

뉴럴네트워크를 이용한 다변수 관측작업의 평균탐색시간 예측

(Prediction of Visual Search Performance under Multi-parameter Monitoring Condition using an Artificial Neural Network)

박 성 준*, 정 의 승*

Abstract

This study compared two prediction methods - regression and artificial neural network (ANN) on the visual search performance when monitoring a multi-parameter screen with different occurrence frequencies. Under the highlighting condition for the highest occurrence frequency parameter as a search cue, it was found from the regression analysis that variations of mean search time (MST) could be explained almost by three factors such as the number of parameters, the target occurrence frequency of a highlighted parameter, and the highlighted parameter size. In this study, prediction performance of ANN was evaluated as an alternative to regression method. Backpropagation method which was commonly used as a pattern associator was employed to learn a search behavior of subjects. For the case of increased number of parameters and increased target occurrence frequency of a highlighted parameter, ANN predicted MST's more accurately than the regression method ($p<0.000$). Only the MST's predicted by ANN did not statistically differ from the true MST's. For the case of increased highlighted parameter size, both methods failed to predict MST's accurately, but the differences from the true MST were smaller when predicted by ANN than by regression model ($p=0.0005$). This study shows that ANN is a good predictor of a visual search performance and can substitute the regression method under certain circumstances.

1. 서 론

산업현장에서 작업자는 공정 시스템으로부터 많은 정보를 주고 받으며 작업을 수행해 나가게 된다. 특히 오늘날에 이르러 정보표현 기술의 발달로 인하여 작업자는 한 관측화면(Monitoring Screen)내에서 여러개의 관측변수(Monitoring Parameter)들을 관측해야 하는 경우가 대부분이라고 할 수 있다. 일반적으로 관측의 대상이 되는 이상치의 발생빈도가 여러개의 관측변수들에 대하여 모두 동일한 경우는 드물며, 관측변수간의 발생빈도가 서로 다른 경우가 대부분이다. 따라서 이러한 경우, 탐색시간의 단축을 위하여는 작업자로 하여금 우선적으로 탐색하여야 할 관측변수를 가르쳐 주는 것이 매우 중요하며, 이를 위하여 Highlighting 기법이 많이 사용되어 왔다. 그러나 불행하게도 Highlighting기법의 적용에 관한 연구들간에 상충되는 결과를 나타내는 경우가 많아 실제 화면설계에의 적용에 어려움이 따르고 있다. 따라서 탐색시간을 단축하여 줄 수 있는 Highlighting기법의 결정은 매우 중요한 연구과제라고 할 수 있다.

이상치를 빠르고 정확하게 찾는것이 관측의 목적이므로, 공정 관측화면의 설계에서 평균탐색시간은 설계의 적합성을 평가할 수 있는 지표(Index)로 사용될 수 있다. 따라서 공정의 변화, 새로운 관측변수의 추가등으로 인하여 관측화면을 수정하여 설계해야 할 경우, 변경된 조건하에서의 평균탐색시간을 실험없이 미리 알 수 있다면 설계의 적합성 평가에 많은 도움이 될것이며, 정확한 예측치는 효율적인 탐색이 가능한 화면설계안을 도출하는데 효과적으로 사용될 수 있다. 그러나 인간의 작업성능

* 포항공과대학 산업공학과

은 매우 복잡한 특성을 가지고 있기 때문에 정확한 예측이 매우 힘든 실정이다. 특히, 지금까지 대부분의 인간성능(Human Performance)의 예측에 사용된 회귀분석기법(특히, 선형회귀분석)은 '선형'을 기본가정으로 하므로 실제값과 많은 차이를 나타내는 경우가 종종 발생하곤 한다. 따라서 본 연구에서는 복잡한 입력-출력 관계를 나타내는데 많이 사용되고 있는 뉴럴 네트워크 기법을 이용하여 인간의 작업성능, 특히, 탐색작업에서의 작업수행능력을 예측해보고자 한다. 회귀분석기법과의 비교 분석을 통하여 탐색시간 예측기법으로서의 뉴럴 네트워크의 적용가능성을 평가하고자 한다.

2. 다관측변수의 탐색작업에서의 Highlighting기법

작업자에게 우선적으로 탐색하여야 할 관측변수에 관한 정보를 제시하므로써 보다 효과적인 관측이 이루어 질수 있도록 하기 위하여 많은 Coding기법들이 사용되어 왔다. 여러 Coding 기법들 중 Alphaneumeric 기법은 시스템의 상태를 나타내는 것과 같은 의미의 전달에는 효과적이나 순간적인 주의를 유도하는데는 효과적이지 못하며, 이러한 경우 'Size', 'Reverse video', 'Blink', 'Brightness', 그리고 'Color'등이 적합한 Coding 기법이라고 할 수 있다[9]. 그러나 'Reverse video', 'Brightness', 'Blink'등은 주의를 유도하는데는 효과적이나, 상태확인에는 비효율적이므로 오히려 탐색에 불편을 초래할 수도 있는것으로 밝혀지고 있으며[3,7], 이러한 이유로 인하여 Highlighting기법의 적용의 효과에 관한 연구결과들이 서로 상반되는 결과를 나타내는 것으로 보인다. 따라서 기존의 연구들을 분석하여 볼때 발생빈도에 관한 정보를 제시하여 주므로써 평균탐색시간을 단축시키고자 할 경우에 적합한 Highlighting기법으로는 'Size'와 'Color'기법이 효과적일 것으로 생각된다.

본 연구에 앞서 수행된 효과적인 Highlighting기법의 선정에 관한 연구에서는 'Size'와 'Color', 그리고 'Size+Color'기법에 관하여 탐색시간의 단축효과를 비교평가 하였다[1]. 각 관측변수 간에 발생빈도가 서로 다른 다관측변수를 관측하는 작업에서 세가지 Highlighting기법의 효과를 평가 하였으며, 각 기법간의 실험조건은 동일하게 하였다. 10명에 의하여 수행된 탐색작업의 시간을 분석한 결과, 위에서 언급한 세 기법간에는 통계적으로 유의한 차이가 없는 것으로 밝혀졌다($P=0.39$). 따라서 'Size'기법과 'Color'기법중 어느 기법을 Highlighting기법으로 사용하여도 비슷한 탐색시간의 단축효과를 얻을 수 있을 것으로 생각된다. 그러나 'Color'기법은 기존의 관측 시스템이 단색화면일 경우, 시설변경으로 인한 추가비용 요소가 발생하며 작업자중 색맹인 사람에게는 효과적이지 못할 수 있는 단점이 있다[8]. 더우기 'Color' 기법은 시스템의 상태를 나타내는 'Coding' 기법으로서도 효과적이기 때문에 이러한 목적으로도 많이 사용되고 있으며 이로 인하여 서로 혼란이 야기될 수도 있다. 따라서 발생빈도가 서로 다른 다관측변수의 관측작업에서 발생빈도에 관한 정보를 제시하기 위한 Highlighting기법으로는 'Size'기법이 매우 효과적일 것으로 생각되므로 본 연구의 Highlighting기법으로 선정하였다.

3. 실험방법

3.1. 피실험자

포항공과대학에 재학중인 학생 10명이 실험에 참여하였다. 남녀의 구성비율은 6:4 였으며, 20세에서 32세까지의 연령분포를 나타내었다. 피실험자들에 대한 시력 및 색맹검사 결과 모두 정상인 것으로 밝혀졌다.

3.2. 실험장비

실험은 IBM-PC를 이용하여 수행되었으며, 관측화면은 640 × 480 해상도의 VGA - Screen을 이용하여 제시되었다. 3 자릿수의 숫자들을 탐색대상으로 하여 CRT화면에 제시하였으며 'Size-cue' 조건 하에서는 대상이 되는 숫자들의 크기를 2배로 하여 제시하였다.

3.3. 실험계획 및 절차

관측대상이 되는 관측변수(Parameter)의 갯수(P), highlighting된 관측변수의 탐색목표물 (Target)의 발생빈도(F), 그리고 highlighting된 관측변수의 항목수(H)를 독립변수로 하는 '3-factor within-subject design'을 사용하여 실험을 실시하였다. Highlighting기법으로써 'Size-cue'가 제시되었다. 각 Session별로 실제 탐색작업을 실시하기전에 피실험자가 실험에 익숙해질 수 있도록 하고 학습효과를 제거하기 위하여 50회의 연습과정을 포함시켰으며, 피실험자별로 270회의 탐색작업을 수행하도록 하였다.

탐색대상은 실제 공정관측화면등에서 자주 볼 수 있는 숫자를 사용하였다. 세자리의 숫자중 앞의 두자리를 피실험자에게 미리 제시하여 준뒤 CRT 화면상의 여러 숫자들중에서 제시된 두자리의 숫자로 시작하는 숫자를 찾는것을 탐색작업으로 하였다. 피실험자는 각 탐색작업을 시작하기 전에 미리 제시되는 숫자를 충분히 인식한뒤 ENTER-key를 누름으로써 탐색작업을 실시하게 되며, 지정된 숫자를 찾은뒤 다시 ENTER-key를 누름으로써 탐색작업 1회가 종료된다. 각 탐색작업의 종료후에 피실험자로 하여금 제시하지 않은 마지막 숫자를 입력하게 하므로써 탐색의 정확도를 측정하였으며 ENTER-key 사이의 시간을 기록하여 탐색작업에 소요되는 시간을 측정하였다.

4. 탐색조건의 영향분석

Highlighting기법이 적용된 조건하에서 평균탐색시간은 Highlighting된 관측변수의 발생빈도가 증가할수록 (즉, Highlighting 효용도가 높아질수록) 감소하는 경향을 나타내었으며, 관측하여야 할 관측변수의 갯수가 증가함에 따라 증가하는 경향을 보였다. 본 연구에서 고려한 세요소들이 평균탐색시간에 미치는 영향을 보다 세밀히 분석하기 위하여 회귀분석기법을 적용하였다. 분산분석 결과 세 변수에 의한 주요인(Main Effect) 뿐만아니라 각 변수간의 교호작용 역시 존재하는 것으로 밝혀져(표 1 참조), 모두 6개의 변수를 이용하여 회귀식을 도출하였다(식 1). 교호작용을 나타내는 변수가운데 관측변수의 갯수(P)와 발생빈도(F)간의 교호작용변수는 두 변수가 평균탐색시간에 미치는 영향이 서로 반대이므로 P*F 대신 P/F를 회귀모형에 포함시켰으며 이 경우 도출된 회귀식이 평균탐색시간의 변동을 더욱 많이 설명하였다.

표 1. 분산분석 결과

SOURCE	DF	SS	MS	F	P
P	2	4.1146	2.0573	19.39	0.000
F	2	16.9911	8.4955	80.05	0.000
H	2	2.9204	1.4602	13.76	0.000
P*F	4	2.9814	0.7454	7.02	0.000
P*H	4	0.8887	0.2222	2.09	0.082
F*H	4	1.8741	0.4685	4.42	0.0018
P*F*H	8	0.1654	0.0207	0.19	0.998
Error	243	25.7889	0.1061		
Total	269	55.7246			

$$MST = 1.11 + 0.16*P - 0.859*F + 0.0932*H + 0.0409*P/F - 0.0155*P*H + 0.0259*F*H$$

(R² = 73.8%, adjusted R² = 72.9%)

(식 1)

실험에서 고려한 세 변수(P,F,H)들로부터 평균탐색시간 변동의 대부분(3/4)이 설명됨이 밝혀졌으며, 이로부터 발생빈도가 서로 다른 관측변수의 관측작업에서 Highlighting기법이 적용되었을 경우, 위에서 언급한 세 변수들을 이용하여 평균탐색시간을 예측할 수 있을 것으로 기대된다.

5. 뉴럴 네트워크의 적용

일반적으로 뉴럴 네트워크는 형상분류 (Pattern Classifier), 연상기억 (Associate Memory), 형상연상 (Pattern Associate)등의 문제를 해결하기 위하여 주로 사용되고 있다[6]. 본 연구에서는 탐색작업에서의 작업자의 평균탐색시간을 예측하기 위하여 뉴럴 네트워크가 사용되었으며 실험을 통하여 얻은 각 조건별 실제 탐색시간을 이용하여 네트워크를 학습시켰다. 뉴럴 네트워크의 학습에는 여러방법이 사용되고 있으나 본 연구에서는 Supervised Learning의 일종인 Backpropagation method를 적용하여 네트워크를 학습시켰다. Backpropagation 방식은 입력치와 출력치간의 관계를 'Propagate - Adapt'로 이루어진 2 단계 cycle을 통하여 학습해나가는 방법이다[5]. 입력된 데이터가 네트워크를 따라 출력 node에 전달되면 미리 지정된 출력치(Desired value)와의 비교과정을 거쳐 네트워크가 생성한 오차를 줄일수 있는 방향으로 네트워크의 각 Node간의 가중치(Weight)가 수정된다. 이러한 과정을 모든 입력 - 출력 쌍(pair)에 대하여 반복하여 수행하므로써 입력데이터와 출력데이터간의 관계를 학습하게 된다. 따라서 올바른 학습을 위하여는 입력과 출력의 쌍으로 구성된 학습데이터의 선정시 관심을 갖는 범위내의 데이터가 고루 포함되어 있어야 하는 것이 중요하며, 편향(Biased)된 데이터를 이용하여 학습시킬 경우 올바른 결과를 얻지 못하게 된다.

Backpropagation 방법을 이용할 경우의 네트워크의 구성에 대한 일반적인 토플로지(topology) 연구결과는 아직 도출되지 않았으며, 따라서 문제의 성격에 따라 시행착오(Trial & Error) 방식으로 네트워크의 구조를 결정하는 여러가지 매개변수(parameter) - 학습률(learning rate), 모멘텀(momentum), Layer의 갯수, Layer내의 nodes의 수 -들의 조합에 대하여 학습효과를 분석하여 가장 적절한 네트워크를 구축하게 된다. 문제의 특성에 따라 네트워크의 구조가 다르게 결정되므로 시행착오 방식에 의존해야 하는 단점이 있으나 한번 학습된 네트워크의 경우 입력 데이터에 대하여 단순한 가중치 계산과정에 의하여 출력값이 생성되므로 빠르게 결과를 얻을 수 있다는 장점이 있다.

6. 탐색시간 예측능력의 비교

6.1. 뉴럴 네트워크를 이용한 평균탐색시간의 예측

관측조건의 변화에 따른 평균탐색시간의 예측을 위하여 Backpropagation 기법을 도입하였다. 입력층(Input layer)은 관측변수의 갯수, 발생빈도, 그리고 Highlighting된 관측변수의 항목수와 같은 관측조건을 나타내기 위하여 3개의 node로 이루어지며 출력층(Output layer)은 평균탐색시간을 제시하는 1개의 node로 구성되었다. 입력층과 출력층을 연결하는 숨은층(Hidden layer)은 각각 6개와 3개의 node로 이루어진 2개의 층(Layer)을 갖는 구조를 선택하였다(그림 1 참조). 학습률과 모멘텀(Momentum)은 각각 0.7로 하였으며 실험에 의하여 얻은 실제 평균탐색시간과 네트워크가 제시하는 평균탐색시간간의 차이가 0.01 미만이 되면 학습이 된것으로 간주하였다. 학습된 범위 밖의 데이터에 대한 예측능력이 의미가 있으므로 각 변수들의 증가에 따른 평균탐색시간을 예측하도록 하였다. 본 연구에서 고려한 세 요인별로 18개의 조합에 대하여 실측치로 학습을 시킨뒤, 학습에 사용되지 않은 9개의

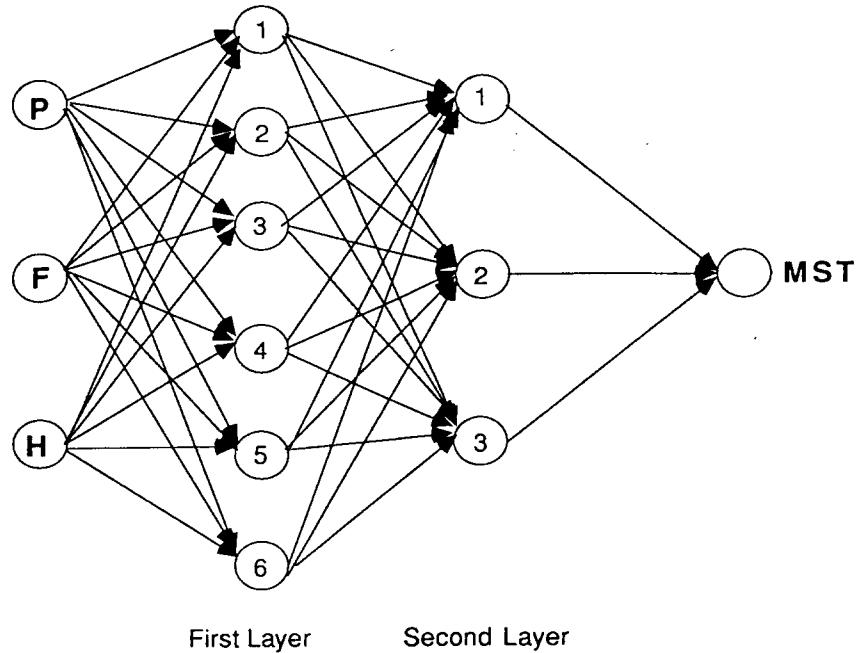


그림 1. 네트워크의 구조

6.2. 관측변수의 증가시의 탐색시간 예측비교

새로운 공정의 추가 도입등으로 인하여 관측해야 할 관측변수가 증가하였을 경우 새로운 관측시스템에서의 평균탐색시간을 예측하는 것은 작업자의 과부하(Overload)를 방지할 수 있는 관측시스템의 설계에 필수적이라고 할 수 있다. 관측변수의 갯수가 3개인 경우와 4개인 경우에서의 평균탐색시간을 이용하여 5개로 증가하였을 경우의 평균탐색시간을 예측하였다. 예측조건에서의 발생빈도 및 Highlighting된 관측변수의 항목수 수준은 학습조건의 수준과 각각 동일하게 하였다(발생빈도 40%, 60%, 80%; 항목수 4개, 6개, 8개).

관측변수가 3, 4개인 경우의 데이터를 이용하여 도출된 회귀식은 (2)과 같으며, 이를 이용하여 5개로 증가하였을 경우의 평균탐색시간들을 각 요인의 수준에 대하여 예측하였다. 같은 방법으로 관측변수가 3, 4개인 상황에서의 탐색시간을 이용하여 네트워크를 학습시켰으며, 학습된 네트워크를 이용하여 관측변수가 증가된 관측시스템에서의 평균탐색시간을 예측하여 회귀분석 기법에 의한 예측치와 비교하였다.

$$\begin{aligned} MST &= 1.04 - 0.748*P + 1.81*F - 0.06*H + 0.271*P/F + 0.0469*P*H - 0.0376*F*H \\ R^2 &= 79.4\% \end{aligned} \quad (식 2)$$

두 가지 방법으로 예측된 평균탐색시간을 실험에 의하여 측정된 실제 평균탐색시간과 비교함으로써 예측능력을 평가하였다. 표 2에서 보는 바와 같이 뉴럴 네트워크 기법에 의하여 예측된 탐색시간만이 실제 시간과 통계적으로 차이가 없는 것으로 밝혀졌으며($p=0.70$), 회귀식을 이용하였을 경우 실제 탐색시간과 유의한 차이가 있는 것으로 나타났다($p<0.0000$).

표 2. 각 기법의 정확성에 대한 Pairwise t-test (관측변수 증가)

	Mean	Stdev	p
Err_by_Reg	-0.3125	0.3982	0.0000
Err_by_NN	0.0113	0.2725	0.70

* H_0 : Error = 0 vs. H_1 : Error \neq 0

6.3. 발생빈도 증가시의 탐색시간 예측비교

특정 관측변수의 이상치(Target) 발생빈도가 다른 관측변수들에 비하여 높을 경우, 적절한 Highlighting기법의 적용은 위에서 언급한 바와 같이 평균탐색시간의 단축에 도움이 된다. 이 경우 Highlighting된 관측변수의 발생빈도(즉, Highlighting Validity)에 따라 그 효과는 다르게 나타나게 되며, 따라서 평균탐색시간 또한 이에 따라 크게 변하게 된다. Highlighting된 관측변수의 발생빈도가 증가하였을 경우의 평균탐색시간을 역시 두가지 방법으로 예측하였다. 40%, 그리고 60%에서의 탐색시간을 이용하여 80%로 증가하였을 경우의 평균탐색시간을 예측하였다. 도출된 회귀식은 식 (3)과 같으며, 이로부터 예측된 평균탐색시간과 뉴럴 네트워크에 의하여 예측된 탐색시간을 실제 평균탐색시간과 비교한 결과는 표 3에 나타난 바와 같다.

$$\begin{aligned} MST &= 1.17 + 0.238*P - 0.164F + 0.25*H - 0.049*P/F + 0.0018*P*H - 0.413*F*H \\ R^2 &= 73.9\% \end{aligned} \quad (\text{식 } 3)$$

표 3. 각 기법의 정확성에 대한 Pairwise t-test (발생빈도 증가)

	Mean	Stdev	p
Err_by_Reg	-0.3912	0.4006	0.0000
Err_by_NN	-0.0345	0.3705	0.38

* H_0 : Error = 0 vs. H_1 : Error \neq 0

관측변수의 갯수가 증가하였을 경우에서와 같이 뉴럴 네트워크에 의한 예측치만이 실제 탐색시간과 유의한 차이가 없었으며($p=0.38$), 회귀식을 이용하였을 경우 정확한 예측에 실패하였다($p<0.0000$).

6.4. Highlighting된 관측변수의 항목수 증가시의 탐색시간 예측비교

Highlighting된 관측변수의 항목수가 증가하면 우선적으로 탐색하여야 할 관측항목의 수가 증가므로 평균탐색시간 역시 길어지게 된다. 항목수가 4개 및 6개인 경우에서의 탐색시간을 이용하여 항목수가 8개로 증가하였을 경우의 증가된 평균탐색시간을 예측하였다. 실측치와의 Pairwise t-Test 결과, 불행하게도 회귀식을 이용하였을 경우 뿐만 아니라 뉴럴 네트워크를 사용하여서도 정확한 평균탐색시간의 예측에 실패하였다(표 4 참조). 이는 평균탐색시간에 영향을 미치는 세가지의 요인들중 Highlighting된 관측변수의 항목수의 영향정도가 다른 두 요인들에 비하여 상대적으로 작기 때문에 항목수의 변화에 의한 평균탐색시간의 변동추세를 발견하기 힘들었기 때문인 것으로 추측된다. 그러나

예측치와 실측치간의 차이는 뉴럴 네트워크에 의한 경우가 훨씬 작은것으로 나타나($p=0.0005$), 네트워크에 의한 방법이 보다 실제 평균탐색시간에 근접한 예측치를 도출해고 있음을 알 수 있다. 또한, 이러한 사실로부터 보다 많은 학습 데이터를 이용하여 네트워크를 학습시킬 경우, 실측치와 유의한 차이가 없는 예측치를 도출해 낼수 있을것으로 기대된다.

$$MST = 2.91 + 0.047*P - 2.18*F - 0.225*H + 0.017*P/F + 0.0165*P*H + 0.213*F*H$$

$$R^2 = 78.1\% \quad (\text{식 } 4)$$

표 4. 각 기법의 정확성에 대한 Pairwise t-Test (관측변수의 항목수 증가)

	Mean	Stdev	p
Err_by_Reg	-0.3851	0.3633	0.0000
Err_by_NN	-0.2132	0.4143	0.0000

* H_0 : Error = 0 vs. H_1 : Error \neq 0

7. 논의

본 연구에서는 일반적으로 음성 또는 문자 인식, Image Processing, 로보트 제어(Robot Control) 등에 많이 사용되고 있는 뉴럴 네트워크에 대하여 인간의 시각성능에 대한 예측기법으로의 적용 가능성에 대하여 실제 실험에 의한 데이터를 이용하여 검증하였다. 각 관측변수간의 발생빈도가 서로 다른 다관측변수의 관측작업에서 평균탐색시간의 변동에 영향을 미치는 각 요인들의 변화에 대하여 회귀분석 기법과의 비교를 통하여 뉴럴 네트워크의 예측능력을 평가하였다. 본 연구에서 고려한 세 가지 요인들의 변동에 대하여 뉴럴 네트워크를 이용하여 도출된 탐색시간은 회귀식으로부터의 예측치보다 정확한 것으로 판명되었다. 이는 인간의 시각성능 예측방법으로서 선형회귀 기법보다 뉴럴 네트워크가 우월할 수 있음을 나타내는 것으로서, 지금까지 인간성능(Human Performance)에 대한 예측기법으로 주로 사용된 회귀분석 기법의 대안으로서 뉴럴 네트워크가 효과적으로 사용될 수 있음을 의미한다.

평균탐색시간은 관측변수의 갯수, 관측변수의 발생빈도, 그리고 Highlighting된 관측변수의 항목수 등과 같은 여러 요인들에 의하여 복합적으로 영향받아 결정되므로 단순한 선형관계로는 이를 설명하기가 어려울 것으로 생각되며, 따라서 보다 구체적인 입력치와 출력치간의 관계도출을 위해서는 뉴럴 네트워크기법의 적용이 필요하다고 하겠다. 그림 2에서 볼 수 있듯이 회귀식을 이용할 경우 각 요인의 변화에 대하여 선형관계로 평균탐색시간을 예측하므로 실측치와의 편차가 크게 되어 실제 평균탐색시간을 정확히 예측하지 못하는 것으로 나타나고 있다. 뉴럴 네트워크를 사용하였을 경우, 실제 탐색시간의 변화형태를 비교적 유사하게 추적해 감으로써 보다 정확한 평균탐색시간을 예측하고 있다. 즉, 단순 선형식에 의존하는 회귀분석보다 뉴럴 네트워크를 사용하여 입력값과 출력값사이의 관계를 보다 정확하게 추정할 수 있음을 알 수 있으며, 인간의 수행능력과 같이 복잡한 특성을 추정하여야 할 경우 뉴럴 네트워크는 적합한 적용기법이라고 할 수 있다.

공정의 변화등으로 인하여 관측화면의 재설계가 요구될 경우, 시스템 설계자가 재설계된 화면에서의 평균탐색시간을 미리 알 수 있는 것은 효율적인 설계를 위하여 매우 중요한 일이라고 할 수 있다. 관측화면에서의 평균탐색시간은 설계에 대한 일종의 평가기준(Evaluation Index)으로 인식될 수 있다. 시간제약이 많은 작업환경하에서, 새로이 설계된 관측화면의 탐색시간은 설계의 적합성을 평가하는데 중요한 지침이 될 수 있으며, 따라서 뉴럴 네트워크를 이용한 평균탐색시간의 정확한 예측은 관

측화면의 설계에 유용하게 이용될 수 있을 것으로 기대된다.

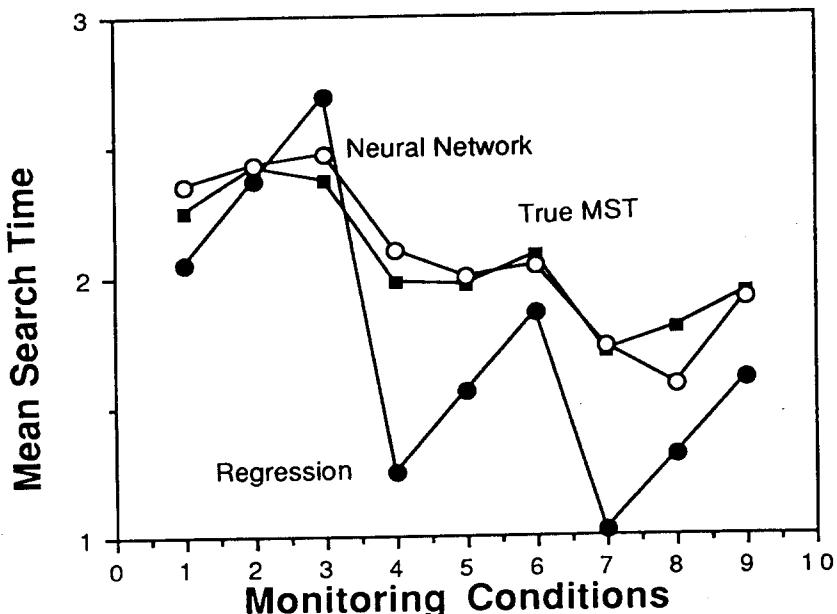


그림 2. 실측치와 예측치의 비교

8. 결 론

각 관측변수간의 이상치 발생빈도가 서로 다른 다관측변수의 관측작업에서 작업의 효율을 향상시키기 위하여는 우선적으로 탐색을 하여야하는 관측변수에 관한 정보를 작업자에게 제시하는 것이 중요하며, 이를 위하여 관측화면 설계과정에서 Highlighting기법의 사용이 제안되고 있다. Highlighting기법의 효용성에 대하여는 많은 논란이 있었으나, 본 연구로부터 'Size' Coding기법과 'Color' Coding기법이 적합한 Highlighting기법으로 평가되었다. 한편, 본 연구를 통하여 관측작업에서의 작업자의 시각성능(Visual Performance) 예측방법으로서 뉴럴 네트워크 기법이 매우 효과적으로 적용될 수 있음이 밝혀졌다. 인간성능의 예측기법으로서 일반적으로 사용되고 있는 회귀분석기법과의 비교, 평가를 통하여 뉴럴 네트워크 기법은 상대적으로 우월한 결과를 나타내었으며, 예측의 정확성, 개발의 용이성등을 고려할때 시각성능의 예측기법으로서 매우 유용하게 사용될 수 있을 것으로 기대된다. 본 연구로부터 도출된 결과를 요약하면 다음과 같다.

1. 뉴럴 네트워크는 작업자의 시각성능 예측기법으로서 매우 효과적으로 적용될 수 있다.
2. 뉴럴 네트워크를 이용하여 정확한 탐색시간의 예측이 가능하므로써 관측화면의 적합성을 평가할 수 있는 기준(Index)을 추가실험없이 얻을 수 있다.
3. Highlighting기법의 적용시 목적에 부합되는 Coding기법을 선정하여야 하며 Color Coding, Size Coding등이 권장된다.

참고문헌

1. 박 성 준, 정 의 승, "차등 발생빈도를 이용한 다공정변수의 관측작업", 91 대한산업공학회 추계 학술발표대회 논문집, pp.296-305, 1991.
2. Brown, T. J., "Visual Display Highlighting and Information Extraction", Proceedings of the Human Factors Society 35th Annual Meeting, pp.1429-1431, 1991.
3. Fisher, D.L. and Tan, K.C., " Visual Display : Highlighting Paradox", Human Factors, Vol.31, pp.17-30, 1989.
4. Fisher, D.L., Coury, B.G., Tengs, T.O., and Duffy, S.A., "Minimizing the Time to Search Visual Display : The Role of Highlighting", Human Factors, Vol.31, pp.167-182, 1989.
5. Freeman, J. A., and Skapura, D.M., "Neural Networks : Algorithms, Applications, and Programming Techniques", Addison-Wesley, 1991.
6. Lippmann, R. P., "An Introduction to Computing with Neural Nets", IEEE ASSP Magazine, April, 1987.
7. Smith, S. L., and Goodwin, N. C., "Blink Coding for Information Display", Human Factors, Vol.13, pp.283-290, 1971.
8. Tullis, T.S., "The Formatting of Alphanumeric Display : A Review and Analysis", Human Factors, Vol.25, pp.657-682, 1983.
9. Umbers, I. G., and Collier, G.D., "Coding Techniques for Process Plant VDU Format", Applied Ergonomics, Vol.21, pp.187-198, 1990