

신경망 모델 기반 조선소 조립공장 작업상태 판별 알고리즘

홍승택 · 최진영[†] · 박상철

아주대학교 산업공학과

Neural Network Model-based Algorithm for Identifying Job Status in Block Assembly Shop for Shipbuilding

Seung Taek Hong · Jin Young Choi · Sang Chul Park

Department of Industrial Engineering, Ajou University

In the shipbuilding industry, since production processes are so complicated that the data collection for decision making cannot be fully automated, most of production planning and controls are based on the information provided only by field workers. Therefore, without sufficient information it is very difficult to manage the whole production process efficiently. Job status is one of the most important information used for evaluating the remaining processing time in production control, specifically, in block assembly shop. Currently, it is checked by a production manager manually and production planning is modified based on that information, which might cause a delay in production control, resulting in performance degradation. Motivated by these remarks, in this paper we propose an efficient algorithm for identifying job status in block assembly shop for shipbuilding. The algorithm is based on the multi-layer perceptron neural network model using two key factors for input parameters. We showed the superiority of the algorithm by using a numerical experiment, based on real data collected from block assembly shop.

Keyword: neural network, multi-layer perceptron, shipbuilding, welding

1. 서론

오늘날 많은 제조업체들이 치열한 경쟁 속에서 생산성 향상과 원가 절감을 위해 지속적인 노력을 하고 있다(Kim *et al.*, 2007). 또한 이러한 목적을 달성하기 위해 IT기술이나 데이터 분석 기법을 생산과정에 적용하는 노력도 활발히 진행하고 있으며, 자동화를 통한 대량생산 체제 혹은 흐름생산 체제를 갖추므로서 탄력적이고 유연한 생산 체제를 구축하고 있다.

그러나 조선업의 경우에는 주문생산방식을 취하고 있기 때문에 항상 다른 설계도를 가진 선박을 제작하므로 자동화를 통한 대량생산 체제의 도입이 어려운 실정이다(Woo, 2003). 따라서 보다 효율적인 관리를 위하여 생산 프로세스 및 관리 전

반에서 전산화를 통한 생산성 향상에 많은 노력을 기울이고 있다.

하지만 생산계획의 수립은 아직도 많은 부분 경험에 의존하고 있으며 실적정보 또한 작업자에 의해 수기로 작성되거나 생산 관리자가 일일이 현장을 체크하며 정보를 얻고 있는 실정이다. 그 이유는 작업의 진척도, 부하율 등 현장의 실적정보를 수집하기 어렵고, 생산계획의 검증 및 평가를 위한 시스템 역시 찾아보기 힘들기 때문이다. 결과적으로 예상하지 못했던 변동사항이 발생할 경우 결품이나 물량의 과부하 등으로 인해 납기를 맞추지 못하는 상황을 야기하기도 한다. 따라서 처음부터 완벽한 생산계획을 세우기 위해 노력하기보다 이미 수립된 생산계획을 관리자가 탄력적으로 수정할 수 있도록 의사결

본 논문은 석사학위를 위한 연구로 수행되었음(Hong, S.T., 2011).

[†]연락처 : 최진영 교수, 443-749 경기도 수원시 영통구 원천동 산 5번지 아주대학교 산업정보시스템공학부,

Fax : 031-219-1610, E-mail : choijy@ajou.ac.kr

투고일(2010년 09월 10일), 심사일(1차 : 2011년 03월 30일), 게재확정일(2011년 07월 28일).

정을 지원하는 방식의 시스템을 도입하는 것이 더 효율적일 수 있다.

그러나 현재 조선업의 경우에 이러한 의사결정 지원이나 작업현장의 정보를 모니터링 할 수 있는 시스템을 도입한 경우는 거의 없는 실정이다. 또한, 지금까지의 문헌 조사에서도 조선업 또는 그 범위를 확장한 금형 산업의 경우에서까지도 이러한 목적으로 적용된 시스템이나 방법론을 도입한 사례는 찾아보기 어렵다. 따라서 작업장에서 진행하고 있는 작업이 무엇인지, 그리고 그 작업이 얼마나 진행되었는지를 손쉽게 파악하고 관리할 수 있도록 하여 눈으로 보는 관리, 효율적인 관리가 이루어질 수 있도록 하는 시스템 및 방법론을 연구하는 것이 매우 필요하다.

이러한 이유로 본 논문에서는 신경망 모델을 기반으로 조선소의 조립공장 작업 상태를 효율적으로 판별하는 방안을 제안한다. 구체적으로 본 연구에서는 Z사의 조선소 조립공장의 작업 중에서 용접 작업을 대상으로 현장 작업 상태를 판별하고 모니터링 할 수 있는 알고리즘을 제안한다. 이를 위해 작업현장에서 발생하는 작업진행 관련 데이터를 취득하고, 이 데이터를 가공하여 인공 신경망의 다계층 퍼셉트론 모델에 적용시킨다. 제안된 모니터링 시스템은 현장 데이터를 수집하여 처리한 후 계획대비 실적의 진척도나 문제 공정을 신속히 파악하여 탄력적인 생산계획 수정과 효율적인 실적 관리를 가능하게 할 수 있을 것으로 기대된다.

본 논문은 다음과 같은 내용으로 구성되어 있다. 제 2장에서 모니터링 및 데이터 수집 방법을 소개한다. 제 3장에서는 다계층 퍼셉트론 모델을 기반으로 하여 조립공장 현장의 작업 상태를 판별하는 알고리즘에 대해 기술하며, 제 4장에서 실험을 통한 모델 검증을 설명한다. 마지막으로 제 5장에서는 본 연구에 대한 결론과 향후 연구 방향을 제안한다.

2. 작업상태 모니터링 방법

2.1 용접작업 데이터의 특성

용접 작업은 선박 건조 공정의 약 70% 이상을 차지하는 가장 중요한 요소이다(Noh *et al.*, 2008; Mun *et al.*, 2006). 그러나 대부분의 작업이 규모가 크고 불규칙적이기 때문에 자동화가 매우 어렵고 현장의 정보가 제한적이어서 작업 현황에 대한 관리가 매우 어려운 실정이다. 따라서 용접작업에 대한 생산계획 및 실적관리, 진도관리 등의 효율성을 극대화시키기 위해서는 현장의 정보를 수시로 확인할 수 있는 모니터링 시스템이 필수적이다.

본 연구에서 적용한 모니터링 시스템의 기본 아이디어는 용접 데이터의 수집을 통한 분석이다. 용접 데이터는 크게 취부, 용접, 사상의 세 가지 작업으로 구분된다. 취부란 가용접하는 작업이고, 용접은 가용접이 된 부분을 좀 더 두껍게 붙이는 작업이다. 사상은 용접 작업이 끝나면 마무리 하는 작업을 의미

하는데, 실제로 많은 시간이 걸리지 않기 때문에 현장에서는 그 작업시간을 크게 고려하고 있지 않다. 따라서 용접 작업에서 취부와 용접작업이 들어가는 시점 및 마무리되는 시점에 대한 정보를 얻는 것은 현장의 실적정보를 반영하는데 있어 의미가 크다.

일반적으로 취부와 용접 작업은 <그림 1>과 같이 두 개의 특성치 A와 B를 이용하여 표현될 수 있다(본 논문에서는 관련 Z사의 정보 비공개 요청에 의해 관련 특성치를 A와 B등으로 표시함). 그림에서와 같이 취부 작업의 경우에는 특성치 A와 특성치 B의 값이 작게 나타나는 반면에, 용접 작업의 경우 두 특성치의 값이 크게 나타난다. 이 때, 두 작업을 구분하기 위해 기준이 되는 두 개의 특성치에 대한 임계치 L_A 와 L_B 를 정의할 수 있다.

그러나 일반적으로 작업자의 작업방식과 작업부분, 작업 자세 등에 따라서 취부와 용접에 대한 특성치 A와 B값이 다르게 나타날 수 있기 때문에 모든 작업자의 작업이 <그림 1>과 같이 용접과 취부에 대한 특성치 A와 B의 값이 분명히 구분되어 나타나는 것은 아니며, 이를 위한 두 개의 임계치를 찾기는 쉽지 않다. 따라서 작업 상태 판별을 위해서 임계치로 정의된 값에 대한 정보만을 고려하는 것은 적중률이나 신뢰도가 많이 떨어질 수 있으며, 이를 위한 효율적이고 체계적인 방법에 대한 연구가 필요하다.




그림 1. 취부/용접 데이터의 특성

2.2 작업상태 모니터링 및 데이터 전처리

본 연구에서 용접작업 데이터 수집을 위해 고려한 모니터링 시스템은 <그림 2>와 같이 구성된다. 우선 모니터링 시스템은 Z사의 조선소 작업 현장으로부터 특성치 A 및 특성치 B에 대한 정보를 취득하여 PC에 저장한다. 저장된 데이터는 적절한 크기와 형태의 정보로 가공되어 분석되고 이를 통해 취부 또는 용접의 작업 상태가 구별된다.

그러나 일반적으로 모니터링 시스템을 통해 측정되는 데이터는 그 수가 너무 많기 때문에 데이터 전체를 사용하는 것은 매우 비효율적이며 적절한 방법을 적용한 데이터 양의 축소를 통하여 좀 더 의미있고 합리적인 형태의 데이터를 얻는 것이 필요하다. 본 연구에서는 이를 위해 k번의 측정에 대한 평균값

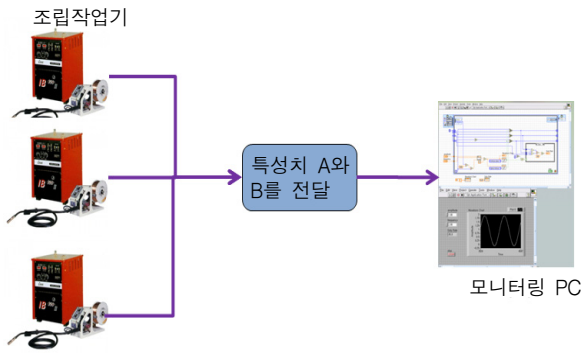


그림 2. 용접 데이터 수집 시스템 구성

sample	4라인	용접	8라인	취부	12라인	용접
	특성치B	특성치A	특성치B	특성치A	특성치B	특성치A
	10	208.8492	101	246.2395	74	251.8816
	13	268.2675	84	240.9104	5	121.2036
	22	175.8698	60	220.4723	3	104.5068
	10	221.6787	2	72.26895	41	341.3291
	19	212.0787	3	70.25527		
	27	273.9603	3	57.45497		
	18	264.7253	7	110.0647		
데이터	10	254.574	7	96.60683		
	51	259.0909	6	78.90595		
	46	262.1748	11	103.9442		
	19	277.015	14	110.354		
	24	272.3349	14	242.7174		
	27	289.7649	14	241.8753		
	23	283.1602				
	3	64.24143				
	5	153.0338				
	평균값	20.4375	233.8012	25.07692	145.5438	30.75

그림 3. 특성치 A와 B에 대한 1차 가공 데이터

을 이용해서 1회 측정된 것으로 데이터 양을 축소하는 방법을 적용하였다. 또한 지나치게 작은 값의 특성치 A와 B의 값은 용접과 관계없는 다른 원인에 의한 것으로 고려하여 작업하지 않은 것으로 처리하였다. 1차 가공을 통해 얻은 특성치 A와 B의 데이터는 <그림 3>과 같다.

이렇게 얻은 데이터를 이용하여 작업상태를 판별하는 간단한 방법으로 앞에서 언급한 것과 같이 두 개의 특성치에 대한 임계치 L_A 와 L_B 를 활용하는 것을 고려할 수 있다. 구체적으로 특성치 A와 특성치 B의 수학적 연산을 통해 새로운 특성치 C를 정의할 수 있는데, 이 값의 임계치 L_C 를 이용하면 취부와 용접에 대한 구분이 일정 수준 가능해질 수 있다. 그러나 이 방법은 사용하기 간단하고 편리한 장점이 있지만 검증되지 않은 임의의 임계치를 사용하기 때문에 그 적중률을 신뢰하기가 어렵다. <그림 4>는 특성치 C 값을 그래프로 표현한 예인데 취부와 용접에 대한 특성치 C 값이 비선형적이기 때문에 하나의 임계치 L_C 를 이용하여 선형적인 방법으로 취부와 용접을 정확하게 구분하는 것은 매우 어렵다.

9일	특성치D	4	특성치C	51708.93	특성치B	681
	특성치D	22	특성치C	18376.88	특성치B	1643
	특성치D	59	특성치C	9243.901	특성치B	2383
	특성치D	27	특성치C	13850.79	특성치B	1645
	특성치D	5	특성치C	32526.94	특성치B	640
	특성치D	57	특성치C	9111.313	특성치B	2202
	특성치D	34	특성치C	9209.82	특성치B	1381
	특성치D	39	특성치C	9517.805	특성치B	1680
	특성치D	62	특성치C	6145.092	특성치B	1763
	특성치D	23	특성치C	4821.128	특성치B	523

그림 5. 특성치 A와 B에 대한 2차 가공 데이터




그림 4. 특성치 C를 이용한 취부와 용접의 구분 방법

따라서 본 연구에서는 좀 더 정확하고 신뢰할 수 있는 방법으로 인공지능망의 다계층 퍼셉트론 모델을 이용한 방법을 고려하였다. 그러나 앞에서 언급된 바와 같이 모니터링 시스템을 통해 수집된 데이터는 작업자마다의 특성에 따라 특성치 A와 B의 값이 작업 상태를 정확하게 반영하지 못할 수 있기 때문에 이에 대한 보정 효과를 위한 작업이 필요하다. 이를 위해 본 연구에서는 1차 가공한 데이터를 2차 가공하여 세 개의 특성치 B, C, D에 대한 데이터를 <그림 5>와 같이 생성하였다.

3. 다계층 퍼셉트론 모델 기반 작업상태 판별 알고리즘

3.1 다계층 퍼셉트론 모델

일반적으로 인공지능망 모형은 대규모의 정보를 신속하게 학습해서 예측하는 능력을 가진다. 이를 위해 인공지능망은 입력된 자료에 대하여 학습을 하고 가중치를 부여한다. 이 가중치는 최초 입력된 자료들에 대하여 상대적 중요성을 나타내며, 학습을 통하여 반복적으로 조절되어 결론에 도달하게 된다. 이러한 인공지능망 모형은 통계모형에 비하여 불완전한 자료나 분산 값이 큰 자료를 이용한 예측에 적응력이 뛰어나다(Dayhoffs, 1990; Arbib, 1995).

본 연구에서는 Z사의 조립공장 작업상태 판별을 위한 알고리즘으로 다계층 퍼셉트론 모델을 제안하였다. 제안된 모델의 입력값으로에서는 2차 가공된 데이터 값 중에서 특성치 C와 D를 모델에 대한 입력값으로 고려하였다. 이는 앞에서 설명된 것과 같이 특성치 C와 D는 특성치 A와 B로부터 가공된 결과로 얻어진 데이터이기 때문에 좀 더 함축된 정보를 포함하고 있기 때문이다.

따라서 제안된 모델의 기본 구성은 <그림 6>과 같이 2개의 입력 노드 0과 1로 구성된 입력층(input layer), 2개의 노드 2와 3으로 구성된 은닉층(hidden layer), 그리고 1개의 노드 4로 구성된 출력층(output layer)을 가진다. 이 때 은닉층을 구성하는 노드 수는 모델의 특성에 따라 가변적일 수 있다. <그림 6>에서 사용된 기호는 다음과 같이 정의된다.

로 구성된 은닉층(hidden layer), 그리고 1개의 노드 4로 구성된 출력층(output layer)을 가진다. 이 때 은닉층을 구성하는 노드 수는 모델의 특성에 따라 가변적일 수 있다. <그림 6>에서 사용된 기호는 다음과 같이 정의된다.

- x_{pi} : 입력노드 i 로의 입력값(특성치 C와 D)
- w_{ji} : 노드 i 와 노드 j 사이의 가중치
- nt_{pj} : 노드 j 로의 입력값
- O_{pj} : 노드 j 의 출력값
- δ_{pj} : 노드 j 에서의 오차값

또한 각 계층의 가중치를 학습하는 방법으로 오류 역전파 방법을 적용하였다. 이는 은닉층의 학습을 위해 출력층에서 발생한 오류(Error)를 이용하여 은닉층의 가중치를 갱신하고, 다시 이 값을 입력층으로 역전파시켜 입력층의 가중치를 갱신하는 학습 방법으로 원하는 목표값과 실제 출력값 사이의 오차제곱합을 경사하강 추정법에 의해 최소화하는 방법이다(Stuart and Peter, 2009). <그림 7>은 오류 역전파 학습의 계산 과정을 나타낸다. 출력값 계산을 위한 활성화 함수는 시그모이드 함수 $f(x) = 1/(1 + e^{-x})$ 를 사용하였다.

3.2 모델 학습 및 작업상태 판별 알고리즘

제안된 모델의 학습과정을 노드 1 → 3 → 4를 지나는 학습을 예로 들면은 다음과 같다.

$$nt_{p3} = \sum_{i=0}^1 w_{3i}x_{pi}$$

여기서 nt_{p3} 은 입력층 노드 1에서 은닉층 노드 3으로의 입력값이고 i 는 입력 노드를 의미한다. 위의 결과 값을 시그모이드 함수에 대입하여 다음의 결과를 얻을 수 있다.

$$O_{p3} = f(nt_{p3}).$$

O_{p3} 은 은닉층 노드 3에서 나오는 출력 값이 된다. 이 출력 값을 통하여 출력층의 입력 값을 다음과 같이 계산한다.

$$nt_{p4} = \sum_{j=2}^3 w_{4j}O_{pj}$$

nt_{p4} 는 출력층 노드 4로의 입력 값이고 j 는 은닉 노드를 의미한다. 이 값을 다시 시그모이드 함수에 대입하여 출력층 노드 4의 출력 값을 얻는다.

$$O_{p4} = f(nt_{p4})$$




그림 6. 다계층 퍼셉트론 모델




그림 7. 오류 역전파 학습

다음으로 입력 패턴의 목표 출력 값(d_{p4})과 실제 출력 값(O_{p4})의 오차값(δ_{p4})을 계산한다. 계산은 다음 공식에 의해 이루어진다(Jiawei, 2000).

$$\delta_{p4} = (d_{p4} - O_{p4})f'(nt_{p4}) = (d_{p4} - O_{p4})O_{p4}(1 - O_{p4})$$

출력층의 오차값과 은닉-출력층 사이의 가중치 값을 이용하여 은닉층의 오차를 계산한다. 은닉층의 오차는 출력층의 모든 노드에 대하여 고려한다.

$$\delta_{p3} = f'(nt_{p3})\delta_{p4}w_{k3} = \delta_{p4}w_{k3}O_{p3}(1 - O_{p3})$$

은닉층 노드 3의 출력값 O_{p3} 과 출력층의 오차값 δ_{p4} 를 이용하여 출력층의 가중치를 갱신한다.

$$w_{43}(t+1) = w_{43}(t) + \eta\delta_{p4}O_{p3}$$

여기서 η 는 학습률이고 $t+1$ 은 반복이 한번 지난 것을 의미한다. 위의 과정을 입력층-은닉층 사이에서도 반복하여 가중치를 갱신한다.

이러한 계산과정을 기반으로 하여 인공신경망의 다계층 퍼셉트론 알고리즘이 구동되는 전체 절차는 <그림 8>과 같다. 먼저 신경망 학습을 몇 번 반복할 것인지와 가중치 갱신에서

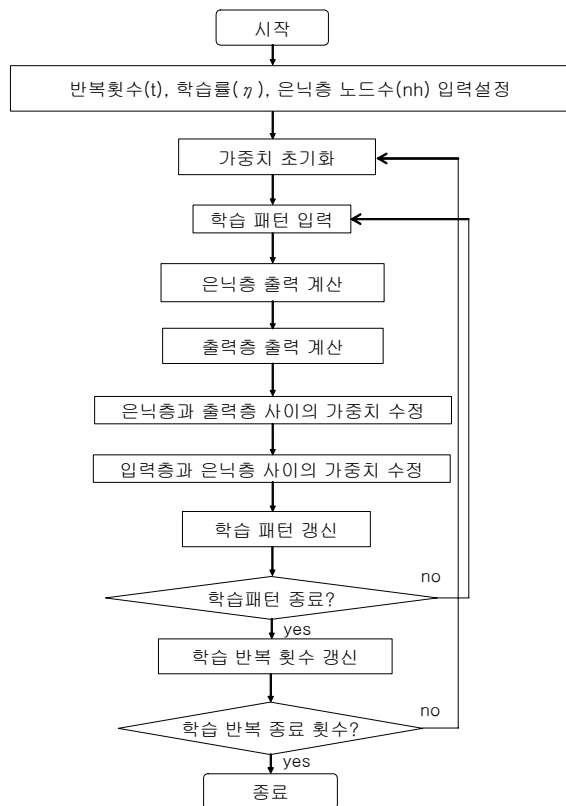


그림 8. 다계층 퍼셉트론 모델 순서도

사용되는 학습률, 그리고 은닉층의 노드 수를 입력 변수로 설정한 후 각 연결에 대한 가중치를 초기화 한다. 다음으로 학습에 필요한 데이터가 입력되고 은닉층의 출력, 출력층의 출력이 계산된다. 이를 통해 오차를 구하고 각각의 가중치를 갱신한다. 갱신이 완료되면 새로운 데이터가 입력되고 이를 학습 반복 횟수만큼 반복하게 된다.

4. 실험을 통한 모델 검증

4.1 데이터 및 실험 설정

제안된 알고리즘의 효율성을 다음과 같이 실험을 통하여 검증하였다. 먼저 제안된 알고리즘을 <그림 8>에 기술된 절차에 따라 Matlab을 이용하여 구현하였다. 특히 은닉층의 노드 수에 따른 알고리즘의 성능 변화를 관찰하기 위하여 은닉층 노드 수를 0에서 3까지 변화시킬 수 있도록 하였다.

실험을 위한 데이터는 Z사의 현장에서 3개월간 수집되었으며, 1차 및 2차 가공을 통해 1761개를 얻었다. 작업 상태 구분을 위하여 편이상 수행한 작업이 용접작업일 경우에는 '1' 취부작업일 경우 '-1'로 표현하였다. 제안된 모델의 검증을 위해 1761개의 데이터 중 학습 및 가중치 설정을 위한 훈련용 데이터로 1200개의 데이터를 활용하였으며, 나머지 561개의 데이터를 검증용 데이터로 사용하였다. 데이터의 샘플은 <그림 9>와 같다.

실험을 위한 파라메타 설정 값으로 학습 반복횟수(t)는 100회로 정하였다. 즉 1761개의 데이터를 이용하여 1회 학습과 적중률을 계산하게 되는데 이를 100회 반복하여 평균 적중률을 계산하게 된다. 초기 가중치는 사전 실험을 통하여 정해진 -0.2~0.9사이의 값을 랜덤으로 적용하였으며, 가중치 갱신에 필요한 학습률은 0.1로 설정하였다.

특성치D	특성치C	취부/용접구분
9	10755.21	1
22	21766.3	1
27	29884.42	1
25	19906.58	1
52	12138.52	1
38	13353.31	1
22	18376.88	1
59	9243.901	1
27	13850.79	1
5	32526.94	1
62	6145.092	1
47	1483.262	-1
61	708.6652	-1
60	561.704	-1
42	852.0702	-1

그림 9. 알고리즘 성능 검증 실험 데이터

4.2 실험 결과 비교 분석

실험의 결과는 두 가지 경우로 나누어 비교 분석하였다. 첫 번째는 제안된 다계층 퍼셉트론 모델의 은닉층 노드 수가 0개에서 3개까지 각각의 경우에 대한 적중률을 100회 반복에 대한 평균값으로 측정하여 알고리즘 성능을 비교 분석하였고, 두 번째는 본 연구에서 제안된 다계층 퍼셉트론 모델 방법을 앞에서 언급된 특성치 C를 활용하는 방법과 비교하였다.

먼저 첫 번째 경우에 대한 결과로서 은닉층 수의 변화에 대한 신경망 모델의 성능 분석은 <표 1>과 같다. 은닉층이 없는 경우인 단층 퍼셉트론 모델 보다는 은닉층의 노드가 존재하는 다계층 퍼셉트론 모델이 좀 더 좋은 적중률을 보였다. 최대 적중률 값 역시 단층보다는 다계층 퍼셉트론 모델이 높은 것으로 나타났다. 하지만 은닉층의 노드 수가 증가할수록 CPU time 역시 증가하였는데, 이는 은닉노드가 추가될수록 계산되는 양이 많아지기 때문이다.

한편, 은닉층이 있는 경우에 대해서도 은닉층에 있는 노드 수에 따른 다계층 퍼셉트론 모델 간의 성능 차이 검증을 위해 2 Sample t-test를 실시하였다. 그 결과 <표 2>와 같은 p-value 값을 구할 수 있었고, 이로 부터 노드 수가 2개 또는 3개인 경우가 노드 수가 1개인 경우 보다 우수한 성능을 보임을 알 수 있다. 또한 마지막 컬럼으로부터 노드 수가 2개인 경우와 3개인 경우에는 두 방법 간의 성능에 큰 차이가 없음을 알 수 있다.

두 번째 경우의 비교 분석 결과는 <표 3>과 같다. 특성치 C를 적용하는 방법은 <그림 4>와 같이 임의의 임계치 L_c 를 설정하여 용접과 취부에 대한 적중률을 계산하였으며, 이를 첫 번째 실험에서 가장 좋은 성능을 나타낸 은닉층 노드 수가 2개인 경우와 비교하였다. 결과적으로 다계층 퍼셉트론 모델에

의한 방법이 적중률 측면에서 평균적으로 약 10% 정도 우월함을 나타내었다. 한편 최대 적중률의 경우에는 제안된 방법이 특성치 C를 적용하는 것 보다 약 20% 정도 높은 적중률을 보였는데, 이 때 적용된 다계층 퍼셉트론 모델은 은닉층 노드 수가 1개이고 가중치가(0.1745, 0.1051, 0.5085)인 경우이다.

4.3 기대 효과

실험을 통하여 제안한 모델의 적중률이 좀 더 우월한 것을 확인하였다. 작업상태 모니터링에서 취부/용접의 구분에 대한 신뢰도가 높아진다면 다음과 같은 기대효과를 얻을 수 있다. 첫째로 스텝들이 현장을 일일이 체크할 필요 없이 현재 진행하고 있는 작업이 어떤 작업인지를 쉽게 판단할 수 있다. 이는 스텝들의 시간이나 동작 손실을 상당부분 감소시킬 수 있다. 그리고 판별 데이터를 기반으로 하여 각각의 블록에 대한 작업 시간 기준을 수립할 수 있다. 작업시간 기준을 수립하면 추후 유사한 블록에 대한 작업을 할 경우 작업의 진척률을 어느 정도 정확하게 파악할 수 있으며 타 정보(블록의 입출고 정보나 오버헤드 크레인 사용정보)와 혼용하여 사용한다면 좀 더 정확하게 진단과약을 할 수 있다. 궁극적으로는 이와 같은 정보를 파악하여 생산 계획의 수립이나 수정 시스템의 의사결정을 지원하여 효율적인 관리가 이루어지도록 할 수 있다.

5. 결론 및 향후과제

본 논문에서는 조선소의 조립 공장에서 작업상태 모니터링을 위해 다계층 퍼셉트론 모델을 적용하여 작업상태를 판별하는 알고리즘을 제안하였다. 실험을 통해 제안한 알고리즘은 현장에서 간편하게 사용할 수 있는 특성치 C를 적용하는 방법보다 적중률 측면에서 우월하다는 것을 검증하였고 은닉층의 노드 수에 따른 결과를 분석하여 가장 적합한 모델을 찾았다. 하지만 어떤 모델이 가장 좋은지는 경우에 따라 달라질 수 있다.

향후 연구 과제로서 본 논문에서 제안된 작업상태 판별 방법을 바탕으로 취부와 용접을 구분하고 이를 기반으로 하여 각 블록별 취부/용접에 대한 작업시간의 표준을 설정하는 문제가 있다. 또한 Man hour와 취부/용접 물량을 바탕으로 블록의 난이도를 설정하고 위의 두 정보를 기반으로 하여 유사 블록별 관계식을 도출하는 문제가 고려될 수 있다.

참고문헌

Arbib, M. A. (1995), The Handbook of Brain Theory and Neural Networks, The MIT Press.
 Dayhoffs, J. E. (1990), Neural Network Architecture : An Introduction, New York, Van Nostrand Reinbold.
 Hong, S. T. (2011), Efficient Job Progress Control Using Block Type

표 1. 은닉층의 노드수에 따른 성능 비교

은닉층 노드수	평균 적중률	최대 적중률	CPU Time
0	81.79%	96.35%	10.3초
1	86.72%	99.50%	12.8초
2	89.97%	99.39%	18.1초
3	88.91%	99.47%	25.6초

표 2. 2 sample t-test 결과

비교대상 은닉층 노드수	1개와 2개	1개와 3개	2개와 3개
P-value	0.012	0.049	0.443

표 3. LC 방법과 제안된 방법의 비교

방법	평균 적중률	최대 적중률
LC 적용	79.28%	-
은닉층 노드가 2개인 신경망 모델 적용	89.97%	99.50%

Standardization Based on Neural Network Model, MS Thesis, Ajou University.
 Jiawei, H. (2000), Data mining : Concepts and Techniques, *Academic press*.
 Kim, Y. S. and Lee, D. H. (2007), A Study on the Construction of Detail Integrated Scheduling System of Ship Building Process, *Journal of the Society of Naval Architects of Korea*, 44, 48-54.
 Lee, K. K. *et al.* (2003), Digital Manufacturing based Modeling and Simulation of Production Process in Subassembly Lines at a Shipyard, *The Korea Society for Simulation*, 1, 185-192.

Mun, S. H., Doh, Y. C., Park, G. B., Kim, D. K., and Kim, S. H. (2006), A CAD/CAM System for Sub-Assembly Welding Robot System at Shipyards, *The Korea Society of Machine Engineer*, 6, 440-443.
 Noh, H. W., Kim, K.-J., Leem, R. S., and Kim, H. K. (2008), A Study on a Development of the Grinding Robot to Remove Welding-bid of Working Pieces, *Journal of Ship and Ocean Technology*, 136-143.
 Stuart, R and Peter, N. (2009), *Artificial Intelligence A Modern Approach*, Pearson.



홍승택
 아주대학교 산업정보시스템공학부 학사
 아주대학교 산업공학과 석사
 현재 : STX 메탈 사원
 관심분야 : 생산시스템 스케줄링, 뉴럴 네트워크, 시뮬레이션



최진영
 한양대학교 산업공학과 학사
 한국과학기술원 석사
 미국 Georgia Tech 박사
 한국전자통신연구원 선임연구원
 삼성 네트워크 부장
 현재 : 아주대학교 산업정보시스템공학부 조교수
 관심분야 : 이산사건시스템 이론 및 응용, SCM, 생산 시스템 최적화, 데이터 마이닝



박상철
 KAIST 산업공학과 박사
 미국 DaimlerChrysler ITM research engineer
 현재 : 아주대학교 산업정보시스템 공학부 교수
 관심분야 : CAD/CAM, Virtual Manufacturing System, Discrete Event System Modeling and Simulation