

■ 論 文 ■

자석검지기를 이용한 차종인식 알고리즘개발

Development of Vehicle Classification Algorithm
Using Magnetometer Detector

김 수 희

(아주대학교 교통연구센터 연구원)

조 형 기

(아주대학교 교통연구센터 수석연구원)

오 영 태

(아주대학교 환경도시공학부 교수)

이 철 기

(아주대학교 교통연구센터 수석연구원)

목 차

- I. 서론
 - 1. 연구배경 및 목적
 - 2. 연구의 방법 및 범위
 - II. 이론적 고찰
 - 1. 자석 검지기의 원리
 - 2. 신경망 이론
 - 3. 국내·외 현황
 - 4. 차종인식 시스템
 - III. 차종인식 알고리즘 개발
 - 1. 차종별 파형의 특성분석
 - 2. 차종인식 알고리즘 개발
 - IV. 차종인식 알고리즘의 평가
 - 1. 차종인식 알고리즘 평가방법
 - 2. 자료의 처리 및 분석
 - 3. 차종 분류별 평가결과
 - 4. 개발모형의 종합분석
 - V. 결론 및 향후연구과제
- 참고문헌

요 약

본 논문의 목적은 최근에 개발 중에 있는 단일 자석검지기를 이용한 차종인식 알고리즘을 개발하고, 현장실험을 통한 현장 적용성을 검토하는 것이다.

고속도로에 설치되어 있는 자석검지기를 이용하여 자료를 수집하며 분석에 이용되는 자료는 개별차량에 대하여 자속밀도의 변화에 따른 전압 값을 Digital Data값으로 변환한 수치를 사용하였다. 그 수치를 토대로 각 차량의 점유시간을 파악하여 각 차량의 점유시간동안 파형의 특징을 추출하여 각 특징들을 기초로 하여 각 차량이 나타내는 고유의 파형을 식별하는 Template Matching 방법과 신경망기법, 그리고 이들을 상호 보완한 복합기법을 사용하였다.

검지차량에 따른 다양한 점유시간을 일정크기로 수평성분 정규화하고 이에 따른 자속속밀도의 변화에 의한 전압 값을 차종별로 샘플을 취하여 이동평균방법으로 처리를 한 후 위의 세 가지 기법을 사용하여 검지차량의 파형과 기준 파형을 비교하여 차종을 인식하는 방법으로 알고리즘을 개발하였다.

차종의 분류는 3가지 단계로 하였는데 2종분류, 3종분류, 5종분류로 접근하였다. 그리고 각각의 분류에 따라 정규화 크기 및 이동평균간격을 달리하여 적용하여 보았고 2종분류에서 인식율이 82%수준이다.

1. 서론

1. 연구배경 및 목적

도로상의 교통상태를 파악하고 이에 따른 적합한 교통제어를 수행하기 위해서는 목적인 교통정보를 수집할 수 있는 다양한 검지센서들이 도로 위에 매설되거나 도로변에 설치되어야 한다. 이러한 검지 목적의 센서들은 유도식 루프검지기 뿐만 아니라 마이크로웨이브, 초음파 센서, 최근 개발중인 자석 검지기 등 다양한 센서들이 사용되고 있지만 국내는 물론 국외에서도 아직 유도식 루프검지기가 주를 이루는 실정이며, 현재 전세계적으로 루프검지기의 한계성 즉, 설치 및 유지보수면에서의 한계를 극복하기 위한 노력으로 여러 가지 대체검지기의 개발이 이루어지고 있는데 대표적인 예가 바로 영상검지기, 자석검지기 등이 있다.

차종구분의 필요성은 우선 교통공학이나 교통계획에서 화물과 사람의 이동등 교통패턴을 파악할 필요가 있으며 이를 위하여 화물차량과 소형차량의 구분이 선행되어야 하고, 현재 사용되고 있는 루프검지기들은 차종구분이 실행되지 않아 신호교차로의 포화도 산출 및 고속도로상의 용량산출에 어려움을 겪고 있고, 또한 도로의 포장설계와 같은 구조적 측면에서도 차종파악은 필수적이며, 교통관련자료 구축이라는 점에서 볼 때에도 매우 중요하다.

그러나 아직 국내에서 운영 중에 있는 각종 검지기 체계들은 외국에서 개발한 체계로서 루프검지와 피에조 센서 등 다양한 센서들을 복합구성해서 차종을 구분하는 고가의 장비들이다.

이에 본 연구의 목적은 최근에 개발되어진 자석 검지기를 이용하여 각 차량의 고유파형을 식별하는 차종인식 알고리즘을 개발하는 것이며, 이 알고리즘을 현장실험을 통하여 현장 적용성을 검토해 보는 것이다.

2. 연구의 방법 및 범위

본 연구에서 목표한 알고리즘은 고속도로상에 설치된 자석 검지기를 대상으로 하고, 본 연구에서 목표한 알고리즘은 차종의 인식을 위하여 고속도로상에서 계속빈도가 높은 차종을 대상으로 하여 가능한 한 구체적으로 차량의 차종인식을 기본으로 한다. 또한 단

일 자석 검지기를 기반으로 알고리즘을 개발하는 것으로, 자석 검지기를 통과하는 차량은 통과시 등속도로 통행함을 가정하며 지체나 정체에 의한 비등속통행은 제외시킨다.

본 연구에서는 검지기 매설장소의 유한성 및 연구대상 도로의 특성으로 인하여, 다양한 차종의 자료수집이 용이하지 못하지만 차종인식 알고리즘상의 차종분류는 우선 구분이 확실한 차종으로 나눈 후 가능한 한 건설교통부 분류기준에 따라 세부적 차종분류로 접근하여 분석하며 점유시간동안 수집된 차종별 파형의 특징을 기초로 한다. 분석에 이용되는 자료는 개별차량에 대한 주파수 변화 값이며, 고속도로에 설치되어 있는 자석 검지기를 이용하여 수집한다. 고속도로를 통행하는 각각의 차량(승용차, 승합차, 소형트럭, 대형버스, 중형트럭, 대형트럭)에 대하여 자속밀도의 변화에 의한 전압 값을 Digital data로 변환시킨 값을 토대로 한다. 이러한 Data를 토대로 각 차량의 점유시간을 파악하여, 각 차량의 점유시간 동안 파형의 특징을 추출하고 추출된 각 특징들을 기초로 하여 각 차량이 나타내는 고유의 파형을 식별하는 통계적 기법을 기반으로 하는 Template Matching 방법 및 신경망기법으로 접근한다. 연구절차에 있어서는 1차적으로 자료를 수집하고 수집된 자료의 전처리 과정을 거친후 대상차량의 차종을 분류하는 순서로 이루어지며 이에 대한 검증 및 현장 적용성평가도 함께 실시한다.

II. 이론적 고찰

1. 자석 검지기의 원리

1) 특성

자석검지기(Magnetometer detector)는 도체로 설계된 차량이 검지기 위를 통과할 때 지구 자장의 변화를 측정함으로써 차량의 존재를 검지하기 위해 설계된 검지기이다. 이 검지기는 교통량 산출에는 매우 효과적이며, 루프검지기와는 달리 철근이 포함된 교량에서도 작용한다. 지구는 극에서 극으로 연결된 자속선을 가진 거대한 막대 자석으로 볼 수 있으며, 수직축의 한쪽 극에서 다른 쪽 극으로 자속이 이동하며, 측정위치에 따라서 자속의 각도가 달라지며 우리나라 중부 지방에서의 각도는 약 55도 방향이다. 그

러므로 자장의 선이 평평한 적도 근처에서는 수직축 자석이 사용될 수 없다. 또한 우리나라에서 지구 자장의 강도는 0.45GAUSS 정도이며, 차량의 이동시 0.01~0.2GAUSS 정도의 변화가 발생한다.³⁾


헤드(센서)에 신호를 발송하는 방식에는 유선과 무선 전자파로 통신하는 두 가지 방식이 있다. 유선은 헤드를 자동차가 다니는 고속도로 경계선 중앙에 매설하고 연결선을 도로 옆 PCB판까지 홈을 파고 매설한다. 무선 전자파 통신 방식은 헤드와 PCB판, 충전 배터리, 배터리에 충전하는 충전 장치 등을 비 자성 재료인 황동 혹은 구리로 만든 케이스 속에 고정하여 도로 경계선 중앙에 매설한다. 무선 전자파 통신 방식을 실현하려면 다음 세 가지 사항을 만족해야 한다. 첫째, 저파워 회로를 작성한다. 전원은 7.5V를 사용하며, 전자파 방사 범위는 약 50m로 하면 충분하다. 둘째, 일정한 주파수로 전자파를 방사하는 회로가 설치되어야 한다. 황동 혹은 구리로 만든 케이스는 전자파를 방사하는 안테나 역할도 겸비한다. 셋째, 배터리의 전류소비를 보상하는 충전장치가 있어야 한다.³⁾

2) 검지원리


비정질연자성 Wire-Core의 MagnetoImpedance (MID)의 원리를 이용한 자석검지기는 비정질 Wire에 1차 코일과 2차 코일을 감고 1차 코일에 oscillator로부터 12~16kHz의 교류 전류를 가하면 1차 코일에서 pulse가 생긴다. 2차 코일에는 지구의 자장을 저소 보상하는 전류를 가한다. 헤드를 노면에 자동차가 진행하는 방향과 평행이 되게 고정하였을 때 코일 속에 자장이 0 이 되도록 보상전류를 조절하여 넣는다. 만약 Wire의 축 방향으로 자장이 작용하였을 때 비정질 Wire의 자화 회선과 그의 면적이 저하되어 Wire의 교류 Impedance가 적어지고 출력 pulse의 peak 값이 급격히 하락한다.

자석검지기가 차량을 검지 하는 원리를 그림을 통하여 설명하면 다음과 같다.


- 차량이 없을 때 지구 자장의 분포는 일정 값의 동일한 크기로 된다.
- 차량이 센서에 근접하면 자속의 밀도가 차량 쪽으로 이동해서 -값을 갖게 되며, 차량의 중심부에서는 자속의 밀도가 높아져 자속의 크기가 +값을 갖게 된다.
- 이러한 변화량을 검지하여 회로에서 차량의 길이에 해당하는 펄스신호를 출력하게 된다.



〈그림 1〉 차량이 없을 때의 자속



〈그림 2〉 차량이 센서 위를 통과했을 때의 자속의 변화



〈그림 3〉 시간에 따른 자속 변화

3) 검지정보 및 장단점

자석 검지기에 의해 수집되는 교통량, 속도, 점유율, 차량길이, 차량의 존재시간등이다. 속도나 차량길이를 측정하기 위해서는 반드시 2개 이상의 센서(sensor)를 매설해야 하며, 그 이외의 자료는 1개의 센서(sensor)로도 측정이 가능하다. 자석 검지기를 이용하여 수집할 수 있는 교통정보자료와 장단점은 다음과 같다.

〈표 1〉 자석검지기 정보 및 장단점

교통정보 수집자료	- 교통량(Volume) - 속도(Speed) - 점유율(Occupancy) - 차량길이(Vehicle-Length) - 차량존재시간(Presence Time)
장 점	- 설치시 교통흐름의 통제가 거의 없다 - 설치비용과 유지관리 비용이 저렴하다 - 검지정보의 신뢰성이 우수하다 - 검지영역에 대한 감도를 조절할 수 있다.
단 점	- 지구자장 각도의 영향 때문에 사용 불가능 지역이 존재한다. (적도를 중심으로 +20° ~ -20°범위에서 사용 불가능) - 무선 사용시 전지 수명의 한계성

2. 신경망 이론

1) 신경망의 배경

신경망 모델의 시초는 1943년 맥컬릭(McCulloch)과 피츠(pitts)의 논문에서 찾을수 있다. 그들은 인간의 두뇌를 수많은 신경세포들로 이루어진 잘 정의된 컴퓨터라고 여겼다. 그들은 단순한 논리적 업무를 수행하는 모델을 보여주었고 또한 패턴분류문제가 인간의 지능적인 행위를 규명하는 이론에 매우 중요하다는 것을 인식하였다. 헵(Hebb)의 학습규칙은 두 뉴런사이의 연결강도(weight)를 조정할 수 있는 최초의 규칙이었다. 이 규칙은 학습에 관한 연구를 발전시켰으며 적용적인 신경망 연구에 많은 영향을 끼쳤다. 이후에 로젠블랫(Rosenblatt)이 1957년 퍼셉트론(Perceptron)이란 최초의 신경망 모델을 발표하였고 민스키(Minsky)와 파퍼트(Papert)가 퍼셉트론(Perceptrons)란 저서에서 퍼셉트론 모델을 수학적으로 철저히 분석하여 그 모델의 단점들을 밝혀내고 난 후 신경망에 관련된 연구는 약 20년간 침체의 길을 걷게 되었다. 그러다가 1970년대 말과 1980년대 초반에 들어 코호넨(Kohonen), 홉필드(Hopfield), 커크패트릭(Kirkpatrick), 힌턴(Hinton), 그로스버그(Grossberg), 러멜하트(Rumelhart)등이 신경망을 다시 활성화 시켰다.⁸⁾

2) 개념

신경망의 구성은 네트워크의 위상(topology), 유닛, 학습규칙의 세가지 요소로 구성된다. 네트워크의 위상은 각 유닛들이 연결된 형태로서 기본적인


로 입력층과 출력층, 그리고 이 두개층을 연결하는 연결강도(weight)로 구성되어 있다. 네트워크의 위상은 항상 일정한 것이 아니며 경우에 따라 그 위상을 다르게 구성할 수가 있다.

예를 들어, 다층으로 구성된 네트워크인 다층퍼셉트론인 경우에는 가장 하위에 위치한 입력층과 가장 상위에 있는 출력층, 그리고 그 사이에 여러개의 은닉층으로 이루어진 은닉층(hidden layer)으로 구성되는데, 이 네트워크에서 은닉층의 수, 그리고 각층을 이루고 있는 유닛의 수는 항상 고정되어 있는 것이 아니라 학습패턴에 따라 적절히 조정하여 구성한다. 유닛은 각 층을 이루고 있는 노드이며, 입력층인 경우 하나의 패턴을 이루고 있는 변수의 수만큼 노드 수가 존재하는데 예를 들어 p차원의 패턴이 네트워크로 입력되어 학습을 한다고 했을 때 이 네트워크는 p개의 입력노드가 필요하다.

네트워크의 입력층과 출력층, 또는 은닉층을 연결하는 연결강도의 값은 반복이 이루어지면서 계속 조정이 되는데 이 작업을 학습(learning)이라고 하고 이 학습은 일정한 공식에 의해서 이루어지는데 이를 학습규칙이라 한다. 신경망에 의한 클러스터링은 신경망의 기본 구성인 네트워크의 위상, 유닛, 학습규칙의 세가지 요소를 갖고 있으면서 입력패턴을 몇 개의 그룹으로 구분하여 출력시키는 네트워크를 의미한다. 네트워크의 위상은 입력층과 출력층인 두 개의 층으로 구성되며, 입력층과 출력층의 연결은 완전연결(fully connected)되어 있다. 유닛은 입력 유닛인 경우 패턴을 이루고 있는 변수의 개수로 구성되고, 출력층은 클러스터의 수, 또는 2차원 정방격자로 구성되며, 학습규칙은 계속 반복을 시켜 가면서 입력패턴과 연결강도와의 차이를 줄여 나가는 방법에 의하여 학습을 한다.

3) 백프로파게이션(Back-propagation) 학습알고리즘

초기의 신경망 모델이었던 퍼셉트론(Perceptrons)는 간단한 선형문제(XOR문제)조차 풀지 못하는 구조적 단점으로 인해 침체일체로 빠진다. 그러나 1980년도 중반에 퍼셉트론의 단점을 극복하기 위해 입력층과 출력층 사이에 한 개이상의 은닉층(hidden layer)을 두는 새로운 모델이 출현하게 되었다. 이런 다층 네트워크는 모든 입력패턴에 대해 발생하는 오차함수를 최소화하는 방향으로 연결강도(weight)를 조정하는 백프로파게이션 학습알고리즘을 사용하며, 은닉층



〈그림 4〉 네트워크의 다층(multi-layered)구조

의 노드특성을 비선형 함수로서 퍼셉트론의 단점을 극복하였다. 이러한 다층네트워크는 〈그림 4〉와 같이 한 개이상의 은닉층으로 구성되어 있으며, 입력되는 데이터 패턴은 입력층에서 출력층으로 전달되며, 연결강도는 이와 반대로 출력층에서 입력층쪽으로 역방향으로 이루어진다. 백프로퍼게이션 학습알고리즘의 기본원리는 다층네트워크와 같은 방식으로 입력층의 각 유니트에 입력패턴을 주면 이 신호는 각 유니트에서 변환되어 중간층에 전달되고 최후에 출력층에서 신호를 출력하게 된다. 이 출력값과 기대값을 비교하여 차이를 줄여나가는 방향으로 연결강도를 조정하고 상위층에서 역전파하여 하위층에서는 이를 근거로 하여 다시 자기층의 연결강도를 조정해 나간다.

3. 국내·외 현황

1) 기존의 차종분류방식 고찰

차종의 구분은 교통공학이나 교통계획서 필수적이며 중차량 및 승용차의 기능 및 역할이 다르기 때문에 생기는 문제를 해결하기 위한 필수 고려요소로써 각 나라마다 실정에 맞는 차종구분을 하고 있다. 본 절에서는 각 국가별로 차종분류현황을 알아보고 차종분류가 가능한 장비들에 대해 센서(sensor)를 중심으로 소개하도록 하겠다.

(1) 영국

차종은 자전거, 이륜차, 승용차 및 택시, 대형버스 및 코치, 경트럭 및 축수 및 축거에 의하여 구분되는

6종의 화물차 등을 포함하여 도합 11개 유형으로 분류하고 있고, 각 장비들의 특징은 다음과 같다.

- MARKSMAN600 : 입력센서는 튜브, 루프, 피에조, 중량센서의 조합으로 운영됨
- MARKSMAN 660 : 차종분류와 다차선 중량 측정(WIM)이 가능하다.
- MARKSMAN MK3 Series : 피에조 차량분류기(Piezo Vehicle Type Classifier : VTC)를 루프검지기와 연결하여 운영함

(2) 미국

차종분류기준은 각 주에 따라 조금씩 다르지만 최종적으로는 FHWA기준인 총 6개 차종으로 다음과 같이 분류한다.

- GK5000 Series : 입력센서로서 2 airswitch, 2 contract 또는 2 piezo cable을 이용함
- GK6000 Series : 입력센서로서 2airswitch, 8loop detector, 8 N/O contact, 8 piezo를 조합하여 운영함
- TrafficCOMP III241 : 입력센서로서는 Road tubes, 루프, 피에조 케이블이 있으며 축 분류에 의하여 차종을 분류함

(3) 일본

차종은 이륜차, 승용차 및 대형버스, 대형트럭 및 특수차 등 3개로 구분한다.

- 3P5HE-02 : 루프와 초음파 센서를 조합하여 사용하며 차종분류의 기준은 〈표 2〉와 같다.

〈표 2〉 3P5HE-02 의 차종분류 기준

차종	분류방법
승용차	차량 높이 1.48m 미만인 차량
소형화물	차량 높이 1.48m이상 2.0m미만인 차량 차량 높이 1.48m이상, 전장 4.75m 미만인 차량
대형화물	차량 높이 2.0m이상, 전장 4.75m이상인 상면이 높은 차량
버스	차량 높이 2.0m 이상, 전장 4.75m 미만 상면이 낮은 차량

〈표 3〉 MT시리즈의 차종분류

장비종류	차종수	구 분 내 용
MT06	2차종	· Cars · HGVs(heavy goods vehicle)
MT08	3차종	· Cars · HGVs · HGVs with trailers or articulated loories
MT10	5차종	· Cars · Cars towing trailers · Buses · HGVs · HGVs with trailers or articulated loories

〈표 4〉 건설교통부 차종 분류기준

차종	분류기준				
	축수 (軸)	윤수 (輪)	UNIT (個)	축거(mm)	OH(mm)
1종 승용차	2	4	1	≤2800	
2-1 소형버스				2800 ~ 3500	≤1200
2-2 중형버스	2	6	1	3500 ~ 6500	>2000
3-1 소형트럭	2	4/6	1	≤3500	1200 ~ 1400
3-2 중형트럭	2	6	1	3000 ~ 6000	1400 ~ 2000
3-3 대형트럭A	3	10	1	≤5000	
3-4 대형트럭B				5000 ~ 8000	
4-1 대형트럭C	4	12	1		
4-2 대형트럭D	4	14	2		
5종 대형트럭E	5	18	2		
6종 대형트럭F	6	22	2		

〈표 5〉 한국도로공사 TCS기준 차종 분류

차종	분 류 기 준
1종	2축, 륜폭 279.4mm이하 - 16인승 이하 승용 - 1.4톤 이하 화물차
2종	2축, 륜폭 279.4mm초과, 륜거 1,800mm이하 - 17~32인승 중형버스 - 5.5톤 초과 화물차
3종	2축, 륜폭 279.4mm초과, 륜거 1,800mm초과 - 33인승 이상 대형버스 - 5.5톤 초과 화물차
4종	3축차량
5종	4축차량

(4) 프랑스

전국 도로망에 걸친 이동화물량을 파악할 목적으로 S.A.T.L.시스템(화물차량 자동검지체계)을 이용하는데 일반적으로 과적 행위가 자주 발생하는 곳에 설치하며, 차종에 따라 5개의 대분류 및 12개의 소분류를 한다.

- HESTIA-B : 센서의 구성은 2개의 루프와 1개의 피에조이며 14종 분류가능
- HESTIA-A : 센서의 구성은 1개 루프와 2개의 피에조이며 33종 분류가능

(5) 독일

AVE사의 MT시리즈는 패턴인식 기법에 의하여 차종을 구분하며, 차종분류내용은 〈표 3〉과 같고 센서로는 루프검지기가 사용된다.

(6) 한국

교통량 조사체계에서의 차종은 승용차, 소형버스, 중형버스, 소형트럭, 중형트럭 및 대형트럭을 축수와 축거에 따라 6개로 총 11종으로 분류하고 분류기준은 〈표 4〉와 같고, 한국도로공사의 TCS (Tollgate-Collection System)체계에서는 축수, 륜폭, 륜거에 의해 5종으로 분류하며, 분류기준은 〈표 5〉와 같다.

4. 차종인식 시스템

1) 차종인식 시스템 연구사례

(1) 국내 연구사례

국내의 경우 1994년 한국도로공사의 FTMS관련 사업의 일환으로 고속도로에 각 차선 당 2개의 원형검지기를 설치하여 대, 중, 소에 대한 차종을 구분한 바 있다. 이는 본래 목적상 차종을 구분하기 위함이 아니고 단지 통행차량의 길이를 수집하기 위함이었다. 이외에 1995년 조한선의 단일 루프검지기 기반의 차종분류 알고리즘개발, 1998년 조형기의 신경망을 이용한 루프기반 차종인식 모형개발등이 있었다.

(2) 외국사례

외국의 경우 1980년에 레이머(J. J. Reijmer)는 두 개의 ILD를 조합하여 한차선에 연속된 두 개의 ILD를 통행하는 차량에 의해 발생되는 인덕턴스의

〈표 6〉 교통량 조사장비

국가	장비명
미국	- GK 5000, 6000시리즈 - TrafiCOMPII model 241 - MSC 3000, 3000-4, 3000-8
영국	- MARKSMAN 600, 660
일본	- Type 3P5HE-02 - Loop+초음파 - STC-1~STC-4
프랑스	- HESTIA-B
독일	-MWD(Microwave Detector) -MAVE System -VISA, 5000 series AWACS

변화에 대한 자료를 사용하였다. 차종분류를 효과적으로 하기 위하여 특정 추출방법을 채택하였으며 클레이톤 스테와트(Clayton Stewart et al.)는 신경망 이론에 기초한 차종인식 모형을 연구 발표하였다. 이 연구는 레이더로부터 수집되는 자료를 사용하였으며 이를 기반으로 승용차와 픽업차량 그리고 밴(Delivery van), 불도저등 총 4개 차종을 인공신경망 모델중 비교사학습모델인 학습벡터 양자화(Learning Vector Quantization:LVQ)방법을 적용하였다.

2) 국내외 시스템 개발사례

ILD를 기반으로 하는 차종인식 관련 기개발된 사례는 국내의 경우 전무한 실정이다. 반면에 외국의 경우 영국과 미국 그리고 프랑스, 독일에서 개발된 몇몇 시스템들이 이미 국내에 설치 운영된 바 있으며 1993년에 도로교통량 조사체계 및 장비에 관한 연구의 일환으로 이들 시스템의 정확도 실험이 수행된 바 있다. 이 연구에서는 주로 이동식 장비를 주요 대상으로 하였으며 다음과 같은 나라별, 장비들이 고려되었다.

III. 차종인식 알고리즘 개발

1. 차종별 파형의 특성분석


1) 자료수집 지점선정 및 방법

본 연구에서 개발하고자 하는 차종인식모형이 현장에서 현실적으로 적용가능할 수 있도록 하기위하여 고속도로를 대상으로 자료를 수집하였고, 계측빈도가


높은 차종을 대상으로 하여 가능한한 구체적으로 차종의 자료를 수집하였다.

(1) 자료수집 지점선정

자료 수집지점은 판교~구리간 고속도로의 성남 TOLL-GATE에서 판교방향 전방 1KM에 설치된 지점이다.



〈그림 5〉 현장 자료수집 환경



〈그림 6〉 자석검지기 현장 설치도

(2) 자료의 수집방법

현장에서의 차종의 분류 및 수집은 실시간으로 이루어지며 유선통신방식으로 수집되며, 수집시 개별 통과차량에 대하여 수동방식으로 차종을 직접 분류하고 검지기 수집정보와 차종정보를 1 : 1 대응시켜 자석 검지기로부터 파형에 관한 자료가 수집될 때 자료의 저장과 동시에 차종의 코드를 함께 저장하는 방식을 취한다.

자료수집시 균을 2분화하여 수집을 한다. 1균은 모형수립을 위한 자료이며, 2균은 모형의 검증을 위한 자료로 활용한다.

〈표 7〉 수집 차종별 구성

차종	구성차종 및 특성
승용차	1종 국내의 모든 승용차 포함
승합차	2종 15인승이하의 승합차
소형트럭	3종 1톤트럭
대형버스	4종 45인승기준의 대형버스
중형트럭	5종 2.5톤~8톤트럭
대형트럭	

〈표 8〉 자료수집 현황

수집구분	모형수립용		모형검증용		차종별 소 계
장소	판교~구리간 중부고속도로				
일시	12월 6일~12월 7일				
수집 자료수	차종	자료수	차종	자료수	
	승용차	67	승용차	40	107
	승합차	35	승합차	23	58
	소형트럭	38	소형트럭	25	63
	대형버스	15	대형버스	10	25
	중형트럭	25	중형트럭	20	45
	대형트럭	29	대형트럭	20	49
	소계	209	소계	138	총계 347

2) 자료의 처리

(1) 자료의 처리

본 연구에서 사용되는 자료들은 자석 검지기의 점유시간자료이다. 이 자료는 통행속도에 따라 변화하므로 검지되는 샘플링수가 변하게 된다. 이러한 자료는 원시자료를 그대로 사용하여 그룹화 한다면 많은 문제가 야기되므로 수평(샘플링된 Data)성분의 정규화 및 이동평균기법이 적용된 후 사용한다.

① 정규화 처리

파형의 정규화는 다양한 점유시간에 의한 파형 변화를 표준화함으로써 일률적이며, 효과적인 특징 추출을 위한 전처리 과정이 될 수 있다.

본 연구에서 수평성분의 정규화는 자석검지기로부터 수집되는 파형의 시간계를 일률적으로 표준규격에 축소화하기 위하여 적용된다. 이는 차량 통과시 수집되는 파형이 차량의 통행속도에 따라 차량마다 파형의 시간계가 다양하게 변하여 이를 표준화하기 위함이다. 물론 정규화를 위한 사전정보로서 원시자료의 최대 샘플링수 및 표준규격의 수평성분의 크기를 알

고 있어야 한다. 여기에서 최대 및 최소값은 점유시간동안 계측된 변환 자료들중 최대값과 최소값을 의미하며, 대상자료의 표본수는 점유시간동안 계측한 횟수를 의미한다. 표준규격의 가로와 세로는 각각 계측된 주파수 자료와 계측순위이다. 수평성분에 대하여 정규화하는 식은 다음과 같다.

$$X(i) = \frac{i \times (X_{max} - X_{min})}{N}$$

X(i) : 정규화된 수평성분의 값

X_{max} : 표준규격의 수평성분 최대값

X_{min} : 표준규격의 수평성분 최소값

N : 원시자료의 샘플링 수

i : 원시자료의 샘플링 순서 i

② 이동평균(Moving Average)법을 이용한 처리

이동평균 방법이란 과거의 관측이 평균에 얼마나 많이 포함되는가를 처음으로 특정화하는 법을 말한다. 즉 다시 말해서 이동평균(Moving Average)이라는 용어는 시간계가 존재하는 관측에서 각각 관측되는 값들이 새로운 값이 되기 때문에 새로운 평균은 구 관측값을 버리고 새로운 관측값을 도입하여 계산하는 것을 의미한다.⁹⁾

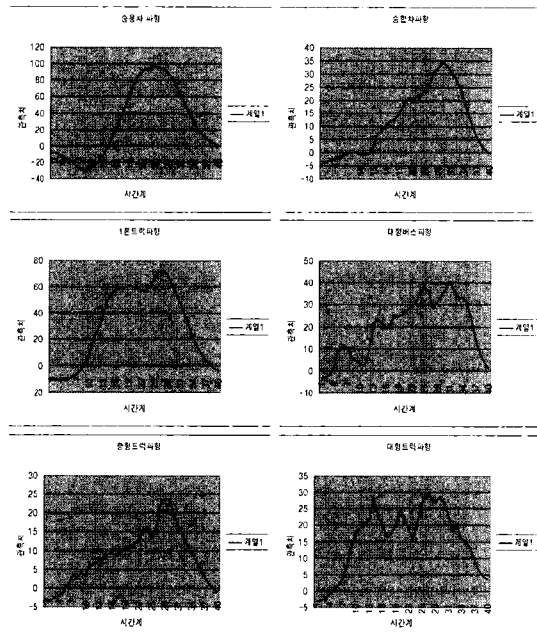
본 논문에서는 시간에 따른 파형수치의 미세한 변화 혹은 이상치에 대한 영향을 줄이고 파형수치들의 평균에 더욱 가깝게 하기위하여 이러한 기법을 사용한다.

3) 차종별 파형의 특성


본 연구에서 수집한 각 차종별 수치data는 차종에 따라 파형의 형태로 표현될 수 있다. 본 연구에서 목적인 차종인식 알고리즘의 개발을 위하여 수집된 차종별 파형의 형태에 대한 특성을 분석한다.

〈그림 7〉에서 보여지는 파형은 X축정규화만으로 자료를 처리하여 각 차종별로 평균파형을 보여준 것이다.(X축은 정규화한 시간계이며 Y축은 이동평균기법을 사용한 관측치임)

승용차의 파형은 1개의 상위 변곡점을 가지고 있고, 1톤트럭의 파형은 2개의 상위 변곡점을 보이며, 대형버스 및 중대형트럭은 불규칙한 상위 변곡점을 가지며 변곡점의 개수도 증가함을 보인다.



〈그림 7〉 각 차종별 정규화(X축)파형



〈그림 8〉 동일계내에서의 각 차종별 정규화한 파형

〈그림 8〉은 〈그림 7〉의 파형을 가지고 Y축을 동일한 Scale로 환산하여 동일계에 나타낸 것이다. 승용차의 경우 최대값이 월등히 높은 값을 가지며 상위 변곡점이 1개가 존재한다는 것이 특이사항이고, 승합차의 경우는 승용차보다 낮은 최대값을 가지며 굴곡이 별로 없는 완만한 형태를 취한다. 소형트럭의 경우는 두 개의 봉우리를 가지며, 대형버스, 중형트럭, 대형트럭은 Y축의 값이 다른 차종보다는 낮은 경향을 보이고 있다.

2. 차종인식 알고리즘 개발

1) 접근 방법

차종인식 알고리즘에 있어서 3가지 단계로 차종분류를

시킨다. 단계별 차종인식 대상은 1단계 대상차종은 2종으로서 승용차 1종, 승용차를 제외한 차종 1종의 분류이고, 2단계 대상차종은 3종으로서 차량의 길이를 이용하여 소형차량군으로 통합시킨 1종 및 외관형태를 고려한 대형버스 1종, 중대형트럭의 통합 1종이며, 3단계 대상차종은 3종분류에서 소형차량군을 세분화하여 5종으로서 승용차, 승합차, 소형트럭, 대형버스, 중형 및 대형트럭으로 구성된 분류이다.

2) 모형 수립

차종인식 모형수립은 목표 차종별 자료군을 정리한 후 차종별 전장길이 즉 차종구분시 외관형태가 유사한 것끼리 그룹화하여 차종별 기준파형을 구축한다. 여기에 사용된 적용방법은 Template Matching 방법, 신경망의 백프로퍼게이션(Backpropagation) 알고리즘. 앞의 두가지 기법과 파형의 변곡점의 개수를 고려한 복합기법을 적용하였다.

(1) Template Matching 방법


본 연구에서는 Template Matching 방법으로서 파형의 특징을 고려한 기법이다. 차종인식 방법에서는 오차제곱합(SSE: Error Sum of Square)을 사용하는데 자세한 내용은 다음과 같다.

다음의 식은 오차제곱합을 나타낸 것이다.

$$SSE = L_1^2 + L_2^2 + L_3^2 + L_4^2 + \dots + L_n^2$$

$$SSE = \sum_{i=1}^n (L_n^2)$$

〈그림 9〉는 정규화 과정 및 이동평균과정을 거친 파형으로서 위의 식을 토대로 하여 대상 차량의 파형을 가지고 각 차종의 기준파형과 SSE를 산출하고 최소가 되는 SSE를 갖는 차종을 대상차량의 차종으로



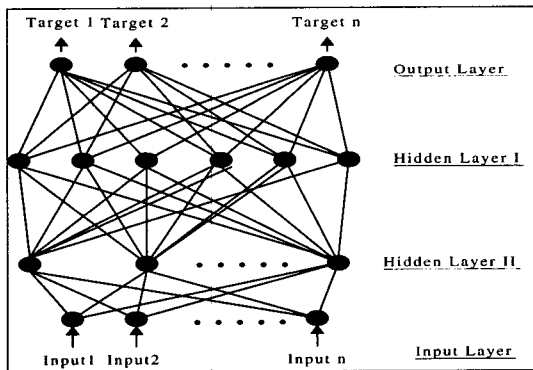
〈그림 9〉 오차제곱합의 예

인식하도록 한다. 여기서 기준파형은 해당 시간계에서 기준자료들의 평균값을 사용한다.

(2) 신경망(Neural network) 기법

본 연구에서 사용된 신경망기법은 백프로퍼게이션(Backpropagation) 학습알고리즘을 사용하였다.

〈그림 10〉은 본 연구에서 사용된 알고리즘으로서 입력 자료로는 자료처리를 거친 파형 수치자료이고 이러한 수치는 자료처리를 거친 후 1과 0사이의 값으로 변환을 시킨 값을 사용한다. 출력값은 인식된 차종이며 본 알고리즘을 수행한 후 도출되는 가중치가 학습시 목표로 한 값에 가장 가까운 값을 해당차종으로 인식하게 된다. 본 연구에서는 3종, 5종분류는 은닉층(Hidden layer)의 수를 2개의 층으로 구성하였으며, 각 층별 50개씩 Hidden Neuron을 설정하고 학습률 0.7, Iteration수 20000번으로 하여 학습을 시켰으며, 2종분류에서는 은닉층(Hidden layer)의 수를 4개의 층으로 구성하였으며, 각 층별 100개씩Hidden Neuron을 설정하고 학습률 0.7, Iteration수 20000번으로 하여 학습을 시켰다.



〈그림 10〉 백프로퍼게이션(Backpropagation) 학습알고리즘

(3) 복합기법

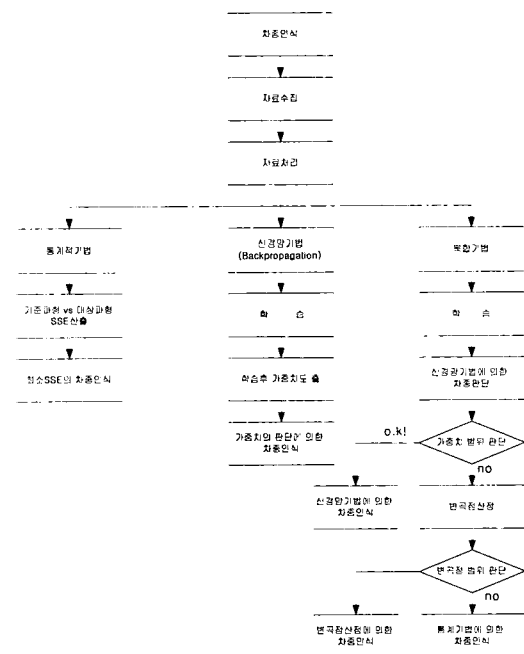
본 연구에서 사용된 복합기법은 파형 변화의 특징을 바탕으로 하여 개발한 기법으로서 1차적인 차종인식은 신경망을 기본으로 하고 2차적인 차종인식은 파형의 상위변곡점의 수를 파악하여 차종의 판단을 하고 마지막 3차적인 차종인식은 Template Matching 방법을 사용하는 것이다.

〈그림 11〉에서 제시된 같이 1차적인 차종인식에서 백프로퍼게이션(Back-propagation) 학습알고리즘을

수행한후 얻어진 가중치의 범위를 정하여 완전한 판단 범위내에 속하지 않는 차종인식은 2차단계로 넘어가 변곡점의 수를 파악하고 차종을 인식하게 되는데 변곡점의 수에도 범위를 정하여 차종인식을 수행하고 범위밖에 존재한다면 3차적인 단계, 즉 Template Matching 방법에 의한 차종인식으로 최종적인 판단을 하도록 한다.

〈그림 11〉은 본 연구에서 차종인식을 위하여 사용한 3가지 기법에 관한 수행도를 나타내는 것이다. 세가지 기법 모두 자료의 전처리 과정을 거치며 Template Matching방법은 기준파형정립후 대상파형과 SSE를 비교하여 제일 작은 값을 가지는 차종으로 인식이 되고, 신경망기법은 기준파형의 Y값을 1과 0사이의 값으로 환산한 후 학습시키고 난 뒤 대상파형과 비교하여 차종을 인식한다. 신경망기법에 사용된 수치Data값은 부록에 제시되어 있다. 마지막으로 복합기법에서는 1차 차종인식기준이 신경망의 가중치가 기준이되며 가중치는 0.9와 0.1의 값이 사용되는데 0.9에 가장 근접한 값을 갖는 파형이 그 차종으로 인식된다. 그리고 가중치의 판단기준을 정한후 기준이하의 값을 가질때 2차 차종인식기준 즉, 변곡점 갯수에 의한 판단으로 진행되며, 최종적으로 Template Matching방법에 의하여 차종을 결정하는 것이다.

3) 차종인식 알고리즘수행 절차



〈그림 11〉 알고리즘 수행도

M. 차종인식 알고리즘의 평가

1. 차종인식 알고리즘 평가방법

1) 차종인식 알고리즘 검증

본 연구에서는 인식 차종에 대하여 인식모형의 검증의 기준으로 인식율이라는 지표를 사용한다. 인식율이라는 것은 목표한 차종에 대해 인식할 수 있는 수준으로 정의되며, 일반적으로 정인식과 오인식 그리고 인식불능에 관한 간접지표에 의하여 산출될 수 있다.

정인식율은 인식결과 해당 차종군에 대응되는 크러스터에 속한 목표차종군의 수를 해당차종의 총수로 나눈값으로 정의하며 다음 식과 같다.

$$\text{정인식율} = \frac{\text{크러스터}(j)\text{에 속한 대표차종}(j)\text{의 수}}{\text{대표차종의 총수}}$$

정인식율은 대상 패턴에 대한 정확한 인식정도를 파악할 수 있는 정보로서, 특정 크러스터가 임의의 차종을 대표할 수 있는 지에 대한 판단을 할수있도록 근거를 제시하는 정보이다.

오인식율은 위의 식에 의하여 특정 크러스터가 임의의 차종을 대표한다고 할 때 해당 크러스터에 대표차종이 아닌 타 차종이 포함되어 있음으로 인하여 발생하는 잘못된 인식율을 의미한다. 이에 대한 관계식은 다음과 같다.

$$\text{오인식율} = \sum_{\text{for all } i} \frac{\text{크러스터}(i)\text{에서의 타차종}(j)\text{의 수}}{\text{차종}(j)\text{의 총수}}$$

이러한 오인식율은 해당 크러스터에 대하여 인식의 효율성을 간접적으로 판단할 수 있는 지표가 되며, 결과적으로 타 패턴간의 유사성수준을 결정하는 유용한 정보가 된다.

인식 불능율은 특정 크러스터가 임의의 특정차종을 대표할 때 대표차종을 인식하지 못하고 다른 차종을 대표하는 크러스터에 포함될 경우 발생하는 사항으로 다음 식에 의하여 정의된다.

$$\text{인식불능율} = \frac{\sum_i \text{크러스터}(i)\text{에서의 대표하지 않는 차종}(j)\text{의 수}}{\text{크러스터를 대표하는 차종}(j)\text{의 총수}}$$

본 연구에서는 상기에 제시된 정인식과 오인식과 인식불능의 세가지 지표를 토대로 본 연구에서 목적한 차종인식율을 정의하는데 사용하도록 한다.

실제 인식모형의 효율을 결정하기 위해서 사용되는 정인식율과 오인식율 및 인식 불능율에 관한 분석을 수행하기 위해서는 수집된 각 차종별 자료의 수가 어느 정도 균형을 유지할 수 있어야 효과적인 분석이 될 수 있다. 그러나 본 연구에서는 차종별 자료의 수가 편차가 매우 심하여 오히려 잘못된 해석을 유발할 수 있다.

따라서 본 연구에서는 인식율에 대한 분석상의 오류를 해결하기 위하여 각 크러스터 내에 포함된 각 차종별 비율을 토대로 기대치 값으로 환산하여 인식율을 산출하도록 한다. 이를 위한 관계식은 다음과 같다.

$$\text{인식율} = \frac{\text{정인식율}(j) \times 100}{(\text{정인식율}(j) + \text{오인식율}(j) + \text{인식불능율}(j)) \times 100}$$

위의 식은 다음과 같은 식으로 단순화 될 수 있다.

$$\text{인식율}(\%) = \frac{\text{정인식율}(j)}{1 + \text{오인식율}(j)} \times 100$$

2. 자료의 처리 및 분석

1) 자료의 처리 및 분석방법

각각의 알고리즘에 대하여 2종, 3종, 5종분류를 시도해 보았고 3종, 5종분류에서는 정규화 및 이동평균의 간격을 달리하여 8번의 차종인식실험을 수행하였으며 2종분류에서는 정규화크기가 40이고 이동평균기법을 사용하지 않은 실험을 수행하였다. 복합기법알고리즘은 2종과 3종분류에만 적용하여 보았다. 그 이유는 승용차의 파형은 변곡점의 수가 적으며, 대형차량의 파형의 변곡점은 앞의 세가지 차종보다는 변곡점의 수가 증가하는 현상을 보이기 때문에 5종의 분류에서는 오히려 차종인식에 있어서 혼란을 초래할수있다고 판단되었기 때문이다. 알고리즘의 수행도 분석은 각 파형의 data값을 20과 40의 크기로 정규화를 수행하고 이동평균의 간격은 0, 3, 4, 5의 크기로 1씩 이동을 하여 이동평균을 구하여 파형의 값으로 사용하여 비교 분석하였다. 또한 Template Matching

방법에서는 자료의 처리과정을 거쳐 얻어진 파형의 평균값으로 기준파형을 설정하였다. 세부적인 실험 결과는 부록의 표에 제시하였고, 표에 제시되는 숫자 및 영어의 약자는 위에서 언급한 정규화의 크기 및 이동평균의 간격을 나타낸다. 예를 들어 20_R_0 은 정규화크기가 20이며 이동평균기법을 사용하지 않았다는 뜻이며, 40_R_3은 정규화 크기가 40이며 간격 3의 크기로 이동평균을 수행하여 분석을 하였다는 것을 의미한다. 또한 앞에서 제시한 각각의 알고리즘들간의 차종인식 수행도 평가를 위하여 각 경우에 해당하는 차종인식 수행결과들의 평균을 제시하였다.

3. 차종 분류별 평가결과

1) 2종분류

2종 분류에서는 승용차와 승용차를 제외한 모든차종을 하나로 그룹화하여 두가지 종으로 나누어 차종인식을 시도하였다. Template Matching 방법의 전체적인 인식율은 82%수준이고 신경망기법에서의 전체적인 인식율은 71%수준이며 복합기법에서의 전체적인 인식율은 72.5%수준이다. 알고리즘 수행결과 Template Matching 방법이 전체적인 인식율에서 우위를 보이고 있다. <표 9>는 각각의 실험결과에 대한 전체적인 인식율을 나타낸다.

<표 9> 2종분류 인식율결과

차종구분		2종분류		
		Template Matching	신경망기법	복합기법
		인식율(%)	인식율(%)	인식율(%)
승용차	1종	83	69	71
승합차	2종	81	73	74
소형트럭				
대형버스				
중형트럭				
대형트럭				

2) 3종 분류

3종 분류에서는 2종분류에서의 차량길이가 비슷한 소형차량군을 하나의 종으로 그룹화하여 소형차량군

<표 10> 3종분류 인식율결과

차종구분		3종분류		
		Template Matching	신경망기법	복합기법
		인식율(%)	인식율(%)	인식율(%)
승용차	1종	49.3	74.1	72.8
승합차				
소형트럭				
대형버스	2종	5	21.4	19.6
중형트럭	3종	86.5	49.8	55.8
대형트럭				

(승용차, 승합차, 소형트럭), 대형버스, 중대형트럭에서 파형의 차이가 뚜렷이 보이지 않기 때문에 중대형트럭 세가지 종으로 나누어 차종인식을 시도하였다. Template Matching 방법의 전체적인 인식율은 47%수준이고 신경망기법에서의 전체적인 인식율은 48.4%수준이며 복합기법에서의 전체적인 인식율은 49.4%수준이다. 그리고 Template Matching 방법에서 3종의 인식율은 87%의 높은 수준을 보이고 있다. <표 10>는 각각의 실험결과에 대한 차종별 평균적인 인식율을 나타낸다.

3) 5종 분류

5종 분류에서는 3종분류에서 소형차량군을 3가지로 세분화하고 중형트럭과 대형트럭의 파형에 있어서 차이가 별로 나지 않는 점에 착안하여 이 두종의 차량을 동일 차량군으로 가정하여 차종인식을 시도하였다. 또한 5종분류에서는 소형차량군이 세분화되면서 변곡점의 수가 더 이상 차종인식의 모수로 사용될수 없다고 판단되었기에 복합기법을 제외시켰는데 Template Matching 방법의 전체적인 인식율은 36.4%수준이며 신경망기법에서의 전체적인 인식율은 42.5%수준이다. 두 알고리즘의 수행도 차이는 신경망기법이 6%정도우위를 갖고있다는 것을 알 수 있고 신경망 기법을 사용한 알고리즘은 대형버스의 인식율이 증가됨을 알수있다. 또한 타 차종에 비하여 대형버스의 인식율이 낮은 이유는 자료의 수가 풍족하지 못하기 때문에 기준파형의 정립 및 학습시에 불리한 작용이 원인이라고 판단된다.<표 11>은 각각의 실험결과에 대한 차종별 평균적인 인식율을 나타낸다.

〈표 11〉 5종분류 인식율결과

차종구분		5종분류	
		Template Matching	신경망기법
		인식율(%)	인식율(%)
승용차	1종	61.3	57.9
승합차	2종	48.6	32.4
소형트럭	3종	40	34.3
대형버스	4종	5	25.5
중형트럭	5종	26.9	62.3
대형트럭			

4. 개발모형의 종합분석

지금까지 Template Matching 방법 및 신경망기법, 복합기법을 이용하여 수행한 차종인식알고리즘의 수행 결과는 〈표 12〉와 같다.

본 연구에서 제안한 세 가지 알고리즘중 2종실협에서 Template Matching 방법이 인식율 82%로 수행결과가 가장 좋게 나타났다. 또한 복합기법이 신경망기법보다 약간의 우위를 보이고 있다. 2종분류와 5종분류에서 1종 즉, 승용차의 인식율이 차이가 발생하는데 이는 Grouping이 원인이라고 사료되는데, 승용차그룹과 대비되는 다른 차종의 파형의 특징이 다르기 때문이라고 할 수 있다. 복합기법은 차종별 파형의 특징을 잘 설명할 수 있는 모수를 더 첨가시킨다면 좋은 결과를 얻을수 있을것이라 사료된다. 또한 백프로퍼게이션(Backpropagation)학습 알고리즘을 토대로 한 신경망 기법이 복합기법에서 1차적인 판단 기준, 즉 신경망기법에 의한 판단이 완전하다면 알고리즘 수행이 종료되므로 자료가 충분하고 많은 여러 가지 상태의 학습이 가능하다면 차종인식에 있어서 높은 인식율을 기대할수도 있을 것이다. 또한 Template Matching 방법을 사용한 알고리즘은 초기에 생성하는 기준치가 중요하므로 충분한 자료의 확보가 필수

〈표 12〉 차종분류별 개발 모형의 결과

사용기법	Template Matching	신경망기법	복합기법
평가기준	인식율(%)	인식율(%)	인식율(%)
2종분류	82	71	72.5
3종분류	47	48.4	49.4
5종분류	36.4	42.5	-

적이다. 따라서 보다 안정화되고 향상된 인식결과를 기대하기 위해서는 각 차종별 충분한 샘플자료가 요구될 것으로 판단된다. 본 차종분류에서는 신경망기법상에서 정규화 크기가 커질수록 이동평균기법을 사용하지 않은 상태에서는 인식율이 좋아지는 경향을 보이고 있다. 이것은 신경망 기법이 순수파형에 대한 특징이 잘 나타나는 파형을 학습함으로써 좋은 결과를 얻을수 있다는 것을 보여주고 있다.

V. 결론 및 향후연구과제

본 연구에서는 자석검지기를 이용한 차종인식 알고리즘들을 개발하였다. 개발된 차종인식 알고리즘은 Template Matching 방법과 백프로퍼게이션(Backpropagation)학습 알고리즘을 이용한 신경망기법, 그리고 이들 각 기법에 변곡점의 수를 고려한 복합기법이었다.

이와 같이 개발 알고리즘은 현장적용성 검토 및 우수 알고리즘 선별을 위하여 고속도로에 설치된 자석검지기로부터 자료를 수집한 후 이 자료를 바탕으로 한 정확도를 인식율을 비교적으로 사용하였다.

본 연구에서 시도하였던 차종인식은 2종분류가 인식율이 높았고, 세부차종으로 분류할수록 인식율이 낮아지는 현상을 보이고 있다. 이러한 현상은 차종별 수집자료가 충분히 확보된다면 해결이 가능하다고 사료된다. 3종 분류에서는 복합기법의 인식율이 다른 기법보다 높게 나타났는데, 복합기법은 파형을 잘 설명할 수 있는 다양한 모수의 개발이 이루어 질 경우 더 나은 결과를 얻을 수 있을 것으로 사료된다.

본 연구에서 백프로퍼게이션(Backpropagation) 학습 알고리즘을 토대로 한 신경망 기법이 복합기법보다는 약간 낮은 인식율을 보여주었는데, 이는 복합기법에서 1차적으로 신경망을 통한 인식 수행후 2차적으로 변곡점을 기반으로 인식함으로써, 결과적으로 신경망에 의한 인식효과에 변곡점에 의한 방법이 전반적인 인식 결과에 상승요인으로 작용한 것으로 판단된다.

본 연구에서 Template Matching 방법을 사용한 알고리즘은 기준치가 중요하므로 충분한 자료의 확보가 이루어져서 좀더 정확한 기준치산정이 이루어진다면 보다 나은 결과를 얻을 것으로 사료된다.

본 연구에서 수집자료의 매체가 된 자석검지기는 개발 및 상용화초기 단계로서 자석검지기의 체계의 안정화 및 지속적인 개발 및 연구가 이루어진다면 차

종인식에 있어서 뿐만 아니라 그 외 다양한 교통정보의 수집에도 좋은 효과가 있을 것으로 기대된다.

참고문헌

1. ITE, TRAFFIC DETECTOR HANDBOOK, Second Edition, 1990.
2. 국토개발연구원, 도로교통량 조사체계 및 장비에 관한 연구, 1993. 4.
3. 한국도로공사, 고속도로교통관리시스템(FTMS)을 위한 MCD평가실험, 1998. 7.
4. 허문열, 數理統計學, 經文社, 1989. 8.
5. 최종욱의 3명, ITS와 첨단정보기술, 참말, 1997. 9.
6. 조한선, 단일루프검지기를 이용한 차종분류 알고리즘 개발, 아주대학교 공학석사학위 논문, 1995. 2.
7. 조형기, 신경망을 이용한 루프-기반 실시간 차종 인식모형 개발, 아주대학교 공학박사학위논문, 1998. 2.
8. 김대수, 신경망이론과응용(1), 하이테크정보, 1992. 8.
9. 김연형, 시계열분석과 예측, 자유아카데미, 1992. 1.
10. 김현숙, 김소윤, 신경망 컴퓨터, 크라운출판사, 1994.