

# 유전자 알고리즘을 활용한 인공신경망 모형 최적입력변수의 선정: 부도예측 모형을 중심으로

## Using GA based Input Selection Method for Artificial Neural Network Modeling: Application to Bankruptcy Prediction

홍승현<sup>1</sup> · 신경식<sup>2</sup>

<sup>1</sup> 이화여자대학교 정보과학대학원

<sup>2</sup> 이화여자대학교 경영학부

### Abstract

Recently, numerous studies have demonstrated that artificial intelligence such as neural networks can be an alternative methodology for classification problems to which traditional statistical methods have long been applied. In building neural network model, the selection of independent and dependent variables should be approached with great care and should be treated as a model construction process. Irrespective of the efficiency of a learning procedure in terms of convergence, generalization and stability, the ultimate performance of the estimator will depend on the relevance of the selected input variables and the quality of the data used. Approaches developed in statistical methods such as correlation analysis and stepwise selection method are often very useful. These methods, however, may not be the optimal ones for the development of neural network models.

In this paper, we propose a genetic algorithms approach to find an optimal or near optimal input variables for neural network modeling. The proposed approach is demonstrated by applications to bankruptcy prediction modeling. Our experimental results show that this approach increases overall classification accuracy rate significantly.

### 1. 서 론

기업의 부도예측에 대한 연구는 1930년대 Fitzpatrick의 연구 이후 회계학에서 가장 활발히 연구되어지는 분야 중 하나로써, 과거 60년간 부도예측이 포함된 이론연구와 사례연구가 지속적으로 이루어졌다[11]. 부도예측모형의 구축은 은행 등 금융기관이 신용평가시스템 혹은 심사역 의사결정지원시스템을 구축하는데 중요한 기반이 된다. 많은 선행 연구들에서는 기업의 부도예측을 위하여 전통적으로 다변량 판별분석(Multivariate discriminant analysis)이나 로짓분석(Logit analysis)과 같은 통계기법이 많이 사용되었다. 그러나 1980년대 후반부터 인공신경망(Artificial neural network), 귀납적 학습방법(Inductive learning), 사례기반추론(Case based reasoning), 유전자 알고리즘(Genetic algorithms)

등 인공지능(Artificial intelligence) 기법이 부도 예측 분야에 응용되기 시작하였고, 많은 연구들이 부도예측모형 구축에 있어서 인공지능 기법의 우수성을 보고하고 있다[6, 13, 15, 16, 18, 23, 24, 28, 35, 40, 41, 42].

일반적으로 인공신경망 기법을 응용한 부도 예측모형에서는 기업의 재무정보 및 비재무정보를 입력변수로, 기업의 부도여부를 출력변수로 설정하여 학습을 통해 이들의 관계를 추출하고 있다. 그러므로 입력변수의 선정은 모형의 정확도에 커다란 영향을 미치며, 입력변수가 잘못 설정된 경우 예측 정확도가 현저히 낮아지게 된다[39]. 그러나 최적의 입력변수군을 선정하는 문제는 매우 어려운 과제 중 하나이다. 인공신경망을 이용한 부도예측모형 구축에 관한 기존의 연구들에서는 주로 전문가의 의견을 반영하거나, 선행 연구들을 통해 도출하거나, 통계적 기법을 활용하여 입력변수를 선정하는 것이 일반적이었다[2, 4, 9, 14, 17, 21, 22, 33, 36].

본 연구에서는 인공신경망의 최적 입력변수군을 선정하기 위하여 유전자 알고리즘을 활용하는 방법론을 제시하고, 기존의 방법론을 통해 선정된 변수군과의 성과비교를 통하여 그 유용성을 검증해 본다.

### 2. 입력변수 선정에 관한 문헌연구

입력변수의 선정은 표본의 선정과 함께 예측정확도에 크게 영향을 끼치는 요소이다 [3].

1966년 Beaver의 연구 이후 기존 연구들은 주로 기업의 재무재표를 통해 쉽게 도출될 수 있는 전통적 재무비율을 대상으로, 가능한 많은 변수를 투입한 후 통계적 기법에 의해 변수를 축소해 나가는 방법을 사용하고 있다.

재무비율 외에도 현금흐름비율[5, 10, 26, 27], 주식시장정보[7, 8, 19, 37, 38], 물가수준 동향[29, 31, 34], 리스의 자본화 여부[22], 거시 경제적 변수[25, 32], 재무비율의 분산[12, 20],

<표 1> 선행연구에서 사용된 독립변수 리스트

변수군	변수명	설명
성장성 (5)	TAG	총자산성장율 (Total Asset Growth)
	TFAG	유형고정자산증가율 (Tangible Fixed Asset Growth)
	OEG	자기자본성장율 (Owner's Equity Growth)
	NSG	매출액증가율 (Net Sales Growth)
	NIG	순이익성장율 (Net Income Growth)
수익성 (13)	OITA	총자본경상이익율 (Ordinary Income to Total Asset)
	NITA	총자산이익율 (Net Income to Total Asset)
	OIWC	운전자본영업이익율 (Operating Income to Working Capital)
	OPITA	총자본영업이익율 (Operating Income to Total Asset)
	NIOE	자기자본순이익율 (Net Income to Owner's Equity)
	OIS	경상이익대매출액 (Ordinary Income to Sales)
	NIS	매출액순이익율 (Net Income to Sales)
	OPIS	매출액영업이익율 (Operating Income to Sales)
	TSI	매출액총이익율 (Total Sales Income)
	FES	금융비용대매출액 (Financial Expenses to Sales)
	FEOI	금융비용대영업이익율 (Financial Expense to Operating Income)
	TIE	이자보상율 (Times Interest Earned)
	NID	순이익대배당금 (Net Income to Dividend)
안정성 (11)	OETA	자기자본비율 (Owner's Equity to Total Asset)
	CACL	유동비율 (Current Asset to Current Liability)
	QACL	당좌비율 (Quick Asset to Current Liability)
	FAOE	고정비율 (Fixed Asset to Owner's Equity)
	FAOELTL	고정장기적합율 (Fixed Asset to Owner's Equity and Long Term Liability)
	CLFLOE	부채비율 (Current Liability and fixed Liability to Owner's Equity)
	FLOE	고정부채비율 (Fixed Liability to Owner's Equity)
	TBBPTA	(총차입금+상환채)대총자산 (Total Borrowings and Bonds Payable to Total Asset)
	FANWC	고정자산대순운전자본 (Fixed Asset to Net Working Capital)
	NWCTA	순운전자본비율 (Net Working Capital to Total Asset)
	AETA	유보이익율 (Accumulated Earning to Total Asset)
현금흐름 (5)	CFTL	현금흐름대총부채 (Cash Flow to Total Liability)
	CFS	현금흐름대매출액 (Cash Flow to Sales)
	CFTBBP	현금흐름대(총차입금+상환채) (Cash Flow to Total Borrowings and Bonds Payable)
	CFTA	현금흐름대총자본 (Cash Flow to Total Asset)
	CFCL	현금흐름대유동부채 (Cash Flow to Current Liability)
활동성 (5)	TAT	총자산회전율 (Total Asset Turnover)
	NWCT	운전자산회전율 (Net Working Capital Turnover)
	FAT	고정자산회전율 (Fixed Asset Turnover)
	IT	재고자산회전율 (Inventory Turnover)
	RT	매출채권회전율 (Receivable Turnover)
규모 (2)	S	매출액 (Sales)
	TA	총자산 (Total Asset)
기타 (6)	CATA	유동자산대총자본 (Current Asset to Total Asset)
	NIDL	(순이익+감가상각)대총부채 (Net Income and Depreciation to Total Liability)
	QATA	당좌자산대총자본 (Quick Asset to Total Asset)
	CLTA	유동부채대총자산 (Current Liability to Total Asset)
	STBLTDMS	월매출액대(단기차입+장기차입) Short-Term Borrowing and Long-Term Debt to Monthly Sales

<표 2> 부도예측 선행연구에서의 입력변수 선정 (국외연구)

	1	2	3	4	5	6	7	8	9	10	11	12	13	14
NITA	♦	♦	♦		♦			♦	♦	♦	♦	♦	♦	♦
OIWC				♦		♦					♦			
NIOE						♦								
NIS			♦			♦					♦			
FES												♦		
FEOI									♦					
NID						♦	♦							
CACL	♦		♦				♦	♦	♦	♦	♦	♦	♦	♦
QACL		♦	♦			♦					♦		♦	
FAOELTL												♦		
CLFLOE								♦						
TBBPTA	♦		♦		♦						♦			
FANWC										♦				
NWCTA	♦	♦	♦										♦	
AETA		♦							♦	♦		♦	♦	♦
CFTL	♦					♦								
CFS			♦				♦							
CFTBPP		♦					♦							
CFTA		♦					♦	♦						
CFCL		♦	♦				♦			♦				
TAT											♦			
NWCT											♦			
S		♦					♦			♦			♦	
TA		♦					♦		♦			♦	♦	
CATA		♦						♦				♦		♦
QATA		♦				♦	♦			♦		♦		♦
FLTA						♦					♦			
CLTA											♦			
STBLTDMS						♦								

(1) Beaver (1966)  
(4) Edminster (1972)  
(7) Elam (1975)  
(10) Ohlson (1980)  
(13) Odom et al. (1989)

(2) Altman (1966)  
(5) Pinches et al. (1973)  
(8) Libby (1975)  
(11) Dambolena et al. (1980)  
(14) Raghupathi et al. (1991)

(3) Deakin (1972)  
(6) Blum (1974)  
(9) Altman et al. (1977)  
(12) Frydman et al. (1985)

회사채와 기업어음의 평정점수[25, 30], 부가 가치 회계정보[1] 등이 기업의 부도 예측율을 높이는 중요한 변수로 고려되고 있다.

본 연구에서는 객관적으로 신뢰할 수 있고 기업의 부도를 잘 나타내주는 지표로서 자료의 입수가 용이하고 객관적인 통계처리가 가능한 재무비율을 대상으로 하고 있다. 이에 기준의 많은 연구들에서 중요한 재무비율로 제시되고 있어 이론상 유용성이 있다고 인정되고 있는 주요 재무비율들을 정리해 보면 <표 1>과 같다. <표 2>와 <표 3>은 각각 국외 및 국내의 부도

예측연구에서 사용된 입력변수군을 보여주고 있다. 표에서 보여지는 바와 같이 다양한 변수들이 사용되고 있는데, 이렇게 선정된 변수군이 다른 것은 국가별, 시대별 상이한 경제 환경, 상이한 모형구축대상 기업군별 특성(예를 들면 업종, 규모 등)에 기인하는 것이다. 결국 모든 모형을 만족하는 최적의 변수군은 존재하지 않으며, 상황 및 특성에 맞는 최적 변수군이 존재한다고 볼 수 있다.

<표 3> 부도예측 선행연구에서의 입력변수 선정 (국내연구)

	1	2	3	4	5	6	7	8	9	10	11	12	13
TAG										◆			
TFAG							◆						
OEG										◆			
NSG		◆						◆		◆			
NIG										◆			
OITA	◆				◆			◆		◆	◆		
NITA												◆	
OPITA							◆					◆	
NIOE		◆	◆				◆	◆		◆			
OIS										◆			
NIS									◆	◆			◆
OPIS			◆		◆			◆		◆			
TSI	◆	◆						◆					
FES										◆			
TIE					◆			◆				◆	
NID										◆			
OETA									◆	◆		◆	◆
CACL	◆	◆	◆	◆	◆			◆	◆	◆	◆	◆	
QACL								◆		◆			◆
FAOE			◆				◆	◆		◆			
FAOELTL	◆	◆		◆				◆		◆			
CLFLOE		◆	◆	◆	◆	◆	◆	◆			◆		◆
FLOE									◆				
NWCTA	◆	◆	◆	◆	◆		◆	◆		◆			
AETA	◆	◆	◆	◆	◆	◆		◆			◆		
CFTL											◆		
CFTA							◆	◆		◆			
CFCL						◆		◆					
TAT	◆	◆	◆		◆	◆		◆	◆			◆	◆
NWCT	◆				◆		◆	◆					
FAT	◆			◆	◆			◆					◆
IT										◆			
RT		◆						◆					
CLTA										◆	◆		◆

- (1) 한국은행 (1982)
- (2) 지청 (1983)
- (3) 전준옥 (1984)
- (4) 박장길 (1984)
- (5) 정준수 (1985)
- (6) 허영빈 (1986)
- (7) 김건우 (1987)
- (8) 김재권 (1987)
- (9) 송인만 (1987)
- (10) Lee and Oh (1990)
- (11) 황석하 (1991)
- (12) 강철승 (1991)
- (13) 이계원 (1993)

## 2. 실험 설계

### 2.1 표본기업 구축

인공신경망을 이용한 최적의 변수군 선정 방법론 개발을 위한 본 연구에서 사용된 실험 자료는 한국신용정보에서 제공한 1995년부터

1997년까지 3년간 부도가 발생한 제조업체 중 외감법인 이상 264개사와 동수의 건전기업으로 구성하였다. 그 결과 인공신경망 실험에서 모형 구축에 사용된 표본기업은 총 528개 기업으로 훈련용으로 424개, 테스트용으로 52개, 검증용으로 52개를 사용하였다.

본 연구에서는 약 90 개 정도의 재무변수 중 1 차로 단일변량검정 및 전문가 설문을 실시하여 총 43 개의 변수를 고려대상변수로 선정하였으며, 1 차적으로 선정된 변수는 <표 4>와 같다.

## 2.2 연구모형 구축

### 2.2.1 변수군의 선정

선행 연구들에서는 기업의 부도예측을 위한 모형의 입력변수 선정을 주로 통계적 분석 방법이나 여신실무 담당자의 전문적 판단을 반영하고 있다. 본 연구에서는 이와 같은 선행 방법들과 본 연구에서 제시하는 유전자 알고리즘을 활용한 입력변수 선정 방법으로 입력 변수군을 선정하였다.

첫째, 설문을 통해 전문가들이 중요하다고 판단한 변수들로 변수군을 선정하였다. 보람은행 심사부 심사역 설문조사, 한국신용정보신용평가 전문가 설문조사, 한국신용평가 기업 평가 전문가 설문조사를 취합하여 선정된 중요 재무비율 중 중요도 상위 10 개 변수들로 한 개의 변수군을 선정하였고(A1), 본 연구에서 사용된 입력변수들의 지표별로 가장 중요하다고 선정된 변수들로도 변수군을 선정하였다.

### (A2).

통계적 방법으로는 크게 3 가지 방법으로 변수군을 선정하였다. t-test에 의한 단일변량분석(B1), 로짓분석(C1)과 다변량 판별분석(C2)에 의한 선택적 변수선정기법(Stepwise selection method)을 사용하여 변수군을 선정하였고, 또한 단일변량분석에서 선정된 변수들을 중심으로 선택적 변수선정기법을 적용하는 복합분석에 의한 변수선정도 실시하였다(D1, D2, D3, D4). 통계방법론을 통한 입력변수 선정에는 SPSS 8.0 을 사용하였다.

마지막으로 탐색, 최적화 기법인 유전자 알고리즘을 이용하여 적응도(Fitness value)가 가장 우수하다고 나타난 변수군으로 입력변수를 선정하였다(E1). 유전자 알고리즘을 활용한 입력변수 선정 및 모형구축을 위해 사용된 소프트웨어는 Neural Ware 사의 Predict™이다. 입력변수 선정을 위한 각 방법들을 정리하면 <표 5>와 같다.

### 2.2.2 인공신경망 모형 구축

본 연구에서는 <표 5>에서 제시된 방법들을 통하여 선정된 입력변수군으로 인공신경망 모형을 구축하였다.

<표 4> 1 차적으로 선정된 변수 리스트

지표	변수명	설명	지표	변수명	설명
규모 (2)	x1	매출액	주제 (1)	x23	유동비율
	x2	자기자본		x24	유동부채대 종자본
생산성 (2)	x3	종자본투자효율		x25	유보액대 종자산비율
	x4	부가가치율		x26	자기자본비율
성장성 (3)	x5	매출액증가율		x27	차입금의존도
	x6	재고자산증가율		x28	총차입금대 매출액
	x7	총자산증가율		x29	금융비용부담율 증가분
수익성 (10)	x8	금융비용대 매출액비율	활동성 (5)	x30	매입채무회전율
	x9	매출효용성계수		x31	순운전자본대 매출액
	x10	매출액순이익율		x32	운전자금대 매출액
	x11	매출원가율		x33	재고자산회전율
	x12	순익분기점율		x34	종자본회전율
	x13	순금융비용대 매출액비율	현금흐름지표 (9)	x35	영업활동후 CF 대 차입금합계
	x14	이자보상배율		x36	영업활동후 CF 대 부채총계
	x15	자기자본순이익율		x37	영업활동후 CF 대 금융비용
	x16	총자본경상이익율		x38	(현금영업이익/금융수입)대 금융비용
	x17	총자본순이익율		x39	이자지급후 CF 대 부채총계
안정성 (11)	x18	고정장기적학율의 역		x40	이자지급후 CF/금융비용
	x19	단기부채대 종차입금		x41	외부자금조달전 CF 대 차입금합계
	x20	당좌비율		x42	외부자금조달전 CF 대 금융비용
	x21	매출채권대 매입채무		x43	외부자금조달후 CF 대 금융비용
	x22	순운전자본비율			

<표 5> 입력변수 선정방법

Group	선정방법	변수선정 기준
A	문자 선정	A1. 전문가 선정 중요도 상위 10 개 변수 A2. 전문가 선정 지표별 중요도 1 위 변수
B	일변량분석에 의한 선정 (t-test)	B1. 유의수준 상위 10 개 변수
C	택적 변수선정기 예에 의한 선정	C1. 로짓분석에 의해 선정된 변수 C2. 다변량 판별분석에 의해 선정된 변수
D	합분석에 의한 수선정: 단일변량 선에서 선정된 수들을 중심으로 택적 변수선정기 을 적용	D1. 단일변량 t-test 결과 p-value 1% 미만인 변수군에 로짓분석을 적용해 선정 된 변수 D2. 단일변량 t-test 결과 p-value 1% 미만인 변수군에 다변량 판별분석을 적용해 선정된 변수 D3. 상관계수의 절대값이 0.2 이상인 변수군에 로짓분석을 적용해 선정된 변수 D4. 상관계수의 절대값이 0.2 이상인 변수군에 다변량 판별분석을 적용해 선정 된 변수
E	전자알고리즘에 한 변수선정	E1. 적응도 1 위 변수군

총 528 개 데이터를 인공신경망의 학습을 위한 훈련용 자료 (424 개), 학습 종료를 위한 최적의 조건(Stopping condition)을 찾기 위한 테스트용 자료 (52 개), 학습을 통해 구축된 모델의 검증을 위한 검증용 자료 (52 개)로 나누어 실험을 실시하였다. 이 때 훈련용, 테스트용, 검증용 데이터 군은 모두 각각 부도업체와 비부도업체가 동수로 구성되었다.

본 연구에서 사용한 인공신경망 모형은 다층 퍼셉트론(Multi-layer perceptron)과 역전파 학습(Back-propagation) 알고리즘으로 입력계층과 출력계층, 그리고 하나의 은닉계층을 가지는 3층 퍼셉트론(Three layer perceptron)을 사용하였으며, 은닉층의 노드(Node)수는 입력변수의 수와 동수를 사용하였다. 본 연구에서 사용된 모형의 출력층은 1개의 노드로 구성되어 부도(0)와 건전(1)을 나타내며, 모형의 출력값은 [0,1]의 범위에 존재한다.

### 3. 실험결과 및 분석

#### 3.1 변수선정 결과

<표 5>의 방법론에 의해 선정된 입력변수 군을 정리하면 <표 6>과 같다. 결과에 의하면 각 모형별로 선정된 변수군의 변수의 개수와 선정된 변수들의 종류가 약간의 차이는 보이고 있지만 거의 유사한 양상을 보이고 있으며, 매출액(x1), 총자본투자효율(x3), 순금융비용대 매출액비율(x13), 유동부채대 총자본(x24), 순운전자본대 매출액(x31)은 공통적 중요 입력변수로 선정되었다.

#### 3.2 인공신경망 모형 구축 결과

<표 5>의 방법론에 의해 선정된 변수(<표

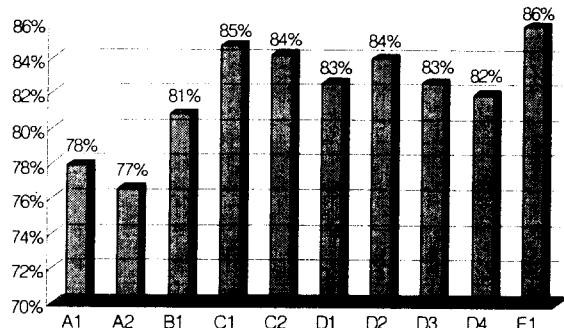
6> 참조)를 입력변수군으로 하여 구축된 인공신경망 모형을 실험하였다. 결과값의 신뢰성을 높이기 위하여 임의선정(Random selection)을 통해 검증용 자료를 달리하여 5 번의 실험을 실시하였고, 이에 대한 결과를 요약하면 <표 7>과 같다. <그림 1>에서는 <표 7>의 결과를 요약하여 도표화함으로써 훈련용 데이터와 검증용 데이터에 대한 적중률을 비교하였다.

<표 6> 입력변수군 선정결과표

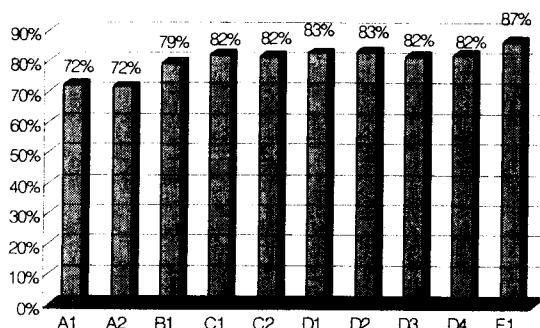
A1	x1, x2, x8, x10, x11, x13, x26, x27, x30, x33
A2	x1, x4, x5, x8, x27, x29, x33, x36
B1	x2, x13, x16, x17, x20, x22, x24, x25, x26, x27
C1	x1, x3, x5, x7, x11, x13, x22, x24, x25, x29, x31
C2	x1, x3, x5, x6, x7, x11, x13, x24, x25, x29, x31
D1	x3, x6, x11, x13, x17, x22, x24, x25, x29, x31
D2	x1, x3, x6, x11, x13, x17, x24, x25, x29, x31, x32
D3	x1, x3, x13, x20, x24, x26, x29, x31
D4	x1, x3, x13, x24, x26, x31
E1	x3, x8, x13, x24, x25, x26, x29, x31, x35, x36

<표 7> 인공신경망 모형별 적중률  
(cut-off:0.5)

	훈련용	테스트용	검증용
A1	77.88%	76.92%	72.31%
A2	76.56%	74.23%	71.54%
B1	80.80%	80.77%	79.23%
C1	84.72%	82.69%	81.92%
C2	84.20%	83.08%	81.54%
D1	82.55%	81.92%	82.69%
D2	83.96%	85.00%	83.08%
D3	82.59%	83.08%	81.54%
D4	81.89%	81.92%	81.92%
E1	85.85%	85.77%	86.54%



(a) 훈련용 자료



(b) 검증용 자료

[그림 1] 인공신경망 모형별 적중률 비교

실험결과에 의하면 전문가에 의해 선정된 입력 변수군(A1, A2)이 다른 방법론에 비해 75% 미만의 상대적으로 낮은 적중률을 보였고, 나머지는 80% 이상의 비교적 높은 적중률을 보였다. 특히, 단일변량분석(t-test)과 선택적 변수선정 기법(로짓분석, 다변량 판별분석)의 복합분석에 의한 변수선정 모형(D1, D2)이 높은 적중률을 보이고 있지만, 유전자 알고리즘을 이용한 입력변수 선정 모형이 다른 방법론들에 비해 좀 더 높은 적중률을 보이고 있어, 유전자 알고리즘을 통한 입력변수 선정 방법이 부도예측을 위한 인공신경망 모형 구축에 있어 효과적임을 보여주고 있다.

### 3.3. 유의성 검증

본 연구에서는 유전자 알고리즘을 이용한 입력변수 선정 방법과 다른 방법론과의 차이가 통계적으로 유의한지 알아보기 위하여 McNemar 테스트를 실시하였다. 본 연구에서는 기업의 부도에 대한 정확한 예측을 목적으로 하고 있으므로 테스트를 위한 관측치는 각 모형의 예측 정확도이다. <표 8>의 결과에 의하면 유전자 알고리즘을 이용한 입력변수 선

정 모형(E1)이 전문가 선정 모형(A1, A2)이나 단일변량분석 분석에 의한 모형(B1)의 결과와 1% 이내 유의수준을, 로짓분석에 의한 모형(C1)과는 10% 이내, 다변량 판별분석에 의한 모형(C2)이나 복합분석에 의한 변수선정 모형(D3, D4)과는 5% 이내의 유의수준을 보이고 있어 다른 방법론에 의한 모형들과의 차이가 통계적으로 유의함을 검증하였다. 이밖에 전문가 선정 모형(A1, A2)이 유전자 알고리즘에 의한 모형(E1)이나 다른 모형들(C1, C2, D1, D2, D3, D4)과 1% 이내의 유의수준을 나타내고 있다.

## 4. 결 론

기업이 도산에 이르기까지 많은 변인들이 다양하게 작용하게 된다. 그러나 이러한 변인들을 모두 모형에 적용하는 것은 비효율적이며, 인공신경망 모형에서 과다 입력변수를 사용하는 경우 수렴(Convergence)과 일반화(Generalization) 모두에 바람직하지 않은 결과가 나타난다. 적절한 입력변수군의 선택은 인공신경망 모형의 효율성과 성능을 향상시키게 되고, 이는 부도 예측율의 향상으로 이어진다.

본 연구에서는 최근 그 유용성이 입증되고 있는 인공신경망 기법의 최적 변수 선정을 위하여 유전자 알고리즘 기법을 이용한 최적화를 통하여 입력 변수군을 도출하는 방법론을 제시하였고, 이 방법론이 다른 통계기법이나 전문가에 의한 변수 선택 방법론에 비해 우수함을 인공신경망 모형에 적용한 결과를 비교함으로 보여 주었으며, 이들간의 예측력의 차이가 유의함을 통계적 검증을 통하여 확인하였다.

본 연구가 가지는 한계점은 다음과 같다. 첫째는 본 연구에서는 자료 입수의 용이성과 객관적 통계처리를 이유로 재무변수만을 고려하여 입력 가능 변수군을 선정하였지만, 비재무정보를 반영할 경우 더욱 효과적인 모형구축이 가능할 것이다.

둘째로 인공신경망 모형에는 모형의 효율을 높이기 위한 여러 제어요소가 있다. 본 연구에서는 최적의 입력변수 선정 방법을 찾기 위해 제어요소를 연구자 임의로 고정시킨 후 실험을 실시하였지만, 은닉층의 개수, 은닉노드의 개수, 학습방법, 전이함수 등의 제어요소를 변경하며 최적의 조건을 찾아 각 모형의 결과를 비교하는 것도 향후 연구과제가 될 수 있을 것이다.

<표 8> McNemar 테스트 결과

	A2	B1	C1	C2	D1	D2	D3	D4	E1
	(유의수준)								
A1	0.9062	0.0046***	0.0006***	0.0009***	0.0001***	0.0001***	0.0003***	0.0002***	0.0000***
A2	-	0.0158**	0.0007***	0.0008***	0.0004***	0.0001***	0.0010***	0.0005***	0.0000***
B1	-	-	0.2295	0.3268	0.0636*	0.0525*	0.2632	0.2100	0.0031***
C1	-	-	-	1.0000	0.8145	0.5488	1.0000	1.0000	0.0518*
C2	-	-	-	-	0.6476	0.3438	1.0000	1.0000	0.0367**
D1	-	-	-	-	-	1.0000	0.6291	0.8238	0.1003
D2	-	-	-	-	-	-	0.2891	0.5811	0.1237
D3	-	-	-	-	-	-	-	1.0000	0.0259**
D4	-	-	-	-	-	-	-	-	0.0376**

(\*\*\* 유의수준 1% 이내, \*\* 유의수준 5% 이내, \* 유의수준 10%이내)

## References

- [1] 강철승 (1991), “부가가치회계정보의 기업부실 예측력에 관한 실증적 연구,” 회계학연구, 12, 79-99.
- [2] 송인만(1987), “기업부실예측모델의 재정립을 통한 기업부실원인과의 연계에 대한 실증적 연구,” 한국경제, 15, 113-142.
- [3] 신경식, 한인구 (1998), “다수의 인공신경망을 통합한 기업부도 예측모형에 관한 연구,” 한국경영과학회지, 145-148.
- [4] 신경식, 한인구 (1998), “Corporate Failure Prediction Modeling Using Genetic Algorithm Technique,” 한국경영정보학회 국제학술대회 논문집, 599-608.
- [5] 윤주석 (1991), 자금흐름정보의 기업도산예측력에 관한 실증적 연구, 동국대학교 대학원 박사학위논문, 미간행.
- [6] 이건창, 김명종, 김혁 (1994), “기업도산예측을 위한 귀납적 학습지원 인공신경망 접근방법: MDA, 귀납적 학습방법, 인공신경망 모형과의 성과비교,” 경영학연구, 23, 2, 109-144.
- [7] 임영규 (1990), 기업부실 예측에 관한 실증적 연구, 성균관대학교 대학원 박사학위논문, 미간행.
- [8] Aharony, J., Jone, C. P. and Swary, I. (1980), An Analysis of Risk and Return Characteristics of Corporate Bankruptcy using Capital Market Data, *Journal of Finance*, September, 1001-1016.
- [9] Altman, E. I. (1968), Financial ratios, discriminant analysis and the prediction of corporate bankruptcy, *The Journal of Finance*, September, 589-609.
- [10] Aziz, A. and Lawson, G. H. (1989), Cash Flow Reporting and Financial Distress Models: Testing of Hypotheses, *Financial Management*, Spring, 55-63.
- [11] Barbro B., Teija L. and Kaisa S. (1996), Neural Networks and Genetic Algorithms for Bankruptcy Predictions, *Proceedings of The third World Congress on Expert Systems*, 123-130.
- [12] Barniv, R. (1990), Accounting Procedures, Market Data, Cash-flow Figures, and Insolvency Classification: The Case of the Insurance Industry, *The Accounting Review*, July, 578-604.
- [13] Barniv, R., Agawal, A. and Leach, R. (1997), Predicting the outcome following bankruptcy filing: A three-state classification using neural networks, *Intelligent Systems in Accounting, Finance and Management*, 6, 177-194.
- [14] Beaver, W. (1966), Financial ratios as predictors of failure. Empirical Research in Accounting; Selected Studies, 1966, Supplement to Vol.5, *Journal of Accounting Research*, 71-111.
- [15] Bell, T. (1997), Neural nets or the logit model? A comparison of each model's ability to predict commercial bank failures, *Intelligent Systems in Accounting, Finance and Management*, 6, 249-264.
- [16] Botiz, J. and Kennedy, D. (1995), Effectiveness of neural networks types for prediction of business failure, *Expert Systems with Applications*, 9, 503-512.
- [17] Cadden, D. T. (1991), Neural Network and Mathematics of Chaos - An Investigation of These Methodologies as Accurate Predictors of Corporate Bankruptcy, *Proceedings of the First International Conference on Artificial Intelligence Application on Wall Street*, 52-57.
- [18] Chung, H. and Tam, K. (1992), A comparative analysis of inductive learning algorithm, *Intelligent Systems in Accounting, Finance and Management*, 2, 3-18.
- [19] Clark, T. A. and Weinstein, M. I. (1983), The Behavior of the Common Stock of Bankruptcy Firms, *The Journal of Finance*, May, 489-504.
- [20] Dambolena, I. G. and Khouri, S. I. (1980), Ratio

- Stability and Corporate Failure, *The Journal of Finance*, 35, 4, 1017-1026.
- [21] Edminster, R. O. (1972), An Empirical Test of Financial Ratio Analysis for Small Business Failure Prediction, *Journal of Finance and Quantitative Analysis*.
- [22] Elam, R. (1975), The Effect of Lease data on the predictive ability of financial ratios, *The Accounting Review*, 50, 24-43.
- [23] Etheridge, H. and Sriram, R. (1997), A comparative of the relative costs of financial distress models: Artificial neural networks, logit and multivariate discriminant analysis, *Intelligent Systems in Accounting, Finance and Management*, 6, 235-248.
- [24] Fletcher, D. and Goss, E. (1993), Forecasting with neural networks: An application using bankruptcy data, *Information and Management*, 24, 3, 159-167.
- [25] Foster, G. (1977), Quarterly Accounting Data: Time-Series Properties and Predictive-Ability Results, *The Accounting Review*, January, 1-21.
- [26] Gentry, J. A., Newbold, P. and Whitford, D. T. (1985), Classifying Bankrupt Firms With Funds Flow Components, *Journal of Accounting Research*, Spring, 146-160.
- [27] Gombola M. J. and Ketz, J. E. (1983), Financial Ratio Patterns in Retail and Manufacturing Organizations, *Financial Management*, Summer, 45-56.
- [28] Jo, H., Han, I. And Lee, H. (1997), Bankruptcy prediction using case-based reasoning, neural networks, and discriminant analysis, *Expert Systems With Application*, 13, 2, 97-108.
- [29] Ketz, J. E. (1978), The Effect of General Price Level Adjustment on the Predictive Ability of Financial Ratios, *Journal of Accounting Research*, Supplement, 273-284.
- [30] Marais, M., Patell, J. and Wolfson, M. (1984), The Experimental Design of Classification models: An Application of Recursive Partitioning and Bootstrapping to Commercial Bank Loan Classifications, *Journal of Accounting Research*, Supplement, 87-118.
- [31] Mensah, Y. M. (1983), The Differential Bankruptcy Predictive Ability of Specific Price Level Adjustments: Some Empirical Evidence, *The Accounting Review*, April, 228-246.
- [32] Mensah, Y. M. (1984), An Examination of the Stationarity of Multivariate Bankruptcy Prediction Models: A methodological study, *Journal of Accounting Research*, Spring, 380-395.
- [33] Miller, W., Cadden, D. T. and Driscoll, V. (1995), Bank Failure and Categorization-A Neural Network Approach, *Proceedings of the Third International Conference on Artificial Intelligence Applications on Wall Street*, 232-235.
- [34] Norton, C. L. and Smith, R. E. (1979), A Comparison of General Price Level and Historical Cost Financial Statements in the Prediction of Bankruptcy, *The Accounting Review*, January 1979, 72-87.
- [35] Odom, M. and Sharda, R. (1990), A neural networks model for bankruptcy prediction, *Proceedings of the IEEE International Conference on Neural Network*, 2, 163-168.
- [36] Ohlson, J. (1980), Financial ratios and the probabilistic prediction of bankruptcy, *Journal of Accounting Research*, Spring, 109-131.
- [37] Pettway, R. H. and Sinkey, J. F. (1980), Establishing On-site Bank Examination Priorities: An Early-Warning System using Accounting and Market Information, *Journal of Finance*, 34, 1, 137-150.
- [38] Queen, M. and Roll, R. (1987), Firm Mortality: Using Market Indicators to Predict Survival, *Financial Analysts Journal*, May-June 1987, 6-27.
- [39] Refenes, A. P. (1995), *Neural networks in the capital markets*, West Sussex: John Wiley & Sons.
- [40] Salchenberger, L., Cinar, E. and Lash, N. (1992), Neural networks: A new tool for predicting thrift failures, *Decision Sciences*, 23, 899-916.
- [41] Tam, K. and Kiang, M. (1992), Managerial applications of neural networks: the case of bank failure predictions, *Management Science*, 38, 7, 926-947.
- [42] Wilson, R. and Sharda, R. (1994), Bankruptcy prediction using neural networks, *Decision Support Systems*, 11, 5, 545-557.