

지식기반인공신경망에서 관련있는 입력노드만 연계된 은닉노드를 이용한 영역이론정련화

심 동 희[†]

요 약

지식기반인공신경망은 다른 기계학습알고리즘보다 우수한 성능을 나타내지만 인공신경망으로 형성된 후 동적으로 그 구조를 변경할 수 없어서 영역이론정련화 기능을 갖추지 못하였다. 지식기반인공신경망의 이러한 단점을 보완하기 위하여 TopGen 알고리즘이 제안되었으나 삽입된 은닉노드를 모든 입력노드에 연결한 점, 빔탐색을 이용한 점 등의 문제를 안고 있다. 본 논문에서는 TopGen의 문제점을 해소하기 위하여 은닉노드를 입력노드 중 관계가 깊은 일부의 노드에만 링크시켰으며, 역추적을 허용한 언덕오르기를 이용하는 알고리즘을 설계하였다.

Theory Refinement using Hidden Nodes Connected from Relevant Input Nodes in Knowledge-based Artificial Neural Network

Dong Hee Shim[†]

ABSTRACT

Although KBANN (knowledge-based artificial neural network) has been shown to be more effective than other machine learning algorithms, KBANN doesn't have the theory refinement capability because the topology of the network can't be altered dynamically. Although TopGen algorithm was proposed to extend the ability of KBANN in this respect, it also had some defects due to the connection of hidden nodes from all input nodes and the use of beam search. An algorithm, which could solve this TopGen's defects by adding the hidden nodes connected from only related input nodes and using hill-climbing search with backtracking, is proposed.

1. 서 론

지식기반인공신경망(KBANN: Knowledge-based Artificial Neural Network)[1, 2]에서는 어떤 문제영역에 대한 이론이 명제논리를 이용한 혼절(Horn Clause) 형

태의 규칙으로 표현되어 있으면 이를 신경망으로 변환한다. 이 규칙들을 신경망으로 변환한 후 예제에 의거하고 역전파 알고리즘[3]을 이용하여 신경망을 학습시킨다. 그러나 지식기반인공신경망에서는 규칙들을 신경망으로 변환한 후, 신경망 구조를 변화시킬 수 없다. 만약 지식기반인공신경망에서 다루는 최초의 규칙집합이 완벽하지 않은 경우 규칙집합이 갖고 있는 오류의 수정을 위하여 신경망 구조는 변화될 수 있어야 한다[4, 5]. 이 신경망 구조의 변경이 바로 영역

※ 이 논문은 1996년도 전주대학교 학술연구조성비에 의하여 연구된 것임.

† 종신회원: 전주대학교 컴퓨터공학과 부교수
논문접수: 1997년 6월 3일, 심사완료: 1997년 10월 18일

이론정련화[6]에 해당한다.

지식기반인공신경망의 단점인 영역이론정련화기능 부족을 보완할 수 있도록 지식기반인공신경망을 확장시키는 연구도 이루어졌다[4, 5, 7]. 첫째 TopGen 알고리즘[4]에서는 훈련된 지식기반인공신경망을 이용해 노드의 오류율에 근거하여 N개의 추가노드 위치를 선정한다. 다음에는 빔탐색(beam search)을 이용하여 신경망을 훈련시킨 후 가장 오류율이 적은 신경망을 도출한다. 그러나 이 알고리즘에서는 오류의 종류-즉 부(False)를 진(True)으로 분류, 진을 부로 분류-에 관계없이 처리하였고, 추가노드를 모든 입력노드에 연결시켰으며, 빔탐색을 함으로써 지나치게 방대한 탐색이 소요된다는 단점을 안고 있다. 둘째 REGENT 알고리즘[5]에서는 유전자 알고리즘을 도입하여 신경망 노드들의 위상에 변화를 가할 수 있도록 하였다. 이 알고리즘에서 사용된 연산자는 crossover와 mutation이었다. 그러나 이 방법 역시 기존의 노드들 간의 연결 형태에만 변화를 가하기 때문에 영역이론정련 범위에 제약을 갖고 있다. TopGen이나 REGENT에 의하여 도출된 신경망은 제한된 범위이긴 하지만 훈련된 지식기반인공신경망을 다시 정련화시킨 결과이기 때문에 원래의 KBANN보다 좋은 성능을 보이고 있다.

위 TopGen의 단점을 보완하기 위하여 THREE-KBANN [7] 방법이 제안되었다. THREE-KBANN에서는 추가되는 노드를 다음 하위계층의 노드에 링크시켰으며, 역추적을 허용한 언덕오르기 탐색(hill climbing search)을 이용하였다. 추가되는 노드를 다음의 하위계층의 노드들과 연결한 점은 하위계층노드들이 보유하고 있는 현재까지의 학습내용을 유지시킨다는 장점이 있지만 오류발생 노드들간의 종속적 효과로 인하여 학습시간이 더 소요될 수도 있다는 단점을 갖고 있다.

본 논문에서는 TopGen 알고리즘과 THREE-KBANN 알고리즘의 단점을 보완하여 보다 효율적이 될 수 있도록 추가되는 노드를 입력노드에 링크시키되 관계가 깊은 일부의 입력노드에만 링크시키는 방법을 제안하였다.

2. THREE-KBANN 알고리즘

2.1 양부제와 음부제의 정의

양부제 및 음부제는 신경망을 구성하는 각 노드 측

면에서 다음과 같이 정의될 수 있다. 즉 부제에 대하여 어떤 노드가 양인 경우 음으로 바꾸어 진제가 되면 양부제(false positive)라 하고, 노드가 음인 경우 양으로 바꾸어 진제가 되면 음부제(false negative)라고 볼 수 있다. 그런데 지식기반인공신경망에서 활성화값(activation value)은 1에 가깝거나 0에 가깝다. 음인 경우는 활성화값이 0에 가깝고 양인 경우는 활성화값이 1에 가까운 것이다. 지식기반인공신경망에서 노드의 음양은 바로 이 활성화값으로 결정한다.

2.2 노드 추가 위치

노드의 추가 위치 즉 수정되어야 할 노드를 결정하기 위하여 부제에 대하여 각 노드는 양부제수, 음부제수에 대한 자료를 유지한다. 그리하여 노드의 추가 위치는 양부제수와 음부제수의 합이 큰 노드를 선택하고, 같은 경우는 양부제나 음부제의 비율이 편중된 노드를 선정한다.

2.3 노드의 추가방법

새로운 노드의 추가위치가 결정되면 노드는 <표 1>에 나타낸 바와 같이 추가된다.

<표 1> 노드 추가시 링크가중치와 bias
<Table 1> Weight and bias in node addition

W: 지식기반인공신경망에서 링크의 기본가중치

현재 노드	음부제 해결시	양부제 해결시
or 노드 $A=B \vee C$ A의 bias = $-W/2$	$A=B \vee C \vee N$ A의 bias = $-W/2$ N-A 링크가중치 = W	$A=B \vee C, N2=A \wedge N1$ A의 bias = $-W/2$ A-N2 링크가중치 = W N1-N2 링크가중치 = W N2의 bias = $-3W/2$
and 노드 $A=B \wedge C$ A의 bias = $-3W/2$	$A=B \wedge C, N2=A \vee N1$ A의 bias = $-3W/2$ A-N2 링크가중치 = W N1-N2 링크가중치 = W N2의 bias = $-W/2$	$A=B \wedge C \wedge N$ A의 bias = $-5W/2$ N-A 링크가중치 = W

or노드에서 음부제를 해결하기 위하여 새로운 노드 N을 만들어 A에 or로 연결할 때 이 링크의 가중치만 W로 하면 된다. 양부제를 해결하기 위하여 생성된 노드 N1과 N2에 대해서는 A-N2 및 N1-N2 링크가중치 모두 W로 하며 N2의 bias는 $-3W/2$ 로 한다. 한편

and노드에서 음부제를 해결하기 위하여 생성된 노드 N1과 N2에 대해서는 A-N2 및 N1-N2 링크가중치 모두 W로 하며 N2의 bias는 $-W/2$ 로 한다. 양부제를 해결하기 위하여 새로운 노드 N을 만들어 A에 or로 연결할 때 이 링크의 가중치는 W로 하고 A의 bias는 $-5W/2$ 로 한다.

2.4 새로운 노드의 bias

or노드에서 음부제 해결시와 and 노드에서 양부제 해결시 노드 N의 bias 및 and노드에서 음부제 해결시와 or 노드에서 양부제 해결시 노드 N1의 bias 모두 $-(2N-1)W/2$ (N는 하위계층 노드로부터의 링크수)로 한다. 또한 or노드에서 음부제 해결시 A의 bias는 $-W/2$ 로, 양부제 해결시 N2의 bias는 $-3W/2$ 로, and노드에서 음부제 해결시 노드 N2의 bias는 $-W/2$ 로, 양부제 해결시 A의 bias는 $-5W/2$ 로 한다.

2.5 새로운 노드로부터 상위계층 노드로의 링크 가중치

새로운 노드로부터 상위계층 노드로의 링크 가중치는 본래의 노드가 갖고 있던 가중치를 따르도록 한다.

2.6 THRE-KBANN 알고리즘

THRE-KBANN(Theory Refinement algorithm for KBANN) 알고리즘[7]은 KBANN에 적용할 수 있는 영역이론전환을 위한 알고리즘으로서 아래에 나타낸 바와 같다.

- (1) 훈련사례를 시험집합, 훈련집합, 조정집합1, 조정집합2로 임의로 분류한다.
- (2) 훈련집합을 이용하여 훈련된 KBANN을 생성한다.
- (3) 조정집합1을 이용하되 다음의 절차를 의하여 신경망을 생성한다.
 - 1) 각 노드의 음부제와 양부제의 값을 0으로 초기화한다.
 - 2) 조정집합1에서 각 부제에 대하여 각 노드에서의 양부제, 음부제 여부를 판단하여 해당값을 증가시킨다.
 - 3) 양부제와 음부제의 합이 가장 큰 노드를 선정한다. 같은 경우는 양부제나 음부제의 비율이 편중된 노드, 입력계층에 가까운 노드 순으로 선정한다.

- 4) 노드 추가방법에 의거하여 노드를 추가하여 신경망을 생성한다.
- (4) 새로운 신경망을 조정집합2를 이용하여 훈련시키고 오류율이 이전의 신경망보다 높으면 위의 3)단계로 되돌아간다.
- (5) 새로운 신경망의 오류율이 중지조건을 만족하면 이를 출력하고 만족하지 않으면 3)으로 간다.

3. TR-KBANN

TR-KBANN(Theory Refinement algorithm for KBANN)은 2장에서 설명한 THRE-KBANN과 같은 절차를 따른다. 다만 새로운 노드는 THRE-KBANN과 같이 하위계층의 노드와 연결하지 않고 입력노드와 연결을 하되 가중치를 다음과 같이 설정한다.

새로운 노드는 입력노드들중 관련이 깊은 노드들로부터 0이 아닌 가중치를 갖도록 한다. 이러한 노드를 결정하기 위하여 다음과 같은 휴리스틱 방법을 이용한다. 여기서 사용하는 기호는 다음과 같다. 먼저 입력노드는 입력특성이 있을 수 있고(값이 1) 없을 수 있는 데(값이 0) 이를 각각 P(present)와 A(absence)로 나타낸다. 추가노드에 대해서는 추가노드가 진 또는 부(활성값이 1에 가까운지 0에 가까운지에 따라 결정됨)일 수 있는 데 이를 각각 T(true)와 F(false)로 나타낸다. 또한 추가노드의 값이 옳을 수 있고 틀릴 수 있는 데 이를 각각 C(correct)와 I(incorrect)로 나타낸다. 이 C와 I에 대한 결정은 출력노드부터 입력노드 방향으로 결정되어 온다. 조건→결론과 같은 규칙에서 만약 결론이 맞으면 조건도 맞은 것으로 간주하며 결론이 틀린 경우 조건을 바꾸어 결론이 맞게 되는 경우 조건이 틀린 것으로 간주한다. 그리고 P(C|T)는 T인 가정 아래 C일 조건부확율을 표기하기로 하고 다음과 같이 처리한다.

앞절에서 설정된 추가노드에 대하여(표1에서 노드 N 또는 노드 N1에 해당)

- (1) 각 입력노드별로 8개의 자료를 유지한다.
 - 입력특성의 존재여부에 따른 P 또는 A로의 분류, 추가노드의 활성화여부에 따른 T 또는 F로의 분류, 추가노드 값이 옳았을 경우는 C(Correct), 틀렸을 경우는 I(Incorrect)로 분류
- 위의 3가지 경우를 조합하여 8가지 자료를 유지

한다.

(2)조정집합2의 각 예제에 대하여 다음을 처리한다.

1)예제에 대하여 추가노드의 활성화 여부 T, F를 판정하며, 옳고 그름 C, I를 판단한다.

2)각 입력노드별로 다음을 처리한다.

a)입력노드의 입력특성여부 P, A를 판단한다.

-P, A 여부, T, F 여부, C, I여부에 따라 8가지 경우중 하나에 해당한다.

b)입력노드의 8가지 자료중 해당자료에 경우수 I을 누적시킨다.

(3)각 입력노드별로 위에서 산출한 경우의 수에 의거하여 다음을 계산한다.

1)on = $P(C|T) * P(P|C \& T)$

$P(C|T)$ 는 추가노드가 활성화되었다는 가정 아래 이 활성화가 옳바를 확률인 데 이런 경우는 확률이 1까지 되어 가중치가 1로 될 수 있다. 그러나 이 확률은 입력특성여부에 관계가 없기 때문에 입력노드별로 모두 동일하다. 따라서 입력노드별로 다른 값을 갖도록 조정하는 것이 필요하다. 그런데 입력특성의 존재가 추가노드에 영향을 미치기 때문에 이 확률을 계산하여야 한다. 그래서 활성화되어 있고 옳바를 가정하여 입력특성이 있을 조건부확률을 곱하도록 한다. 확률값을 이용한 것이므로 이 값은 0에서 1의 값을 갖게 된다. 이 확률은 $P(P \& C|T)$ 와 동일하다.

2)off = $-P(C|F) * P(P|C \& F)$

off의 계산은 on의 경우와는 활성/비활성 측면에서 대칭이 되어야 한다. 또한 가중치가 반대값이 되도록 부호가 바뀌어야 한다. 따라서 on의 수식에서 T를 F로 바꾸고 부호를 변경시키면 된다. 이의 해석은 다음과 같다.

$P(C|F)$ 는 비활성화되었다는 가정 아래 옳바를 확률인 데 이런 경우는 확률이 1까지 되어 가중치가 -1까지 될 수 있다. 그러나 이 확률 역시 입력특성여부에 관계없이 입력노드별로 모두 동일하다. 따라서 입력노드별로 다른 값을 갖도록 조정하는 것이 필요하다. on에서와 마찬가지로 입력특성의 존재가 추가노드에 영향을 미치기 때문에 이 확률을 계산하여야 한다. 그래서 활성화되어 있으면서 틀렸을 가

정하여 입력특성이 있을 조건부확률을 곱하도록 한다. 이 값 역시 확률간의 계산이므로 0에서 1의 값을 갖게 된다. 한편 이 값은 on을 계산한 수식에서 활성화 여부를 바꾼 값이 되며 부호를 바꾼 값이 된다. 이 값은 $-P(P \& C|F)$ 와 동일하다.

3)입력노드에서 추가노드로의 링크가중치

앞에서 계산된 on과 off 중 절대값이 큰 수를 링크가중치로 한다.

4. TR-KBANN의 성능평가

4.1 평가대상 알고리즘

본 연구에서 제시한 TR-KBANN의 성능을 THRE-KBANN[7], TopGen[4, 5]과 비교하고, 또한 간단한 확장신경망[4]과 비교한다. 간단한 확장신경망이란 노드들을 하나씩 추가하여 이 노드들을 모든 입력노드 및 출력노드와 연결한 것이다.

4.2 평가대상 문제영역

유전학에서 나타나는 두가지 문제 즉 프로모터(promoter) 인식문제와 접목점(splice-junction) 결정문제를 평가에 이용하였다. 분자생물학에서 DNA는 뉴클레오타드라고 불리우는 {A, G, T, C} 문자집합에서 선택된 문자들의 선형배열이다. 이 DNA는 RNA로, RNA는 다시 단백질(protein)으로 복제가 된다. 이 단백질은 세포의 활성적 요소에 해당한다. 그런데 DNA에 있는 명령에 근거하여 단백질이 생성되기 때문에 DNA에서의 오류는 잘못된 단백질을 유발하며 선천적 질병으로 나타나게 된다. 따라서 인간의 DNA배열을 아는 것은 선천적 질병을 처리하기 위한 첫 단계가 된다. DNA배열에서는 위치를 명시하는데 특별한 표기법을 이용한다. 즉 생물학적으로 의미있는 고정된 점(기준점)을 기준으로 위치를 숫자화한다. 음수는 기준점에 앞서는 위치를 나타내고 양수는 기준점 뒤의 위치를 나타낸다. 예를 들어 @3 'AGTC'는 기준점에서 오른쪽으로 3번째의 뉴클레오타드는 A이며 다음에는 GTC임을 의미한다.

(1)프로모터 인식문제

DNA의 배열중 단백질으로 복제되는 부분을 유전인자(genes)라고 한다. DNA배열의 이해를 위해서

는 먼저 이 유전인자의 시작부분과 끝을 인식해야 한다. 유전인자의 끝부분은 3개의 뉴클레오티드에 의하여 표시가 되기 때문에 쉽게 인식이 되는 데 시작부분의 인식은 쉽지가 않다. 프로모터란 유전인자앞에 선행하는 짧은 DNA배열을 의미한다. 따라서 프로모터를 인식하면 유전인자의 시작부분을 알게 된다. 프로모터 DNA배열은 뉴클레오티드 57개로 구성되는데 이것이 프로모터인지 아닌지를 판단할 수 있는 일부의 규칙[8]들이 알려져 있는데 이 규칙들이 완벽하지는 않다. 프로모터 인식문제에 대한 예제는 프로모터에 해당하는 234개의 진제와 4921개의 부제로 구성하였다.

(2) 접목점 결정(splice-junction determination) 문제
 접목점(splice junction)은 단백질 생성과정중 DNA 배열에서 불필요한 DNA가 제거되는 지점들이다. 이 DNA 배열에는 접목후에도 유지되는 부분에 해당하는 엑손(exons), 접목후에 없어지는 부분에 해당하는 인트론(introns)이 있다. 그래서 E/I 부분이라 불리우는 엑손/인트론 경계와 I/E 부분이라 불리우는 인트론/엑손 경계를 인식해야 하는 데 이러한 경계인식문제를 접목점 결정문제[8]라 한다. 이 문제에 대한 예제는 1210개의 진제와 1890개의 부제로 구성하였다.

4.3 평가방법

프로모터 인식문제와 접목점 결정문제에 대하여 규칙을 1개부터 5개까지 삭제한 경우에 대하여 TR-KBANN을 수행하였다. 각 경우에 대하여 조정집합2의 오류율이 0%가 되거나 수행시간이 1시간이 경과할 때까지 TR-KBANN을 수행시켰다. 수행결과 최종 형성된 각 신경망의 오류율을 시험집합을 이용하여 측정하였으며 이러한 시험을 5회씩 수행하였다.

4.4 평가결과

프로모터 인식문제와 접목점 결정문제에 TR-KBANN을 적용한 결과 인식오류율의 평균은 <표 2>에, 추가된 노드수의 평균치는 <표 3>에 나타낸 바와 같다. <표 2>에서는 오류율을 비교하였는데 본 논문에서 제안한 TR-KBANN의 프로모터 인식문제와 접목점 결정문제에 대한 오류율은 각각 1.97%, 4.05%로서 TopGen의 오류율 2.06%, 4.17%보다 낮아 오류율 측

면에서 성능이 좋음을 알 수 있으며 THRE-KBANN과 비교할 때도 비슷한 수준을 나타냈다. <표 3>에서는 추가된 노드수를 비교하였는데 TR-KBANN이 THRE-KBANN 보다 추가된 노드수가 더 적게 나타났다. 인식오류를 측면에서는 TR-KBANN이 THRE-KBANN과 비슷한 수준이지만 추가노드수 측면에서는 더 적다는 것은 학습효율이 더 좋음을 나타내는 것이다.

5. 결론 및 향후과제

KBANN은 명제논리로 표현된 문제영역에 대하여 기존의 학습방법보다 더 효율적인 방법으로 입증된 바 있다. 그러나 그러나 실세계의 대부분의 초기 지식은 근사적으로 올바르기 때문에 영역이론정련화가 사실 필요하다. 그런데 KBANN은 영역이론정련화 능력을 보유하고 있지 않다. KBANN의 이러한 단점을 보완하기 위하여 TopGen에서는 오류의 원인이 되는 노드를 찾아 노드를 추가하되 이 노드를 모든 입력노드들과 연결시켰다. 또한 노드를 추가할 때 빔탐색을 이용하므로써 시간복잡성의 부담을 안고 있다. THRE-KBANN에서는 TopGen알고리즘을 2가지 측면에서 개선하였다. 즉 빔탐색을 역추적을 허용한 언덕오르기 탐색으로 바꾸었고, 추가노드를 모든 입력노드와 연결하는 대신 하위계층의 노드와 연결하였다. 그 결과 TopGen보다 좋은 효율성을 높였다. 본 논문에서 제안한 TR-KBANN은 THRE-KBANN과 처리골격은 같지만 영역이론 정련화를 위하여 추가되는 노드에 대하여 관계가 깊은 입력노드만을 연결시켰다. 그리하여 추가된 노드를 관계가 깊은 일부의 입력노드에만 링크를 시켰으며 링크의 가중치를 노드간의 성격에 따라 차별성을 부여함으로써 그동안의 학습효과가 반영되도록 하였다. 유전학에서 발생하는 두 문제영역에 이 알고리즘을 적용하여 본 결과 이러한 개선으로 인하여 KBANN과 TopGen보다는 인식율뿐만 아니라 추가노드수 측면에서도 효율적인 성능을 보였으며, THRE-KBANN보다는 추가노드수 측면에서 성능이 다소 앞섰다.

향후 연구로는 영역이론의 상위계층의 규칙이 누락되었을 경우에도 TR-KBANN이 잘 적용될 수 있도록 보완되어야 할 것이다. 이를 위해서는 복수전략

학습(multistrategy learning)과 같은 방법을 도입해야 할 것이다.

〈표 2〉 인식오류율 결과
 (Table 2) Error rate comparison

알고리즘	오류율	
	프로모터 인식문제	접목점 결정문제
TR-KBANN	1.97	4.05
THRE-KBANN	1.98	4.05
TopGen	2.06	4.17
간단한 확장신경망	2.12	4.53
KBANN	2.31	4.58

〈표 3〉 추가 노드 수
 (Table 3) Total number of nodes added

알고리즘	추가된 노드수	
	프로모터 인식문제	접목점 결정문제
TR-KBANN	4.0	3.6
THRE-KBANN	4.2	3.8
TopGen	4.4	4.0
간단한 확장신경망	5.0	5.2

참 고 문 헌

[1] G.G. Towell, "Symbolic Knowledge and Neural Networks: Insertion, Refinement, and Extraction", Ph.D thesis, University of Wisconsin-Madison, 1991.

[2] G. G. Towell, & J. W. Shavlik, "Using Symbolic Learning to Improve Knowledge-Based Neural Networks", Proceedings of AAAI, pp. 177-182, 1992.

[3] D.E. Rumelhart, G.E. Hinton, and J. R. Williams, "Learning Internal Representations by Error Propagation", Vol. 1, pp. 318-363, MIT press, 1986.

[4] D.W. Opitz, and J. W. Shavlik, "Heuristically Expanding Knowledge-Based Neural Networks", In Proceedings of the Thirteenth International Joint Conference on Artificial Intelligence, 1993, pp.

1360-1365, 1993.

[5] D. W. Opitz, 'An Anytime Approach to Connectionist Theory Refinement: Refining the Topologies of Knowledge-Based Neural Networks', Ph.D thesis, University of Wisconsin-Madison, 1995.

[6] D. Ourston and R. Mooney, "Theory Refinement Combining Analytical and Empirical Methods", Artificial Intelligence, Vol. 66, pp. 273-309, 1994.

[7] 심동희, "지식기반인공신경망에서 은닉노드삽입을 이용한 영역이론정련화", 정보처리학회논문지 제3권 제7호, pp. 1773- 1780, 12월, 1996년

[8] G. G. Towell, & J. W. Shavlik and M. Noorde-wier, "Refinement of Approximate Domain Theories by Knowledge-based Neural Networks", In Proc. of the 8th National Conference on Artificial Intelligence, pp. 861-866, Boston, MA, 1990.

심 동 희



1980년 서울대학교 산업공학과 졸업(공학사)
 1982년 서울대학교 대학원 산업공학과 졸업(공학석사)
 1994년 고려대학교 대학원 전산과학과 졸업(이학박사)
 1983년~1985년 국토개발연구원 근무

1985년~1988년 해운산업연구원 근무
 1988년~현재 전주대학교 컴퓨터공학과 부교수
 관심분야: 기계학습, 전문가시스템