

인공신경망 기초 의사결정트리 분류기에 의한 시계열모형화에 관한 연구*

A Neural Network-Driven Decision Tree Classifier Approach to Time Series Identification

오상봉**, 이건창***

Sang Bong Oh, Kun Chang Lee

Abstract

We propose a new approach to classifying a time series data into one of the autoregressive moving-average(ARMA) models. It is based on two pattern recognition concepts for solving time series identification. The one is an extended sample autocorrelation function(ESACF). The other is a neural network-driven decision tree classifier(NNDTC) in which two pattern recognition techniques are tightly coupled: neural network and decision tree classifier. NNDTC consists of a set of nodes at which neural network-driven decision making is made whether the connecting subtrees should be pruned or not. Therefore, time series identification problem can be stated as solving a set of local decisions at nodes. The decision values of the nodes are provided by neural network functions attached to the corresponding nodes. Experimental results with a set of test data and real time series data show that the proposed approach can efficiently identify the time seires patterns with high precision compared to the previous approaches.

1. 서 론

일반적으로 시계열자료(time series data)는 시간의 경과에 따라 일정한 간격으로 측정된 일련의 자료들을 의미한다. 이러한 시계열자료는 기업경영시 각 경영 기능별로

(즉, 생산, 재무, 인사 등) 발생이 되기 때문에, 각 경영 기능의 성과를 효과적으로 측정하고 예측하기 위해서는 이러한 시계열자료를 통계학적으로 모형화 할 필요가 있다. 학계나 실무에서 가장 널리 이용되고 있는 시계열 모형으로 Box and Jenkins[7]가 제시한 ARMA(AutoRegressive

* 이 논문은 1994년도 한국학술진흥재단의 공모과제 연구비에 의하여 연구되었음

** 대전대학교 공과대학 정보통신공학과

*** 성균관대학교 경상대학 경영학부

Moving Average) 모형을 들 수 있다. ARMA 모형에 의한 시계열 모형화 문제는 통계학에서 오랜 전통을 갖고 있는 연구 과제였으며, 그 동안 많은 통계학적 시계열 모형화 방법이 소개되었다[1, 4, 18, 20, 31, 33, 41, 42, 47]. 그러나, 이러한 통계학적 시계열 모형화 방법은 복잡한 통계학 이론에 근거하고 있어 사용자 편의성과 아울러 경영 의사 결정에 있어서 필수적인 실용성이 결여되어 있다는 점이 커다란 약점으로 지적되어 왔다.

본 연구에서는 이러한 문제를 해결하기 위한 하나의 방법으로서, ESACF와 NNDTC를 이용한 인공지능 적인 시계열 모형화 방법을 제안하고자 한다. 우선 ESACF 방법은 Tsay and Tiao[41]에 의하여 제안된 방법으로서 주어진 시계열로부터 삼각형의 패턴을 추출하는 방법으로서 반복적인 회귀 분석을 통해 얻어지는 통계량(statistics)의 하나이다. 한편, NNDTC는 기존의 의사결정트리 분류기(DTC: Decision Tree Classifier)와는 달리 각 노드에서 수행되는 분류 기능을 보다 지능적인 인공신경망으로 대체한 의사결정트리 분류기이다. 인공신경망은 뛰어난 학습 성과와 일반화 기능으로 인해 여러 응용 분야에서 이미 널리 사용되고 있는 인공지능 방법 중의 하나로 특히 패턴 분류 및 패턴 인식에 널리 사용되고 있다[32]. 한편, 의사결정트리 분류기는 다양한 패턴 인식 문제에 적용되어 왔는 바, 지질학[40, 48], 음성 분석[11], 생의학[10, 36], 그리고 문자 인식[19, 43, 44] 등에 효과적으로 적용되었으나 시계열 모형화 문제에 적용한 예는 Lee and Park[28]의 연구 외에는 아직 이렇다 할 연구가 없었다. 그러나, Lee and Park[28] 연구도 의사결정트리 분류기 내의 분류 함수를 주관적으로 폐지하여 이용하였기 때문에 시계열 모형화 과정에서 객관성이 결여되어 있다는 점에서 방법론상의 한계가 있다고 할 수 있다. 따라서 본 논문에서는 의사결정트리 분류기 상의 결정 함수로 인공신경망을 이용함으로써 시계열 모형화 과정상에서 객관성과 일반화 기능을 보장하고자 한다. 한편, 의사결정트리 분류기를 적용한 연구의 경우, 의사결정트리 분류기내에서 가장 적합한 분류 경로(classification path)를 찾는 것이 중요하기 때문에[22, 23, 24], 본 연구에서는 의사결정트리 분류기내에서의 새로운 분류 경로 알고리즘인 ‘인공신경망에 의한剪枝探索’(NPS: Neural Pruning Search) 알고리즘을 이용하고자 한다[26].

본 논문의 구성은 다음과 같다. 2장에서는 시계열 모형

화를 위하여 본 연구에서 채택하고 있는 패턴 인식 접근 방법에 관한 특성 및 적용 가능성에 대하여 언급한다. NNDTC에 관한 자세한 방법론은 3장에서 서술되며, 아울러 NPS 알고리즘의 이론적인 면도 소개한다. 이러한 방법론에 기초하여 실제 시계열자료 및 시뮬레이션에 의해 생성된 시계열자료에 적용한 실험 결과와 그 의의는 4장에서 서술한다. 마지막으로 5장에서는 결론 및 향후 연구 방향에 대하여 언급하기로 한다.

2. 패턴 인식 방법

2.1 개요 및 기존 연구

패턴 인식(Pattern Recognition)은 주어진 입력 패턴의 특징을 추출하여 이를 미리 정해진 패턴 클래스로 분류하는 것을 의미한다. 이러한 패턴 인식에서의 패턴 분류 방법을 ‘패턴매칭’(pattern matching)이라 하는데, 이는 주어진 입력 패턴과 가장 유사한 패턴 클래스를 택하여 이를 해당 입력 패턴의 클래스로 간주하는 방법이다. 이러한 패턴매칭 방법을 시계열 모형화에 적용하면 다음과 같이 3단계로 설명할 수 있다.

- (1) 주어진 입력 시계열에 대한 특성 패턴을 추출한다.
- (2) 원형 패턴 클래스를 결정한다.
- (3) 해당 입력 시계열의 특성 패턴과 원형 패턴 클래스 간의 유사성을 계산하여 가장 유사한 패턴 클래스를 선정한다.

본 논문에서 고려하는 패턴 클래스는 Box and Jenkins [7]가 제안한 ARMA 모형이 된다. 이상과 같은 패턴 인식에 의한 시계열 모형화 과정은 기존의 통계학적인 방법과는 달리 인공신경망과 같은 인공지능 적인 방법을 적용하기가 용이하다는 특징을 가지고 있다. 즉, 패턴매칭에 의한 패턴 인식은 인공지능 방법의 학습 기능(learning function)으로 해결이 가능한 방법이기 때문이다. 이러한 패턴 인식에 의한 시계열 모형화 접근 방법의 타당성을 보다 구체적으로 확인하기 위하여 패턴 인식에 의한 시계열 모형화에 관한 기존의 연구를 살펴보기로 하자.

패턴 인식 분야에서 시계열 모형화 문제는 많은 관심을 받고 있는 분야 중의 하나이다. 그러나, 패턴 인식에 의한 시계열 모형화에 관한 연구 중 본 논문에서처럼 ARMA 모형화에 관한 연구는 거의 없고, 대부분 시계열 자체의

특성을 인식하여 특정 클래스로 분류하는 연구가 주를 이루고 있다. 시계열 패턴을 인식하기 위한 패턴 인식 방법의 적용은 주로 지진 관련 시계열자료 및 음성 인식 시계열자료에 적용되었고[21, 5, 6, 9, 30, 35, 37, 46], 신호에 의한 시계열 패턴 인식 또는 잡음에 의한 시계열 패턴의 구분에 관하여도 패턴 인식 방법이 효과적으로 적용되었다[12, 36]. 뇌파 검사에 관한 시계열자료 모형화에 관한 연구는 주로 수면 상태 클래스의 경우와 간질 발작에 관한 클래스로의 구분이 주요 과제였으며, 이를 위한 패턴 인식 방법의 적용 결과는 매우 우수하게 나타났고[16, 17]. 생의학 분야에서 흔히 접하는 파동 모양의 시계열자료도 패턴 인식에 의하여 매우 효과적으로 인식되었다[38, 39, 45]. 물체를 2차원 상에서 인식하는 로보트 비전에 관한 연구 분야에서도 AR모형화를 통한 패턴 인식 방법의 유용성이 입증된 바 있다[13]. 이와 같이 이공 분야에 대한 패턴 인식 방법의 적용은 활발한 반면에, 경영 과학 분야에서 패턴 인식 방법을 적용한 연구는 미미한 실정이다. Fogler[15]는 보다 정확한 예측 결과를 얻기 위한 방안으로서 패턴 인식 방법을 통해 경제학적 시계열자료를 보다 균일한 집단으로 구분하는데 성공하였다. Basilevsky and Hum[3]은 패턴 인식 방법의 하나인 Karhunen-Loeve 방법을 적용하여 자마이카의 식물 성장에 관한 시계열자료를 추세, 순환 및 계절성 요인으로 효과적으로 분해하였다.

2.2 ESACF 특성 패턴

ESACF는 Tsay and Tiao[41]에 의하여 개발된 방법으로서, 특정 시계열자료에 적용하였을 경우, 이에 의한 특성 패턴은 삼각형 패턴을 갖는 것이다. ESACF에 의한 특성 패턴 추출 과정은 우선 주어진 시계열자료 Z_t 가 ARMA(p,q) 모형에 의하여 생성되었다고 가정하고, 임의의 p 및 q 에 대하여 잔차간의 자기 상관 계수를 구하고, 이를 2차원 테이블 상에 표시하므로 써 해당 시계열자료에 관한 특성 패턴을 구하는 방법이다. 이에 대한 자세한 내용은 Tsay and Tiao[41]의 논문을 참조하면 된다. ARMA(2,2) 모형을 따르는 시계열자료에 대한 ESACF 특성 패턴은 <표 1-1>과 같다.

<표 1-1>에서 1로 표시되어 있는 부분은 잔차간의 자기 상관 계수가 표준편차의 두 배수 안에 존재하는 경우를 의미하는 것이고, 0은 두 배수밖에 존재하는 경우를 의미

<표 1> ARMA(2,2)모형을 따르는 시계열 자료의 원형 ESACF 특성 패턴

AR \ MA	0	1	2	3	4	5	6	7	8	9
0	0	0	0	0	0	0	0	0	0	0
1	0	0	0	0	0	0	0	0	0	0
2	0	0	1	1	1	1	1	1	1	1
3	0	0	0	1	1	1	1	1	1	1
4	0	0	0	0	1	1	1	1	1	1
5	0	0	0	0	0	1	1	1	1	1
6	0	0	0	0	0	0	1	1	1	1
7	0	0	0	0	0	0	0	1	1	1
8	0	0	0	0	0	0	0	0	1	1
9	0	0	0	0	0	0	0	0	0	1

한다. 한편, 밑줄친 부분은 1로 구성된 삼각형 패턴의 경계 패턴을 의미한다. 만약 경계패턴내에 1이 존재하게 되면(이 경우 1은 잡음이 된다) 그만큼 인식이 어렵게 된다. 일반적으로 경계 패턴에 잡음이 없고, 삼각형 패턴이 모두 1로 구성된 ESACF 특성 패턴을 원형 패턴 클래스(prototype pattern class)라고 한다. ESACF 특성 패턴에 의한 ARMA모형으로의 시계열 모형화에 관한 연구는 주로 국내 학자들에 의하여 수행되었다[21, 25, 26, 27, 28, 29]. 이중 Lee and Park[27]의 연구에서는 퍼셉트론에 의한 학습 기능을 적용한 의사 결정 지원 시스템을 개발하여 ARMA모형에 의한 시계열 모형화를 시도하였고 Lee and Jhee[25]의 연구는 2 단계에 걸쳐 인공신경망을 이용하여 시계열자료에 내포된 잡음의 수준을 감소시킴으로써 시계열자료 모형화의 정확도를 향상시킬 수 있었다. Lee and Oh[26]의 연구는 ARMA 모형화를 위해 인공신경망에 기초한 의사결정트리 분류기를 이용하였으나 ESACF 특성 패턴을 6 X 6 행렬까지로 제한함으로써 AR 차수와 MA 차수가 커짐에 따라 정확한 시계열 모형화에 한계를 보이고 있다. 따라서 본 논문에서는 ESACF 특성 패턴을 10 X 10 행렬로 확장한 인공신경망을 이용하여 시계열 모형화를 시도하고자 한다.

2.3 의사결정트리 분류기

의사결정트리 분류기, 즉 DTC는 많은 응용 분야에서 활용되어 왔는 바[8, 22, 23, 24], 일반적으로 DTC의 효용성

은 주어진 문제를 특정 노드에서의 소규모 문제로 ‘지역화’(localize) 하므로써, 해당 문제를 보다 효과적으로 해결하고자 하는 데에 있다. 따라서 기존 연구에서 DTC가 적용되는 문제는 중국한자 인식문제(chinese character recognition), 공중촬영사진 판독문제(aerial image recognition), 심장박동이상 인식문제(EEG wave recognition)등 문제해결에 많은 노력이 요구되는 대규모 문제였다. 본 연구에서도 이와 같은 취지로 인공신경망을 이용한 새로운 NNDTC를 적용하여, 문제해결이 까다로운 시계열 모형화 문제를 보다 효과적으로 해결하고자 하는 것이다.

이와 아울러 해당 응용 분야별로 각 의사결정트리 분류기 내의 최적 경로를 찾기 위한 알고리즘에 대해 많은 연구가 진행되었다. 본 연구에서도 NNDTC상에서 보다 효과적인 시계열 모형화를 위한 NPS라고 명명된 최적 경로 발견 알고리즘을 이용하고자 한다[26]. 이는 탐색 이전에 해당 경로가 과연 가능성이 있는 경로인지를 사전에 확인하여, 가능성이 없는 경로의 경우 미리 탐색을 포기하는 알고리즘으로서 그만큼 탐색 시간을 단축시키고 정확성을 제고시킬 수 있다는 장점을 지니고 있다.

3. 인공신경망 기초 의사결정트리 분류기

3.1 개요

본 연구에서 제안하는 NNDTC에 관한 일반적인 정의를 살펴보기로 한다.

정의 1: k 개의 가지(branch)를 가진 노드 x 에서의 의사 결정 함수 f_x 는 k 투플(tuple) 인공신경망 합수이다. 즉, $f_x : X \rightarrow [0,1]^k$ 이다.

정의 2: $T(\text{root})$ 는 NNDTC를 의미하며, 임의의 i 번째 노드는 의사 결정 함수 f_i 를 가진다.

정의 3: 노드 x 에서 노드 y 로의 의사 결정 경로를 (x,y) 로 표현하나, 의사 결정 경로 x 는 (root,x) 를 의미한다. 한편 (w,x,\dots,y,z) 는 노드 w 로부터 노드 x,\dots,y 를 거쳐 노드 z 까지의 의사 결정 경로를 의미한다.

정의 4: 노드 x 에서의 의사결정값 $v(x)$ 는 해당 노드에 연결되어 있는 인공신경망 합수에 의하여 계산 된다.

정의 5: 의사 결정 경로 x 에 해당하는 의사결정값은 $v(x)$ 이다.

각 노드에서 결정되는 의사결정값은 NPS 알고리즘이

구동되는데 필요한 자료를 제공한다. 본 연구에서는 인공신경망 학습 알고리즘으로 이미 각 응용 분야에서 널리 사용되고 있는 역전파 학습 알고리즘(Backpropagation Learning Algorithm)[34]을 적용하였다. 특히, 촉발 함수(Activation function)로써 bipolar sigmoid 함수를 이용하여 (ESACF 특성 패턴 값이 입력될 때에 0을 -0.5 로, 1을 0.5로 변환시키고 출력시 이를 다시 0과 1 사이의 값으로 다시 환원하여 사용자 편의성을 제고하였음) 학습의 효율성을 도모하였다[14]. 또한 대부분 실무에서 발생되는 시계열자료의 경우, ARMA(5,5) 모형을 넘지 않기 때문에[25, 26] 본 연구에서 제안하는 NNDTC는 <그림 1-1>과 같다.

<그림 1-1>에 표현된 NNDTC는 $T(\text{root})$, $T(\text{순수모형})$, $T(\text{혼합모형})$, $T(\text{AR모형})$, $T(\text{MA모형})$, $T(\text{ARMA}(1,*))$, $T(\text{ARMA}(2,*))$, $T(\text{ARMA}(3,*))$, $T(\text{ARMA}(4,*))$, $T(\text{ARMA}(5,*))$ 로 구성된 10개의 내부 노드(internal nodes)를 지니고 있다. 또한 내부 노드 $T(\text{AR모형})$, $T(\text{MA모형})$, $T(\text{ARMA}(1,*))$, $T(\text{ARMA}(2,*))$, $T(\text{ARMA}(3,*))$, $T(\text{ARMA}(4,*))$, $T(\text{ARMA}(5,*))$ 에는 각각 5개씩의 최종 노드(terminal nodes)가 연결되어 있다. 결국 주어진 시계열자료에 관한 ESACF 특성 패턴을 추출하고 이를 인공신경망에 의해 학습된 <그림 1-1>과 같은 NNDTC 상에 투입하여 ARMA모형화를 시작하면, $T(\text{root})$ 에서 시작하여 최종 노드 중 어느 하나의 노드에 이르게 되고, 동시에 해당 최종 노드의 ARMA 클래스로 모형화 되는 것이다.

3.2 NPS 알고리즘

의사결정트리 분류기내에서의 최적 경로 탐색 알고리즘은 일반적으로 위험 합수 r 을 정의하여 사용한다. S-채택 가능 탐색 알고리즘은 최종 노드 s^* 의 위험 합수 $r(s^*)$ 를 root에서 s^* 까지의 특성 값으로만 구성된 합수로서 정의 한다(Wang and Suen, 1984). 반면에 B-채택 가능 탐색 알고리즘은 $r(s^*)$ 을 표본으로부터의 모든 측정치의 합수로 정의한다. 그러나, 이러한 최적 경로 탐색 알고리즘은 의사결정트리 분류기의 규모가 커질 수록 탐색해야 할 경로 수가 많아진다는 것이 문제점으로 지적되고 있다. 이러한 문제를 개선하기 위하여 Chang and Pavlidis[8]은 Branch-Bound-Backtrack(BBB)알고리즘을 제안하였다. BBB 알고리즘에서는 의사 결정 f_i 가 해당 노드 x 에 주어지고, 최종적으로는 의사결정값이 가장 큰 최종 노드를 찾는 알고

리즈다. 이러한 BBB 알고리즘의 가장 큰 장점은 최종 노드 수가 커지더라도 $O(\log n)$ 의 탐색 시간을 요구한다는 점이며, 아울러 역추적(backtracking) 과정이 있어서 효과적으로 최적 경로를 찾을 수 있다는 것이다. 그러나, 이러한 BBB 알고리즘도 해당 경로가 최적이 아니라는 것이 확인되어야 비로소 역추적을 한다는 면에서 보다 개선된 탐색 알고리즘이 필요하다.

본 논문에서 이용하는 NPS 알고리즘은(NPS 알고리즘의 correctness에 대한 증명은 [26]을 참조) 해당 경로가 최적인지 아닌지를 탐색 초기에 확인하여 경로 탐색의 효율성을 제고시킨 알고리즈다. 이때 최적 여부를 결정하는 결정 값으로는 각 노드에 할당된 인공신경망에 의해 계산된 합수 값을 이용한다. <표 1-2>에는 NPS 알고리즘에 대한 개괄적인 로직챠트가 소개되어 있다. 물론, NPS 알고리즘의 경우 DTC상에서 잘못된 경로에 들어서게 되면 역추적과정이 없기 때문에 주어진 입력 패턴을 잘못 분류할 수도 있다. 그러나 이러한 현상은 DTC상의 각 노드에 할당된 인공신경망의 성능과 밀접한 관계가 있다. 즉 인공신경망이 각 노드에서 입력 패턴을 정확하게 분류할수록 역추적의 필요성이 적어지기 때문에 각 노드에 할당된 인공신경망의 성능을 높일 수 있다면 그 만큼 역추적 탐색 과정의 필요성은 적어지게 되는 것이다. 본 논문에서는 인공신경망의 성능을 향상시킴으로써 위에서 언급된 문제를 완화시키고자 하였으며 현재 NNDTC의 성능을 향상시키기 위해 인공신경망과 의사결정트리 분류기를 폐지환경 하에서 통합할 수 있는 역추적 mechanism에 대한 연구가 진행 중에 있다.

4. 실험 결과

4.1 인공신경망 구조

<그림 1-1>에 나타난 바와 같이 시계열 모형화를 위한 NNDTC 상에는 10 개의 내부 노드(internal node)가 존재하고 이를 각각에 하나의 인공신경망 합수가 할당되어야 하므로 10 개의 인공신경망을 학습시켜야 할 것이다. 본 논문에서 이용된 인공신경망의 구조와 관련된 사항은 <표 1-3>에 요약되어 있다. 먼저 인공신경망의 계층은 3 계층(3 layers), 즉 입력 계층(input layer), 출력 계층(output layer), 그리고 하나의 은닉 계층(one hidden layer)를

<표 2> NPS 알고리즘의 로직챠트

(a) Main Module

Goal: 주어진 NNDTC에서 최적 경로를 발견하는 것.
Input: 임의의 시계열자료의 ESACF 특성 패턴 및 T(root).
Output: 최종 노드

1단계: 잠재 노드 리스트 (potential node list)인 PNL 그리고 최종 노드 리스트(terminal node list)인 TNL을 생성한다.
2단계: 내부 노드인 T(순수모형), T(혼합모형)에서 의사결정값인 v(순수모형), v(혼합모형)를 계산한다.
3단계: If $v(\text{pure}) > v(\text{mixed})$, then do
begin
 search T(순수모형);
 prune T(혼합모형);
end;
Else if $v(\text{순수모형}) < v(\text{혼합모형})$, then do
begin
 search T(혼합모형);
 prune T(순수모형);
end;
4단계: PNL에 있는 잠재 노드에 대한 의사결정값을 계산한다.
5단계: 의사결정값이 가장 큰 잠재 노드를 TNL에 삽입한다.

(b) search T(순수모형) Module

Input: ESACF 특성 패턴 및 T(순수모형).
Output: 잠재 AR노드 및 잠재 MA노드

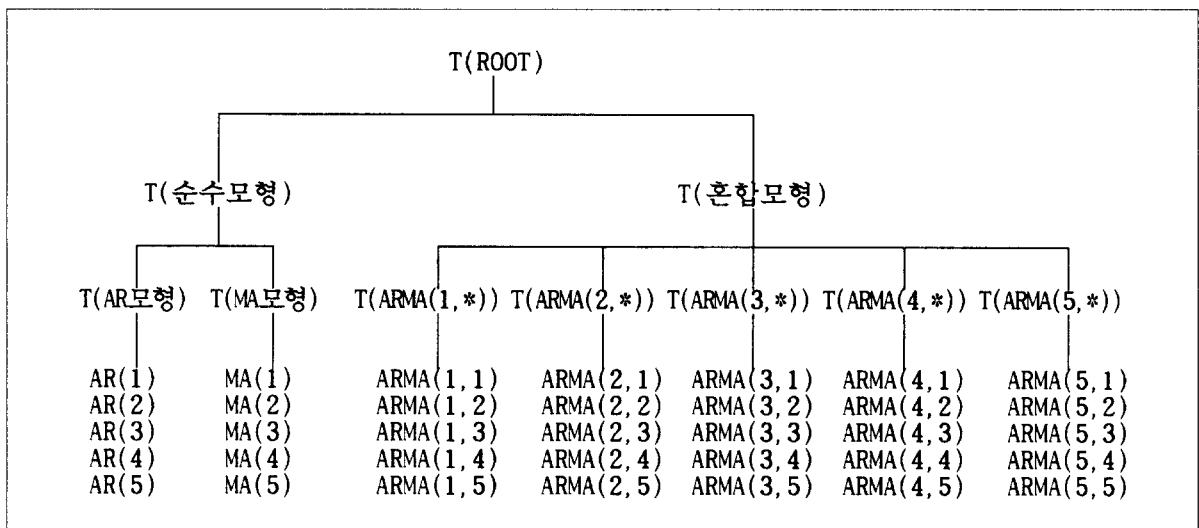
1단계: $v(\text{MA모형})$ 및 $v(\text{AR모형})$ 을 계산한다.
2단계: If $v(\text{MA모형}) > v(\text{AR모형})$, then do
begin
 search T(MA모형);
 prune T(AR모형);
end;
Else if $v(\text{MA모형}) < v(\text{AR모형})$, then do
begin
 search T(AR모형);
 prune T(MA모형);
end;
3단계: 잠재 AR노드 및 잠재 MA노드를 PNL에 삽입한다.

(c) search T(혼합모형) Module

Input: ESACF 특성 패턴 및 T(혼합모형).
Output: 잠재 ARMA노드

1단계: $v(\text{ARMA}(1,*)), \dots, v(\text{ARMA}(5,*))$ 값을 계산한다.
2단계: If $v(\text{ARMA}(p,*)) > v(\text{ARMA}(k,*))$ where $p,k=1,\dots,5$ and $p \neq k$
 search T(ARMA(p,*));
 prune T(ARMA(k,*)) where $p,k=1,\dots,5$ and $p \neq k$.
3단계: 잠재 ARMA노드를 PNL에 삽입한다.

채택하였다. 하나의 은닉 계층을 채택한 이유는 시계열 모형화 문제를 계층적 구조의 하위 문제로 분할하여 이를



〈그림 1〉 ARMA모형화를 위한 NNDTC

각각의 하위 문제에 하나의 인공신경망이 할당되므로 하위 문제를 해결하기 위한 인공신경망의 구조는 3 계층 구조이면 충분하리라는 판단 하에서 결정되었다. 본 논문에서는 모든 인공신경망의 입력 자료로 10×10 ESACF 특성 패턴 행렬을 이용하므로 총 100 개의 입력 노드가 필요하고 각각의 인공신경망의 출력 노드의 수는 해당 인공신경망이 할당된 DTC 상의 노드의 하위 노드 숫자만큼 필요하다. 은닉 계층의 노드 수는 인공신경망의 성과가 특별히 나쁘지 않는 한 입력 노드의 수와 같게 하였다. 그리고 인공신경망의 학습 과정에서 bipolar sigmoid 함수를

이용한 역전파 학습 알고리즘을 채택하였다.

4.2 데이터

인공신경망을 학습시키기 위해 각각의 인공신경망에 대해 네 종류의 학습데이터, 즉 원형데이터, 10% 잡음데이터, 20% 잡음데이터, 30% 잡음데이터를 이용하였다. 원형데이터는 〈표 1-1〉과 같이 잡음이 하나도 섞이지 않은 ESACF 특성 패턴을 의미하고 10%, 20%, 30% 잡음데이터는 원형데이터의 100 개 이진수 중에서 10%, 20%, 30%에 해당되는 10, 20, 30 개의 숫자를 무작위로 선택하여 이를 이진 변환한(0은 1로, 1은 0으로) ESACF 특성 패턴을 의미한다. 단 Jhee and Lee(1994)의 연구에서와 같이 ESACF 특성 패턴의 삼각형 구조가 심하게 왜곡되지 않도록 하기 위해 삼각형 안의 잡음갯수는 ARMA(p,q) 모형의 경우 $12 - p - q$ 를 넘지 않도록 하였다.

이와 같이 준비된 학습데이터를 이용하여 각각의 인공신경망에 대해 네 종류의 학습데이터 Set 을 준비하였다: 원형학습데이터 Set, 10% 잡음학습데이터 Set, 20% 잡음학습데이터 Set, 30% 잡음학습데이터 Set. 원형학습데이터 Set 은 원형 ESACF 특성 패턴만으로 구성하였고 10% 잡음학습데이터 Set 은 원형학습데이터 Set 에 각각의 원형 ESACF 특성 패턴에 대해 3 개씩의 10% 잡음데이터가 더

〈표 3〉 인공신경망 구조

인공신경망	NNDTC상의 해당노드	입력노드 수	은닉노드 수	출력노드 수
PMNET	T(ROOT)	100	100	2
PURENET	T(순수모형)	100	100	2
MIXEDNET	T(혼합모형)	100	100	5
ARNET	T(AR모형)	100	100	5
MANET	T(MA모형)	100	100	5
MIX1NET	T(ARMA(1,*))	100	100	5
MIX2NET	T(ARMA(2,*))	100	100	5
MIX3NET	T(ARMA(3,*))	100	100	5
MIX4NET	T(ARMA(4,*))	100	100	5
MIX5NET	T(ARMA(5,*))	100	100	5

해진 것이다. 20%, 30% 잡음학습데이터 Set 의 경우도 10% 잡음학습데이터 Set 의 경우와 마찬가지로, 10%, 20% 잡음학습데이터 Set 에 각각의 원형 ESACF 특성 패턴에 대해 3 개씩의 20%, 30% 잡음데이터를 더하여 구성하였다.

그러나 <표 1-4>에 나타난 바와 같이 각각의 인공신경망이 NNDTC 상에서 수행하는 역할이 다르므로 각각의 인공신경망의 학습데이터 Set 에 포함된 학습 패턴의 수가 다르다는 것에 주의를 기울여야 할 것이다. PMNET 은 임의의 ESACF 특성 패턴을 순수모형과 혼합모형으로 구분하는 역할을 수행하므로 원형데이터 Set 은 35 개의 ARMA 모형 각각에 대해 1 개의 원형 ESACF 특성 패턴으로(총 35 개의 ESACF 특성 패턴) 구성되었고 10% 잡음데이터 Set 의 경우에는 35 개의 원형 ESACF 특성 패턴에 이들 원형 ESACF 특성 패턴 각각에 대해 3 개씩의 10% 잡음데이터가 더해져 총 140 개의 ESACF 특성 패턴으로 구성되어 있다. PURENET 는 순수모형을 AR 모형과 MA 모형으로 분류하기 때문에 PMNET 의 원형데이터 Set 은 10 개의 순수모형에 해당되는 ESACF 특성 패턴 10 개로 구성되어 있다.

본 논문에서는 개별 인공신경망과 NNDTC 에 대한 테스트를 수행할 예정이다. 개별 인공신경망의 테스트를 위해서 10%, 20%, 30% 의 잡음 수준에 대해 각각 10 개씩의 테스트데이터 Set 을 준비하였다. PMNET 의 10%, 20%, 30% 잡음 수준의 테스트데이터 Set 은 35 개의 ARMA 모형 각각에 대해 10%, 20%, 30% 잡음 수준을 갖는 ESACF 특성 패턴으로 구성되었다. PURENET 의 경우는 10%, 20%, 30% 잡음 수준의 테스트데이터 Set 은 순수모형 각각에 대해 2 개씩 총 20 개의 ESACF 특성 패턴으로 구성되었고 MIXEDNET 의 테스트데이터 Set 은 혼합모형에 대해 1 개씩 총 25 개의 ESACF 특성 패턴으로 구성되었다. 나머지 인공신경망의 테스트데이터 Set 은 해당 인공신경망의 분류 대상이 되는 ARMA 모형 각각에 대해 4 개씩 총 20 개의 ESACF 특성 패턴으로 구성되었다. NNDTC 의 평가는 임의의 ESACF 특성 패턴에 대해 시계열 모형화가 제대로 이루어지는지를 확인하기 위한 테스트로써 10 개의 인공신경망이 모두 올바른 분류를 하는지를 알기 위한 종합적인 테스트이다. 이를 위해서 10%, 20%, 30% 의 잡음 수준에 대해 각각 10 개씩의 테스트데이터 Set 을 준비하였고 각각의 테스트데이터 Set 은 35 개의 ARMA 모형에 대해 해당 잡음 수준을 갖는 ESACF

특성 패턴 1 개씩 총 35 개의 ESACF 특성 패턴으로 구성되어 있다.

<표 4> 각 인공신경망 모형에 관한 학습 패턴 수

인공신경망 이름	학습 패턴 수			
	원형데이터 Set	10% 잡음데이터 Set	20% 잡음데이터 Set	30% 잡음데이터 Set
PMNET	35	140	245	350
PURENET	10	40	70	100
MIXEDNET	25	100	175	250
ARNET	5	20	35	50
MANET	5	20	35	50
MIX1NET	5	20	35	50
MIX2NET	5	20	35	50
MIX3NET	5	20	35	50
MIX4NET	5	20	35	50
MIX5NET	5	20	35	50

4.3 학습 및 개별 인공신경망 테스트

인공신경망의 학습을 위해 학습율(Learning rate)과 Momentum 을 각각 0.25 와 0.9 로 정하고 MSE(mean squared error)가 0.005 미만인 경우 학습이 완료되도록 하였다. 본 논문의 실험에서는 Lee and Oh(1995)에서 적용한 반복 학습 전략(Iterative training strategy)을 이용하였다. 반복 학습 전략은 학습과 테스트를 동시에 진행하는 학습 전략으로 처음에는 원형데이터 Set 만을 가지고 학습한 인공신경망을 10%, 20%, 30% 잡음 수준의 테스트데이터 Set 각각에 대해 테스트를 하고 각각의 잡음 수준의 테스트데이터에 대해 미리 정해진 수준의 정확도(본 논문에서는 약 95%)를 보이면 학습을 중단하고 그렇지 못한 경우에는 10% 잡음학습데이터 Set 을 이용하여 재학습시키고 이를 다시 테스트데이터 Set 을 이용하여 테스트를 실시하여 테스트에 통과하면 학습을 중단하고 그렇지 못한 경우에는 20% 잡음학습데이터를 이용하여 재학습시키는 과정을 30% 잡음학습데이터 Set 까지 계속하는 전략을 말한다.

각각의 인공신경망에 대해 반복 학습 전략을 적용한 결과가 <표 1-5>에 요약되어 있다. PMNET 의 경우 원형학습데이터 Set 을 이용하여 학습시킨 결과 10%, 20%, 30% 잡음 수준의 테스트데이터 Set 에 대해 96%, 84.57%,

〈표 5〉 각 인공신경망 모형에 관한 학습 및 테스트 결과

(* 는 애러 수준이 0.005 에 도달하기 전에 수렴한 경우를 의미)

인공신경망 이름	학습 국면			테스트 국면			
	자료 집합	epoch수	MSE	10% 잡음	20% 잡음	30% 잡음	평균
PMNET	원형데이터 Set	25	0.0007	0.96	0.8457	0.7971	0.8676
	10% 잡음데이터 Set	9	0.0002	0.9628	0.8628	0.8086	0.8781
	20% 잡음데이터 Set	31	0.0006	0.9743	0.9086	0.8543	0.9124
	30% 잡음데이터 Set	134	0.0007	0.9743	0.9343	0.9286	0.9457
PURENET	원형데이터 Set	2	0.004	1.00	1.00	0.9967	0.9967
MIXEDNET	원형데이터 Set	16	0.0012	0.984	0.916	0.860	0.920
	10% 잡음데이터 Set	4	0.0006	0.984	0.956	0.944	0.961
ARNET	원형데이터 Set	100*	0.009	1.00	1.00	0.98	0.993
MANET	원형데이터 Set	100*	0.0126	0.995	0.98	0.965	0.980
MIX1NET	원형데이터 Set	100*	0.0129	0.995	0.98	0.96	0.978
MIX2NET	원형데이터 Set	100*	0.0124	0.995	0.97	0.935	0.967
MIX3NET	원형데이터 Set	100*	0.0135	0.995	0.975	0.940	0.970
MIX4NET	원형데이터 Set	100*	0.0125	0.985	0.965	0.920	0.957
MIX5NET	원형데이터 Set	100*	0.0135	0.990	0.940	0.925	0.952

79.71%의 정확도를 보이므로 이는 다시 10% 잡음학습데이터 Set 을 이용하여 재학습시킨 것이다. PMNET의 경우에는 이러한 과정이 30% 잡음학습데이터까지 계속된 경우이고 PURENET의 경우에는 원형학습데이터로 학습시킨 결과 평균적으로 99.67%의 정확도를 보이므로 학습이 종료된 경우를 의미한다. 이러한 반복 학습 전략은 학습 시간을 단축시켜 주고 또한 높은 잡음 수준을 갖는 ESACF 특성 패턴에 내재된 시계열 모형화의 모호성을 줄일 수 있다는 장점을 지니고 있다(ARMA(1,1) 모형에 대해 30% 잡음 수준을 갖는 ESACF 특성 패턴이 ARMA(2,2) 모형의 10% 잡음 수준의 ESACF 특성 패턴과 유사한 경우를 의미함).

4.4 NNDTC 테스트

본 논문에서 제안한 NNDTC의 평균인식률은 10% 잡음 수준의 경우 약 96.6%에 이르고 있다. 그러나 〈표 1-6〉에서 알 수 있듯이 잡음 수준이 커짐에 따라 평균인식률은 하락하여 20% 와 30% 잡음 수준의 경우 각기 90.9%, 86.6%의 정확도를 나타내고 있어 Lee and Jhee[25]의 결과와 일치된 양상을 보이고 있다. 그러나 Lee and Jhee[25]

의 연구 결과(10%, 20%, 30% 잡음 수준의 경우 96.7%, 89.7%, 80.8%의 정확도를 보임)에 비해 NNDTC의 경우 잡음 수준이 커짐에 따른 정확도의 감소 폭이 적을 뿐만 아니라 잡음 수준이 커질 수록 Lee and Jhee[25]의 연구에 비해 평균인식률이 높은 것으로 나타났다. 물론 두 접근 방법을 정확하게 비교하기 위해서는 같은 테스트데이터를 이용해야 한다는 것을 간과해서는 안될 것이다.

4.5 실제 데이터를 이용한 NNDTC 테스트

우리는 4.3 절과 4.4 절을 통해 NNDTC를 이용하여 시계열자료에 대한 모형화를 시도하였을 때 정확도가 매우 높다는 것을 알 수 있었다. 본 절에서는 이러한 결과를 보강하기 위해 시계열 모형이 이미 밝혀진 실제 시계열자료를 대상으로 한 NNDTC 테스트 결과를 보이고 있다.

Caffeine 데이터(Tsay and Tiao, 1984):

Caffeine 데이터는 시계열자료 모형화 방법의 검증을 위한 가장 대표적인 데이터 중의 하나로 ARMA(2,5) 모형을 따르는 것으로 밝혀져 있다. 〈표 1-7〉에 나타난 바와 같이 본 논문에서 제안한 NNDTC 역시 ARMA(2,5) 모형을

〈표 6〉 NNDTC 테스트 결과
(정확히 모형화한 패턴의 수/전체 패턴수)

테스트데이터 Set	접음 수준		
	10% 수준	20% 수준	30% 수준
1st	35/35	29/35	29/35
2nd	33/35	31/35	29/35
3rd	34/35	34/35	30/35
4th	32/35	31/35	30/35
5th	35/35	32/35	31/35
6th	32/35	33/35	31/35
7th	34/35	32/35	28/35
8th	33/35	33/35	33/35
9th	35/35	31/35	31/35
10th	35/35	32/35	31/35
평균인식률	96.6% (338/350)	90.9% (318/350)	86.6% (303/350)

제시하는 것을 알 수 있다. T(root)에 할당된 PMNET의 경우 출력 노드의 값이 (0.222228, 0.777958)로 나타나 혼합모형을 제시하고 있다. 따라서 T(mixed) 노드로 이동하게 되고 이 노드에 할당된 MIXEDNET의 출력 노드의 값을 살펴보면 AR 차수가 2인 ARMA 모형을 따르는 것으로 나타나 있고 다시 T(mix2net)의 출력 노드의 값을 통해 MA 차수가 5인 것을 확인할 수 있다. 따라서 기존에 밝혀진 모형과 일치된 ARMA(2,5) 모형을 제시하고 있다.

미국 소비자 물가지수(Pandit and Wu, 1983):

ARMA(4,3) 모형을 따르는 것으로 밝혀진 미국 소비자 물가지수에 대해 NNDTC를 적용한 결과, 〈표 1-8〉에서 알 수 있는 바와 같이 NNDTC 역시 같은 모형을 제시하고 있다. T(root)에서 T(mixed)을 거쳐 T(mix4net)에 이르게 되고 T(mix4net)의 출력 노드의 값이 (0.224505 0.129788 0.922926 0.359998 0.011857)으로 나타나 ARMA(4,3) 모형을 제시하고 있다.

미국 GNP 데이터(Pandit and Wu, 1983):

미국 GNP 데이터는 AR(2) 모형을 따르는 것으로 알려져 있다. 〈표 1-9〉에 나타난 바와 같이 본 논문에서 제안한 NNDTC 역시 AR(2) 모형을 제시하고 있다는 것을 알 수 있다. 미국 GNP 데이터에 NNDTC를 적용한 결과 NNDTC 상에서 T(root), T(pure), T(arnet)을 따라서 최종적

〈표 7〉 Caffeine 데이터의 모형화 결과

T(ROOT): 0.222228 0.777958 ► mixed model
T(혼합모형): 0.005149 0.856709 0.000091 0.000012 0.000253 ►
ARMA(2,*)
T(ARMA(2,*)): 0.683107 0.083115 0.049791 0.045631 0.801752 ►
ARMA(2,5)

〈표 8〉 미국 소비자 물가지수의 모형화 결과

T(ROOT): 0.016681 0.984346 ► mixed model
T(혼합모형): 0.113215 0.000044 0.000020 0.873215 0.000001 ►
ARMA(4,*)
T(ARMA(4,*)): 0.224505 0.129788 0.922926 0.359998 0.011857 ►
ARMA(4,3)

〈표 9〉 미국 GNP 데이터의 모형화 결과

T(ROOT): 0.921272 0.218727 ► 순수모형
T(순수모형): 0.993989 0.008387 ► AR 모형
T(AR모형): 0.093801 0.765146 0.070382 0.044305 0.072403 ► AR(2)

으로 AR(2) 모형을 제시하고 있다.

5. 결론

본 논문에서는 시계열자료를 ARMA모형으로 모형화하기 위한 새로운 시도로서 NNDTC, 즉 인공신경망에 기초한 의사결정트리 분류기를 제안하였다. 제안한 NNDTC 내에서 최적 경로를 효과적으로 찾기 위하여 본 논문에서는 NPS 알고리즘을 이용하여 그 성과를 다양한 시계열자료를 대상으로 하여 실험하였다. 본 논문에서 사용한 방법은 패턴 인식의 개념에 기초한 것으로서, 특성 패턴으로는 통계학적인 ESACF 패턴을 적용하였고, 이를 NNDTC로 효과적으로 분류하기 위하여 역전파 학습 알고리즘으로 학습된 인공신경망을 NNDTC의 각 노드에 할당하고 이를 각 노드의 의사 결정으로 이용하였다. 본 논문에서 제안한 시계열 모형화에 대한 접근 방법은 (1) 기존의 통계학적인 이론에 의한 시계열 ARMA모형화보다 보다 용이하고 상황적용적이며, (2) 아울러 해당 시계열 모형화 문제를 소규모의 문제群으로 분해하여 해결할 수 있다는 장점이 있다. 향후 연구 방향으로서 시계열 모형화를 위한 각

종 방법, 즉 인공신경망을 이용한 제반 시계열 모형화 방법, 의사결정트리 분류기를 이용한 퍼지 시계열 모형화 방법, 그리고 인공신경망과 의사결정트리 분류기를 통합한 본 논문의 NNDTC 방법과의 성과 비교에 대한 연구가 의미가 있을 것으로 사료된다.

참고문헌

- [1] Akaike,H. "A New Look at the Statistical Model Identification", *IEEE Transactions on Automatic Control*, Vol.19(1974), pp.716-723.
- [2] Anglin,F.M. "Discrimination of Earthquakes and Explosions Using Short Seismic Array Data", *Nature*, Vol.223 (1971), pp.51-52.
- [3] Basilevsky, A. and D.P.J. Hum, "Karhunen-Loeve Analysis of Historical Time Series With an Application to Plantation Births in Jamaica", *Journal of the American Statistical Association*, Vol.74, No.366(1979), pp.284-290.
- [4] Beguin, J.M., C. Gourieroux and A. Monfort, "Identification of a Mixed Autoregressive Moving Average Process: The Corner Method", in Anderson, D.D. Ed., *Time Series*, North-Holland, Amsterdam(1980), pp.423-436.
- [5] Booker, A. and W. Mitronovas, "An Application of Statistical Discrimination to Classify Seismic Events", *Bull. Seismological Soc. America*, Vol.54(1964), pp. 961-977.
- [6] Boucher, R.E. and J.P. Noonan, "Adaptive Detection and Removal of Non-Gaussian Spikes for Gaussian Data", *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol.4, No.2 (1982), pp.132-136.
- [7] Box, G.E.P. and G.M. Jenkins, *Time Series Analysis-Forecasting and Control*, Holden-Day, San Francisco, 1970.
- [8] Chang, R.L.P. and T. Pavlidis, "Fuzzy Decision Tree Algorithms", *IEEE Transactions on Systems Man & Cybernetics*, Vol.7(1977), pp.28-35.
- [9] Chen, C.H. "Adaptive and Learning Algorithms for Seismic Detection of Personnel", *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol.4, No.2 (1982), pp.129-132.
- [10] Chen, C.J. and Q.Y. Shi, "Shape Features for Cancer Cell Recognition", in *Proceeding of 5th International Conference on Pattern Recognition*(1980), pp.579-581.
- [11] Dattatreya, G.R. and V. V. S. Sarma, "Decision Tree Design for Pattern Recognition Including Feature Measurement Cost", in *Proceeding of 5th International Conference on Pattern Recognition*(1980), pp.1212-1214.
- [12] Davenport, W.B. and W.L. Root, *An Introduction to the Theory of Random Signals and Noise*, McGraw-Hill, New York, 1958.
- [13] Dubois, S.R. and F.H. Glanz, "An Autoregressive Model Approach to Two-Dimensional Shape Classification", *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol.8, No.1 (1986), pp.55-66.
- [14] Fausett, L., *Fundamentals of Neural Networks: Architectures, Algorithms, and Applications*, Prentice Hall International, Inc., 1994.
- [15] Fogler, H.R. "A Pattern Recognition Model for Forecasting", *Management Science*, Vol.20, No.8(April 1974), pp.1178-1189.
- [16] Gersh, W., J. Yonemoto, and P. Naitoh, "Automatic Classification of Multivariate EEGs Using an Amount of Information Measure and the Eigen Values of Parametric Time Series Model Features", *Computers and Biomedical Research*, Vol.10(1977), pp.297-318.
- [17] Gevins, A.S., C.L. Veager, S.L. Diamond, J. Spire, G. Zeitlin, and A. Gevins, "Automated Analysis of the Electrical Activity of the Human Brain (EEG): A Progress Report", *Proceeding of IEEE*, Vol.63(1975), pp.1382-1399.
- [18] Gray, H.L., A.G. Kelly and D.D. McIntire, "A New Approach to ARMA Modelling", *Communications in Statisticsl*, Vol.B7(1978), pp.1-77.
- [19] Gu, Y.K., Q.R. Wang and C.Y. Suen, "Application of Multilayer Decision Tree in Computer Recognition of Chinese Characters", *IEEE Transactions on Pattern Analysis & Machine Intelligence*, Vol.5(1983), pp.83-89.
- [20] Hamilton, D.C. and D.G. Watts, "Interpreting Partial Autocorrelation Functions of Seasonal Time Series Models", *Biometrika*, Vol.65(1978), pp.135-140.

- [21] Jhee, W.C., K.C. Lee and J.K. Lee, "A Neural Network Approach for the Identification of the Box-Jenkins Model", *Network*, Vol.3(1992), pp.323-329.
- [22] Kanal, L.N. "On Hierarchical Classifier and Interactive Design", in Krishnaiah, P.R., Ed., *Applications of Statistics*, North-Holland, Amsterdam(1977), pp.301-321.
- [23] Kanal, L.N. "Problem-Solving Models and Search Strategies for Pattern Recognition", *IEEE Transactions on Pattern Analysis & Machine Intelligence*, Vol.1 (1979), pp.193-201.
- [24] Kulkarni, A.V. and L. N. Kanal, "Admissible Search Strategy for Parametric and Nonparametric Hierarchical Classifiers", in *Proceeding of 4th International Conference on Pattern Recognition*(1978), pp.238-248.
- [25] Lee, J.K. and W.C. Jhee, "A Two-Stage Neural Network Apprach for ARMA Model Identification with ESACF", *Decision Support Systems*, Vol.11(1994), pp.461-479.
- [26] Lee, K.C. and S.B. Oh, "An Intelligent Approach to Time Series Identification by a Neural Network-Driven Decision Tree Classifier", forthcoming in *Decision Support Systems*(1995).
- [27] Lee, K.C. and S.J. Park, "Decision Support in Time Series Modeling by Pattern Recognition", *Decision Support Systems*, Vol.4(1988), pp.199-207.
- [28] Lee, K.C. and S.J. Park, "A Knowledge-Based Fuzzy Decision Tree Classifier for Time Series Modeling", *Fuzzy Sets and Systems*, Vol.33(1989a), pp.1-18.
- [29] Lee, K.C. and S.J. Park, "PRTSM: Pattern Recognition-Based Time Series Modeler", *Computer Science in Econometrics and Management*, Vol.2(1989b), pp.239-254.
- [30] Liu, H.H. and K.S. Fu, "A Syntactic Approach to Seismic Pattern Recognition", *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol.4, No. 2(March 1982), pp.136-140.
- [31] Pandit, S.M. and S.M. Wu, *Time Series and System Analysis with Applications*, John Wiley and Sons, 1983.
- [32] Pao, Y.H. *Pattern Recognition and Neural Networks*, Addison-Wesley, 1988.
- [33] Parzen, E. "ARMA Models for Time Series Analysis and Forecasting", *Journal of Forecasting*, Vol.1(1982), pp.67-82.
- [34] Rumelhart, D.E., G.E. Hinton and R.J. Williams, "Learning Internal Representations by Error Backpropagation", in Rumelhart, D.E. and J.L. McClelland, Eds., *Parallel Distributed Processing: Explorations in the Microstructure of Cognition*, Vol. I: Foundations, MIT Press, 1986.
- [35] Sarna, C.S. and H. Stark, "Pattern Recognition of Waveforms Using Modern Spectral Estimation Techniques and Its Application to Earthquake/Explosion Data", in *Proceeding of 5th International Conference on Pattern Recognition*(December 1980), pp.1-4.
- [36] Shi, Q.Y. "A Method for the Design of Binary Tree Classifiers", in *Proceeding of IEEE Conference on Image Processing and Pattern Recognition*(1981), pp. 21-26.
- [37] Shumway, R.H. "Discriminant Analysis for Time Series", Krishnaiah, P.R. and L.N. Kanal, Eds., *Handbook of Statistics*, Vol.2, North-Holland Publishing Co.(1982), pp.1-46.
- [38] Stockman, G.C. "Waveform Parsing System", Krishnaiah, P.R. and L.N. Kanal, Eds., *Handbook of Statistics*, Vol.2, North-Holland Publishing Co.(1982), pp.527-548.
- [39] Stockman, G.C., L.N. Kanal and M.C. Kyle, "Structural Pattern Recognition of Carotid Pulse Waves Using a General Waveform Parsing Systems", *Communications of the ACM*, Vol.19(December 1976).
- [40] Swain, P.H. and H. Hauska, "The Decision Tree Classifier: Design and Potential", *IEEE Transactions on Geoscience and Electronics*, Vol.15(1977), pp.142-147.
- [41] Tsay, R.S. and G. C. Tiao, "Consistent Estimates of AR Paramaters and ESACF for Stationary and Nonstationary ARMA Models", *Journal of American Statistical Association*, Vol.79 (1984), pp.84-96.
- [42] Tucker, W.T. "On the Pade Table and Its Relationship to the R and S Arrays and ARMA Modelling", *Communications in Statistics A11*(1982), pp.1335-1379.
- [43] Wang, Q.R. and C.Y. Suen, "Analysis and Design of a Decision Tree Based on Entropy Reduction and Its

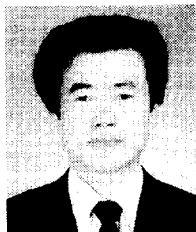
- Application to Large Character Set Recognition", *IEEE Transactions on Pattern Analysis & Machine Intelligence*, Vol.6(1984), pp.406-417.
- [44] Wang, Q.R. and C.Y. Suen, "Large Tree Classifier with Heuristic Search and Global Training", *IEEE Transactions on Pattern Analysis & Machine Intelligence*, Vol. 9 (1987), 91-102.
- [45] Valenzuela, W.R. and A. Klinger, "Pattern Recognition Applied to Monitor Waveforms", *IEEE Transactions on Biomedical Engineering*, Vol.22(Jan. 1975), pp. 18-24.
- [46] Wolf, J.J. "Speech Recognition and Understanding", in Fu, K.S., Ed., *Digital Pattern Recognition*, Springer-Verlag, Berlin(1976), pp.167-203.
- [47] Woodward, W.A. and H.L. Gray, "On the Relationship between S-Array and the Box-Jenkins Method of ARMA Model Identification", *Journal of American Statistical Association*, Vol.76(1981), pp.579-587.
- [48] You, K.C. and K.S. Fu, "An Approach to the Design of a Linear Binary Tree Classifier", in *Proceeding of 3rd Symposium on Machine Processing of Remotely Sensed Data*, Purdue University, (June-July, 1976), pp. 1-10.

● 저자소개 ●



오상봉

서울대학교 경제학과(B.A.), 한국과학기술원 경영과학과(M.S., Ph.D.)를 졸업하였고 한국통신 본사 경영전산부장, 연구개발단 요금전략연구실장을 거쳐 현재는 대전대학교 정보통신공학과의 학과장으로 재직중이다. International Social Work, Fuzzy Sets and Systems, Expert Systems with Applications, Information Processing Letters, Decision Support Systems 등에 논문을 발표하였으며 지역정보 데이터베이스의 구축 및 응용시스템의 개발, 인공지능기법을 이용한 예측방법론 및 예측시스템의 개발, 인공지능분야의 알고리즘에 관한 연구를 하고 있다. 현재 충청지역정보화 추진협의회 위원, 재단법인 충청지역정보원 상임연구위원 및 정보화시범지역 사업추진협의회 자문위원으로 활동중이다.



이건창

성균관대학교에서 경영학사, 한국과학기술원 (KAIST) 경영과학과에서 MIS로 석사, 박사를 취득하였다. 저자는 경기대학교, 한동대학교를 거쳐 현재 성균관대학교 경영학부에 재직중이다. 주요 연구분야는 인공신경망을 이용한 전문가시스템 개발이며, 특히 전략계획 분야 또는 예측분야에서 사용될 수 있는 퍼지 인공신경망 전문가시스템 개발에 관심을 갖고 있다. 정보과학회지, 산업공학회지, Decision Support Systems, Fuzzy Sets and Systems, Expert Systems, Intelligent Systems in Accounting Finance & Management, Long Range Planning, Decision Sciences, 등에 논문을 발표하였고 현재 IEEE Computer Society, IEEE SMC Society 등의 Member로 활동중이다.