}\}$, for all $k=1, 2, \dots, R$ 로 정의된다.

제약조건 식 (2)은 모든 주문 $i, i=1, 2, \dots, N$ 에 대하여 강종 등 품질 특성 관련 제약조건 r_1, r_2, \dots, r_R 각각에 대하여 처리 가능한 공장 들 중 하나로 배분 되는 규칙을 나타낸다.

선형계획법에서 표현되는 제약조건의 두 번째 범주는 각 열연 공장의 공정 능력이다. 주문 i 의 주문량을 w_i 라 하고 각 공장의 처리 능력을 $b_j, j=1, 2, 3$ 라 하면 공장 j 에서 처리 되는 총 주문량의 합계가 처리 용량을 초과 할 수 없는 제약 조건은 아래 식 (3)과 같이 표현된다. 선형 계획의 목적 함수는 수익성의 최대화 혹은 비용 최소화가 될 수 있으며 본 논문에서는 이를 최근 P제철소에서 전략적 이슈가 되고 있는 수익성 최대화로 한다. 주문 i 의 처리 원가는 제품 가격과 각 공장별 강종 별 상이한 표준 원가를 이용하여 계산되며 주문 i 가 열연 공장 j 에서 처리 될 때의 이윤을 d_j^i 로 정의하면 선형계획의 목적 함수는 다음 식 (1)과 같이 정형화 된다. 이제까지 정형화된 선형계획 모델은 주어진 주문 i 속성 $\{(d_1^i, d_2^i, d_3^i), (q_{i1}, q_{i2}, \dots, q_{ik}), w_i\}$ 과 관련하여 다음과 같이 정형화 된다.

$$\text{Maximize } \sum_{i=1, N} \sum_{j=1, 3} d_j^i x_{ij} \quad (1)$$

$$\text{Subject to } \sum_{j | Q_{jk} \ni q_{ik}} x_{ij} = 1 \text{ for each } k=1, 2, \dots, R, \text{ and } i=1, 2, \dots, N. \quad (2)$$

$$\sum_{i=1, N} w_i x_{ij} \leq b_j \text{ for each } j=1, 2, 3. \quad (3)$$

$$x_{ij} = 0 \text{ or } 1 \text{ for each } i=1, 2, \dots, N, \text{ and } j=1, 2, 3. \quad (4)$$

정형화 된 선형계획은 (0, 1) 정수계획법으로 모델링 되며 제약조건을 갖는 대규모 할당 문제 (Large scale assignment problem with side constraints)의 성격을 갖는다. 이와 같은 문제는 최적해를 구하기 매우 힘든 문제로 알려져 있다.

2.2 최적화 기법 적용의 복잡성

공장 배분 문제의 최적화 기법 적용의 현실적인

문제점은 수리적 계획의 근본적인 배치(Batch) 처리방식, 계산적 복잡도, 그리고 제약조건의 유연성 부족 등으로 구분된다. 최적화 모델 활용을 위해서는 적정량의 주문이 수집된 이후에 공장 배분 모델을 적용하게 되는데 적정량의 주문 수집에 소요되는 주문 충족 리드 타임이 증가하게 된다. 웹 기반 전자상거래 환경에서 고객이 주문을 투입 시 즉각적인 납기와 주문 확답을 통보하는 것은 고객 만족을 위하여 매우 중요한 요소이며 또한 납기 적중률 향상을 위해서는 주문의 처리 능력 확보가 반드시 고려 되어야 한다. 공장 배분은 고객 주문이 제한된 납기 내에 처리 될 수 있는 공정 능력 확보와 생산 원가, 품질 등의 생산성에 영향을 주는 의사결정 문제로 적절한 주문 배분 시점 선정을 통한 고객 서비스와 생산성의 균형을 맞추는 데 또한 어려움이 있다. 고객에 대한 즉시 응답을 위한 실시간 공장 배분을 통한 납기 약속을 할 경우에는 적정량의 주문을 축적하여 최적화 모델을 통하여 얻게 되는 생산성 향상을 희생해야 하며 역의 경우에는 생산성 및 최적화는 달성 할 수 있으나 고객 주문의 확답 리드 타임이 소요되고 납기가 길어지는 단점이 있게 된다.

앞 절에서 제시된 최적화 모델은 (0, 1) 정수 계획법에 일반 제약조건이 추가되고 의사결정 변수의 수가 많아 계산적으로 매우 풀기 어려운 문제의 수리적 모델이다. 제시된 정형화 문제는 열연 공장 배분 문제만을 대상으로 한 문제이므로 이를 제강, 냉연 공장으로 확장 할 시에는 변수의 증가뿐 아니라 제약조건의 증가로 해를 구하기가 더욱 어려워진다. 전 공정으로 확장 시 각 주문에 대하여 제강, 냉연 공장 배분 결정 변수와 공장간 크로스 제의 비용 반영 등으로 모델이 더욱 대형화 되고 복잡하여지며 이는 최적화 모델이 실제 업무 담당자에 의해 사용되지 않는 원인 중 하나이다.

제약 조건의 유연성 부족은 모델의 현업 활용성을 저조하게 하는 또 하나의 주요 원인이 된다. 최적화 모델 제약조건 (2)에서 제시된 품질 관련 공장 배분은 하드 제약조건(Hard constraints)으로

품질 조건 상 주문의 특정 공장으로의 배분이 가능 혹은 불가능 만을 다룰 수 있다. 그러나 현실적으로는 주문 i 가 처리 될 수 있는 가능한 열연 공장 j 는 품질 속성 r_k 각각에 대하여 유연성이 있으며 일부 특정 조건을 제외하고는 우선 순위에 의한 공장 결정이 선호 된다. 또한 실제로는 상황에 따라 다소 처리하기 힘든 주문이라도 공장에 배분하고 공장의 생산 부서에서 이를 제조기술 차원에서 해결하기도 한다. 이러한 주문의 공장 배분 우선 순위를 수리적 모델로 정형화 하는 기법으로는 목적계획법(Goal programming)이 있으나 우선 순위 가중치를 수리적 모델에 포함 시키는 것은 문제의 복잡성을 더욱 증대 시키며 적절한 가중치를 선택하는 것 또한 현실적으로 매우 어려운 문제이다.

이와 같은 문제점으로 인하여 실제 현업에서의 공장 배분은 수리적 모델이 사용되지 않고 업무 담당자들의 휴리스틱 의사 결정에 의존하고 있다. 휴리스틱에 의한 공장 배분은 배분 시점을 자유롭게 할 수 있으나 복잡한 공장 배분 조건 및 수익성의 반영이 어렵고 공장 배분 규칙이 공유 되어 있지 않아 의사 결정의 객관성과 일관성을 보장하기 어렵다는 단점을 갖고 있다. 이러한 문제점을 보완하고 사용이 쉬운 과학적 의사결정 모델을 다음 절에서 제시한다.


2.3 지능형 의사결정 모델

선형계획법 구조의 공장 배분 최적화 모델의 단점은 적정량의 주문이 축적되어야 하는 데 따른 주문 충족 리드타임의 증가, 품질 관련 제약조건의 유연성 부족, 수리적 모델 활용에 대한 불편함 등으로 실제 활용이 저조하다는 데에 있다. 한편 현재의 업무 담당자의 휴리스틱에 의존하는 공장 배분은 품질 특성, 수익성 등 많은 공장 배분 변수들과 주문 특성 매칭 문제의 복잡도를 체계적으로 고려 할 수 없다는 근본적인 문제점이 있다.

본 논문에서는 데이터 마이닝의 주문 패턴 추적

접근 방식을 사용하여 현업 담당자들의 휴리스틱 의사 결정 규칙을 도출해 내고 기존의 수리적 모델 및 휴리스틱 공장 배분 방식을 대체 혹은 보완 할 수 있는 새로운 데이터 마이닝 기법을 이용한 공장 배분 모델을 구현한다. 이러한 방식의 적용을 통해 적정 주문량을 수집하는데 필요한 리드 타임을 단축하여 전체 주문 충족 프로세스 리드 타임을 줄일 수 있으며 객관적이고 일관성 있는 의사 결정을 지원할 수 있다. 또한 품질 속성 별로 유연성 있는 공장 배분이 가능하도록 하여 수리적 최적화 모델의 단점을 극복할 수 있으며 사용이 용이하여 현업 담당자들의 활발한 적용을 이끌 수 있다.

<그림 2>는 주문 접수 후 즉각적 공장 배분을 위해 사용된 데이터 마이닝 적용 구조로서 공장 배분의 품질 관련 제약조건, 수익성, 공정 능력 등의 최적 공장 배분 논리를 수리적 최적화 모델과 대응시켜 정리하였다. 데이터 마이닝 응용 모델에서는 주문 자체의 속성을 이용하여 주문 패턴을 추적 하는 학습과정을 통해 공장 배분을 위한 최적해를 구할 수 있도록 한다.



<그림 2> 데이터 마이닝 응용구조

본 모델의 핵심은 공장 배분 최적화 제약조건에 가장 큰 영향을 주는 품질 관련 속성을 업무 전문가의 휴리스틱에 의한 공장 배분 패턴을 이용하여 학습하는 데 있다. 품질 속성에 의한 공장 결정은 실질적으로 우선 순위에 의한 배분이며 이는 수리적 모델에서 반영되기가 가장 어려운 제약조건이나 데이터 마이닝 기법에서는 효과적으로 처리 될 수 있다. 선형계획에서 목적함수는 실질적으로 소프트 제약조건(Soft constraint)으로 해석되며 본

모델에서는 수익성 역시 품질 관련 속성과 같은 방식으로 처리하였다. 최적화 모델의 하드 제약조건 중 하나인 공장 능력에 따른 주문의 균등 배분은 데이터 마이닝 기법 성격상 속성을 직접적으로 이용할 수 없으므로 속성에 의한 주문 배분 후 공정 능력이 초과한 부분과 잉여 능력이 남은 공장을 대상으로 타겟 공장 선택 우선순위 %를 기준으로 공장을 재배하는 사후 조정(Post rearrangement)을 통하여 해결한다. 사후 조정 방식은 속성에 의한 공장 배분의 최적화 정도가 희생되는 단점이 있으며 향후 보완 될 부분이다. 마지막으로 최적화 모델 의사 결정 변수가 0 혹은 1의 정수 만을 취하는 조건은 데이터 마이닝 구조를 통하여 자연스럽게 만족된다.

공장 배분과 같은 분류(Classification)와 예측(Forecasting)에 사용되는 데이터 마이닝 응용의 대표적인 기법은 의사결정나무(Decision tree)와 신경망(Neural network) 기법 등이다. 규칙 기반 전문가 시스템도 응용할 수 있으나 실제 현업의 업무 전문가 또한 공장 배분의 명확한 규칙에 의한 공장 배분을 하기 보다는 여러 가지 속성을 공장 운영 상황 및 담당자 특성에 의하여 가변적으로 배분을 하며 체계적이고 규칙적인 배분 규칙 추출이 어려운 현실을 고려하여 데이터 마이닝 방법을 택하였다.

의사결정나무 기법은 신용카드 도용 예측에서 각종 외국환 환율의 시계열 분석에 이르기까지 데이터의 분석이나 예측을 요하는 다양한 비즈니스 영역에 적용할 수 있는 기법이다. 의사결정나무는 나무의 구조에 기반한 예측모델로서 나무의 가지는 데이터를 분류하기 위한 질문이며 옳은 분류 결과에 따라 분리된 데이터 집합이라고 할 수 있다. 의사결정나무는 연속 형과 범주 형 자료를 모두 취급할 수 있어 정량적이며 정성적인 분석이 가능하다는 장점이 있으며 오류 데이터에 덜 민감하다는 장점이 있다. 또한 의사결정 나무는 독립변수와 종속 변수의 관계를 쉽게 설명할 수 있는 If-then 규칙을 생성하는 장점이 있어서 결과를 쉽게 이해하

고 설명하고자 할 때는 적합한 방법이지만 독립변수가 취할 수 있는 값이 많아질 경우에는 오류가 발생할 가능성이 많다는 약점을 가지고 있다. 의사결정 나무는 그 단독으로 데이터 분석에 쓰이는 것 이외에 다른 데이터 마이닝 기법과 함께 사용되는데 연속 형이나 범주 형 등 예측 변수를 있는 그대로 처리하므로 데이터의 변환에 소요되는 시간과 노력을 줄일 수 있고 모델을 구축하는 시간을 줄일 수 있으므로 타 예측기법의 선행과정으로 다수의 예측 변수 중에서 유용한 변수를 선별하는 작업에도 사용한다[4].

신경망은 인간 두뇌의 신경 노드를 모방하여 만든 컴퓨팅 메커니즘이며 복잡한 유형을 찾아주는 컴퓨터 프로그래머가 대용량의 데이터로부터 예측 모델을 만들어 주는 기계적 학습 알고리즘이다 [12]. 신경망은 사용하기가 어렵고 모델을 이해하기 어렵다는 단점을 가지고 있으나 가장 높은 예측력을 제공한다는 장점 때문에 다양한 문제 영역에서 사용되고 있고 또한 수리적 최적화 응용 영역에도 활용된다[10, 19, 20]. 신경망은 인간의 두뇌 조직과 학습방식을 그대로 모방한 개념으로 마디(인간두뇌의 신경세포)와 링크(인간두뇌에서 신경세포 들을 이어주는 연결자)로 구성된다. 신경망은 복잡한 구조를 가진 자료에서의 예측 문제를 해결하기 위해서 사용되는 비선형 모형의 하나로 은닉 마디라고 불리는 독특한 구성요소에 의해서 일반적인 통계모형과 구별된다. 신경망은 과거에 수집된 데이터 전체를 한번에 입력시켜 학습하는 전통적 통계 기법과 달리 인간이 학습하는 것과 마찬가지로 레코드를 하나씩 입력시켜 레코드가 하나씩 입력될 때마다 조정 받고 보완되는 동적인 모델이다. 레코드에 기록된 실제 부류 값과 신경망이 예측하는 값을 하나씩 서로 비교하여 링크의 강도 값을 조정함으로써 예측능력을 증진시킨다. 은닉 층은 여러 개의 은닉 마디로 구성되는데 은닉 층의 수와 뉴런 수는 적용 문제에 따라 달라지며 따라서 그 타당성은 실험을 통해서 확인하여야 한다[15].

데이터 마이닝 기법들은 단일 기법만으로 쓰이

기도 하지만 여러 개의 데이터 마이닝 기법이 결합된 모델이 사용될 경우 일반적으로 예측율이 향상된다. 결합모형은 대부분 신경망의 단점을 제거할 수 있는 기법들이 결합되어 사용된다. 신경망은 미래의 목표 값을 예측하는 데 있어 입력벡터의 값의 수나 형태를 결정할 수 있는 체계적인 방법의 결여와 모델의 분류가 어떻게 이루어지는지 명확하게 이해 할 수 없다는 단점이 있다. 이러한 단점을 해결하기 위하여 신경망에서 상징적 분류 규칙을 찾거나 의사결정 나무를 통하여 이해 할 수 있는 해석을 얻고자 하는 연구 등이 이루어졌는데 Kao & Chiu(2001)는 의사결정 나무 기법을 통해서 도출된 결과를 신경망의 입력변수로 선정하는 모델을 사용하였다. 이러한 결합 모델은 의사결정나무의 CART 알고리즘이나 신경망 단일로 구성된 모델보다 좋은 성과를 나타냈다[14]. 결합모델에서는 목표 변수에 큰 영향을 주지 않는 변수를 제거함으로써 최적 필요 변수만이 신경망 입력 노드로 선정되어 신경망의 과부하를 예방하는 효과가 있다[4]. 본 논문에서는 의사결정 나무와 신경망 기법 및 두 개의 기법을 혼용하는 결합모델 또한 사용하였다.

3. 데이터 마이닝 응용

본 연구에서는 제철소의 2003년도 데이터 중 35,000개의 열연 제품 주문 데이터를 이용하여 21,000개의 데이터는 훈련용으로 14,000개의 데이터는 검증용으로 사용하였다. 모델 개발을 위해 사용된 변수는 <표 1>에 제시된 주문 데이터베이스의 속성을 이용하였다. 속성 변수는 주문 자체의 속성과 표준원가 데이터베이스와의 연계를 통해 가공한 수익성 데이터, 그리고 실제 공장 배분 결과를 포함하고 있다. 공장 배분에서 사용한 주문 자체 속성은 주문량, 최종고객, 내수/수출 수주 구분, 강종명, 용도, 규격약호, 출강목표(강종코드), 주문폭, 주문 두께, SLAB폭, 1, 3, 3 열연 각각의 압연재 MAX 단중, 열연제조 조건, 정포장 상한, 정포장 하한, 가능통과 공장, 주편 손질 방법, 출강요

구일과 제조공기시작일, 원래 납기 및 조정 납기 등이다. 가능통과 공장은 설비 제약 조건으로 인해 통과가 불가능한 공장과 가능한 공장을 지정해 주며 확정통과 공장은 실제 배분된 공장 정보로 2003년도에 현업 전문가 휴리스틱에 의해 결정된 공장 배분 결과이다.

이러한 강종 관련 정보, 규격관련 정보, 제조관련 정보, 시점 관련 정보, 주문자 정보 이외에 수익성 데이터 베이스로부터 기존 데이터의 수익성을 분석하여 입력 변수로 생성 활용하였다. 이를 위해 수익성 DB의 2003년도 수익성 데이터를 활용하였으며 각 강종 별 수익성을 기준으로 하여 해당 강종의 수익성 데이터가 없을 때에는 유사 강종 수익성의 평균값을 수익성으로 추정하여 계산하였다. 신경망의 범주형 변수는 0에서 1사이의 값으로 표준화 될 때 성과가 최대화 되므로 각 수익성 데이터는 공장별로 0에서 1사이의 값으로 표준화 하였다. 시간당 수익성은 톤 당 수익성을 공장의 시간당 처리량으로 곱한 식으로 계산되며 시간당 처리량은 처리량을 순 작업시간으로 나눈 수치를, 톤당 수익성은 판매가격과 매출원가의 차이로 계산된다.

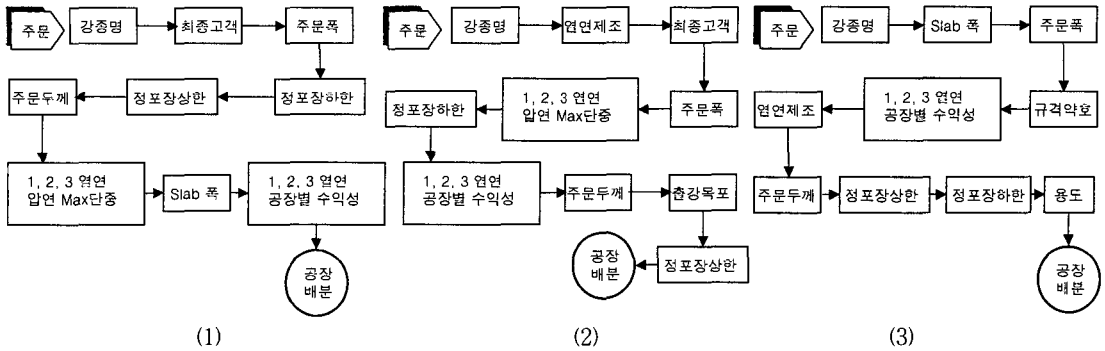
데이터 속성에 의한 공장 배분 패턴을 학습을 통하여 가장 적절한 공장으로 주문을 배분하는 방식은 공장별 공정 능력에 대한 고려가 없어 실제 활용에 있어 특정 공장으로의 주문의 과부하를 막기가 어려우며 생산성 최적화를 이루는데 어려움이 있다. 이를 보완하기 위해 실제 2003년도 전체 주문 데이터의 열연 공장 배분 비율로 데이터 마이닝 공장 배분 결과를 사후 조정하였다. 사후 조정은 데이터 마이닝 모델을 통한 공장 배분 결과를 타겟 공장이 선택되는 % 순위를 기준으로 실 공장 배분 비율에 맞게 공장을 재분배 하는 규칙을 적용하였다. 사후 조정은 2003년 현업 전문가의 공장 배분 결과인 열연 1공장에 약 44%, 열연 2공장에 약 32%의 주문, 그리고 열연 3 공장에는 가장 적은 24%의 주문이 배분된 결과를 기본으로 하였다. 각 공장 별 주문 배정 비율이 동일하지 않은 것은 각 공장 별 설비와 조강 능력 차이로 인한 것이다.

본 연구에서 사용된 의사결정 나무 알고리즘은 C4.5, CART, CHAID[18]를 사용하여 공장 배분의 사결정 속성의 흐름 및 알고리즘 별 성과를 파악하였다. 신경망 기법에서는 다계층 퍼셉트론(Multi-layer perceptron)과 시그모이드(Sigmoid) 함수를 이용한 역전파(Back propagation) 학습 알고리즘을 이용 하였다. 적절한 은닉 층과 은닉 마디의 수를 결정하기 위해 반복적 실험을 하였고, 학습용 데이터와 검증용 데이터 모두 층화 추출(Stratified sampling)을 통해 같은 공장 배분 비율(1공장 : 44%, 2공장 : 32%, 3공장 : 24%)을 갖도록 하였다. 또한 결합 모델에서는 의사결정나무 기법 중 반복적 실험을 통해 보다 나은 성과를 보인 알고리즘에서 도출된 속성을 유용변수로 하여 신경망 모형을 위한 적절한 입력 노드 선정을 하였다.

3.1 의사결정 규칙 흐름도(Decision rule flow chart) 결과

공장 배분 모델 구현을 위해 사용된 의사결정 나무 알고리즘 C4.5, CART, CHAID를 사용하여 도출된 의사결정 규칙 흐름도(Decision rule flow-chart)는 <그림 3>의 (1), (2), (3)과 같다. 의사 결정 나무에서의 규칙 생성 결과는 1순위, 2순위의 순위별 분리 기준에 따라 최적 분리에 도달할 때까지 분리를 최종 의사 결정 나무의 가지 수(Depth)는 각 노드 별로 차이를 보인다. 도출된 공장 배분 의사결정 기준 속성변수는 적용 알고리즘 별로 부분적으로 차이는 있으나 전체적으로 일관적 결과를 나타낸다.

흐름도 내의 분류 속성들은 강종 등의 품질 관련 적합성에 의한 분류가 우선적으로 그리고 설비 관련 변수와 제조유형 변수 등이 포함되었는데 이는 전문가의 공장 특성과 설비 변경 비용 감소를 위해 선택하는 공장 배분 데이터가 훈련되어 도출됨을 반영하는 좋은 결과이다. 최종 고객 변수도 흐름도에 포함되었는데 철강제는 고객 수가 제한된 제품으로서 장기적 고객이 반복 주문을 내는



〈그림 3〉 의사결정나무 적용 규칙 흐름도

경우가 많고 고객별 품질 유지 요구 조건을 충족시키기 위하여 고객별 제조 공장 변동을 최소화하는 경향을 반영한다.

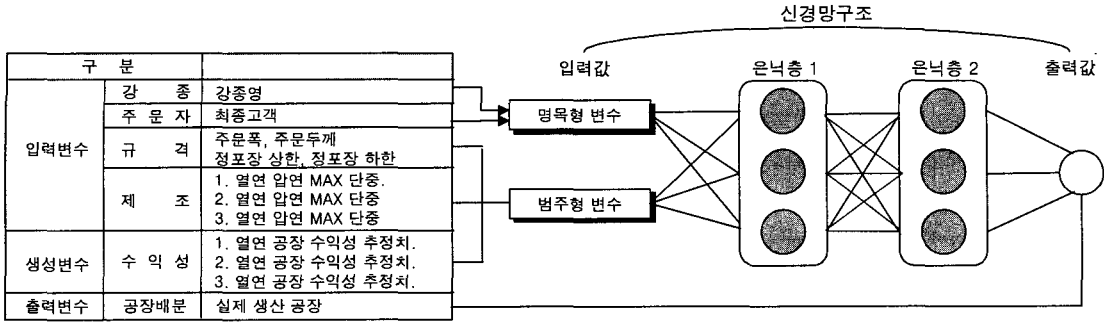
흐름도에 포함된 설비 및 제조 관련 변수는 각 열연 공장 별 가능 압연 최대 중량, 주문 두께와 주문 폭, 슬라브 폭, 정포장 상한과 하한 등이며 현업 업무 전문가의 공장 배분 고려 조건과 유사한 결과를 나타낸다. 추가적으로 입력한 공장 별 수익성 변수도 의사결정 나무에서 유효한 변수로 선택됨으로써 실제 공장 배분 결과가 수익성이 고려되었고 또한 도출된 모델이 효과적으로 활용될 수 있음을 의미한다. 수익성 변수는 의사결정 규칙 흐름도의 하위에 위치 하였는데 이는 세분화 된 원가 체계가 아직 미흡하여 공장별 강종 별 원가 체계가 정교화 하지 않은 데 기인한 것으로 판단되며 향후 정교한 원가시스템 활용 시 더욱 나은 수익성 위주의 배분이 될 것으로 기대한다.

3.2 모델 평가 및 수익성 검증

의사결정나무 기법만을 통해 공장 배분 한 실험 결과와 신경망 알고리즘 만을 통해 공장 배분을 한 실험 결과, 그리고 의사결정나무 기법을 통해 신경망의 입력 변수를 찾은 결합 모델의 공장 배분 결과를 <표 2>에 정리하였다. 의사결정나무 기법을 이용한 모델의 평균편차(ASE, Average square error)와 분류오류율(MSE, Mis-classification rate)이 신경망 모델과 결합 모델에 비해 예측 정확도가 가장 낮은 것으로 나타났다. 그러나 C4.5 알고리즘을 이용한 의사결정나무 모델은 최대 5개의 다지 분류를 허용함으로써 훈련용 데이터에 대한 예측율을 높였기 때문에 과적합 문제로 인해 일반성을 가지는 모델을 구현하기 어려운 단점이 있다. 신경망 모델에서는 반복적 실험 결과 2개의 은닉층과 은닉노드를 갖는 모델의 예측율이 단일

〈표 2〉 데이터 마이닝 모델 적용 결과

Data Mining Model		Root ASE		MSE	
		Training data set	Validation data set	Training data set	Validation data set
Decision Tree(DT) Model	CHAID	0.4032	0.4290	0.3839	0.4328
	CART	0.3776	0.4419	0.3296	0.4264
	C 4.5	0.3747	0.4450	0.3166	0.4258
Neural Network(NN) Model	1HL3Node	0.4086	0.4316	0.3900	0.4500
	2HL6Node	0.3793	0.4298	0.3160	0.4413
Connection(DT+NN) Model	DT(C4.5)+2HL6Node	0.3829	0.4349	0.3186	0.4373



<그림 4> 결합 모델

은닉층을 갖는 모델보다 더 높은 것으로 나타났다.

결합모델에서는 의사결정나무 알고리즘 중 가장 나은 성과를 보인 C4.5에서 가지 분리를 위해 사용된 변수만이 신경망 입력 노드에 적용되는 변수로 사용되었다. 그러나 결합모델의 예측 정확도는 타 모델에 비하여 차별화 되지 않는 결과를 나타냈다. 결합모델 응용 구조와 사용된 변수는 <그림 4>와 같다.

본 논문에서 적용한 데이터 마이닝 모델의 예측 정확도는 일반적 기준에 비추어 미흡하나 정확도의 미흡이 모델의 가치를 저하시키지는 않는다. 예측 정확도가 낮은 근본적 원인은 본 모델의 훈련과 검증용을 위하여 사용된 데이터가 특정 공장에 배분되어야 하는 주문들을 제외하였기 때문이다. 이는 특정 공장으로 지정되는 주문들은 훈련에 의한 중요성이 적으며 최적화 의사결정 모델이나 휴리스틱 공장 배분 시 우선적으로 배분되기 때문에 본 연구에서는 다양한 배분이 가능한 공통제를 대상으로 하였다. 이는 어느 공장에 배분되어도 품질에 크게 문제가 되지 않는 주문들에 대한 예측이 떨어진 것으로 해석되며 이러한 관점에서 모델 평가를 위한 수익성 검증의 중요성이 있다.

본 모델의 수익성 검증을 위해서 모델의 훈련용과 검증용으로 사용되지 않은 열연 제품의 실제 공장 배분 결과 데이터 500개를 이용하여 업무 전문가의 휴리스틱에 의한 실제 공장 배분 결과와 본 모델 적용을 통하여 도출된 공장 배분 결과의 수익성을 비교하였다. <표 3>은 데이터 마이닝 모

델 별 수익성 검증 결과이다. 모든 알고리즘 적용 결과는 실제 업무 전문가에 의한 공장 배분 결과에 의한 155,265보다 나은 결과를 나타내며 사후 조정 이전 수익성은 신경망 모델이 176,396으로 조정 이후의 수익성은 결합 모델이 160,735로 가장 높게 나타났다. 예측율과 수익성과의 관계는 나타나지 않았고 공정능력을 고려한 사후 조정이 수익성 성과를 감소시켰다.

<표 3> 데이터 마이닝 모델 수익성 검증

(단위 : 원)

	데이터 마이닝 모델	수익성	사후 조정 후 수익성
현업 전문가 공장 배분 실적	N/A	155,265	
데이터 마이닝 알고리즘 적용 결과	DT(CH4ID)	169,733	155,258
	DT(CART)	158,204	156,188
	DT(C 4.5)	168,549	157,678
	NN(1H3N)	176,393	156,882
	NN(2H6N)	176,133	156,912
	CM(C4.5+2H6N)	176,004	160,735

수익성 결과는 본 논문에서 제시된 모델의 유효성을 입증하며 단순한 사후 조정 방식보다 체계적이고 과학적인 사후 조정을 위한 새로운 논리 개발이 필요함을 제시한다. 이는 구축된 데이터 마이닝 모델을 통해 전문가 결정의 오류를 없애고 의사결정의 일관성을 획득했다는 것을 뜻하며 사람이 동시에 고려하기 어려운 다변수의 복잡한 특성이 정

형화된 규칙으로 훈련되어 체계적으로 테스트 데이터에 적용되었기 때문으로 해석된다.

4. 결론 및 토의사항

본 논문에서는 제철소의 공장 배분 최적화 문제를 데이터 마이닝 기법을 이용하여 주문단위 기준 실시간으로 처리할 수 있는 지능형 의사결정 방법을 제시하였다. 인터넷 기반 전자상거래 환경에서 고객의 주문 투입 시점에서 실시간으로 납기 등의 주문응답 프로세스를 구축하는 것은 고객 만족도 향상 및 주문 충족 프로세스 리드 타임 단축에 매우 중요하다. 주문 충족 프로세스를 구성하는 다양한 운영 계획 및 스케줄링 과정 중 공장 배분 결정은 판매 생산 인터페이스의 첫 번째 단계로 납기 등 고객만족과 생산 효율성 두 가지를 동시에 만족시키는 데 어려움이 있다.

공장 배분 의사결정 문제는 본 논문에서 제시된 바와 같이 많은 변수와 복잡한 제약조건을 갖고 있는 선형계획 형태의 (0, 1) 정수계획법 문제이다. 수리적 최적화 모델은 충분한 고객 주문의 축적을 위한 일정 기간 리드 타임이 필요한 단점이 있다. 또한 수리적 최적화 모델은 제약조건을 유연하게 적용하기가 어렵고 현업 사용자들의 의사결정 개입이 어려운 구조적 문제점과 복잡한 알고리즘에 대한 현업 실무자의 거부감이 존재한다. 따라서 현재의 P제철소에서는 현업 업무 전문가의 휴리스틱에 의한 공장 배분 결정이 적정 간격을 두고 행해지고 있는데 많은 공장 배분 조건 및 수익성을 동시에 만족시키는 일관적이고 체계적인 의사결정을 하는데 어려움이 있다. 이러한 문제점들을 해결하고자 본 논문에서는 주문 단위로 여러 제약조건을 만족시키고 즉각적인 공장 배분을 할 수 있는 지능형 공장 결정 의사결정 모델을 개발하였다.

본 논문에서 제시된 모델은 P제철소의 실제 데이터를 이용하여 개발되었으며 수익성 성과를 검증해 본 결과 현업의 휴리스틱에 의존한 의사결정 실적보다 나은 결과를 보였다. 학습과 검증과정에

서 예측율이 낮게 나타난 것은 문제의 성격과 사용된 데이터 속성에 기인하며 본 모델의 실질적 활용 가치를 저하시키지 않는다. 본 모델의 특징은 주문 속성에 의한 배분 실적 학습을 통한 의사결정 규칙의 유연한 적용을 가능하게 하여 수리적 최적화 모델에서 하드 제약조건이 불필요하게 솔루션 범위를 축소하여 활용을 제한하는 단점을 극복하고, 주문 단위의 실시간 의사결정을 가능하게 한 데 있다. 또한 학습과정을 통하여 컴퓨터 기반 수리적 의사결정모델에서 제공하는 결과치와 업무 담당자가 익숙한 결과치의 갭을 줄이고 일반적으로 통용되는 친숙한 데이터 마이닝 기법을 사용함으로써 사용자의 모델 사용에 대한 거부감을 최소화 하였다.

본 연구의 한계점은 진정한 최적화 데이터를 이용한 데이터 마이닝 규칙을 학습하지 못한 데 있다. 이는 공장 배분 문제의 계산적 복잡도와 제약 조건 성격상 최적화 솔루션을 찾기가 어렵고 상황별 공정 능력에 따라 최적화 솔루션이 변하는데 기인한다. 이러한 문제점을 최소화 하기 위하여 가능한 많은 데이터를 훈련과 검증과정에 사용하였으며 공장 배분의 기본이 되는 변수 선택 등에 완벽성은 향후 더욱 나은 훈련용 데이터의 확보와 현업 전문가의 참여 비중을 높여 개선되어 질 수 있을 것이다.

또한 공정능력 균등화를 위한 사후 조정 과정의 단순성은 수익성 최적화 수준 저하의 근본 원인이 되었다. 본 논문에서는 품질 속성과 관련된 선형계획의 하드 제약조건을 비유연성을 데이터 마이닝을 이용한 보완에 초점을 두었으며 사후 조정 휴리스틱의 정교화 및 데이터 마이닝 기법과의 결합을 통한 새로운 알고리즘의 개발 등이 향후 발전 방향이 될 것이다. 본 논문에서 시도한 최적화 수리계획 문제의 데이터 마이닝 기법 응용 방식은 e-비즈니스 경영환경에 필요한 많은 운용 계획, 자원 할당 및 최적화 문제에 활용 될 수 있을 것으로 생각한다. 또한 기존 업무에 사용되는 최적화 모델과의 결합을 통한 시너지 기회로 확장될 수 있을 것이다.

참 고 문 헌

- [1] 박동규, 「광양제철소의 최적 Mill 배분 Model 개발」, 산업과학기술 연구소, 1999.
- [2] 이진창, 정남호, 신경식, “신용카드 시장에서 데이터 마이닝을 이용한 이탈고객 분석”, 「한국지능정보시스템 학회 논문지」, 제8권, 제2호(2002).
- [3] 이기동, “데이터 마이닝 기법의 기업 도산 예측 실증분석”, 「한국경영학회지」, 제28권, 제2호(2003).
- [4] 이극노, 이홍철, “이동통신고객 분류를 위한 의사결정나무(C4.5)와 신경망 결합 알고리즘에 관한 연구”, 「한국지능정보시스템학회 논문지」, 제9권, 제1호(2003).
- [5] 지원철, 서민수, “데이터 마이닝을 활용한 공급사슬관리 의사결정 지원시스템의 구조에 관한 연구”, 「경영정보학연구」, 제8권, 제3호(1998).
- [6] Berry, M.J.A. and G. Linoff, *Data Mining Techniques for Marketing, Sales, and Customer Support*, John Wiley, 1997.
- [7] Baker, G.L., W.A. Clark, J. Frund and R.E. Wendell, “Production Planning and Cost Analysis on a Microcomputer,” *Interfaces* Vol.17, No.4(July-August 1987), pp.53-60.
- [8] Berson, A., *Building Data Mining Application for CRM*, McGraw Hill, 2000.
- [9] Box, R.E. and D.G. Herbe, “A Scheduling Model for LTV Steel’s Cleveland Works’ Twin Strand Continuous Slab Caster,” *Interfaces* Vol.18, No.1(1998), January-February, pp.42-56.
- [10] Cichocki, A., R. Unbehauen, K. Weinzierl and R. Holzel, “A New Neural Network for Solving Linear Programming Problems,” *European Journal of Operational Research*, Vol.93, No.2(1996), pp.244-256.
- [11] Diaz, A., L. Sancho, R. Garcia and J. Larraneta, “A Dynamic Scheduling and Control System in an Ensidesa Steel Plant,” *Interfaces* Vol.21, No.5(1991), September-October, pp.53-62.
- [12] Growth, R., *Data Mining Building Competitive Advantage*, Prentice Hall, 2000.
- [13] Lee, H.S., S.S. Murthy, S.W. Haider and D. V. Morse “Primary Production Scheduling at Steelmaking Industries,” *IBM Journal of Research and Development*, Vol.40, No.2 (1996), March.
- [14] Kao, L.J. and C.C. Chiu, “Mining the Customer Credit by Using the Neural Network Model with Classification and Regression Tree Approach,” *IFSA World Congress and 20th NAFIPS International Conference*, Vol.2(2001), pp.923-928.
- [15] Lippmann, R.P., “An Introduction to Computing with Neural Nets,” *IEEE ASSP Magazine*, Vol.3, No.4(1998), pp.4-22.
- [16] Mohanty, R.P. and R. Singh, “A Hierarchical Production Planning Approach for a Steel Manufacturing System,” *International Journal of Operations & Production Management*, Vol.12, No.5(1992), pp.69-78.
- [17] Nguyen, P.L. and L. Dupont, “Production Management of a Steel Manufacturing System : A Hierarchical Planning Model,” *Computers and Industrial Engineering*, Vol.25, No.1/4(1993), pp.81-84.
- [18] Quinlan, J.R., *C4.5 : Programs for Machine Learning*, Morgan Kauffman, 1993.
- [19] Ramanujam, J. and P. Sadayappan, “Optimization by Neural Networks,” *In Proceedings of The IEEE International Conference on Neural Networks*, San Diego, CA, Vol.2(1988).
- [20] Smith, K., M. Palaniswami and M. Krishnamoorthy, “Neural Techniques for Com-

- binatorial Optimization with Applications," *IEEE Transactions on Neural Networks*, Vol.9, No.6(1998), pp.1301-1318.
- [21] Sung, T.K., N. Chang and G. Lee, "Dynamics of Modeling in Data Mining : Interpretive Approach to Bankruptcy Prediction", *Journal of Management Information Systems*, Vol.16, No.1(1999), pp.63-86.
- [22] Tang, L., J. Liu, A. Rong and Z. Yang, "A Review of Planning and Scheduling Systems and Methods for Integrated Steel Production," *European Journal of Operational Research*, Vol.133(2001), pp.1-20.
- [23] Turban, E., J. Lee, D. Viehland and D. King, *Electronic Commerce : A Managerial Perspective 2004*, Prentice Hall. 2004.