

운전자 통행시간예측을 위한 신경망
-칼만필터 알고리즘 적용 및 검증-

운전자 통행시간예측을 위한 신경망
-칼만필터 알고리즘 적용 및 검증-

치안정책연구소 교통대책연구실

책임연구관 김 남 선

목 차

제1장 서론	1
제1절 연구의 배경 및 필요성	1
제2절 연구의 내용 및 절차	3
1. 연구의 내용	3
2. 연구절차	5
제2장 이론적 고찰 및 선행연구	6
제1절 이론적 고찰	6
1. 통행시간과 통행시간가치	6
2. 신경망 알고리즘	9
3. 칼만필터 알고리즘	28
제2절 선행 연구 고찰	35
제3장 통행시간 예측 알고리즘	38
제1절 자료수집 및 가공처리	38
1. 자료수집	38
2. 가공 처리	40
제2절 통행시간 모형	44
1. 모형의 구조	46
2. 적용 모형	48

제4장 통행시간 모형평가 및 결과분석	51
제1절 평가방법	51
제2절 평가결과	52
1. 공간평균법 통행시간의 평가	52
2. 통행시간 추정모형 평가결과	53
3. 통행시간 예측모형 평가결과	57
제3절 적용모형과 공간평균법 비교평가	61
제5장 모형의 검증 및 수행도 평가	63
제1절 통행시간 모형의 검증방법	63
제2절 통행시간 모형의 검증결과	65
제3절 통행시간 모형의 수행도 평가	69
제6장 결론	72
참고문헌	73
I. 국내문헌	73
II. 외국문헌	74
III. 기타	80

표 목차

<표 1> RBFNN의 학습알고리즘	23
<표 2> 통행시간 예측방법의 특징 비교	35
<표 3> 수집자료 내역	38
<표 4> 구간 및 차로현황	39
<표 5> 단일구간 추정모형	48
<표 6> 다중구간 추정모형	49
<표 7> 단일구간 예측모형	49
<표 8> 다중구간 예측모형	50
<표 9> 통행시간 평가지표(MOE)	51
<표 10> 공간평균법의 통행시간 평가결과	52
<표 11> 단일구간추정모형의 평가결과(수원-서울)	53
<표 12> 다중구간추정모형의 평가결과(수원-서울)	54
<표 13> 다중구간추정모형의 평가결과(오산-서울)	55
<표 14> 단일구간예측모형의 평가결과(수원-서울)	57
<표 15> 다중구간예측모형의 평가결과(수원-서울)	58
<표 16> 다중구간예측모형의 평가결과(오산-서울)	58
<표 17> 평가지표별 공간평균법에 대한 적용모형의 개선도	61
<표 18> 가설을 위한 범위	65
<표 19> 단일구간 통행시간 추정모형 검정결과(수원-서울)	66
<표 20> 다중구간 통행시간 추정모형 검정결과(수원-서울)	66
<표 21> 다중구간 통행시간 추정모형 검정결과(오산-서울)	67
<표 22> 단일구간 통행시간 예측모형 검정결과(수원-서울)	67
<표 23> 다중구간 통행시간 예측모형 검정결과(수원-서울)	68

<표 24> 다중구간 통행시간 예측모형 검정결과(오산-서울)	68
<표 25> 개발모형의 종합적인 수행도 평가결과	71

그림 목차

<그림 1> 연구절차	5
<그림 2> 통행시간 가치산정 방법	7
<그림 3> 일반 신경망 모형	10
<그림 4> 인공신경망의 기본구성	11
<그림 5> 신경망 모형의 구분(Lipmann)	12
<그림 6> 일반화된 역전파 신경망 모형의 구조	13
<그림 7> LVQ 모형의 망구조	15
<그림 8> RBFNN의 신경망구조	18
<그림 9> RBFNN의 학습수행단계	24
<그림 10> BP신경망 알고리즘 흐름도	26
<그림 11> 칼만 필터링의 Block Diagram	29
<그림 12> Time Update와 Measurement Update의 상호 연계	34
<그림 13> Spacial Mapping 기반의 신경망 모형(단일)	44
<그림 14> Spacial Mapping 기반의 신경망 모형(다중)	45
<그림 15> 단일 구간 모형	46
<그림 16> 다중 구간 모형	47

제1장 서론

제1절 연구의 배경 및 필요성

근래 들어, 사회·경제·문화적으로 다양한 변화가 심화되면서 우리의 일상생활에도 변화가 발생하고 있다. 이에 따라 우리생활속의 교통문화도 변화하고 있다. 사회적으로 고령화 사회, 저출산 핵가족화, 교육계의 주5일제 수업실시 등 주5일 근무제의 확산 등이 주요 변화요인이다. 경제적으로는 세계적인 자유무역체계의 일환인 NAFTA, WTA, FTA 등이 확산되는 추세에 있고 표준의 글로벌화 현상도 점차 확산되고 있다. 또한 소득의 증가와 유류비 인상으로 인한 일상패턴의 변화도 일어나고 있다. 이에 따라 우리생활속의 교통문화도 주말교통량의 증가와 노인교통수요의 증가로 나타나고 있고 생활수준향상에 따른 여가를 이용한 여행형태의 교통수요가 증가하는 경향이 나타나고 있다. 출퇴근 교통수요와 달리 여행형 교통수요는 대부분 가본 적이 없는 미지의 목적지를 향한 차량운행 시도인 만큼 운전자가 목적지로 이동하기 위해 가장 중요한 정보는 “목적지까지 헤메지 않고 잘 찾아 갈수 있을까”, “지금 출발하면 목적지까지 시간이 얼마나 걸리는가”, “어느 길로 가는 것이 혼잡하지 않고 좋을까” 하는 목적통행에 대한 교통정보와 전방향의 교통사고 및 혼잡 유무와 원인 등에 대한 정보이다. 전방향의 통행시간은 운전자로 하여금 통행 중에 현재의 위치로부터 종착지까지 다양한 우회 및 대안경로의 선택여부를 결정할 수 있는 기초정보이며, 정시성을 제공하는 중요한 정보가 된다. 그러나 이러한 구간의 예측통행시간은 고속도로 및 도시간선도로는 물론 국도 등의 국내 교통정보제공시스템에서 안정적으로 제공하기

위해 정보의 신뢰성을 높이기 위한 노력이 지속적으로 필요한 분야이다. 현재는 단순한 산술기법이나 과거자료(Historical Data)의 시간/공간대별 평균자료에 의하여 현재의 통행속도를 생성하여 제공하는 곳이 대부분이며, 이는 현재의 출발지-목적지간 통행에서의 전체교통상황 반영이라는 측면을 고려하지 못하고 있다. 따라서 통행시간에 대한 다양한 연구가 지속적으로 이루어져서 현재시점에서의 실시간 통행시간과 미래시점의 출발에 대한 예측통행시간을 도출할 수 있는 상황까지 도달해야 할 필요성이 있다.

본 연구의 목적은 루프검지기를 통해 수집할 수 있는 속도정보를 기반으로 통행시간을 추정 및 예측알고리즘에 대한 후속 연구로서 개발된 알고리즘에 대하여 적용에 따른 통계적 검정을 통하여 객관적인 신뢰성을 검증하는데 있다. 또한, 대부분의 교통관제시스템의 통행시간정보는 VDS에서 수집된 교통정보에 대해 공간평균속도(Space Mean Speed)방식으로 산출되어 적용되고 있으며, 이러한 방식은 각 차량들이 경험하게 될 감속/가속시간, 대기행렬에 의한 지체시간을 산출하기가 어렵다. 따라서, 본 연구에서는 신경망이론을 이용하여 추정된 통행시간과 신경망-칼만필터기법을 기반으로 한 통행시간예측 알고리즘에 대하여, 이용자에게 보다 나은 실시간 통행시간정보를 제공할 수 있는 알고리즘에 대한 통계적 검정을 실시하고 알고리즘의 정확성과 안정성을 검증하여 시스템의 적용성을 높이는데 기여하고자 한다.

제2절 연구의 내용 및 절차

통행시간모형의 구축은 신경망과 칼만필터 알고리즘을 통한 통행시간 추정과 예측모형에 대하여 다음과 같은 범주로 모형을 구분하여 적용에 대한 검증을 실시하고자 한다.

1. 연구의 내용

단일구간 추정모형은 임의의 출발지와 인접한 중간도착지를 모형의 공간적 적용대상으로 하며, 현재시점에서 통행시간을 추정하는 모형이다. 각 영업소를 통행한 차량의 TCS자료를 정확한 통행시간으로 정의하고 동일시점의 VDS자료와 연계하여 신경망의 학습자료를 이용한 추정모형에 대한 검증을 실시한다.

다중구간 추정모형은 임의의 출발지와 인접한 중간도착지 보다 원거리에 위치한 임의의 도착지를 모형의 공간적 적용대상으로 하며, 현재시점에서 통행시간을 추정하는 모형이다. 출발지와 도착지를 포함하여 모든 영업소를 경유한 차량의 TCS자료를 정확한 통행시간으로 정의하고 동일시점의 VDS자료와 연계하여 신경망의 학습자료를 이용한 추정모형에 대한 검증을 실시한다.

단일구간 예측모형은 임의의 출발지와 인접한 중간도착지를 모형의 공간적 적용대상으로 하며 미래시점을 시간적 적용대상으로 하는 예측모형이다. 각 영업소를 통행한 차량의 TCS자료를 정확한 통행시간으로 정의하고 동일시점의 VDS자료에 대해 칼만필터링 기법으로 단위시간 이후의 지점속도를 예측하여 신경망의 학습자료로 이용한다. 예측단위 5분은 Moving Average에 의한 Data Smoothing 효과와 시계열적 변동요소를 예측에 반영하기 위하여 기초적인 수집자료를 5분단위로 가공하여 사용

하므로 자료의 시간적 연장선상의 최소단위로서 정한 예측단위이다.

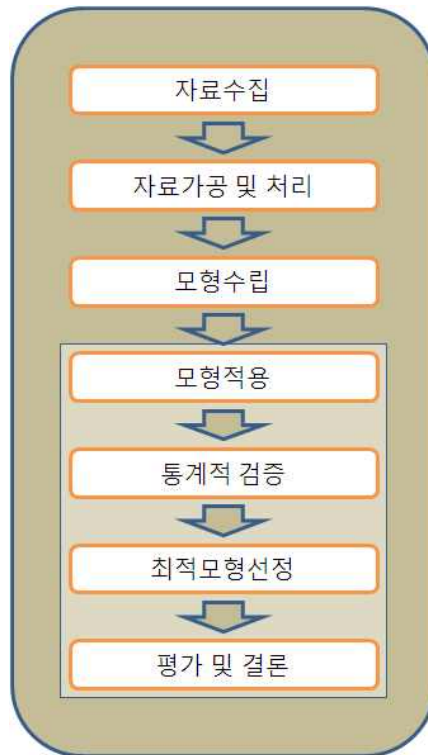
다중구간 추정모형은 임의의 출발지영업소와 인접영업소보다 원거리에 위치한 임의의 도착지영업소를 모형의 공간적 적용대상으로 하며, 미래 시점에서 통행시간을 추정하는 모형이다. 출발지와 도착지를 포함하여 모든 영업소를 경유한 차량의 TCS자료를 정확한 통행시간으로 정의하고 동일시점의 VDS자료에 대해 칼만필터링 기법으로 5분 후를 예측하여 신경망의 학습자료로 이용한다. 실험 및 검증은 고속도로교통관리시스템과 대상지역의 영업소에서 제공하는 VDS 교통정보 및 통행시간을 학습 자료와 검증 자료로 구분하여 수행한다.

자료 처리는 수집된 기초 교통자료의 이상치 제거와 통행시간 예측을 위한 기반 입력자료의 처리로 구분하여 처리한다. 특히 기반 입력자료의 처리는 예측단위시간(Prediction Lead-Interval)을 고려하여 처리할 수 있도록 한다. 그의 자료의 처리 부문에서 이상치의 제거기법은 이론적으로 통계적 처리기법에 기초하여 수행토록 하며, 이를 통해 보다 안정적 모형을 구축할 수 있도록 적용한다.

2. 연구절차

연구의 절차는 자료수집을 바탕으로 입력자료로서의 요건을 갖추기 위하여 자료의 가공 및 처리과정을 거침으로서 이상치 제거 및 입력자료형식으로 정리하며, 모형수립 및 적용, 적용결과를 통해 선정된 모형의 일반성을 확인하기 위한 통계적 검증, 검증결과를 바탕으로 한 최적모형선정 및 평가과정을 거쳐 결론을 도출하는 단계로 진행된다.

<그림 1> 연구절차



또한, 본 연구의 범위는 이상에서 제시하고 있는 연구범위에 적합한 모형의 검증을 위하여 서울톨게이트(Toll Gate)~청원IC의 전 구간을 대상으로 선정하였다.

제2장 이론적 고찰 및 선행연구

제1절 이론적 고찰

이론적 고찰에서는 본 연구와 관련하여 통행시간의 의미와 통행시간 추정 및 예측과 관련된 신경망이론과 칼만필터 알고리즘에 대한 이론적 사항을 다룬다. 여기서 통행시간(通行時間;Travel Time)은 차량의 통행시간으로 차량통행(Trip Time)에 소요되는 모든 시간으로 차도 내에서의 주행, 정지, 지연을 포함한 모든 시간으로 정의한다. 통행시간 추정 및 예측을 위한 부분은 신경망을 기반으로 접근하며, 신경망 모형은 신경망 모형의 일반적 개념과 본 연구와 관련하여 모형구축에 적용 가능한 역전파 신경망 모형과 방사형함수 신경망모형에 초점을 두어 제시하였다. 통행시간예측을 위한 칼만필터 알고리즘은 확률변수를 시간영역 기준으로 상태공간으로의 모형화를 통하여 추정하는 최적순환필터링방법으로서 예측방법은 시간에 따라 입력되는 관측값과 이전시간을 기준으로 예측된 예측값을 비교하여 평균제곱오차의 최소화 조건을 만족하게 필터를 동적으로 적용시키는 방법이다. 따라서 칼만필터모형은 추계적 모형으로써 조건부 추정오차를 최소화하는 동적 예측방법으로 통행시간의 시간적 전이에 의한 예측방법에 초점을 맞추어 고찰하였다.

1. 통행시간과 통행시간가치

여기서 통행시간(通行時間;Travel Time)은 차량의 통행시간으로 차량 통행(Trip Time)에 소요되는 모든 시간으로 차도 내에서의 주행, 정지,

지연을 포함한 모든 시간을 포함한다.

통행시간가치의 산정은 접근방법과 이용하는 자료의 형태에 따라 다양하며 Hensher(1977), Wardman(1997) 등의 연구를 토대로 정리하면 아래 표와 같다. 통행시간가치의 산정방법은 두 가지로 구분되는데 자원가치에 따른 방법과 행동가치에 따른 방법이다. 자원가치에 따른 방법은 시간을 자원으로 생각하여 개인의 임금이나 요소비용 등 사회자원이 시간가치의 산정기준이 되며 교통행동과의 관계는 고려되지 않는다.

<그림 2> 통행시간 가치산정 방법

구분	내용	
	산정근거	산정기준
산정방법의 특징에 따른 구분	자원가치	
	행동가치	교통행동 접근방법
		관련행동 접근방법
자원의 종류에 따른 구분	RP조사(Revealed Preference Survey) 자료 SP조사(Stated Preference Survey) 자료	
자료의 집계에 따른 구분	집계자료(Aggregated Data) 분석 비집계자료(Disaggregated Data) 분석	

행동가치에 따른 방법은 실제 이루어 지는 교통행동으로부터 시간가치를 구하는 방법으로 교통수단과 경로, 자동차의 주행속도 등 교통선택 행동이 기준이 되는 경우와 주택가격, 토지가격 등 교통과 관련된 간접 행동이 기준이 되는 경우로 분류된다. 그렇지만 지금까지 일반적으로 적용되는 방법은 임금률법(wage rate method)과 한계대체율법(marginal rate of substitution method)이다. 임금률법은 자원가치 중에서 소득에 근거를 둔 것이며 한계대체율법은 행동가치 중에서 교통수단과 경로의 선택에 따른 방법이다.

임금률법은 시간당 임금의 일정비율을 시간가치로 계산하는 방법으로 과거 화물교통에 대한 조사가 부족하였을 때 주로 이용되었다. 임금률법은 통행자가 통행시간의 절감만큼 자신의 생산 활동 업무를 수행할 수 있다는 가정에 바탕을 둔다. 통행자의 단위업무시간당 한계임금을 통행시간가치로 산정하는 방법은 $VOT = W/T$ 로 계산된다. W 는 월평균 임금, T 는 월평균 근로시간을 나타낸다. 여객교통의 경우는 비업무통행의 시간가치를 별도로 산정하지만 화물교통의 경우는 화물이 운송되는 시간만을 화물통행 시간가치로 고려하고 있다.¹⁾

한계대체율법은 가장 많이 이용되는 방법으로 운송수단이나 운송경로의 선택과 관련한 행태모형으로 부터 통행시간가치를 산정한다. 교통수단선택모형에포함된 효용함수로부터 계산된 통행시간과 통행비용의 한계대체율을 통행시간의 가치로 산정한다. 통행의 효용함수를 $U(c,t)=\beta_0 + \beta_1 c + \beta_2 t$ 로 정의하면(α 는 상수, β_1 , β_2 는 효용함수의 계수), 한계대체율은 이 효용함수의 기울기로 각 변수에 대한 한계효용의 비율인 $MRS = -(dc/dt) = (\partial U/\partial t)/(\partial U/\partial c)$ 로 나타낸다.²⁾ 통행시간가치의 산정을 위해 사용되는 모형은 Logit(binominal, multinominal 등)모형, Probit모형 등 다양하며 추정이 비교적 용이한 Logit모형이 일반적으로 사용되고 있다.³⁾

- 1) Fowkes(2001)에 의하면 화물자동차의 통행시간가치에서 운송중인 화물의 재고가치는 고려되지 않으며, 운전자의 비근로시간을 배제하여야 인식비용과 시장비용이 동일하기 때문에 화물자동차의 통행시간가치는 화물자동차가 운행하는 상황만을 고려한다고 하였다. 화물교통의 이와 같은 특성은 여객교통에서 비근로시간의 시간가치를 별도로 산정하는 것과 구별되는 내용이다.
- 2) 1980년대 중반 이후에 RP자료와 SP자료 사이의 우월성을 평가하기 위한 연구가 소수 이루어졌다. Wardman(1987)은 RP자료와 SP자료에 대한 통행시간가치를 각각 추정하여 비교하였는데 두 자료에 따라 커다란 차이를 발견하지는 못하였다. 1990년대 이후부터 RP자료에 비하여 조사시간과 조사비용이 절감되고 통행자의 효용을 보다 세밀하게 측정할 수 있는 SP자료를 이용한 연구가 보다 선호되는 추세다.
- 3) 최창호, 유료도로의 경제성평가를 위한 화물교통 통행시간가치 산정 연구, 국토연구 제43권 pp109~125, 2004.

2. 신경망 알고리즘

가. 신경망을 이용한 시스템 모델링

신경망의 연구목적은 인간에 가까운 능력을 가진 정보처리 시스템을 실현하는 것으로서, 정보처리 시스템이 인간의 뇌와 같고, 다수의 처리 요소가 동시에 동작하는 병렬처리장치의 일종으로, 주어진 데이터로부터 스스로 학습하는 능력을 갖는 특징이 있다.

신경망은 여러 분야에 응용할 수 있지만, 크게 다음의 4분야로 나누어 볼 수 있다. 먼저, 패턴분류분야로서 주어진 많은 데이터 중에서 유사한 특성을 가진 것들끼리 묶는 것을 말한다. 즉, 많은 데이터 그룹에서 일단의 특성을 따라 클러스터를 분석하는 등의 패턴분석단계를 거친 후에 유사하거나 같은 것을 하나의 패턴으로 분류하게 된다. 두 번째 분야는 자기조직화로서 주어진 입력 데이터에 대하여 정확한 해답을 미리 주지 않고 스스로 학습할 수 있는 능력을 말하는데, 인간의 신경시스템과 유사하게 모델링하는 것이다. 세 번째는 다양한 종류의 문제들에 대해 모델을 구축하며 주어진 문제의 최적화 해를 구하는 분야로써, 문제에 대한 디자인 방면에 적용할 수 있다. 마지막으로 비선형 매핑분야로서 신경망을 사용하여 비선형 문제에 대한 매핑이 가능하다. 신경망에서의 매핑이란 신경망의 입력과 출력의 관계를 결정하는 것으로서 신경망의 구조를 확립함을 의미한다.

어떤 실험을 통해 시스템을 규명하기 위해서는 첫째, 센서를 통해 정보를 수집하고 둘째, 모델의 구조를 결정하고 셋째, 모델구조의 모수를 추정하며, 마지막으로 모델구조의 효율성을 평가하는 과정이 필요하다. 신경망을 이용하여 시스템을 규명하기 위해서는 신경망의 입력과 출

력의 수, 중간층의 수, 중간노드를 지나가는 함수, 그리고 함수의 변수들을 결정해야 한다. 아래 그림은 신경망의 입력과 출력의 관계를 일반적으로 나타낸 것으로 신경망을 이용하여 구조를 결정하고자 하는 것이다.

<그림 3> 일반 신경망 모형



신경망 모델링 성능은 많은 문헌에서 우수성을 보였으며, 특히, 최근에는 시간지연 입력형 신경망(Time Delay Neural Network)을 설계하여 모델링의 성능이 향상되었다. 특히 계층적인 신경망을 정규분포의 난수로 생성된 임의의 Noise들을 입력과 함께 사용하여 시스템 모델링의 정확도를 향상시킨 것은 주목할 만하다. 본 연구에서는 역전파 신경망(Back Propagation Neural Network : BPN)모형을 이용하여 이상치가 포함되어 있는 차량검지체계(Vehicle Detection System : VDS)로부터 수집된 자료의 데이터의 처리 및 통행시간 추정방법론을 제시한다. 자료에 포함되어 있는 이상치들을 제거한 VDS데이터를 신경망 모형의 입자료로 사용한다. 이때, 신경망의 마지막 단계에서 출력되는 결과값은 목적인 고속도로 영업소까지의 통행시간이 된다.

나. 인공신경망의 개요

신경망 이론은 단순퍼셉트론(single perceptron)을 기반으로 1960년대 초반에 출범한 이론으로, 인공신경망(artificial neural network)은 일

반적인 생물학적 신경망이 갖는 특성을 수행하는 일종의 정보처리시스템 (Information Processing System)이다. 이는 신경생물학 혹은 인간의 인지과정을 수학적 모형으로 일반화함으로써 개발되었으며, 다음과 같은 기본기능을 수행한다.

첫째, 정보의 처리는 뉴론(neuron)이라 하는 인자에서 수행되며, 각 뉴론은 여러 개로 구성될 수 있다.

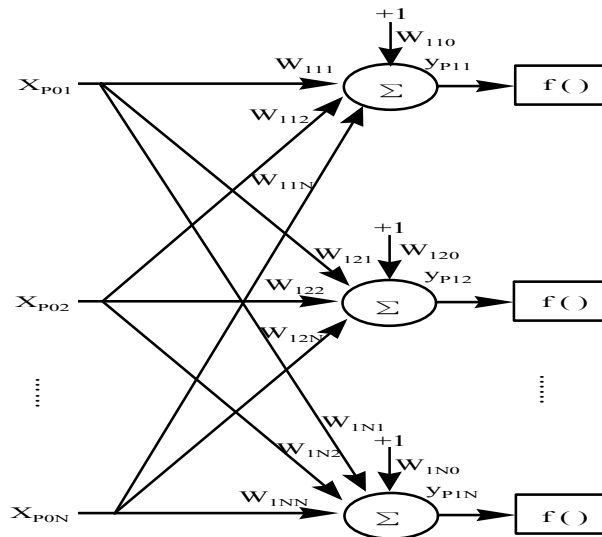
둘째, 신호는 뉴론들간의 연계된 연결자를 통하여 전이된다.

셋째, 신경망에서 각 뉴론을 연결하는 연결자는 가중치(weight)와 대응되며, 가중치와 전이된 신호를 곱하는 기능을 수행한다.

넷째, 각 뉴론은 각 뉴론에서 출력신호를 결정하기 위하여 뉴론에 응집된 정보(가중치와 전이된 신호 곱의 총합)를 보통 비선형의 특성을 갖는 활성화함수(Activation Function)에 적용한다.

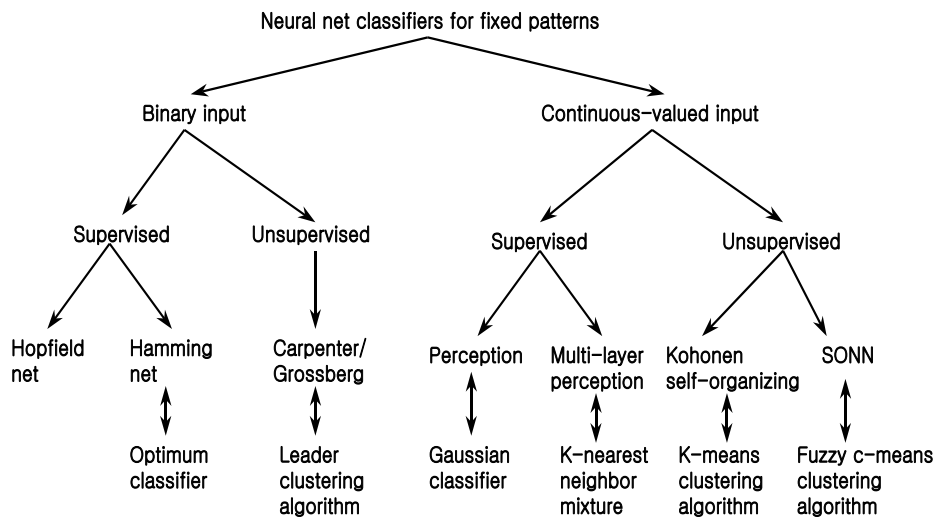
상기의 인공신경망의 기본기능은 다음 그림과 같이 대응된다.

<그림 4> 인공신경망의 기본구성



이러한 신경망모형들은 신경망을 구성하는 네트워크의 구성 (architecture)과 학습방법에 따라 구분하는 것이 일반적이다. 보통 신경망 모형의 구분은 학습방법에 따라 구분되며, 크게 교사학습방법 (Supervisor Learning Method)와 비교사학습(Unsupervisor Learning Method)로 구분된다. 신경망 모형의 학습방법에 의한 구분은 다음 그림과 같다.

<그림 5> 신경망 모형의 구분(Lipmann)



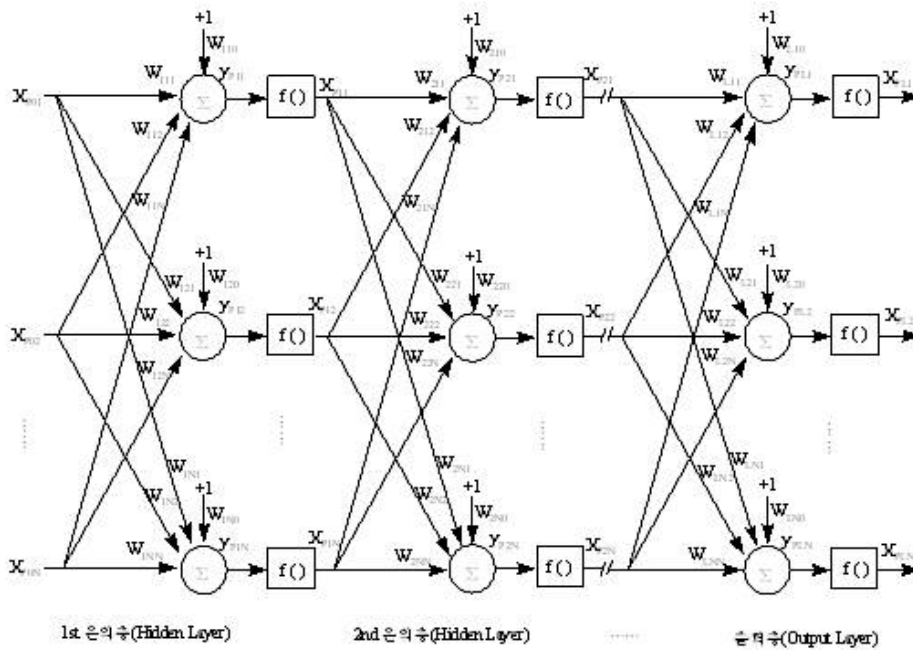
신경망 모형은 각 모형의 특성에 따라 다양한 학습방식을 갖으며, 일반적으로 신경망 모형을 구분하는 방법으로 신경망 모형의 학습 방법을 구분 기준으로 하는 경우도 있다. 이러한 학습방법에 의한 신경망 구분은 교사학습방법과 비교사학습방법으로 구분된다.

1) 교사학습모형

교사학습방법은 초기 단순퍼셉트론에 기초한 모형으로 다층퍼셉트론 (Multi-Perceptron)구조의 역전파 신경망모형(BackPropargation Neural Network Model : BPN)이 정립되어 최근 예측 및 제어부문에

이르기까지 다양하게 응용되고 있다. 이 BPN 모형은 기존의 단순퍼셉트론이 가지고 있는 단점인 선형분리문제를 근본적으로 해결할 수 있는 모형으로 아래 그림과 같이 입력층과 출력층 사이에 은닉층(Hidden Layer)을 최소한 하나 이상을 포함하는 구조를 가지고 있으며, 출력층에서 발생하는 오차(Error)를 출력층에서 부터 입력층에 이르기까지의 연결행렬들을 학습률(Learning Rate)의 비율로 매 반복과정(iteration)마다 조정함으로써 입력된 패턴을 학습하며, 모형의 특성상 학습효과가 우수하여, 우수한 인식효과를 기대할 수 있는 것이 특징이다.

<그림 6> 일반화된 역전파 신경망 모형의 구조



그러나 이러한 BPN 이 가지고 있는 단점은 다음과 같다.

첫째, 지역최소(local minimum)에 빠질수 있다. BPN에서는 보통 최급강하법(Steepest Descent method)의 학습방법을 사용하는데 이는 현 위치에서 기울기가 적은 방향으로 이동하므로 학습결과

오차가 0인 전역최소(Global Minimum)가 아닌 지역최소에 도달할 수 있다.

둘째, 학습알고리즘에서 시그모이드변환함수(Sigmoid Function)의 입력치가 포화상태에 도달시 학습효과가 없게 된다. 학습율이 0과 1 사이에서 결정되며, 매 반복과정에서 발생하는 오차는 매우 작은 값이 발생되어 학습에 의한 오차보정율이 소숫점이하의 매우 작은값이 되어 더 이상 오차보정이 안되는 경우가 발생되어 반복과정이 종료되면 그결과가 최적인지 결정하기 어렵다.

셋째, 최적 인식을 위한 은닉층의 수를 결정하기 어렵다. 최근까지 은닉층의 수를 시행착오에 의한 임의의 탐색적 방법을 통하여 결정하고 있다.

넷째, 각 은닉층에 구성되는 최적 뉴런(neuron)의 수를 결정하기 어렵다.

다섯째, 학습하는 데 있어서 다층구조에 의한 학습시간이 많이 소요된다.


여섯째, 다층구조에 의한 학습결과 현장적용에 있어서 실시간이 불가능한 경우가 발생될 수 있다. 매우 복잡한 망구조를 갖는 BPN의 경우 계산량이 많아 현장에서의 현장적용이 불가피한 경우가 발생될 수 있다. 최근 고성능 디지털신호처리(Digital Signal Process :DSP)의 개발활성화로 실시간성 구현이 가능해지고 있으나 부대비용의 증대로 아직까지 개선의 여지가 남아있다.

2) 비 교사 학습모형

비교사학습방법에 의한 신경망은 오랜기간동안 꾸준히 연구된 모형들

로서 Mcqueen 에 의하여 제안된 통계적 모형인 K-Means 알고리즘에 기초한 모형들이 주를 이루고 있다. 이러한 신경망모형은 크게 Kohonen Network과 Carpenter & Grossberg의 ART-I(Adaptive Resonance Theory- I), ART-II 모형이 있다. Kohonen Network은 자기조직화(Self Organization Feature Maps)모형과 학습벡터양자화(Learning Vector Quantization :LVQ)모형으로 구분된다. LVQ 망구조는 아래 그림과 같다. 특히 이 방법은 입력패턴과 클러스터의 중심값간의 거리(Euclidian Distance)를 최소화하는 알고리즘으로 K-Means 알고리즘과 대응된다는 점이 특징이며, 모형적용시 사전에 입력 그룹에 대한 클러스터의 수를 정의해야 한다는 점이 단점으로 될 수 있으나 망구조가 간단하여 학습결과 현장적용에 있어서 실시간이 용이하다는 것이 장점이 될 수 있다.

<그림 7> LVQ 모형의 망구조



ART- I 모형과 ART- II 모형은 1976년에 제안된 전형적인 비교사학습 모형으로 망구조적으로 입력층(Input Layer)과 클러스터층(Cluster Layer) 그리고 인터페이스층(Interface Layer)으로 구성되며, 알고리즘이 수행시 패턴이 입력이되면 기존의 클러스터들에 대하여 귀속여부를 평가하여 결정한다. 귀속여부결과 해당 클러스터가 존재하지 않으면 새로운 클러스터를 생성하여 귀속시키며, 귀속될 수 있는 클러스터가 있는

경우에는 해당 클러스터에 귀속시켜 학습을 진행하도록 되어 있다. ART-I 모형과 ART-II 모형의 차이점은 ART-I 모형은 2진화된 자료(binary data)만을 처리하는 반면에 ART-II 모형은 임의의 정량화된 연속값(continuous data)을 수행할 수 있다는 점이 다르다. Kohonen Network 과 ART 모형들의 차이는 Kohonen 모형이 클러스터의 수를 사전에 설정하여야 하는 반면에 ART 모형들은 Cluster 의 수를 학습수행중 자율적으로 결정한다는 점이 다르다.

Pal.et.al.(1993)의 GLVQ (Generalized Learning Vector Quantization)알고리즘은 Kohonen의 LVQ알고리즘에서 초기 연결강도(initial weight)에 따라 클러스터의 중심값이 크게 영향을 받아 오분류(misclassification)되는 패턴이 발생하는 경우가 많다는 단점을 개선시킨 방법으로 모든 출력 노드에 대하여 학습을 함으로써 학습률, 반복횟수, 초기 연결강도의 값에 크게 영향을 받지 않고 일정한 클러스터의 중심값이 계산되기 때문에 각 클러스터별로 오분류 되는 패턴이 적게 나타난다는 장점이 있다. 실제 클러스터링 데이터로 많이 쓰이는 Fisher의 IRIS데이터를 가지고 실험을 하였을 경우 GLVQ알고리즘이 패턴 분류에 있어서 가장 정확도가 높은 것으로 나타났다.

다. 방사형 기저함수 신경망 모형

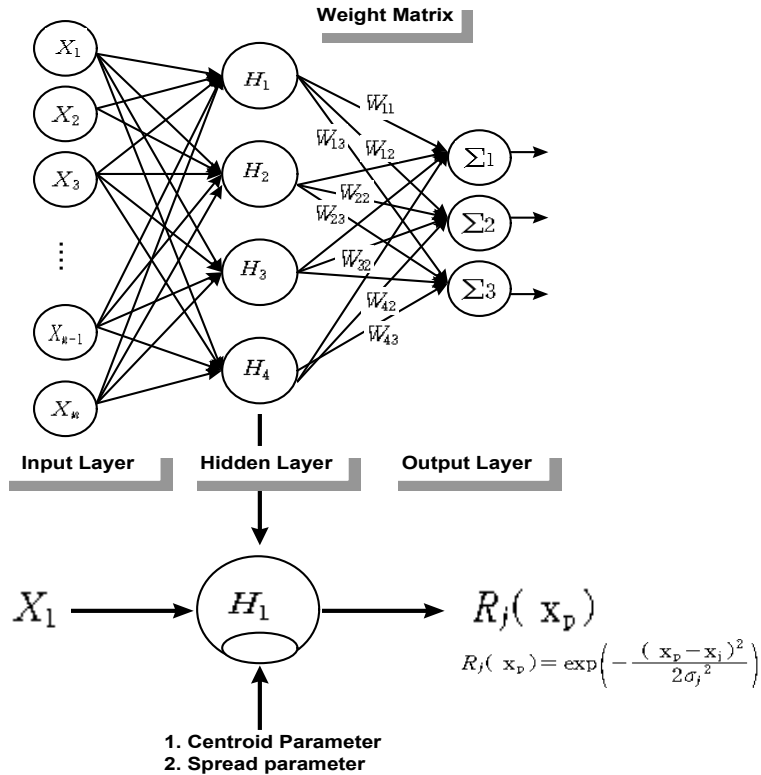
1) RBFNN의 개요

방사형기저함수 신경망은 가우스함수 형태의 방사형기저함수들에 대한 유한개의 선형결합 형태로 표현된 신경망이다. 또한 함수근사이론으로부터 유래되었으며, 여러가지 학습방법들을 제시되어 있으나 크게 방사형기저함수를 생성하는 은닉층의 구성방법과 이들의 가중합을 위한 가중

치를 학습하는 방법으로 나누어진다. 은닉층 생성은 주로 자기구성 방법을 사용하는데 K-means, SOM등을 사용한다. 이들은 입력공간을 패턴간 거리의 척도로 클러스터링한다는 점에서 같지만 알고리즘이 조금씩 다르다. 이러한 클러스터링 알고리즘은 주로 패턴인식 문제에 응용되었으나 함수근사 문제도 입력의 패턴을 인식하여 그에 대응하는 함수값을 생성한다는 점에서 동일한 문제로 간주된다.

방사형기저함수 신경망은 입력패턴의 수가 한정된 경우 역전파방법에 비하여 학습속도가 빠르다는 장점을 가지고 있으나 입력패턴의 수가 증가함에 따라 요구되어지는 은닉층의 노드수가 기하학적으로 증가하므로 독립변수(입력패턴)의 수가 많은 경우에는 부적합한 단점을 가지고 있다. 방사형기저함수 신경망의 은닉층노드는 각 입력에 대하여 한개의 파라미터를 가지며 이 파라미터들은 입력에 대한 연결강도라기보다, 은닉층노드 출력함수의 중심인 입력공간내에서의 좌표이다. 출력함수는 중심에서 높이가 1인 종모양의 곡선이며 분포의 폭은 추가적인 파라미터에 의하여 조절된다. RBFNN은 다음과 같은 신경망 구조를 갖는다.

<그림 8> RBFNN의 신경망구조



2) RBFNN의 학습방법

RBFNN은 출력층 노드가 원하는 함수값을 출력하도록 연결강도를 학습하기 위하여 지도학습 알고리즘에 의하여 수행되며, 이의 학습방법에는 LMS알고리즘, RLS등이 사용된다.

가) LMS에 의한 학습방법

LMS는 신경망으로 부터 생성된 출력과 기대한 목표치간의 차이를 최소화하도록 수정해가는 방법이다. 이 경우 특정 학습벡터에 대하여 나타나는 오차는 $E = (t_p^i - f_i(x_p))^2$ 로 표현되며, 주어진 입력벡터 전체에

대해서는 다음의 식과 같이 일반화된 식으로 표현된다.

$$E_p = \frac{1}{2} \sum_i (t_i^p - f_i(x_p))^2$$

여기서, $f_i(x_p) = \sum_j w_{ij} \cdot R_j(x_p)$,

$$R_j(x_p) = \exp\left(-\frac{(x_p - x_j)^2}{2\sigma_j^2}\right) \text{ 이다.}$$

RBFNN은 상기의 식을 토대로 네트워크에서의 연결강도, 각 은닉에서의 centroid local parameter 그리고 Spread parameter를 학습할 수 있는 관계식을 간단하게 도출할 수 있다.

w_{ij}에 대한 학습관계식

$$\begin{aligned} \Delta w_{ij} &= \frac{\partial E_p}{\partial w_{ij}} = n_1 (t_i^p - f_i(x_p)) \cdot \frac{\partial f_i(x_p)}{\partial w_{ij}} \\ &= n_1 (t_i^p - f_i(x_p)) \cdot R_j(x_p) \end{aligned}$$

$$\therefore \Delta w_{ij} = n_1 (t_i^p - f_i(x_p)) \cdot R_j(x_p)$$

x_j에 대한 학습관계식

$$\begin{aligned} \Delta x_j &= \frac{\partial E_p}{\partial x_j} = n_2 \cdot \frac{\partial R_j(x_p)}{\partial x_j} \cdot \left\{ \sum_i (t_i^p - f_i(x_p)) \cdot w_{ij} \right\} \\ &= n_2 \cdot R_j(x_p) \cdot \frac{(x_p - x_j)}{\sigma_j^2} \cdot \left\{ \sum_i (t_i^p - f_i(x_p)) \cdot w_{ij} \right\} \end{aligned}$$

$$\therefore \Delta x_j = n_2 R_j(x_p) \frac{(x_p - x_j)}{\sigma_j^2} \left\{ \sum_i (t_i^p - f_i(x_p)) \cdot w_{ij} \right\}$$

σ_j에 대한 학습관계식

$$\begin{aligned} \Delta \sigma_j &= \frac{\partial E_p}{\partial \sigma_j} = n_3 \cdot \frac{\partial R_j(x_p)}{\partial \sigma_j} \cdot \left\{ \sum_i (t_i^p - f_i(x_p)) \cdot w_{ij} \right\} \\ &= n_3 \cdot R_j(x_p) \cdot \frac{\|x_p - x_j\|^2}{\sigma_j^3} \cdot \left\{ \sum_i (t_i^p - f_i(x_p)) \cdot w_{ij} \right\} \end{aligned}$$

$$\therefore \Delta\sigma_j = n_3 \cdot R_j(x_p) \cdot \frac{\|x_p - x_j\|^2}{\sigma_j^3} \cdot \left\{ \sum_i (t_i^p - f_i(x_p)) \cdot w_{ij} \right\}$$

나) RMS에 의한 학습방법

대부분의 경우에 있어 공정관측치들은 시간의 흐름에 따라 연속적으로 수집되며, 새롭게 수집된 관측치들에 대한 신경망의 연결강도를 LS 방법에 의하여 수정하는 경우 각 입력 예제패턴들에 대하여 새로운 수정치를 계산하여야 하므로 계산시간의 증가를 가져온다. 이에 따라 t시점에서의 연결강도 수정치를 t+1시점에서의 연결강도 수정에 이용할 수 있는 효율적 방법이 RLS이다. 그러나 LMS에 비하여 수행속도가 빠르지만 발산(diverse)할 위험이 있다. RLS에 의한 학습과정은 아래 식과 같다.

$$\hat{y}_{t+1} = \sum_{j=1}^m w_j(t) Z_j = \phi^T(t) W(t)$$

$$W(t+1) = W(t) + G(t) [y_{t+1} - \phi^T(t+1) W(t)]$$

$$G(t) = P(t) \phi(t+1) [1 + \phi^T(t+1) P(t) \phi(t+1)]^{-1}$$

$$P(t+1) = [X_t - G(t) \phi^T(t+1)] P(t)$$

$$\phi(t) = (Z_1, Z_2, \dots, Z_m)$$

단, \hat{y}_{t+1} : t+1 시점에서의 신경망의 실제출력

$$W(t) = (w_1(t), w_2(t), \dots, w_m(t))$$

: 시점 t에서의 신경망 연결강도 벡터

$$X_t = (x_t, x_{t-1}, \dots, x_{t-N+1})$$

: 시점 t에서의 입력벡터

위의 식들에 의하여 신경망의 연결강도벡터 $W(t)$ 가 RLS에 의하여 각 단계별로 수정되며, 초기의 $P(t_0)$ 는 $[\Phi^T(t_0)\Phi(t_0)]^{-1}$ 에 의하여 결정된다. 또한 $P(t)$ 는 순환적으로 수정해 나간다.

다) 칼만필터링에 의한 학습방법

칼만 필터링(Kalman Filtering)은 우선 상태모형으로 변환하여야 하며, 상태방정식과 관측방정식에서 각각 오차항의 분산을 설정하여야 하는 것이 단점이다. 칼만 필터링의 일반적인 모형은 아래 식의 상태방정식과 추계적모형의 측정방정식에 의하여 표현된다.

$$x_{k+1} = \Phi x_k + \Gamma U_k + v_k$$

$$y_k = C x_k + D U_k + e_k$$

단, x_k : 시점 k에서의 상태변수

U_k : 시점 k에서의 제어입력변수

y_k : 시점 k에서의 측정변수

v_k : $N(0, \sigma_v^2)$ 을 따르는 상태잡음

e_k : $N(0, \sigma_e^2)$ 을 따르는 관측잡음

Φ, Γ, C, D : 사전에 주어지는 물리적 계수

$$E\{v_k\} = 0, \quad E\{e_k\} = 0$$

또한 R_0, R_1, R_2 를 각각 식(2.16)~식(2.18)와 같이 정의한다.

$$E\{vv^T\} = R_1$$

$$E\{ee^T\} = R_2$$

$$P(0) = E\{x_0 x_0^T\} = R_0$$

관측 데이터들의 입·출력 관계 및 식에 근거한 x_k 의 최적추정치는 아래 식을 최소화함으로써 계산된다.

$$J(\hat{x}_k) = E\{(\hat{x}_{k+1|k} - x_{k+1})^2\}$$

단, $k = 1, 2, 3, \dots$

현재의 시점 k 에서의 관측 데이터에 근거한 x 의 예측치를 위한 칼만 필터는 아래 식과 같은 순환적인 방법에 의하여 계산된다.

$$\hat{x}_{k+1|k} = \Phi \hat{x}_{k|k-1} + \Gamma U_k + K_k(y_k - C \hat{x}_{k|k-1})$$

$$K_k = \Phi P_k C^T (R_2 + C P_k C^T)^{-1}$$

$$P_{k+1} = \Phi P_k \Phi^T + R_1 - \Phi P_k C^T (R_2 + C P_k C^T)^{-1} C P_k \Phi^T$$

칼만 필터는 잡음요소인 v_k 와 e_k 가 서로 독립인 정규분포를 따르는 경우 위의 식을 최소화한다.

라) RBFNN의 알고리즘

RBFNN알고리즘은 변수초기화 부문과 활성화함수 계산부문 그리고 각종 모수조정부문으로 구분되며, 이외 학습완료 후, 검증할 패턴의 실험부문이 있다. 일반적으로 검증 패턴의 실험은 학습시 수행되는 알고리즘과 같으나 본 연구에서는 이를 구분하여 제시한다. 변수초기화 부문은 출력층에서의 초기가중치를 초기화하고, 알고리즘의 정지규칙(stopping rule)을 위한 정보로서 최대 반복회수 및 오차허용한계를 설정한다. 모수의 조정은 매 반복과정마다 출력층의 가중치(weight)와 크러스터 중심값(centroid) 그리고 넓이보수(spread parameter)에 대하여 준식에 의하여 수정한다. 이러한 RBFNN에 대한 주요 알고리즘은 다음과 같다.

<표 1> RBFNN의 학습알고리즘

Weight Initialization

Weights in the output layer are initialized to small random value.

Calculation of Activation

1. The activation level $R_j(X_p)$ of hidden node is calculated by

$$R_j(x_p) = \exp\left(-\frac{(x_p - x_j)^2}{2\sigma_j^2}\right)$$

2. The activation level $f_i(X_p)$ of an output node is determined by

$$f_i(x_p) = \sum_j w_{ij} \cdot R_j(x_p)$$

Weight Learning

1. Adjust a parameters by

$$\Delta w_{ij} = \eta_1 (t_i^p - f_i(x_p)) \cdot R_j(x_p)$$

$$\Delta x_j = \eta_2 R_j(x_p) \frac{(x_p - x_j)}{\sigma_j^2} \left\{ \sum_i (t_i^p - f_i(x_p)) \cdot w_{ij} \right\}$$

$$\Delta \sigma_j = \eta_3 \cdot R_j(x_p) \cdot \frac{\|x_p - x_j\|^2}{\sigma_j^3} \cdot \left\{ \sum_i (t_i^p - f_i(x_p)) \cdot w_{ij} \right\}$$

2. The parameter change is computed by η_1, η_2, η_3

where, η_1 : weight learning rate

η_2 : centroid learning rate

η_3 : spread learning rate

and $0 < \eta_1, \eta_2, \eta_3 < 1$

3. Repeat iterations until max. iteration or error tolerance converge

Test Pattern Mapping

1. Loading a learned weight

2. The activation level $R_j(X_p)$ of hidden node is calculated by

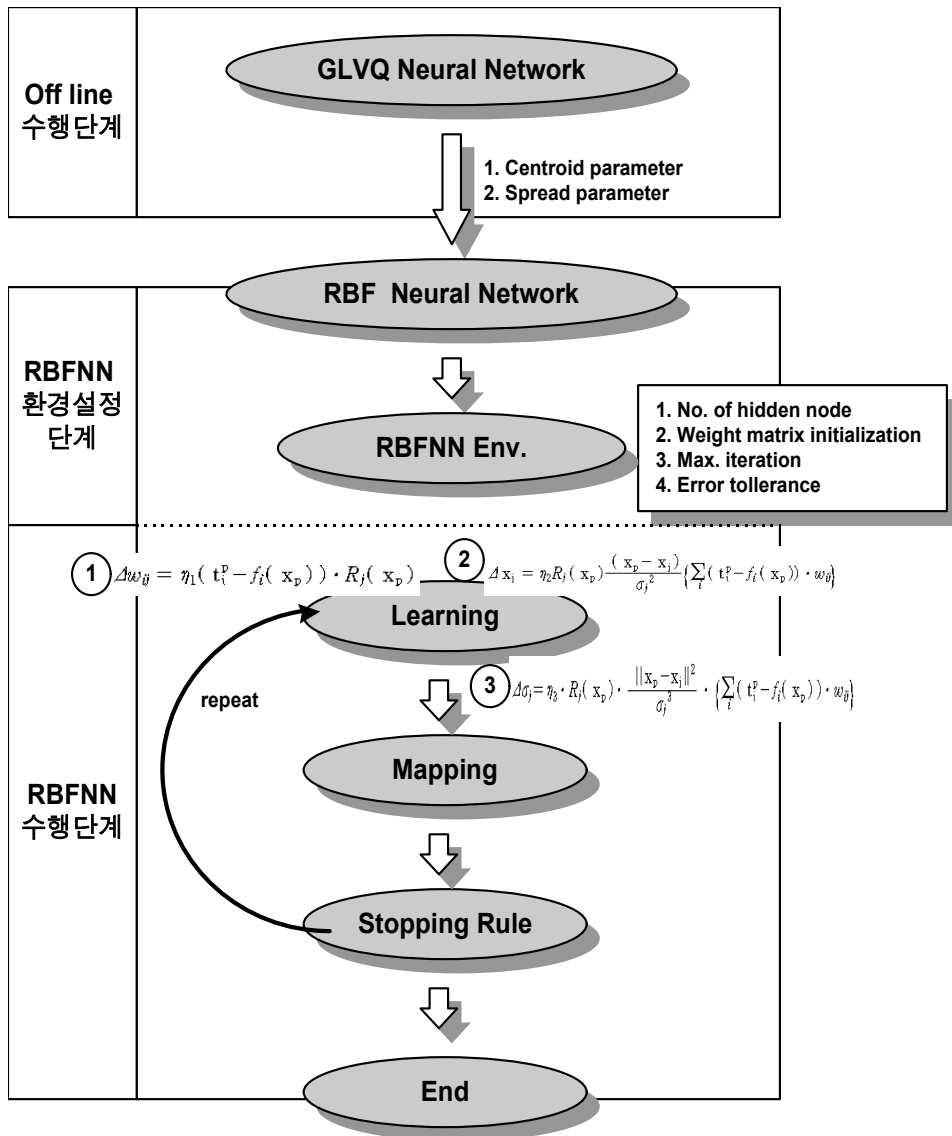
$$R_j(x_p) = \exp\left(-\frac{(x_p - x_j)^2}{2\sigma_j^2}\right)$$

3. The activation level $f_i(X_p)$ of an output node is determined by

$$f_i(x_p) = \sum_j w_{ij} \cdot R_j(x_p)$$

4. Repeat iterations until test pattern is nothing.

<그림 9> RBFNN의 학습수행단계

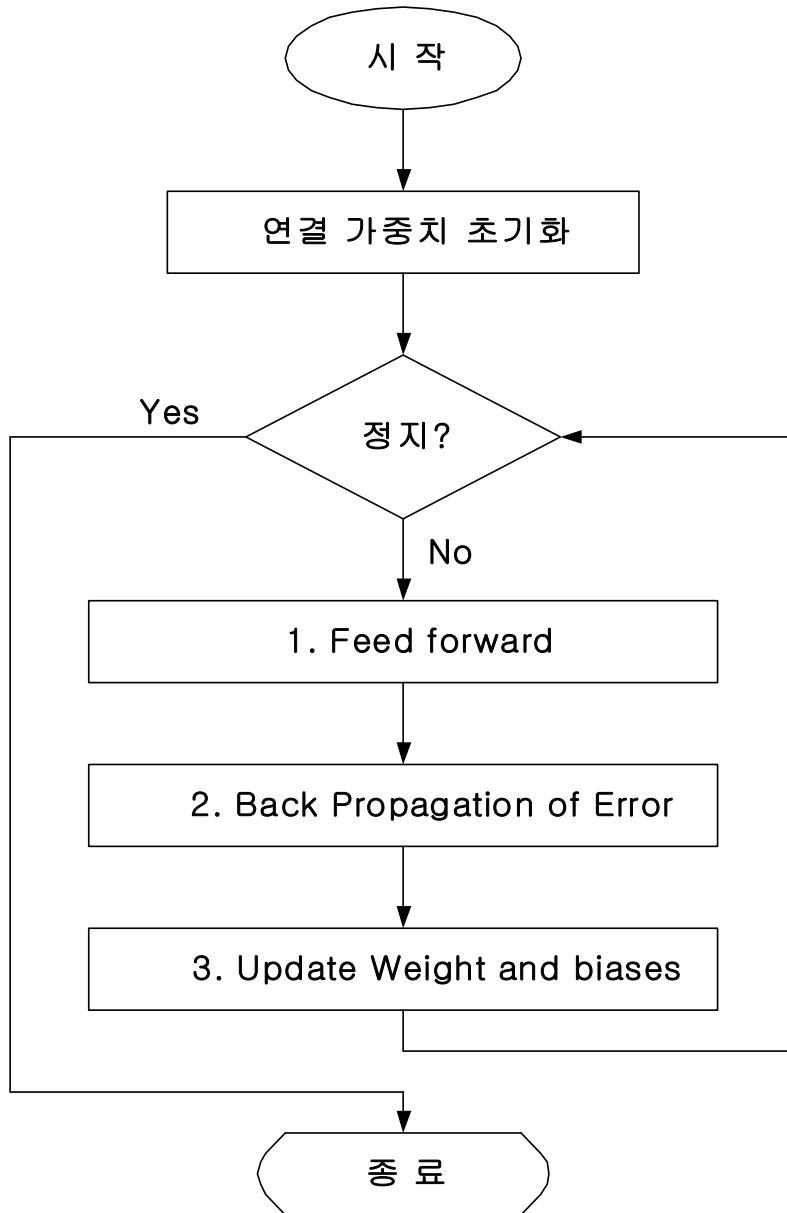


라. BPN 신경망 모형

BPN의 학습알고리즘의 기본원리는 다음과 같다. 입력층의 각 유니트에 입력데이터를 제시하면, 이 신호는 각 유니트에서 변환되어 중간층에 전달되고 최종적으로 출력층에서 신호를 출력하게 된다. 이 출력값과 원하는 출력값을 비교하여 그 차이를 줄여나가는 방향으로 연결강도(Weight)를 조절하고, 상위층에서 역전파하여 하위층에서는 이를 근거로 다시 자기층의 연결강도를 조정해 나간다. 신경망의 입력층에 주어진 입력패턴이 출력층에 전파되면서 변환 출력 패턴을 목표패턴과 비교한다. 신경망에서 출력된 패턴이 목표패턴과 일치하는 경우에는 학습이 일어나지 않는다. 그렇지 않은 경우는 얻어진 출력패턴과 목표패턴의 차이를 감소시키는 방향으로 신경망의 연결강도를 조절하여 학습을 한다. 네트워크의 초기 가중치의 선택은 네트워크가 빠르게 수렴하는데 중요한 영향을 미친다. 활성화 함수나 활성화 함수의 미분이 영으로 되는 초기 가중치의 선택은 피하는 것이 중요하다. 따라서, 초기 가중치의 값은 너무 크지 않는 것이 좋다. 그리고, 초기 가중치의 값이 너무 작으면 은닉층의 유니트에서 네트워크의 입력값은 영에 가까워지기 때문에 학습이 속도가 느려지는 경향이 있다. 일반적으로 초기 가중치의 결정은 $-0.5 \sim 0.5$ 사이의 난수값을 보통 사용한다.

본 연구에서는 초기 연결 가중치로서 0과 1사이의 값을 사용하였다. 이상과 같은 BP신경망의 학습알고리즘의 흐름도는 다음 그림과 같다.

<그림 10> BP신경망 알고리즘 흐름도



위의 그림에서의 각 단계에 대해 상세히 설명하면 다음과 같다.

Feed Forward

- (1) 입력 노드($X_i, i=1, 2, \dots, n$)은 입력신호를 받아 상위층에 전달
 (2) 중간층 노드의 계산($Z_j, j=1, 2, \dots, p$)

$$Z_{in_j} = V_{oj} + \sum_{i=1}^n X_i V_{ij}, \quad Z_j = f(Z_{in_j})$$

- (3) 출력층 노드의 계산

$$Y_{in_k} = W_k + \sum_{j=1}^p Z_j W_{jk}, \quad Y_k = f(Y_{in_k})$$

Back Propagation of Error

- (1) 출력층 노드의 오차 계산

$$\delta_k = (t_k - Y_k) f'(Y_{in_k}),$$

중간층과 출력층 사이의 연결강도 수정

$$\Delta W_{ik} = \alpha \delta_k Z_i, \quad \Delta W_{ok} = \alpha \delta_k$$

- (2) 중간층 노드의 오차계산

$$\delta_{in_j} = \sum_{k=1}^m \delta_k W_{jk}, \quad \delta_j = \delta_{in_j} f'(Z_{in_j})$$

입력층과 중간층 사이의 연결강도 수정

$$\Delta V_{ij} = \alpha \delta_j Z_i, \quad \Delta V_{oj} = \alpha \delta_j$$

Update Weight and biases

중간층과 출력층 사이의 연결 강도 수정

$$W_{jk}(\text{new}) = W_{jk}(\text{old}) + \Delta W_{jk},$$

$$V_{ij}(\text{new}) = V_{ij}(\text{old}) + \Delta V_{ij}$$

3. 칼만필터 알고리즘

가. 개요

칼만필터 알고리즘은 확률변수를 시간영역 기준으로 상태공간으로의 모형화를 통하여 추정하는 최적순환필터링방법이다. 칼만은 1960년 발표한 논문에서 시계열 그 자체를 실시간에서 파악된 신호 $X(t)$ 로 정의하였다. 이는 화이트 노이즈(White Noise)에 의하여 구동된 선형동적시스템(LDS; Linear Dynamic System)의 출력으로 하여 신호의 상관성은 동적 구조에 유래하는 것으로 간주하고, 그 동적 구조하에서 최적필터를 구했다. 이와 같이 선형필터를 구성하는 칼만필터링은 선형시스템의 실현이론으로 정립되어 확률통계이론과 무관하게 최종적으로 선형시스템의 틀안에서 해석되었다. 칼만필터에 의한 예측방법은 시간에 따라 입력되는 관측값과 이전시간을 기준으로 예측된 예측값을 비교하여 평균제곱오차의 최소화 조건을 만족하게 필터를 동적으로 적응시키는 방법이다. 따라서 칼만필터모형은 추계적 모형으로써 조건부 추정오차를 최소화하는 동적 예측모형이며, 모델링은 초기 조건에 대한 정보, 시스템의 동적 상태에 대한 모형화가 요구된다. 필터링은 신호의 초기 추정값, 오차 공분산(Error Covariance)과 새로운 측정값을 이용하여 이전 상태의 추정값을 새로운 추정값으로 교체한다. 이러한 순환과정은 시스템의 관측 가능한 상태에서 초기 추정값을 더 이상 향상이 불가능한 안정상태에 도달할 때까지 새로운 측정 데이터를 이용하여 개선된다.

칼만필터는 시스템의 현재상태에 관한 추정값들을 예측하거나 과거의 데이터들을 수정하는데 쓰이고 있다. 칼만필터를 이용한 예측모형에는 베이지안 예측 관점에서의 칼만필터 유도, 시간축에 따라 변이하는 파라미터를 갖는 단기예측모형에 칼만필터를 적용한 연구, 회귀모형과

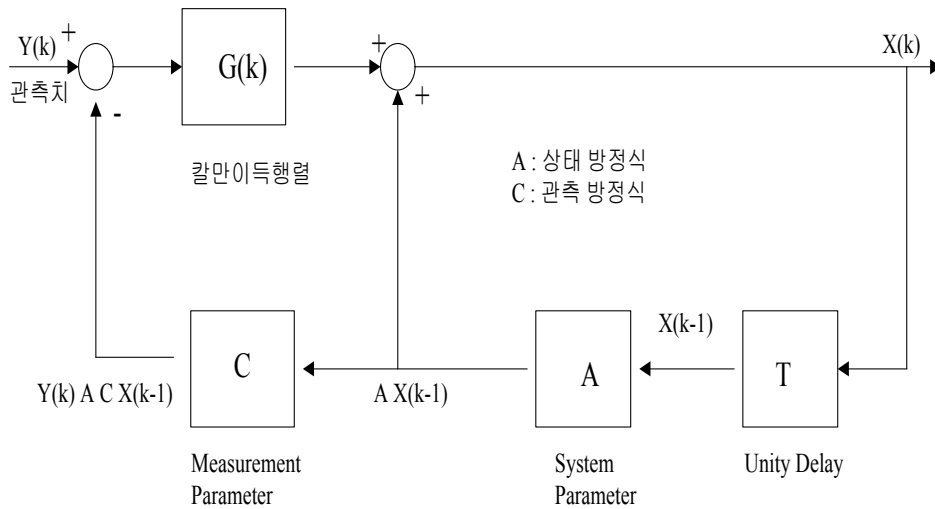
ARIMA모형에서의 모수들을 추정하기 위한 필터링 적용, 혼합모형을 위한 순환추정방정식을 유도하기 위한 연구 등이 있다.

나. 칼만필터 모형

1) 모형의 기본구조

일반적으로 칼만필터의 이득행렬형태는 보통 두 가지 유형 즉, 벡터와 스칼라로 산출하여 적용하고 있으며, 이에 대한 적용 개념도는 다음과 같다.

<그림 11> 칼만 필터링의 Block Diagram



위의 개념도에서 보면, 칼만필터 “ $G(k)$ ”는 평균오차제곱(MSE; Mean Square Error)과 상태방정식에 의한 화이트노이즈 $W(t)$ 및 관측방정식의 오차항 $V(t)$ 의 조합으로 이루어진 칼만필터의 이득행렬(Gain Matrix)이다. 따라서 최초 반복이 수행되기 위해서는 실측 초기값 「 $Y(0)$ 」 값과

각 오차항의 값이 필요한데, 이들의 값은 초기 값에 한하여 임의적으로 입력이 가능하며, 이에 대한 보정은 다음번 반복을 통하여 즉각적으로 보정된다. 일반적으로 칼만 모형으로 예측시 안정상태에 도달하기 위해서는 예측에 의한 관측치의 피드백이 최소한 5회에서 8회 수준까지 반복되어야 한다. 칼만 모형의 예측알고리즘에 대한 기본 관계식은 다음과 같다.

관측 방정식

관측방정식은 상태방정식과 직접적으로 연계되어 있으며, 보통 상태방정식을 구성하는 입력정보들의 관측치에 대한 관계식으로 구성된다.

$$Y_t = F_t X(t) + V_t$$

여기서, Y_t : 실제 관측자료(t 시점 기준)

$X(t)$: t 시점의 예측 상태자료

F_t : t 시점의 전이 (벡터 또는 스칼라)

V_t : t 시점에서의 관측 오차

: Random noise vector or scalar

$$(V_t \sim N(0, V_t))$$

상태 방정식

상태 방정식은 최종적인 예측 혹은 추정을 위한 메카니즘을 구성하는 관계식으로 관측방정식과 직접적으로 연계되어 있다. 이러한 시스템 방정식은 제어입력(control unit)에 대한 정보 및 상수값의 조합으로 구성될 수도 있다.

$$X_t = G_t X_{t-1} + W_t$$

여기서, X_t : t 시점에서의 예측 상태 자료

X_{t-1} : $t-1$ 시점에서의 예측 상태 자료

G_t : t 시점의 transit (vector or scalar)
 W_t : t 시점에서의 시스템 방정식의 오차
 : Random noise vector or scalar
 $(W_t \sim N(0, W_t))$

이들의 두 방정식을 근거로 다음의 예측 알고리즘을 구할 수 있다.

$$X(t) = F(t-1) X(t-1) + K(t) [Y(t) - F(t-1) X(t-1)]$$

여기서, $X(t)$: t 시점에서 t+1 시점의 예측 자료

$X(t-1)$: t-1 시점에서 t 시점의 예측자료

$Y(t)$: t 시점에서의 실측자료

$K(t)$: t 시점에서의 칼만이득벡터/스칼라

: posterior error covariance(POEC)

: prior error covariance (PREC)의 조합.

(*) posterior error covariance는 관측자료(Y_t)가 조건부 일때의 예측자료(X_t)의 오차를 의미하며, prior error covariance는 관측자료(Y_{t-1})가 조건부 일때의 예측자료(X_t)의 오차를 의미한다. 이상과 같은 칼만필터모형을 구축하기 위해서는 다음과 같은 초기 자료가 설정되어야 한다.

(가) positive definite posterior error covariance $G(t)$

(나) $X(t)$ 의 불편추정치

(다) 실측방정식의 공분산 $Q(t)$

(라) 상태 방정식의 공분산 $R(t)$

① Q(t)의 산출 근거 : $E[W(t) \cdot W(u)] = Q(t) \cdot \delta_{tu}$

② R(t)의 산출 근거 : $E[V(t) \cdot V(u)] = R(t) \cdot \delta_{tu}$

δ_{tu} = Kronecker delta

㉞ Calculate prior error covariance

$$P(t) = G(t-1) S(t-1) G(t-1)^T + Q(t-1)$$

㉟ Calculate Kalman gain vector

$$K(t) = P(t) F(t)^T [F(t) P(t) F(t)^T + R(t)]^{-1}$$

㊱ Update estimate of state

$$\bar{X}(t) = [G(t-1) \bar{X}(t-1)] + K(t) [Y(t) - F(t) G(t-1) \bar{X}(t-1)]$$


㊲ Update posterior error covariance

$$S(t) = P(t) - K(t) F(t) P(t)$$

다. 예측모델의 메카니즘

칼만필터모형은 이론적 특성상 베이지안 추정방법에 기초한 관계로 적용모형의 메카니즘 역시 베이지안 방법과 같이 Prior Estimation과 Posterior Estimation으로서 단계적으로 구분된다. 이러한 특성은 칼만필터모형 중에 가장 핵심적인 요소라 할 수 있는 칼만 이득메트릭스를 산출하는데 있어서 예측오차를 추정하는 과정과 대응된다. 칼만필터모형에서의 이득메트릭스는 오차공분산에 의하여 산출되는데, 이러한 오차공분산은 Prior Estimation과 Posterior Estimation, 이들 각각에 대하여 수행되어야 한다. 여기서 Posterior Error Covariance를 산출하는 과정을 “Time Update”과정이라 하며, Prior Error Covariance를 산출하는 과정을 “Measurement Update”과정이라 한다. 따라서 구축된 칼만필터모형에 대하여 초기치에 의하여 수행되는 반복1은 1차적으로 “Time Update”의 과정을 거쳐 2차적으로 “Measurement Update”를 완료함으로써 종료된다. 그러나 중요한 사항은 반복1이 종료하는 시점에서의 결과가 예측치가 아니라는 점이다. 반복1에서 결정되는 값은 단지 추정치일 뿐이다. 따라서 예측치를 산출하기 위해서는 반복1이 종료된 후, 이들 결과를 다시 “Time Update”시켜야만 예측치를 얻을 수 있다. 이러한 예측치는 Prediction Lead-Interval이 1단계로 만일 2단계 이후의 상황을 예측하기 위해서는 시스템 방정식을 구성하는 상태전이행렬(State Transition Matrix)를 누승하여 적용해야 한다. 이상의 칼만필터모형에 있어서 “Time Update”와 “Measurement Update”의 상호 연계성에 대한 개념도는 다음 그림과 같다.

<그림 12> Time Update와 Measurement Update의 상호 연계



제2절 선행 연구 고찰

신경망이론이 교통분야에서 적용된 시기는 1989년부터 연구사례가 발표된바 있으며, 이때의 적용연구는 차량번호판 인식이였다. 교통분야에서 주로 적용된 분야는 운전자 행태분석에 주로 적용되었으며, 그 외 모수추정 및 항공 및 교통제어 등 짧은 시기에 다양한 분야에 적용된 바 있다. 통행시간 예측방법으로는 과거 통행시간 이력자료 접근법, 시계열 모형, 신경망 모형, 비모수 회귀분석, 동적 통행배정 모형, Traffic Simulation 모형 등이 있다. 이러한 방법론을 통한 통행시간 예측은 단기예측과 장기예측, 지점기반과 구간기반으로 구분할 수 있으며, 예측기간에 따라 사용되는 방법도 달라진다. 단기예측은 현 교통류 상황과 크게 관련되므로 실시간 데이터를 이용하는 기법이 적합하다.⁴⁾

<표 2> 통행시간 예측방법의 특징 비교

예측방법	특징
과거통행시간 이력자료 접근법	과거 통행시간의 대표값과 교통류의 주기적 특징을 고려
시계열 모형	시간 순서대로 배열된 통계관측치의 집합으로 통행시간 예측
신경망 모형	교통류 패턴에서 현재 통행시간 추정방법을 신경망의 학습능력을 통해 도출
비모수 회귀분석	현재상황과 유사한 과거사례집단을 파악하는 패턴인식기법
동적 통행배정 모형	시간에 따라 달라지는 교통수요 변화를 모형이 규정하는 시간범위에서 수학적의 연산을 통해 도출
Traffic Simulation 모형	이산시간 모형을 기초로 하여 시간을 알려진 일련의 시간단위로 분절화한 시뮬레이션으로 도출

4) 김동호, 노정현, 박동주, 박지형, 김한수, 고속도로 통행시간 예측을 위한 과거 통행시간 이력자료 구축에 관한 연구 :지점 검지기를 중심으로, 대한교통학회지 제26권 제5호 pp.131-141, 2008

선행연구검토는 예측방법으로 신경망 이론과 칼만필터기법을 이용하기로 결정하고 지점기반의 통행시간 연구와 구간기반의 통행시간연구로 나누어 검토하였다. 우선 지점기반 통행시간 선행연구는 다음과 같다.

Bruce 및 Chi Xie(2000)⁵⁾는 검지기 자료, Probe 차량 및 운전자 제보 등에 의한 통행시간을 data fusion 기법을 통해 합성하여 단일링크의 통행시간을 추정하였다.

Cristian(2001)은 링크 내에 설치된 VDS 지점 간의 통행시간을 합산하여 링크의 통행시간을 추정한 결과, Probe 차량에 의한 통행시간과 비교할 때 거의 비슷한 정확성을 나타냄을 보였다.

Hiroshi(2004)는 실시간으로 얻어지는 VDS의 교통량을 과거 이력자료와 비교하여 가장 비슷한 패턴을 갖는 날의 VDS 자료를 이용하여 통행시간을 예측하였다.

Oliver(2006)⁶⁾는 TCS 데이터와 VDS 데이터를 이용하여 통행시간을 추정하였다. Newell이 제시한 링크의 상·하류 검지기의 누적교통량곡선을 이용하여 통행시간을 추정하였고, TCS에 의한 통행시간으로 보정하였다. 구간 내 속도는 상류부와 하류부에서 선형적으로 변한다는 가정하에 Taylor's series를 이용하여 링크 내 통행속도를 산출하여 통행시간으로 변환하였다.

또한, 구간기반 통행시간 선행연구는 다음과 같다.

Yoshikazu(1999)⁷⁾는 고속도로의 TCS 데이터의 이상치를 제거하는 방법론과 회박구간에서의 결측치 보정방법론에 대하여 연구하였다.

5) Chi, X. and Reuy, L., Improving Arterial Link Travel Time Estimation by Data Fusion, 83rd TRB Annual Meeting. 2004

6) Olivier, D. and Nour-Eddin, E., Innovative Processing of Toll Collection Data, LICIT report, No. 0604. 2006

7) Yoshikazu, Travel time calculation method for expressway using toll collectionsystem data, Intelligent Transportation Systems. 1999

남궁성(2005)⁸⁾은 반복전진 전후 탐색법 알고리즘을 통해 TCS 데이터를 활용한 경로통행시간 산정을 제안하였다. 이 방법은 TCS 자료를 이용하여 고속도로 통행시간에 포함되어 있을 수 있는 휴게소 체류시간 등의 고속도로 본선외의 통행시간을 제거하는 방법이다.

Oliver(2006)⁹⁾는 인접구간 ETC 데이터를 이용하여 단거리 영업소간 통행시간을 산출하였다. ETC에 의한 통행시간 추정시 혼잡 시간대 ETC 데이터가 충분하지 않은 경우 통행시간 추정치의 신뢰구간이 커지는 경향이 있는데 이 경우 인접 영업소까지의 통행시간 자료를 이용하여 대상구간의 통행시간을 계산하였다.

Soriguera(2007)¹⁰⁾는 고속도로상의 본선영업소에서 출발한 단일구간에 대하여 TCS 데이터를 이용하여 인접한 두 영업소의 본선구간 통행시간과 출구 램프 통행시간 및 요금 정산시간을 포함한 통행시간을 추정하였다.¹¹⁾

8) 남궁성, 고속도로 경로통행시간 산출을 위한 전진반복 전후방탐색법(PIFAB)의 개발, 대한교통학회지, 제23권 제5호, 대한교통학회, pp.147~155. 2005

9) Olivier, D. and Nour-Eddin, E., Innovative Processing of Toll Collection Data, LICIT report, No. 0604. 2006

10) Soriguera, F., Thorson, L., and Robuste, F., Travel Time Measurement Using Toll Infrastructure, Transportation Research Record 1981, pp.99~107. 2007

11) 이현석, 전경수, TCS 링크통행시간을 이용한 고속도로 경로통행시간 추정, 대한교통학회지 제27권 제5호 P209-221. 2009

제3장 통행시간 예측 알고리즘

제1절 자료수집 및 가공처리

1. 자료수집

고속도로교통관리시스템의 VDS별 교통정보와 TCS의 통행시간 정보를 수집하여 이용되었다. 수집자료에 대하여 학습에는 6일간의 VDS자료와 TCS자료를 이용하였으며 검증시에는 3일간의 VDS자료가 사용되었다. VDS자료는 경부고속도로 양재 I.C와 청원 I.C사이의 구간에 있는 지점검지기로부터 얻었다. 많은 비가 내리는 등 교통류의 흐름에 크게 영향을 주는 요소는 없었으며, 지점검지기 또한 잘 운영되었다. 모든 검지기 지점은 고속도로의 기본구간에 위치하고 있고 쌍루프 검지기는 모든 지점의 각 차로에 설치되어 있고 선택된 구간사이에 어느 정도의 구배 차이가 있음에도 불구하고, 특별히 심한 구배를 가진 구간은 없었다.

<표 3> 수집자료 내역

자료구분	자료특성	수집기간
신경망 학습자료	구간별 VDS 구간별 TCS	6일 (금)(토)(일)(월)(화)(수)
검증자료	구간별 VDS	3일 (금)(토)(일)
평가자료	구간별 TCS	3일 (금)(토)(일)

또한 평가시에는 검증에 이용된 VDS자료에 대하여 TCS자료를 동일 시간자료로 가공하여 사용하였으며 상세사항은 위의 표와 같다.

〈표 4〉 구간 및 차로현황

구간명	구간	차로수
구간 1	양재~판교	4
구간 2	판교~수원	4
구간 3	수원~기흥	4
구간 4	기흥~오산	4
구간 5	오산~안성	4
구간 6	안성~천안	4
구간 7	천안~목천	3~4
구간 8	목천~청주	3
구간 9	청주~청원	3~4

각 IC간 통행시간을 추정 및 예측하기 위하여 모형을 단일 IC구간에 적용 가능한 모형과 다중구간에 적용 가능한 모형으로 구분하여 접근하였다. 단일 IC적용 모형은 인접된 IC간 통행시간을 추정 혹은 예측하는데 적용되는 모형이다. 다중구간 적용모형은 인접된 단일 IC간 통행시간 이외 임의 IC구간 사이에 다른 IC구간을 포함하여 단일 IC 보다 광범위한 구간의 통행시간을 추정 및 예측할 수 있는 모형이다. 이러한 단일구간 적용모형과 다중구간 적용모형의 구분은 각 모든 IC구간에서 목적인 교통정보가 수집된다는 전제조건 하에서 신경망모형에 의하여 추정 및 예측하려는 구간 내 IC의 수에 의존적이다. 신경망 모형 구축을 위해서는 보다 다양한 시행착오(trial and error)를 통하여 더욱 정교하고 현재의 모형에 알맞은 구성을 갖추는 과정이 필수적이므로 많은 학습과정을 통하여 학습 파라미터가 선정되었다.

2. 가공 처리

가. 이상치 제거

검지기에서 수집된 데이터, 즉 각 영업소 또는 고속도로 교통관리센터로 수집된 데이터는 다른 데이터들과 상당한 차이를 보이는 값들이 존재한다. 일반적으로 분석대상이 되는 자료중에서 다른 데이터들과 비교하여 특히 편차가 큰 데이터들을 흔히 이상치라 한다. 즉 관측자가 보기에 대부분의 다른 데이터들과 멀리 떨어진 데이터라고 할 수 있다. 이상치들은 현실적으로 자료를 수집할 때 발생하며, 환경 또는 기기에 의한 여러 가지 오류 등이 원인이 된다. 이러한 이상치들의 발생원인은 크게 다음의 두 가지로 구분할 수 있다. 첫째, 자료에 오류값이 포함되어 있는 경우이다. 이러한 오류값들은 환경에 의한 오류 혹은 기기의 통신상태 불량 등의 이유로 발생한다. 둘째, 모델자체의 원인으로선형인 모델을 실제상황으로 묘사하기 위해 비선형적으로 근사하는 경우에 발생원인에 관계없이 분석자료에 포함되어 있는 이상치들은 자료분석의 정도를 저하시키며, 분석결과를 왜곡시키게 된다. 자료에 포함되어 있는 이상치들은 주어진 자료만으로는 존재유무를 판단하기는 상당히 어렵다. 따라서 분석자료에 포함되어 있는 이상치를 식별하는 체계적인 과정이 필요하다. 자료에 포함되어 있는 이상치를 제거하기 위하여 산업공학 분야의 관리도법(Control Chart Method)에 기반을 두고 1σ (표준편차)를 지표로 삼아 Upper Bound를 설정하여 2단계에 걸쳐 이상치를 제거되었다. 수집자료는 5분단위로 하루기준 288개 군으로 관리되며, 각 군에 해당하는 원시자료(Raw Data)를 이상치의 제거대상으로 설정되었다.

나. Moving Average

추정 및 예측을 위하여 이용되는 기초자료들과 추정된 결과들에 대하여 효과적인 상태판정과 예측을 위하여 Moving Average 기법을 적용되었다. 이 기법은 자료의 관리 측면에서는 Block Moving과 같은 개념으로 적용이 가능하다.

$$\widehat{X}(m) = \frac{L_{MA}}{T} \sum_{m-(L_{MA}/T)-1}^m X(m)$$

여기서,

$\widehat{X}(m)$ = m번째 시간 간격에서의 smoothing된 데이터

L_{MA} = 이동평균 시간간격(초)

T = 시간 간격 (본 연구의 경우 30초)

$X(m)$ = m번째 시간간격에서의 원시 데이터.

사용된 기초자료는 VDS의 속도 및 TCS의 통행시간 등의 개별적 속성을 갖는 자료를 의미하며, 이상치 제거 과정에서 이상치가 제거된 5분 단위의 데이터를 제공받아서 20분 또는 30분 동안의 각 5분 단위의 기초자료를 이용하여 통계적인 대표값을 산정된다. 이는 추정 단위가 5분으로서 추정을 위한 시계열적 변동요소를 추정시 반영하기 위함이다. 따라서 Block Moving은 20분 혹은 30분 동안의 Block에 대한 자료를 기준으로 수행하며, 이를 토대로 추정을 한 후에 이루어진다.

다. 통행시간 예측을 위한 칼만 필터링

Moving Average 기법에 의해 제공되는 VDS의 속도 및 TCS의 통행시간 정보는 5분 단위로 제공된다. 이들 정보를 칼만필터모형을 통해 5분 후의 교통정보를 예측하여 모형 구축에 이용되었다. 기존의 자료 가공 처리방법에 의해 제공되는 교통정보를 통해 구축된 모형은 현재의 교통정보를 추정하는데 반해, 이상에서 제시하는 방법에 의해 예측된 정보를 모형구축에 함께 사용한다면, 구축된 모형에 의해 5분 후의 교통정보를 예측할 수 있다. 예를 들어 교통상태가 계속적으로 혼잡추세로 교통량이 계속해서 증가하는 추세라 할 때, 단지 5분에 대한 정보는 정보제공을 목적인 정보로서는 의미가 있으나 교통운영 및 제어관리 측면에서는 큰 의미가 없다. 오히려 현재 시점으로부터 15분 이상 30분 이후의 교통상태에 대한 예측 정보를 토대로 도로의 용량상태 및 과포화 유발가능성에 대한 기준을 토대로 본 연구에서 의도한 교통분석이 가능하므로 이에 대한 정보가 더 이용가치가 높은 정보가 된다.

라. 통행시간 예측간격

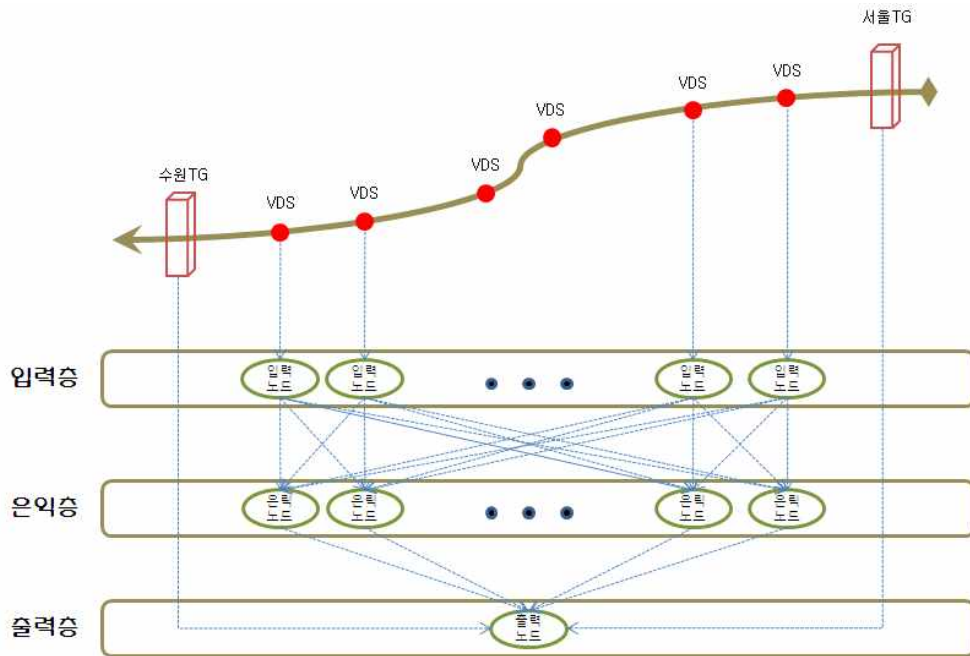
통행시간의 예측간격은 모형의 정확도 및 안정성을 결정하는 핵심적 요소 중 하나이다. 특히 이는 목표 예측모형으로부터 생성된 예측결과를 제공하는데 있어서 제공되는 교통정보의 실효성을 결정하게 된다. 이러한 통행시간 예측 시간간격을 결정하기 위해서는 두가지 전제조건을 만족시켜야 한다. 첫째는 수집되는 교통정보의 특성을 왜곡시키지 않아야 한다. 고속도로상에서의 교통류 특성은 매 5분단위의 실측 교통정보에 기반을 둔다. 이는 약 5분 단위의 교통정보를 통하여 연속류 교통정보의 특성을 분석할 수 있는 최소단위이다. 현재 고속도로 교통관리시스템에

서 ILD를 통하여 수집되는 교통정보는 매 30sec Polling 자료에 기초하고 있으며, 각 ILD간 설치 간격이 약 1Km ~ 2Km 수준에 이르고 있어 교통류의 군집(platoon)의 형태에 따라 매우 다양한 패턴이 나타난다. 이는 예측 시간간격과 수집되는 교통정보의 자료처리결과 기반입력정보의 시간적 특성이 동질화되어야 함을 필수조건으로 같은 교통상황에 대하여 다양한 패턴의 생성은 예측모형의 구축함에 있어서 예측결과의 산포발생 등의 비효율적 결과를 유발하게 된다. 따라서 기초 교통정보로 활용되는 자료는 예측시간간격과 시간적 동질성을 유지함과 동시에 도로상에서 발생가능한 유고발생 및 혼잡등의 관련 교통류 특성을 그대로 반영하고 있어야 함을 의미한다. 둘째는 예측결과의 활용 측면에서 적용상 실효성을 가져야 한다. 시스템에 적용할 때 이에 대한 실제 적용효과를 기대하기 위해서는 예측결과에 대한 교통정보를 효과적으로 제공할 수 있는 시간적 간격을 확보하는 것이다. 현재 고속도로 영업소간 통과시간을 고려할 때, 가장 짧은 통행시간을 나타내는 구간은 서울-수원간 영업소구간으로 평균 약 8분대의 통행시간을 나타내고 있으며, 최소 5분대까지 기본 특성을 갖는다. 따라서 이러한 특성을 고려할 때 예측결과에 대한 실효성을 확보하기 위해서는 통행시간의 예측 간격이 5분을 초과하지 않아야 한다.


제2절 통행시간 모형

Spatial Mapping기반의 신경망 모형을 구축함에 있어 구간 교통정보를 현실성 있게 반영하기 위하여 필수적으로 고려되는 구간인 각 지점간의 관계성을 정립하여 지점정보를 구간화하고, 각 지점에서의 교통정보가 전이되는 과정을 통하여 구간 통행시간의 추정 및 예측을 수행하였다.

<그림 13> Spatial Mapping 기반의 신경망 모형(단일)



<그림 14> Spatial Mapping 기반의 신경망 모형(다중)




위의 그림에서 제시된 바와 같이 Toll Gate(T/G) - Toll Gate(T/G) 간 설치된 각각의 루프검지로부터 속도를 기반으로 다음과 같은 과정에 의하여 통행시간을 추정 및 예측을 시행한다. 첫째, 대상 Inter Change(IC)-Inter Change(IC)간 설치된 VDS로부터 속도를 입력한다. 이때 기초정보는 30초 Polling Data이므로 이를 Moving Average Method에 의하여 단위시간 마다 대표치를 추출한다. 둘째, Moving Average에 의하여 대표치로서 추출된 대상 VDS별 속도와 TCS에 의한 구간통행시간을 1:1 대응시킨다. 셋째, 통행시간 예측인 경우, VDS별 속도를 예측하여 TCS의 예측 Interval 후의 통행시간과 1:1 대응시킨다. 넷째, 신경망의 초기 모수를 설정하여 수행한다. 다섯째, 반복학습을 수행하며, 수렴허용치에 도달 여부를 결정한다. 여섯째, 수렴시 학습수행을 종료한다.

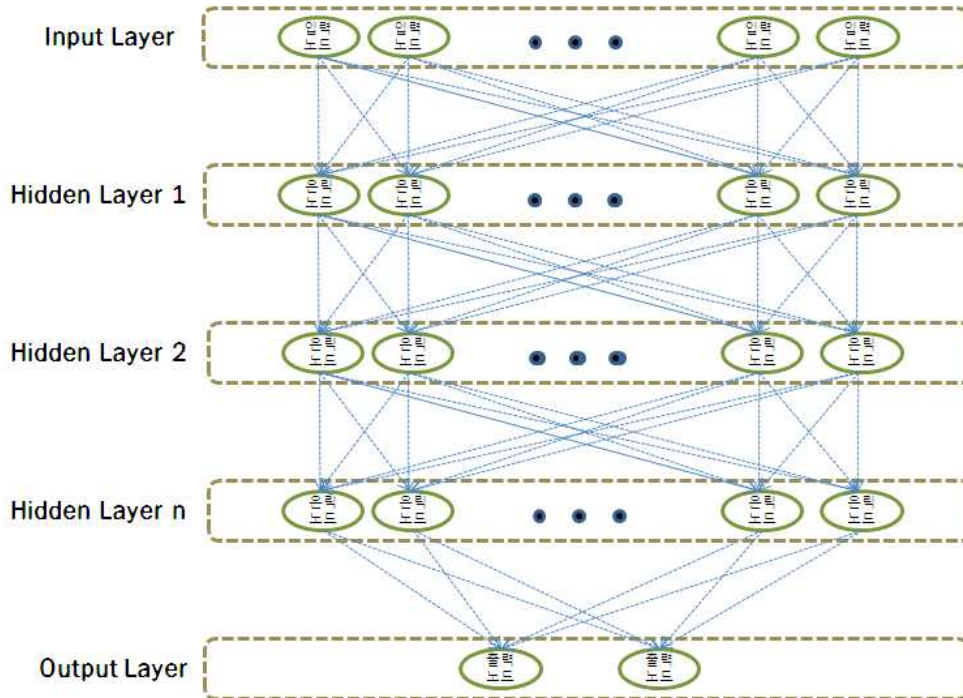
1. 모형의 구조

대상지역은 VDS의 설치 현황 및 자료의 충족성을 감안하여 수원-서울과 오산-서울간을 대상으로 하였다. 모형은 통행시간 추정과 예측모형으로 구분하였으며, 출력층의 노드수에 따라 수원-서울간을 단일구간 모형, 수원-서울과 오산-서울간을 다중구간 모형으로 구분한다. 또한 대표값, 이상치제거 유무(有無), Moving시간 및 과거자료 반영 정도 등 모형 구축에 있어서 통행시간에 영향을 미치는 요인에 대하여 자료의 처리를 서로 달리하여 모형에 적용되었다. 즉, 자료의 처리방식에 따라 각각 다른 세부모형으로 구분되었다. 모형은 단일구간 모형과 다중구간 모형으로 구분되었으며, 모형의 구조는 다음과 같다.

<그림 15> 단일 구간 모형



〈그림 16〉 다중 구간 모형



단일 구간 모형은 수원-서울간의 검지기 자료를 입력자료로 이용하여 통행시간을 추정 및 예측하기 위한 모형이다. 모형은 입력층, 은닉층, 각 은닉층의 노드(Node), 출력층으로 구성하였다.

다중구간 모형은 수원-서울, 오산-서울간의 검지기 자료를 입력자료로 이용하여 통행시간을 추정 및 예측하기 위한 모형으로서 입력층, 은닉층, 출력층으로 구성되며, 각 은닉층의 노드는 조건에 따라 구성되었다. 또한, 상세 실험 구간인 수원-서울 및 오산-서울 구간을 제외한 나머지 구간에 대해서는 실험 구간에 대한 평가 결과 가장 좋은 결과를 얻은 모형이 적용되었다.

2. 적용 모형

적용 모형은 자료의 속성에 따라 추정과 예측으로 구분되고, 모형 내의 구간의 수에 따라 단일구간 및 다중구간으로 구분하여 실시되었다. 각 모형은 다음과 같은 기준에 의해 구분되었다. 첫째, 자료의 속성에 따라 현재시점의 자료를 이용하는 추정모형과 칼만필터링기법에 의해 예측된 미래 시점의 자료를 이용하는 예측모형으로 구분되었다. 둘째, 추정 및 예측하고자 하는 구간의 수에 따라 단일구간과 다중구간으로 구분되었다. 셋째, TCS자료의 대표값은 최빈값과 평균값으로 구분되었다. 넷째, 이상치 제거는 유(有),무(無)로 구분되었다. 다섯째, Block Moving단위는 5분이며 Moving시간은 20분과 30분으로 구분되었다. 여섯째, 과거Moving자료의 반영횟수는 3회와 5회로 구분되었다. 이상에서 제시하고 있는 기준에 따라 모형을 구분하였다.

<표 5> 단일구간 추정모형

Zone	Factor	Filtering	Block (min)	Historical Data
IC-IC	Mode	No	20	3
			20	5
			30	3
			30	5
	Mean		20	3
			20	5
			30	3
			30	5
	Mode	Yes	20	3
			20	5
			30	3
			30	5
Mean	20		3	
	20		5	
	30		3	
	30		5	

<표 6> 다중구간 추정모형

Zone	Factor	Filtering	Block (min)	Historical Data
IC-IC-IC	Mode	No	20	3
			20	5
			30	3
			30	5
	Mean		20	3
			20	5
			30	3
			30	5
	Mode	Yes	20	3
			20	5
			30	3
			30	5
Mean	20		3	
	20		5	
	30		3	
	30		5	

<표 7> 단일구간 예측모형

Zone	Factor	Filtering	Block (min)	Historical Data
IC-IC	Mode	No	20	3
			20	5
			30	3
			30	5
	Mean		20	3
			20	5
			30	3
			30	5
	Mode	Yes	20	3
			20	5
			30	3
			30	5
Mean	20		3	
	20		5	
	30		3	
	30		5	

<표 8> 다중구간 예측모형

Zone	Factor	Filtering	Block (min)	Historical Data
IC-IC-IC	Mode	No	20	3
			20	5
			30	3
			30	5
	Mean		20	3
			20	5
			30	3
			30	5
	Mode	Yes	20	3
			20	5
			30	3
			30	5
Mean	20		3	
	20		5	
	30		3	
	30		5	

제4장 동행시간 모형평가 및 결과분석

제1절 평가방법

일반적으로 구축된 예측모형의 경우 그 수행결과를 평가하는 척도는 다양하며, 아직까지 절대적인 평가기준은 없으며, 단지 다음과 같은 지표를 토대로 상대적인 평가에 의존한다.

<표 9> 동행시간 평가지표(MOE)

평가 기준	수 식
Mean Absolute Relative Error (MARE)	$MARE = \frac{1}{N} \sum_{i=1}^N \frac{ x(i) - \widehat{x}(i) }{x(i)}$
Mean Absolute Error (MAE)	$MAE = \frac{1}{N} \sum_{i=1}^N x(i) - \widehat{x}(i) $
Relative Mean Square Error (RMSE)	$RMSE = \frac{1}{N} \sqrt{\sum_{i=1}^N x(i) - \widehat{x}(i) ^2}$

이러한 지표중 널리 이용되는 지표는 MARE이다. 그러나 본 연구에서는 상기의 제시된 각 지표들을 기준으로 구축된 모형의 효율성을 평가한다. 이외에도 예측모형의 타당성을 평가하는 방법으로 잔차분석을 고려할 수 있다. 잔차분석에서 잔차의 자료군이 정규분포(Normal Distribution) $N(0, \sigma_e^2)$ 임이 검증되면 목표한 모형이 타당성을 갖게 된다.

제2절 평가결과

1. 공간평균법 통행시간의 평가

적용모형의 통행시간 추정 방식과 공간평균법 통행시간 산출 방식과의 비교/분석을 위해 공간평균법 통행시간 산출방식을 평가한 결과는 다음과 같다.

<표 10> 공간평균법의 통행시간 평가결과

Zone	Filtering	Factor	MARE	MAE	RMSE
IC-IC	No	Mode	0.66434	4.90237	0.23415
		Mean	1.06717	7.48719	0.41584
	Yes	Mode	0.71620	5.36195	0.27094
		Mean	0.68039	5.09029	0.25612
IC-IC-IC	No	Mode	0.59379	4.52018	0.21320
		Mean	0.99041	7.10500	0.40287
	Yes	Mode	0.63637	4.92796	0.24635
		Mean	0.60453	4.65630	0.23292
IC-IC-IC	No	Mode	0.49330	9.48255	0.54614
		Mean	0.65742	11.96008	0.59399
	Yes	Mode	0.52264	10.31556	0.63033
		Mean	0.50297	9.73643	0.57080

이상에서 제시하는 바와 같이 기존의 시스템에서 이용하고 있는 공간 평균법 통행시간 산출방식은 오차가 크고 실제 통행시간과 비교하면 편이(Bias)하는 경향이 비교적 분명히 나타나고 있다.

2. 통행시간 추정모형 평가결과

평가결과 신경망을 이용한 통행시간 추정모형이 기존의 시스템에서 사용중인 공간평균을 이용한 모형에 비하여 모두 만족스러운 결과를 보였다. 구체적으로 살펴보면 MAE를 기준으로 볼 때 단일구간 통행시간 추정모형에서는 모형2가 가장 좋은 결과를 보였고 다중구간 통행시간 추정모형 또한 모형2가 가장 좋은 결과를 보였다. 다중구간 통행시간 추정모형은 모형5가 가장 좋은 결과를 보였다.

<표 11> 단일구간추정모형의 평가결과(수원-서울)

Model	MARE	MAE	RMSE
1	0.1237	1.6613	0.0850
2	0.1222	1.6366	0.0861
3	0.1240	1.6599	0.0853
4	0.1298	1.7950	0.0943
5	0.2303	2.8520	0.2962
6	0.2090	2.6135	0.2968
7	0.2303	2.8405	0.2986
8	0.2104	2.6265	0.2990
9	0.1286	1.8024	0.0989
10	0.1293	1.7969	0.1012
11	0.1296	1.7975	0.0984
12	0.1311	1.8056	0.1023
13	0.1232	1.7048	0.0937
14	0.1248	1.7018	0.0954
15	0.1252	1.7125	0.0939
16	0.1273	1.7275	0.0974

<표 12> 다중구간추정보형의 평가결과(수원-서울)

Model	MARE	MAE	RMSE
1	0.1448	1.9930	0.0985
2	0.1386	1.9169	0.0971
3	0.1445	1.9750	0.0965
4	0.1615	2.3751	0.1281
5	0.2266	2.9955	0.2942
6	0.2108	2.9060	0.2963
7	0.2250	3.0037	0.2957
8	0.2129	2.9477	0.2990
9	0.1432	2.0959	0.1133
10	0.1422	2.1496	0.1195
11	0.1416	2.0597	0.1129
12	0.1361	2.0460	0.1165
13	0.1743	2.6054	0.1330
14	0.1734	2.6412	0.1415
15	0.1775	2.6633	0.1369
16	0.1815	2.8194	0.1505

〈표 13〉 다중구간추정보형의 평가결과(오산-서울)

Model	MARE	MAE	RMSE
1	0.1340	3.7911	0.2000
2	0.1317	3.6984	0.1937
3	0.1346	3.8038	0.2074
4	0.1912	7.2129	0.4775
5	0.1196	3.5057	0.1772
6	0.1237	3.7324	0.1937
7	0.1214	3.5979	0.1895
8	0.1240	3.7301	0.1875
9	0.1336	4.0092	0.2350
10	0.1376	4.2484	0.2582
11	0.1329	3.9257	0.2366
12	0.1250	3.7861	0.2355
13	0.2226	7.2607	0.3735
14	0.2239	7.5129	0.4018
15	0.2280	7.5176	0.3852
16	0.2471	8.8108	0.4625

단일구간 통행시간 추정보형에서 특이한 점은 대표값으로 평균값을 사용하고 이상치를 제거하지 않은 모형5~8이 다른 실험모형에 비해 상대적으로 많은 오차를 보이는 것으로 나타났다. 그 이유는 평균(Mean)이

휴게소 장시간이용차량, 갓길에서의 수면 및 휴식차량, 공공차량 등 일부차량이 전체 통행시간에 미치는 영향이 매우 크게 작용하기 때문이다. 특히 짧은 구간의 경우 통행시간 역시 짧기 때문에 긴 구간에 비해 상대적으로 많은 영향을 받아 대표값의 편이(Bias)가 발생하기 때문인 것으로 판단된다.

다중구간 통행시간 추정모형은 대표값으로 평균값을 사용하고 이상치를 제거하지 않은 모형5~8이 상대적으로 많은 오차를 보이는 것으로 나타났다. 그 이유는 일부차량의 통행시간이 각 자료군의 통행시간에 미치는 영향이 매우 크게 작용하기 때문이다. 특히 짧은 구간의 경우 통행시간 역시 짧기 때문에 긴 구간에 비해 상대적으로 많은 영향을 받아 대표값의 편이(Bias)가 발생하기 때문인 것으로 판단된다. 또한 대표값으로 평균값을 사용하고 이상치를 제거한 모형13~16도 상대적으로 많은 오차를 보이는 것으로 나타났다. 이것은 이상치의 제거가 오히려 신경망학습에 필요한 속도와 통행시간의 관계에 대한 설명력을 저하시키기 때문인 것으로 판단된다.

다중구간 통행시간 추정모형은 대표값으로 최빈값을 사용하고 이상치를 제거하지 않은 모형4가 상대적으로 많은 오차를 보이는 것으로 나타났다. 그 이유는 대표값으로서 최빈값이 가진 단점으로서 동일한 값을 가진 편기된 자료가 일부지역에 집중되어 있을 때 대표값으로서의 기능을 상실할 수 있다는 점을 보여주며, 다른 한편으로 신경망의 학습이 충분히 하여 모형의 안정화가 필요하다는 점을 의미한다. 또한 대표값으로 평균값을 사용하고 이상치를 제거한 모형13~16도 상대적으로 많은 오차를 보이는 것으로 나타났다. 이것은 이상치의 제거가 오히려 신경망학습에 필요한 속도와 통행시간의 관계에 대한 설명력을 저하시키기 때문인 것으로 판단된다.

3. 통행시간 예측모형 평가결과

평가결과 신경망을 이용한 통행시간 예측모형이 기존의 시스템에서 사용중인 공간평균을 이용한 모형에 비하여 모두 만족스러운 결과를 보였다. 구체적으로 살펴보면 MAE를 기준으로 볼 때 단일구간 통행시간 예측모형에서는 모형2가 가장 좋은 결과를 보였고 다중구간 통행시간 예측모형 또한 모형1이 가장 좋은 결과를 보였다. 다중구간 통행시간 예측모형은 모형5가 가장 좋은 결과를 보였다.

<표 14> 단일구간예측모형의 평가결과(수원-서울)

Model	MARE	MAE	RMSE
1	0.1249	1.6876	0.0872
2	0.1237	1.6656	0.0887
3	0.1244	1.6732	0.0874
4	0.1251	1.6776	0.0906
5	0.2206	2.7578	0.2983
6	0.1931	2.4657	0.2799
7	0.2216	2.7511	0.3007
8	0.1948	2.4797	0.2823
9	0.1297	1.8233	0.1013
10	0.1311	1.8309	0.1044
11	0.1304	1.8155	0.1013
12	0.1327	1.8359	0.1056
13	0.1246	1.7196	0.0956
14	0.1268	1.7304	0.0982
15	0.1263	1.7295	0.0966
16	0.1289	1.7545	0.1003

<표 15> 다중구간예측모형의 평가결과(수원-서울)

Model	MARE	MAE	RMSE
1	0.1440	1.9831	0.1002
2	0.1511	2.1246	0.1066
3	0.1577	2.2013	0.1108
4	0.1492	2.1268	0.1094
5	0.2185	2.9297	0.2973
6	0.1959	2.7282	0.2792
7	0.2197	2.9268	0.3004
8	0.1933	2.6754	0.2797
9	0.1445	2.1149	0.1177
10	0.1399	2.0838	0.1210
11	0.1506	2.2613	0.1294
12	0.1416	2.1185	0.1192
13	0.1766	2.6805	0.1423
14	0.1743	2.7135	0.1492
15	0.1791	2.7261	0.1445
16	0.1874	2.9575	0.1618

<표 16> 다중구간예측모형의 평가결과(오산-서울)

Model	MARE	MAE	RMSE
1	0.1433	4.1145	0.2210
2	0.1402	4.0609	0.2285
3	0.1429	4.1907	0.2464
4	0.1386	4.1132	0.2479
5	0.1261	3.7892	0.1976
6	0.1258	3.8294	0.1984
7	0.1285	3.8909	0.2058
8	0.1257	3.8095	0.2001
9	0.1441	4.4074	0.2624
10	0.1382	4.3892	0.2974
11	0.1456	4.7624	0.3300
12	0.1346	4.1055	0.2645
13	0.2194	7.2859	0.3938
14	0.2323	8.1782	0.4483
15	0.2203	7.2839	0.3941
16	0.2307	8.1040	0.4454

단일통행시간 예측모형에서 특이한 점은 대표값으로 평균값을 사용하고 이상치를 제거하지 않은 모형5~8은 상대적으로 많은 오차를 보이는 것으로 나타났다. 그 이유는 평균값이라는 파라미터가 휴게소 장시간이 용차량, 갓길에서의 수면 및 휴식차량, 공공차량 등 일부차량이 전체 통행시간에 미치는 영향이 매우 크게 작용하기 때문이다. 특히 짧은 구간의 경우 통행시간 역시 짧기 때문에 긴 구간에 비해 상대적으로 많은 영향을 받아 대표값의 편기(Bias)가 발생하기 때문인 것으로 판단된다.

다중통행시간예측모형은 대표값으로 평균값을 사용하고 이상치를 제거하지 않은 모형5~8이 상대적으로 많은 오차를 보이는 것으로 나타났다. 그 이유는 일부차량의 통행시간이 각 자료군의 통행시간에 미치는 영향이 매우 크게 작용하기 때문이다. 특히 짧은 구간의 경우 통행시간 역시 짧기 때문에 긴 구간에 비해 상대적으로 많은 영향을 받아 대표값의 편기(Bias)가 발생하기 때문인 것으로 판단된다. 또한 대표값으로 평균값을 사용하고 이상치를 제거한 모형13~16도 상대적으로 많은 오차를 보이는 것으로 나타났다. 이것은 이상치의 제거가 오히려 신경망학습에 필요한 속도와 통행시간의 관계에 대한 설명력을 저하시키기 때문인 것으로 판단된다.

다중통행시간예측모형은 대표값으로 평균값을 사용하고 이상치를 제거한 모형13~16이 상대적으로 많은 오차를 보이는 것으로 나타났다. 이것은 이상치의 제거가 오히려 신경망학습에 필요한 속도와 통행시간의 관계에 대한 다양한 관계에 대한 설명력의 범위를 제한시키기 때문인 것으로 판단된다. 또한 모형구성이 유사한 다중통행시간추정모형의 모형4에 비해 상대적으로 낮은 오차율을 보이는 이유는 Kalman Filtering 알고리즘을 이용한 예측과정에서 Kalman Filter의 예측값이 자료의 패턴을 양성하여 신경망 알고리즘의 설명력에 기여하기 때문인 것으로 판단된다.

결론적으로 통행시간 추정모형의 경우, 신경망을 이용한 모형이 기존

의 시스템에서 사용중인 공간평균을 이용한 모형에 비하여 모두 만족스러운 결과를 보였다. MAE를 기준으로 볼 때 단일구간 통행시간 추정모형에서의 최적모형은 모형2였고 다중구간 통행시간 추정모형에서는 모형2로 나타났다. 또한 다중구간 통행시간 추정모형에서는 모형5가 가장 좋은 결과를 보였다. 통행시간 예측모형의 경우, 단일구간 통행시간 예측모형에서의 최적모형은 모형2로 나타났고 다중구간 통행시간 예측모형에서는 모형1이 가장 좋은 결과를 보였다. 또한 다중구간 통행시간 예측모형은 모형5가 가장 좋은 결과를 보였다.

제3절 적용모형과 공간평균법 비교평가

본 연구에서는 시스템의 기존 공간평균법과 적용모형의 비교를 위해 각 모형별 평가결과를 이용하였다. 공간평균법의 평가결과와 적용모형의 평가결과의 비교를 통해 결론을 도출하고자 한다. 적용모형의 평가결과와 공간평균법의 평가결과는 상당한 차이를 보이고 있다. 이들 평가 지표의 차이는 TCS의 통행시간에 대한 적용모형과 공간평균법에 의한 통행시간의 반영정도를 나타낸다. 따라서 본 연구에서는 이들 평가지표의 차이를 이용하여 각 모형의 TCS 통행시간 반영정도를 비교/평가하고자 한다.

<표 17> 평가지표별 공간평균법에 대한 적용모형의 개선도

Zone	Filtering	Factor	MARE	MAE	RMSE	RMSE
IC-IC	No	Mode	1	0.541	3.241	0.149
		Mean	5	0.837	4.635	0.120
	Yes	Mode	9	0.588	3.560	0.172
		Mean	13	0.557	3.385	0.162
IC-IC-IC	No	Mode	1	0.449	2.527	0.115
		Mean	5	0.764	4.109	0.109
	Yes	Mode	9	0.493	2.832	0.133
		Mean	13	0.430	2.051	0.100
IC-IC-IC	No	Mode	1	0.359	5.691	0.346
		Mean	5	0.538	8.454	0.417
	Yes	Mode	9	0.389	6.306	0.395
		Mean	13	0.280	2.476	0.197

공간평균법과 적용모형의 비교 결과는 첫째, MARE, MAE 및 RMSE 등의 차이에 의한 평가 결과 적용모형의 결과가 공간평균법 보다 TCS에서의 통행시간을 잘 반영 한다고 할 수 있다. 둘째, 대체로 적용모형의 결과가 TCS의 통행시간을 잘 반영한다고 할 수 있다. 이상에서 제시되고 있는 바와 같이 적용모형의 통행시간 추정방식과 현재 적용되고 있는 공간평균법 산출방식의 평가결과는 적용모형의 평가 결과가 모두 우수하게 나타났다.

제5장 모형의 검증 및 수행도 평가

제1절 동행시간 모형의 검증방법

통계적 검증절차는 우선 모든 가설검정 문제에 있어서 두 개의 상반되는 귀무가설과 대립가설이 명확히 설명되어야 한다. 어떤 경우이든지 가설은 서로 배반적이고 또 모집단의 모수의 참값은 귀무가설이든지 아니면 대립가설이어야 한다. 이 의미는 두 개의 가설이 동시에 풀린다는 것은 인정되지 않는다는 것이다. 본 연구에서 개발된 속도추정모형은 그 오차의 절대값의 허용범위가 일정값 이내일 것이 요구된다. 그리고 검정통계량을 선택해야 한다. 검정통계량이란 가설검정에 사용되는 통계량을 말하며 이의 선택은 일반적으로 검정하고자 하는 모수와 추출한 표본의 크기에 따라서 결정된다. 본 연구에서는 검정하고자 하는 모수가 모집단의 오차의 절대값의 평균이고, 추출한 표본의 크기가 충분히 크다고 인정¹²⁾되므로 검정통계량은 다음과 같다.

$$Z = \frac{\bar{X} - \mu_0}{s/\sqrt{n}}$$

여기서,

s = 표본표준편차

X = 확률변수 (본 연구에서 오차의 절대값)

12) 일반적으로 통계학에서는 표본의 크기가 30 이상이면 충분하다고 인정하고, 중심극한의 정리(Central Limit Theorem)에 의해 모집단 분포의 모 표준편차를 표본표준편차로 대치하여 사용할 수 있다.

\bar{X} = 표본평균

μ_0 = 귀무가설 하의 모평균 (본 연구에서는 8km/hr)

n = 표본의 수

위의 검정통계량 Z 는 이 특정한 표본결과가 검정되고 있는 가설들 중 어느 것과 일치하는가를 결정하는 데 쓰이는 또 하나의 확률변수이다. 이 검정통계량 Z 의 분포는 표준정규분포 $N(0,1)$ 을 따르는 것으로 알려져 있으며, 표본표준편차와 표본평균은 표본으로부터 계산된다. 또한, 가설검정에 있어서의 유의수준 α 란 통계적 가설검정에 있어서의 제 1종 오류로서 귀무가설이 사실임에도 불구하고 기각될 확률을 의미한다. 이 유의 수준은 보통 0.05 (5%)와 0.01(1%)이 많이 쓰인다. 즉, 유의수준 0.05를 사용하였다는 것은 귀무가설이 사실인데도 불구하고 사실이 아니라고 판단할 확률이 0.05라는 뜻이다. 한편, 만일 표본으로부터 계산된 검정통계량의 값이 기각역에 속한다면 귀무가설을 기각하게 되고, 반대로 채택역에 속한다면 귀무가설을 채택하게 된다. 이러한 기각역과 채택역을 구별시켜 주는 그 기준점을 임계값이라 한다. 이러한 임계값은 유의수준과 검정통계량의 분포에 따라서 결정되게 된다. 본 연구에서는 유의수준으로 0.05를 적용하기로 하고, 검정통계량이 표준정규분포를 따르므로 임계값은 -1.64485가 된다. 마지막으로 가설과 대립가설의 형태에 따라 다음과 같은 통계적 결정의 기준이 수립된다.

if (검정통계량 $Z \leq$ 임계값) then 귀무가설을 채택

else 귀무가설을 기각

제2절 통행시간 모형의 검증결과

본 연구에서의 통행시간추정 및 예측모형은 그 오차의 절대값의 허용범위는 추정 및 예측의 거리에 따라 다르며, 이들을 위한 가설설정은 다음과 같다.

귀무가설(H_0) : 오차절대값의 평균이 특정시간 이하라고 볼 수 있다.

대립가설(H_1) : 오차절대값의 평균이 특정시간 이하라고 볼 수 없다.

특정시간에 대한 정의는 다음 표와 같다.

<표 18> 가설을 위한 범위

Model	Zone	특정시간(분)
단일구간 추정	IC-IC	2
다중구간 추정	IC-IC-IC	2.5
	IC-IC-IC	5
단일구간 예측	IC-IC	2
다중구간 예측	IC-IC-IC	2.5
	IC-IC-IC	5

위에 보여진 통계적 결정 기준에 의해 귀무가설이 채택된다면, 그것은 유의수준 5% 하에서, 어떤 경우에 대해서도 수립된 통행시간추정 및 예측모형으로 추정한 통행시간에 대한 오차의 절대값의 평균이 위의 표에서 제시한 값이라고 말 할 수 있는 통계적 근거가 있다는 것을 의미한다. 아래 표에서 제시하고 있는 모형의 통행시간 검정결과는 통계적 유의수준 0.05이며, 임계값은 -1.64이다.

<표 19> 단일구간 통행시간 추정모형 검정결과(수원-서울)

Model	Sample	Mean(평균)	S(표준편차)	검정결과
1	657	1.66	1.41	귀무가설 채택
2	622	1.64	1.39	귀무가설 채택
3	651	1.66	1.41	귀무가설 채택
4	618	1.79	1.51	귀무가설 채택
5	657	2.85	7.04	귀무가설 기각
6	622	2.61	6.93	귀무가설 기각
7	651	2.84	7.07	귀무가설 기각
8	618	2.63	6.96	귀무가설 기각
9	562	1.80	1.50	귀무가설 채택
10	526	1.80	1.47	귀무가설 채택
11	560	1.80	1.48	귀무가설 채택
12	525	1.81	1.50	귀무가설 채택
13	562	1.70	1.43	귀무가설 채택
14	526	1.70	1.38	귀무가설 채택
15	560	1.71	1.42	귀무가설 채택
16	525	1.73	1.41	귀무가설 채택

<표 20> 다중구간 통행시간 추정모형 검정결과(수원-서울)

Model	Sample	Mean(평균)	S(표준편차)	검정결과
1	657	1.99	1.55	귀무가설 채택
2	622	1.92	1.48	귀무가설 채택
3	651	1.98	1.47	귀무가설 기각
4	618	3.78	1.84	귀무가설 기각
5	657	3.00	6.93	귀무가설 기각
6	657	3.00	6.93	귀무가설 기각
7	657	3.00	6.93	귀무가설 기각
8	657	3.00	6.93	귀무가설 기각
9	657	3.00	6.93	귀무가설 기각
10	657	3.00	6.93	귀무가설 기각
11	657	3.00	6.93	귀무가설 기각
12	657	3.00	6.93	귀무가설 기각
13	657	3.00	6.93	귀무가설 기각
14	657	3.00	6.93	귀무가설 기각
15	657	3.00	6.93	귀무가설 기각
16	657	3.00	6.93	귀무가설 기각

〈표 21〉 다중구간 통행시간 추정모형 검정결과(오산-서울)

Model	Sample	Mean(평균)	S(표준편차)	검정결과
1	657	3.79	3.45	귀무가설 채택
2	622	3.70	3.11	귀무가설 채택
3	651	3.80	3.68	귀무가설 채택
4	618	9.04	11.52	귀무가설 기각
5	657	3.51	2.89	귀무가설 채택
6	657	3.51	2.89	귀무가설 채택
7	657	3.51	2.89	귀무가설 채택
8	657	3.51	2.89	귀무가설 채택
9	657	3.51	2.89	귀무가설 채택
10	657	3.51	2.89	귀무가설 채택
11	657	3.51	2.89	귀무가설 채택
12	657	3.51	2.89	귀무가설 채택
13	657	3.51	2.89	귀무가설 채택
14	657	3.51	2.89	귀무가설 채택
15	657	3.51	2.89	귀무가설 채택
16	657	3.51	2.89	귀무가설 채택

〈표 22〉 단일구간 통행시간 예측모형 검정결과(수원-서울)

Model	Sample	Mean(평균)	S(표준편차)	검정결과
1	639	1.69	1.42	귀무가설 채택
2	608	1.67	1.42	귀무가설 채택
3	634	1.67	1.43	귀무가설 채택
4	604	1.68	1.47	귀무가설 채택
5	639	2.76	7.02	귀무가설 기각
6	608	2.47	6.45	귀무가설 기각
7	634	2.75	7.06	귀무가설 기각
8	604	2.48	6.48	귀무가설 기각
9	543	1.82	1.50	귀무가설 채택
10	512	1.83	1.49	귀무가설 채택
11	541	1.82	1.50	귀무가설 채택
12	512	1.84	1.53	귀무가설 채택
13	543	1.72	1.42	귀무가설 채택
14	512	1.73	1.40	귀무가설 채택
15	541	1.73	1.44	귀무가설 채택
16	512	1.75	1.44	귀무가설 채택

<표 23> 다중구간 통행시간 예측모형 검정결과(수원-서울)

Model	Sample	Mean(평균)	S(표준편차)	검정결과
1	639	1.98	1.58	귀무가설 채택
2	608	2.12	1.55	귀무가설 채택
3	634	2.20	1.71	귀무가설 채택
4	604	2.13	1.65	귀무가설 채택
5	639	2.93	6.93	귀무가설 기각
6	608	2.73	6.33	귀무가설 기각
7	634	2.93	6.98	귀무가설 기각
8	604	2.68	6.34	귀무가설 기각
9	543	2.11	1.75	귀무가설 채택
10	512	2.08	1.78	귀무가설 채택
11	541	2.26	1.99	귀무가설 채택
12	512	2.12	1.67	귀무가설 채택
13	543	2.68	1.95	귀무가설 기각
14	512	2.71	2.01	귀무가설 기각
15	541	2.73	1.97	귀무가설 기각
16	512	2.96	2.16	귀무가설 기각

<표 24> 다중구간 통행시간 예측모형 검정결과(오산-서울)

Model	Sample	Mean(평균)	S(표준편차)	검정결과
1	639	4.11	3.78	귀무가설 채택
2	608	4.06	3.91	귀무가설 채택
3	634	4.19	4.58	귀무가설 채택
4	604	4.11	4.50	귀무가설 채택
5	639	3.79	3.26	귀무가설 채택
6	608	3.83	3.05	귀무가설 채택
7	634	3.89	3.43	귀무가설 채택
8	604	3.81	3.11	귀무가설 채택
9	543	4.41	4.24	귀무가설 채택
10	512	4.39	5.11	귀무가설 채택
11	541	4.76	6.02	귀무가설 기각
12	512	4.11	4.36	귀무가설 채택
13	543	7.29	5.58	귀무가설 기각
14	512	8.18	6.01	귀무가설 기각
15	541	7.28	5.57	귀무가설 기각
16	512	8.10	6.00	귀무가설 기각

제3절 통행시간 모형의 수행도 평가

본 연구에서는 시스템에서 운영 하에 있는 ILD로 부터 수집되는 기초 교통정보로서 속도자료를 이용하였으며, 고속도로의 영업소간 통행시간 추정 및 예측 알고리즘 적용을 수행하였다. 적용된 모형은 현장에서 실시간으로 수집된 지점교통정보를 입력정보로 하여 역전과 신경망 모형에 기반을 두고 있으며, 모형의 수렴효과 향상과 입력정보의 다양화를 위하여 동적기반의 칼만필터 모형을 적용하였다. 모형의 비교우위를 결정하기 위하여 기존에 운영되고 있는 공간평균법(Space Mean Speed)에 기반한 추정모형에 대하여 평균절대오차 등의 간접평가지표를 통하여 평가하였으며, 또한 현장 적용성을 검증하기 위하여 통계적 검증방법을 이용하여 이를 평가하였다. 수행도 평가 결과 다음과 같은 결론을 얻었다.

첫째, 통행시간의 추정 및 예측시 단위 시간 동안 수집된 자료 군의 대표치 추출방법은 최빈값이 평균값보다 우수하다. 본 연구에서는 단위 시간당 수집되는 TCS(Toll Collection System) 정보의 산포를 안정화시키기 위하여 Moving기법을 적용하였으며, 이때 Moving처리를 위한 기본 단계로서 단위 시간당 수집된 자료의 대표치를 추출하기 위한 방법으로 최빈값과 평균값방법을 적용하였다.

둘째, 추정모형과 예측모형에 있어서 학습자료의 양이 충분한 경우 최빈값으로 적용하는 것이 다른 자료처리 방법의 경우 보다 우수한 것으로 나타났다. 그러나 자료수가 충분한 경우 이상치를 제거한 후 평균치를 사용하여도 무방하다. 자료수가 불충분한 경우 통행시간 산정에 있어서 수집된 교통정보에 대하여 이상치를 제거할 경우 적용 전에 비하여 상대적으로 더 우수한 추정 및 예측결과를 기대할 수 있다. 모형의 적용에 있어 수집된 교통정보에 대하여 이상치 제거기법으로 기본적으로 Moving기법에 의한 평활화(Smoothing) 효과를 적용하였으며, 이외 통

계적 방법을 이용하여 별도의 이상치 제거방법을 적용하였다. 이러한 이상치 제거는 고속도로의 각 영업소를 통과하는 모든 차량들 중 정상적인 고속도로 통행 이외 휴게소이용차량 및 갓길이용 등에 위한 것으로 제거하지 않을 경우 추정 및 예측시 심각한 예측 오차를 유발할 수 있는 요인에 해당한다. 이 방법을 적용한 결과 이상치를 제거한 경우, 보다 우수한 정확도를 나타냈다.

셋째, 시스템으로부터 수집되는 VDS 정보를 기반으로 한 이론적 통행시간과 TCS를 통한 실측된 통행시간은 다르다. VDS에서 계측되는 교통정보는 지점교통정보로서 이들을 공간평균속도로 환산했을 경우와 실제 TCS에서 계측된 각 영업소간 통행시간을 비교할 경우 많은 차이를 갖는다. 이러한 차이는 TCS의 각 영업소를 차량들이 통과할 경우 모든 차량들이 경험하게 될 Toll Plaza에서의 지체시간을 VDS에서 수집된 교통정보로 이들을 설명할 수 없기 때문인 것으로 판단된다.

넷째, 통행시간 추정 및 예측을 위한 각 신경망 모형은 단일구간 적용을 위한 모형과 다중구간 적용을 위한 추정 및 예측 모형으로 구분하였으며, 이들 각 모형들은 간접 평가지표 및 통계적 검증에 의하여 그 타당성을 평가하였다. 평가결과는 다음과 같다.

〈표 25〉 개발모형의 종합적인 수행도 평가결과

Model	Zone	평가결과 (MAE)	적용성 평가
단일구간 추정	IC-IC	1.63~2.85	최우수 (모형2)
다중구간 추정	IC-IC-IC	1.91~3.00	우수 (모형3)
	IC-IC-IC	3.50~7.51	보통 (모형2)
단일구간 예측	IC-IC	1.66~2.75	최우수 (모형2)
다중구간 예측	IC-IC-IC	1.98~2.95	우수 (모형1)
	IC-IC-IC	3.78~8.17	보통 (모형5)

위의 결과, 적용한 각각의 모형들은 VDS와 TCS간의 이론적 차이를 다소 해결할 수 있었다. 시스템으로부터 수집되는 VDS 정보를 기반으로 한 이론적 통행시간과 TCS를 통한 실측된 통행시간이 다른 문제점을 해결하기 위한 방법으로 적용모형에 신경망-칼만필터 알고리즘을 적용하였다. 적용한 결과 칼만필터 알고리즘을 적용한 모형이 VDS정보에 의해 산정된 통행시간보다 상대적으로 더 우수한 결과를 나타냈다.

결과적으로 본 연구에서 적용모형이 TCS의 Toll Plaza에서 경험하는 지체시간을 통행시간추정 및 예측에 보다 안정적으로 고려하는 것으로 판단되었다. 또한, 이상치를 제거하지 않은 데이터에서 최빈값을 채택하여 구축된 모형이 우수한 것으로 나타났다. 따라서 본 연구에서는 신경망 모형의 입력자료를 구성하는 방법으로 이상치를 제거하지 않은 데이터에서 최빈값을 추출하는 방법을 채택하였다.

제6장 결론

본 연구는 고속도로 구간을 대상으로 신경망과 칼만필터 알고리즘 기반의 적용 가능한 통행시간 추정 및 예측모형에 대해 적용성 및 수행도를 통계적으로 검증하여 운전자 및 운전자의 통행시간 예측에 도움을 주기 위한 것이다. 본 연구에서는 서울~청원 구간 내 모든 ILD 자료를 수집하여 수집된 ILD자료 중 보다 신뢰율이 높다고 평가되는 자료를 선별하여 이용하였으며 영업소와 영업소간 최소한 2개 이상의 지점자료를 이용하였다. 적용된 모형은 시간전이성과 지역전이성을 감안하여 적용하였으며, 각 모형을 여러 가지 통계적 평가지표를 사용하여 평가하였다. 또한 최종적으로 각 모형의 상호 비교우위를 통해 선정된 모형에 대하여 현장 적용 가능성을 판단하기 위하여 통계적 검증을 이용하여 객관적이고 일반화된 검증절차를 수행하였으며, 그 결과를 제시하였다.

이상의 본 연구에서 모형적용 결과분석 및 평가검증을 통한 연구 수행 결과 다음과 같은 종합적 결론에 도달하였다. 통행시간 추정모형은 단일구간 모형이 다중구간 모형과 비교하여 보다 우수하였으며, 단일구간 추정모형은 통계적으로 평균 수분 이내의 오차를 기대할 수 있는 것으로 나타났다. 수행도 평가결과 역시 단일모형과 다중모형을 비교하면 수행도가 대등한 것으로 나타나 결과적으로 모형구조가 단순하고 사용이 용이한 단일구간 적용모형이 더 적용성이 높은 것으로 나타났다. 예측모형의 평가결과 최소 20분 이내의 통행시간 예측결과는 비교적 양호하였으나 20분부터 그 이상 미래시점으로 나아갈수록 예측오차는 급격하게 출렁임이 발생하였다. 따라서 통행시간 예측에 있어 칼만필터 알고리즘의 적용은 장기예측 보다는 단기예측에 적합하다는 결론에 도달하였다.

참고문헌

I. 국내문헌

- 김성인, 통계적 품질관리, 박영사, 1989.
- 허문열, 수리통계학, 경문사, 1989.
- 김대수, 신경망 이론과 응용 (1), 하이테크 정보사, 1993.
- 김응수, C로 만드는 뇌의 정보시스템, 생능출판사, 1996.
- 도철용, 교통공학원론(상), 청문각, 1996.
- 김원경, 시계열분석, 경문사, 1996.
- 정윤성, On-line Monitoring and Prediction System of Machine Condition by Neural Network, 공학 박사 학위 논문, 아주대학교 대학원, 1995.
- 고영철, 이상치가 존재하는 비선형 공정의 신경망 모델링, 공학석사학위 논문, 아주대학교 대학원, 1997.
- 김규욱, Kalman-Filtering 모델을 이용한 고속도로상에서의 교통량 추정, 공학석사학위 논문, 아주대학교 대학원, 1996.
- 김남선, 신경망을 이용한 고속도로 여행시간 추정 및 예측모형 개발, 공학석사학위 논문, 아주대학교 대학원, 1999.
- 김재진·노정현·박동주, 구간검지체계를 이용한 On-Line 출발시각기준 링크 통행시간 추정 (연속류를 중심으로), 대한교통학회지, 제24권 제2호, 대한교통학회, pp.157~168. 2006

남궁성, 고속도로 경로통행시간 산출을 위한 전진반복 전후방탐색법 (PIFAB)의 개발, 대한교통학회지, 제23권 제5호, 대한교통학회, pp.147~155. 2005

도명식· 이향미· 남궁성, TCS데이터를 이용한 이상치 제거 및 결측보정 알고리즘 개발, 대한교통학회지, 제26권 제4호, 대한교통학회, pp.241~250. 2008

오세창· 김명하· 백용현, 차량검지기 교통량 데이터를 이용한 고속도로 통행시간추정 및 예측모형개발에 관한 연구, 대한교통학회지, 제21권 제5호, 대한교통학회, pp.83~95. 2003

장진환· 백남철· 김성현· 변상철, AVI 자료를 이용한 동적 통행시간 예측, 대한교통학회지, 제22권 제7호, 대한교통학회, pp.169~175. 2004

김동호, 노정현, 박동주, 박지형, 김한수, 고속도로 통행시간 예측을 위한 과거 통행시간 이력자료 구축에 관한 연구 :지점 검지기를 중심으로, 대한교통학회지, 제26권 제5호 pp.131-141, 2008

II. 외국문헌

Bellman R., Dynamic programming, Princeton University Press, Princeton, New Jersey, 1957.

Acha-Daza, J.A., and F.L. Hall, "Graphical Comparison of the Predictions for Speed Given by Catastrophe Theory and Some Classic Models," In Transportation Research Record 1398, TRB, National Research Council, Washington, D.C., 1993, pp. 119-124.

Acha-Daza, J.A, The Application of Catastrophe Theory to

Traffic Flow Variables, Mater's thesis, Department of Civil Engineering, McMaster University, Hamilton, Ontario, Canada, June 1992.

Adolf D. May, "Traffic Management from Theory to Practice: Past, Present, Future," In Transportation Research Record 1457, TRB, National Research Council, Washington, D.C., pp.5-14.

Anna Pushkar, Fred L.Hall, and Jorge A. Acha-Daza, "Estimation of Speeds from Single-Loop Freeway Flow and Occupancy Data Using Cusp Catastrophe Theory Model," In Transportation Research Record 1457, TRB, National Research Council, Washington, D.C., pp.149-157.

Ceder, A, Investigation of Two Regime Traffic Flow Models at the Micro- and Macroscopic Levels, Ph.D. dissertation. University of California, Berkeley, 1975.

Dillon, D.S., and F.L. Hall, "Freeway Operations and the Cusp Catastrophe: An empirical Analysis," In Transportation Research Record 1132, TRB, National Research Council, Washington, D.C., 1988, pp. 66-76.

Forbes, G.J., and F.L. Hall, "The Applicability of Catastrophe Theory in Modelling Freeway Traffic Operations," Transportation Research, Vol. 24A, No. 5, 1990, pp. 335-344.

Gilchrst, R.S. and F. L. Hall, "Three-Dimensional Relationships among Traffic Flow Theory Variables," Transportation Research Record 1225, TRB, NRC, Washington, DC, pp. 99-108, 1989.

Hall, F.L., and B.N. Persaud, "Evaluation of Speed Estimates

Made with Single-Detector Data from Freeway Traffic Management Systems," In Transportation Research Record 1232, TRB, National Research Council, Washington, D.C., 1989, pp. 9-16.

Hall, F.L, "An Interpretation of Speed-Flow Concentration Relationships Using Catastrophe Theory," Transportation Research, Vol. 21A, No. 3, 1987, pp. 191-201.

Jorge A. Acha-Daza., and Fred L.Hall, "Graphical Comparison of Predictions for Speed Given by Catastrophe Theory and Some Classic Models," In Transportation Research Record 1398, TRB, National Research Council, Washington, D.C., pp.119-124.

Koshi, M., M. Iwasaki, and I.Ohkura, "Some Findings and an Overview on Vehicular Flow Characteristics," Proc., 8th International Symposium on Transportation and Traffic Theory (V. F. Hurdle, E. Hauer, and G. N. Steuart, eds.), University of Toronto Press, Ontario, Canada, 1983, pp. 403-426.

Navin, F.P.D, "Traffic Congestion Catastrophes," Transportation Planning and Technology, Vol. 11, 1986, pp. 19-25.

Special Report 165: Traffic Flow Theory - A Monograph, TRB, National Research Council, Washington, D.C.,1975.

Special Report 165: Traffic Flow Theory - A Monograph, Revised ed. TRB, National Research Council, Washington, D.C.,1997.

Special Report 209: Highway Capacity Manual, 3rd ed. TRB, National Research Council, Washington, D.C., 1994.

Bernard Rosner, "Percentage Point for a Generalized ESD Many Oulier Procedure," Technometrics ©, Vol. 25, No. 2, May 1983.

S. Cohen and C. Nouveliere, "Travel Time on Urban Controlled Links : A Neural Network Approach," 1997.

James A. Freeman and David M. Skapura, Neural Networks, Addison-Wesley, 1992

Optimization of Railway Operations Using Neural Networks, Transpn Res, 1993.

G. N Wang, "An Adaptive Hybrid Neural Network Approach to Prediction of Nonstationary Process," Hybrid Intelligent System Application, Edited by Dr. Jay Liebowitz, IOS Press, 1995.

G. N Wang and Y. C. Go, "On-line Neuro-Tracking of Non-Stationary Manufacturing Processes," Computers and Industrial Engineering, Vol. 30, No. 3, pp. 449 ~ 461, July, 1996.

W. W. Wei, Time Series Analysis, Addison Wesley, 1990.

K. L. Moore, Iterative Learning Control for Deterministic Systems, Springer-Verlag, 1993.

C. H. Wei and P. M. Schonfeld, "An Artificial Neural Network Approach For Estimating Multiperiod Travel Time In Transportation Networks," Presented At The 71st Annual Meeting Of The Transportation Research Board, 1993.

L. Fausett, Fundamentals of Neural Networks-Architectures, Algorithms, and Applications, Prentice Hall, 1994.

Al-Deek, H. M. and Wang, M.(1998), Travel Time Prediction

with Non-Linear Time Series, Proceedings of the ASCE 5th International Conference on Applications of Advanced Technologies in Transportation, Newport Beach, CA, pp.317~324.

Anderson, J. M., Bell, T., Sayers, F., and Busch, G.(1994), The Short-Term Prediction of Link Travel Time in Signal Controlled Road Networks, Proceedings of the IFAC/IFORS 7th Symposium on Transportation Systems : Theory and Application of Advanced Technology, Tianjin, China, pp.621~626.

Ashish, S., Piyushimita, T., Xioquon, Z., and Alan, F.(1997), Frequency of Probe Vehicle Reports and Variance of Arterial Link Travel Time Estimates, Journal of Transportation Engineering, ASCE, Vol. 123, No. 4, pp.290~297.

Bajwa, S., Chung, E., and Kuwahara, M.(2003), Sensitivity Analysis of Short-term Travel Time Prediction Model's Parameter, 10th ITS World Congress, Madrid, Spain.

Hellinga, B. and Gudapati, R.(2000), Estimating Travel Times from Different Data Sources for Use in ATMS and ATIS, Proceedings of the ITE District 1 & 7 Joint Annual Conference held in Niagara Falls, Ontario, May 6.

Chi, X. and Reuy, L.(2004), Improving Arterial Link Travel Time Estimation by Data Fusion, 83rd TRB Annual Meeting.

Dion, F. and Rakha, H.(2003), Estimating Spatial Travel Time Using Automatic Vehicle Identification Data, 82nd TRB Annual Meeting.

Dion, F. and Rakha, H.(2006), Estimating Dynamic Roadway Travel Times Using Automatic Vehicle Identification Data for Low Sampling Rates, Transportation Research Part B, Vol. 40, No. 9, pp.745~766.

Emam, E. and Al-Deek, H.(2005), Utilizing a Real Life Dual Loop Detector Data to Develop a New Methodology for Estimating Freeway Travel Time Reliability, 85th TRB Annual Meeting.

Nishiuchi, H., Nakamura, K., Bajwa, S., Chung, E., and Kuwahara, M.(2006), Evaluation of Travel Time and OD Variation on the Tokyo Metropolitan Expressway Using ETC Data, 22nd ARRB Conference, Canberra, Australia.

Olivier, D. and Nour-Eddin, E.(2006), Innovative Processing of Toll Collection Data, LICIT report, No. 0604.

Shamas, Chung, and M. Kuwahara(2003), Sensitivity Analysis of Short-Term Travel Time Prediction Model's Parameters, Proceedings of 10th ITS World Congress , Madrid, Spain.

Soriguera, F., Thorson, L., and Robuste, F.(2007), Travel Time Measurement Using Toll Infrastructure, Transportation Research Record 1981, pp.99~107.

Yoshikazu(1999), Travel time calculation method for expressway using toll collectionsystem data, Intelligent Transportation Systems.

A.S. Fowkes. 2001. Value of Time for Road Commercial Vehicles. Working Paper 563. ITS Leeds.

Wardman, M. 1987. An Evaluation of the Stated Preference and Transfer Price Data in Forecasting the Demand for Travel. University of Leeds PhD thesis.

Ⅲ. 기타

<http://www.police.go.kr>

<http://www.mltm.go.kr>

<http://www.kor-kst.or.kr>

<http://www.kits.or.kr>

책임연구보고서 2011-12

운전자 통행시간예측을 위한 신경망 -칼만필터 알고리즘 적용 및 검증-

2011년 12월 20일 발행

발행인 : 한 광 일

발행처 : **치안정책연구소**

경기도 용인시 기흥구 언남로 74

홈페이지 : www.psi.go.kr

이 책의 무단 복제를 금합니다.

이 책자에 게재된 내용은 연구자 개인의 의견이며
치안정책연구소 공식견해가 아님을 밝혀드립니다.



POLICE SCIENCE INSTITUTE