

# 클러스터링 방법을 이용한 차종인식 모형

조 형 기<sup>†</sup> · 민 준 영<sup>††</sup> · 최 중 옥<sup>†††</sup>

요 약

최근에 이르기까지 교통분야에서 차량에 관한 정보를 수집하기 위하여 사용되고 있는 검지체계는 유도식 루프 검지기(Inductive Loop Detector,ILD)이다. 유도식 검지기로 부터 수집되는 교통자료는 점유시간(차량이 검지기를 점유한시간)과 비점유시간(통행 차량과 차량간의 시간차) 및 교통량이 기초 수집자료가된다. 특히 점유시간은 신호의 현시길이를 결정 및 과포화제어를 위한 대기행렬예측 등 다양한 관제 알고리즘에 있어서 핵심적인 자료가므로 높은 신뢰도가 요구된다. 이러한 신뢰도는 검지로 부터 수집될 수 있는 자료들을 토대로 통행 차종을 식별함으로써 향상시킬 수 있으며, 관련 관제 알고리즘의 신뢰도 향상은 물론 최근 관심이 고조되고 있는 무인자동감시체계 및 교통정보 자동 수집장치의 개발을 유도할 수 있다. 본 논문에서는 통행하는 차량들에 대하여 수집되는 기초자료를 기반으로 차종을 인식하기 위한 방법으로서 통계적 클러스터링 방법 두가지와 신경망 클러스터링 방법 등 세가지 방법을 제시하고, 결과로서 무인자동감시체계에 관한 활용방법을 제시한다.

## Recognition Model of the Vehicle Type using Clustering Methods

Hyung Ki Cho<sup>†</sup> · Joon Young Min<sup>††</sup> · Jong Uk Choi<sup>†††</sup>

ABSTRACT

Inductive Loop Detector(ILD) has been commonly used in collecting traffic data such as occupancy time and non-occupancy time. From the data, the traffic volume and type of passing vehicle is calculated. To provide reliable data for traffic control and plan, accuracy is required in type recognition which can be utilized to determine split of traffic signal and to provide forecasting data of queue-length for over-saturation control.

In this research, a new recognition model is suggested for recognizing type of vehicle from the collected data obtained through ILD systems. Two clustering methods, based on statistical algorithms, and one neural network clustering method were employed to test the reliability and accuracy of the methods. In a series of experiments, it was found that the new model can greatly enhance the reliability and accuracy of type recognition rate, much higher than conventional approaches. The model modifies the neural network clustering method and enhances the recognition accuracy by iteratively applying the algorithm until no more unclustered data remains.

본 논문은 1995년 4월 한국과학재단의 연구과제(과제번호:95-0600-10-01-3)에 대한 연구비 지원에 의하여 연구되었음.

† 정 회 원:아주대학교 박사과정, 상명대학교 정보처리학과 강사.

†† 정 회 원:상지대학교 병설 전문대학 전자계산과 교수


††† 정 회 원:상명대학교 정보처리학과 교수

논문접수:1995년 11월 3일, 심사완료:1996년 1월 24일

### 1. 서 론

도로상에서 야기되는 각종 교통상태를 판단하고 이에 따른 적합한 신호제어를 수행하기 위해서는 목적인 교통정보를 수집할 수 있는 다양한 검지센서들

이 도로에 매설되거나 도로변에 설치되어야 한다. 교통부문에서 이용되는 검지 목적의 센서들은 유도식 루프 검지기와 마이크로 웨이브 및 초음파 센서등 매우 다양한 센서들이 사용되기는 하지만 국내는 물론 국외에서도 아직 ILD가 주를 이루고 있는 실정이다. 비록 최근에 이러한 ILD의 관리체계 및 보수 유지에 관한 비용의 증대로 기존의 검지체계를 대체할 만한 다양한 검지센서에 관한 관심이 고조되고 있으며, 이에 대한 다양한 연구가 진행되고 있는 실정이다.



(그림 1) 도로에 설치된 ILD  
(Fig. 1) ILD in Road

ILD는 (그림1)과 같이 차량이 도로에 매설된 루프 코일의 위를 차량이 통행할 경우 코일에서 발생되는 자장의 세기(주파수의 변화)를 계측하여 교통자료를 수집하게 된다. 일반적으로 수집되는 정보는 통과 교통량과 점유시간 및 비점유시간이 기본적으로 계측되며, 그 이외의 교통분석 및 제어/관리 측면에서 효과적으로 활용될 수 있는 차종에 관한 자료는 세부적으로 파악할 수 없다는 것이 일반적인 중론으로 인식되어 왔다. 단지 대형/중형/소형의 대략적인 3개 차종으로 인식하기 위하여 동일 차선에 두개의 루프 검지기를 약 2m~3m 간격으로 설치하여 통행차량을 인식하는 정도였다.[1]

ILD를 이용하여 통행 차종을 파악하기 위한 노력은 과거에서 부터 최근에 이르기 까지 국내 및 국외

에서 많은 관심이 대두되어 왔으며, 최근 몇 년전 독일 AVE사에서 개발된 MT 계열의 시스템이 ILD의 복합적 조합구조를 이용하여 통행차량들에 대한 차종을 최하 2종에서 부터 최대 6종으로 인식하여 수집할 수 있는 이동식 상용제품을 개발한 바 있으나 그 차종인식에 대한 실험적 신뢰도가 아직 밝혀지지 않은 실정이다. 프랑스의 ECM사가 개발한 HESTIA 시스템은 타 관련 체계중 신뢰도가 상대적으로 우수한 것으로 나타났으며, 차종을 식별하기 위하여 2개 ILD와 1개의 피에조(Piezo) 센서를 복합구성하는 방법과 1개의 ILD와 2개의 피에조 센서를 복합구성하여 차종을 14종(2개의 ILD와 1개의 Piezo 구성)에서 최대 33종(1개의 ILD와 2개의 Piezo 구성)을 식별할 수 있도록 하고 있으나 그 신뢰도는 약 87% 정도의 수준(14종 실험결과)에 이르고 있어[2], 이를 이용한 종합 교통정보 수집체계에 관한 관심이 고조되고 있다. 그 외에 영국의 MAXMAN 660 등 다양한 교통정보 수집장치들이 개발되어 일부는 국내에 이미 소개되어진 바 있으나 그 차종에 관한 수집정보의 신뢰도가 타 시스템에 비하여 상대적으로 낮은 수준에 이르고 있다.

한편으로 국내의 경우 본 연구과제와 관련한 연구가 극히 미진한 상태에 있으며, 현재 국내에서 운영중에 있는 각종 체계들은 외국에서 개발된 체계로서 ILD와 피에조 센서등의 다양한 센서들을 복합구성하여 차종을 인식하는 고가의 장비들이다.

차종 식별 및 자동수집장치와 관련하여 상기 기술된 외국 장비들의 비교에 관한 사항이 <표 1>에 제시되어 있다.

<표 1> 외국 차종인식장비 비교  
<Table 1> comparison of foreign vehicle equipments

구 분	구 성(복합구조)	장비명	신뢰도
미 국	Loop(8) + Piezo(8)	GK-6000s	70%
영 국	Loop + Piezo + WIM	M.M 660s	70%
독 일	Loop(2) + Loop(4)	MTs(AVE)	-
프랑스	Loop + Piezo(2)	HESTIAs	87%


본 연구는 ILD를 이용하여 실시간으로 통행차량의 차종을 인식할 수 있는 알고리즘을 개발함으로써 첫째, 도시가로상의 용량산정에 있어서 기존의 보정계

수 산정방식에서 실측에 의한 용량산정을 가능토록 하며, 둘째, 유료도로 및 고속도로 톨게이트 자동 요금징수 체계에서의 운영효율을 향상시키며, 셋째, 기존의 차종식별 교통자료 수집을 위한 고가의 투자비용을 최소화할 수 있으며, 넷째, 현 신호시스템에서 운영되고 있는 대기행렬길이 예측알고리즘과 관련하여 보다 신뢰성이 높은 대기행렬 예측 결과 등 정보의 질적 향상을 기대할 수 있는 기초 정보를 제공하고, 다섯째, 향후 순수 국내기술에 의한 이동식 자동교통정보 수집장치의 개발을 활성화하는데 그 목적이 있다.


**2. ILD 시스템**

**2.1 ILD의 구성**

ILD는 (그림 2)와 (그림 3)과 같이 3개의 기본적인 요소 즉, 루프코일과 도입선(lead-in-cable) 그리고 검지기(detector)로 구성되어 있다. ILD를 정상적으로 설치하기 위해서는 도로면에 2cm의 폭으로 깊이 약 5cm로 홈을 만들어야 하며, 코일을 2회에서 4회의 회전수로 구성하여 홈내에 설치한다. 홈에 설치된 코일로부터 검지기까지 도입선을 연결한다. 이 도입선은 검지부의 인덕턴스의 변화를 상쇄시키기 위하여 1 feet 당 5회에서 10회 휘어감아 설치한다.[3]



(그림 2) ILD 구성도  
(Fig. 2) Blockdiagram of ILD



(그림 3) 코일단면도  
(Fig. 3) Section of Coil

**2.2 ILD의 검지 원리**

전압이 일정한 경우 전류와 저항은 상호 반비례의 관계가 성립된다. 이때 도선에 전류가 흐르면 도선 주위에 “프레밍의 오른손 법칙”에 따라 자장이 형성되며, 이때 발생하는 자속(magnetic flux)은 도선의 인덕턴스에 비례한다. 이와 관련 된 식은 다음과 같다.

$$F \propto N \times I \tag{식 1}$$

N: 코일의 회전수

I: 코일의 전류

$$F = R \times \theta \tag{식 2}$$

R: 비례상수(Reluctance)

θ: 자속

따라서 ILD에서는 도로위에 설치된 루프 코일과 도입선까지 전류가 흐르므로 통행차량이 없는 경우 일정한 인덕턴스에 비례하는 자속이 발생된다. 만일 ILD에 의해 형성된 자장(magnetic field)위를 차량이 통과하는 경우에는 차량과 코일 사이에 매우 큰 자속의 변화가 발생된다.

**2.3 ILD의 유형**

검지기의 유형은 일반적으로 검지기의 용도에 따라 구분되지만 최근 이와 관련하여 다양한 형태 및 코일의 권선방식에 따른 유도식 검지기가 연구개발되어 설치 운영되어지고 있으며, 이들에 대한 구분은 <표 2>와 같다.

<표 2> 용도, 형태에 따른 검지기의 구분  
<Table 2> Classification of Inductive Loop Detector by Usage-Types

구분	장형	단형
주용도	감응제어용 차량 유/무	교통량 계측
형태	사각형	사각/원형
크기	각변 1.8m 이상	지름 1.8m 각변 1.8m

일반적으로 원형 검지기와 단형(short loop)(크기: 1.8m×1.8m)간의 성능 비교에 관한 연구결과는 아직 없는 실정이지만, 본 연구에서는 원형 검지기를 주요 대상으로 고속도로를 통행하는 9개차종(승용차, 봉

고, 버스, 2, 5, 8, 11, 15톤트럭, 트레일러)에 대하여 매 20msec 마다 A/D변환장치에 의하여 계측된 수집 자료를 토대로 파형의 특징을 추출하고, 추출된 각 특징들을 기초로 대상 차종을 인식에 있어서 보다 효과적인 특징요소를 분석하고, 분석결과를 토대로 인식알고리즘을 구축했다.

### 3. 자료의 처리


#### 3.1 자료의 수집방법

본 연구에서 인식하기 위하여 이용한 각 9개 차종에 관한 기초자료는 고속도로 관리 시스템(Freeway Traffic Management System, FTMS)구축의 일환으로 설치된 총 320Km 구간중 중부고속도로의 구간중 관교-구리선에 설치된 직경 1.8M 크기의 원형 검지기로 부터 1994. 11. 13~1994. 11. 19까지 수집되었다. 이러한 원형 검지기로 부터 수집되는 자료는 통행차량이 검지기를 점유하는 동안 루프코일에서 발생하는 자장의 변화를 A/D 변환장치에 의하여 변환된 정보로서 목표한 차종(9종)에 관한 자료를 기초자료로 수집하였으며, 각 수집된 자료의 현황은 다음 <표 3> 과 같다.

<표 3> 자료수집현황  
<Table 3> Data Collection


구 분	자료의 수	비 고
승 용 차	250 set	불량 2 set
봉 고	349 set	불량 2 set
버 스	46 set	
2톤 트럭	205 set	
5톤 트럭	83 set	
8톤 트럭	34 set	
11톤 트럭	35 set	
15톤 트럭	109 set	
트레일러	18 set	

이들 자료들은 2차원의 표현시 수직성분은 자속의 변화이며 수평성분은 샘플링 순서이다. 각 차종별 수집된 자료에 근거한 대표적인 파형의 특성이 (그림 4)와 같다.



(그림 4) 9개 차종의 샘플링된 파형  
(Fig. 4) Sampled Signature of 9 Vehicles

이 수집된 자료들은 이상적인 상태(점유하는 동안 등속도로 통행하는 경우)에서는 그 해당차종에 대한 고유의 자속변화에 대한 특징이 명확하여 차종을 식별하는데 매우 용이하게 접근할 수 있다. 그러나 실제 상황에서는 (그림 5)와 같이 점유시간중 부분적 자체에 의한 다양한 파형변화가 있을 수 있으며, 파형변화가 일정하다 하더라도 차량 점유시간의 다양한 변화로 이상적인 상태에서 차량이 갖는 고유의 파형을 파괴하는 요인이 된다.



(그림 5) 비등속에 의한 파형  
(Fig. 5) Signature of Non-Uniformly Velocity

이러한 현상은 평상시 등속도로 통행되는 고속도로 보다는 통행속도의 완급이 빈번한 도시가로 상에서 자주 발생될 수 있는 요인이 된다. 이러한 고유 파형의 파괴는 다음과 같은 상황에서 발생된다.

첫째, 고속도로의 경우 검지기가 설치된 지역에서 사고에 의한 급진적 정체시 혹은 급정거의 경우에 발생될 수 있다.

둘째, 도시가로망의 경우 검지기가 정지선 부근과

상류부(링크의 길이가 300M 기준시 약 250M 부근에 설치된 경우)[4]에 설치된 경우 상류부 혼잡 및 정지선에서의 출발손실시간에 따른 속도의 완급변화에 따라 파형의 변화가 발생할 수 있다.

이러한 현상은 도로를 통행하는 차량들의 비등속도 통행에 의하여 나타날 수 있는 결과라 할 수 있다. 비 등속도 통행에 의한 파형의 변화는 어느 정도의 수준까지는 인식분야에 있어서 효과적으로 활용될 수 있는 소위 전처리과정(pre-processing) 들의 다양한 방법들을 토대로 극복할 수는 있으나 근본적인 해결방법은 될 수 없는 요소이다.

본 연구에서는 이러한 비등속도 통행으로 인한 부분적 증가분의 지체요인을 배제한 정상적인 등속도로 고속도로를 통행하는 차량들에 준하여 수집된 자료들을 이용하였다. 또한 하나의 보완장치로서 비등속도 통행에 의한 변화를 어느정도 완화시킬 수 있으며 자료특성의 동질성을 유지시킬 수 있는 방법으로 자속변화 및 점유시간의 변화에 대하여 각각을 정규화(normalization)하는 전처리 과정을 이용하였다.

3.2 자료의 1차처리







1차처리 과정은 일반적으로 거의 모든 클러스터링 기법에서 적용되어지는데, 소위 자료의 형변환등 수집된 패턴의 특징점 추출을 위한 전처리 과정이 이러한 1차 자료처리과정에 속할 수 있다.


본 연구에서 수집되는 자료들은 점유시간동안 계속된 자속의 변화를 기초자료로 활용하고 있다. 점유시간은 통행속도에 직접적으로 영향을 받는다. 즉 저속 통행으로 인하여 점유시간이 증가할 경우 20msec 단위당 샘플링수가 증가하게 된다. 이러한 영향은 각 차종에 대하여 샘플링된 자료들을 표준규격으로 변환하지 않고 원시 자료들을 그대로 클러스터링에 활용하는데 있어서 많은 문제들이 야기할 수 있다.

따라서 본 연구에서는 각 차종들에 대한 원시자료들을 수직성분(자장의 변화)와 수평성분(샘플링 순서) 각각에 대하여 2개 유형으로 정규화하였다.

1) 샘플링수의 정규화

검지기로 부터 수집되는 파형은 점유시간동안 계속되는 자료로서 검지기를 통행하는 속도에 따라 점유시간이 다양함으로 인하여 파형 수평성분의 스케





(그림 6) 9개 차종의 정규화된 자료  
(Fig. 6) Normalized Data of 9 Vehicles

일을 표준화하여 (그림 6)과 같이 동일한 규격에 대응시킬 필요가 있다.

이러한 파형의 정규화는 다양한 점유시간에 의한 파형 변화를 표준화함으로써 일률적이며, 효과적인 특징 추출을 위한 전처리과정일 수 있다. 검지기로부터 수집된 파형을 정규화하기 위해서는 수집된 파형과 표준 규격에 대하여 다음의 사전정보를 알고 있어야 한다.

- (1) 원시자료의 최대 샘플링수
- (2) 표준규격의 수평성분의 크기

위에서 최대 및 최소값은 점유시간동안 계측된 변환 자속변환 자료들중 최대값 과 최소값을 의미하며, 대상자료의 표준수는 점유시간동안 계측한 횟수를 의미한다. 표준규격의 가로와 세로는 각각 계측된 주파수 자료와 계측순위이며, 이들은 1 대 1 대응된다.

이상의 관련 정보가 주어졌을 때 다음 식에 의하여 정규화가 가능하다.

$$X(i) = (X_{min} - 1) + \frac{i \times (X_{max} - X_{min})}{N} \quad (식 3)$$

여기서,

- X(i) = 정규화된 수평성분의 값
- X<sub>max</sub> = 표준규격의 수평성분 최대값
- X<sub>min</sub> = 표준 규격의 수평성분 최소값
- N = 원시자료의 샘플링 수
- i = 원시자료의 샘플링 순서

2) 수직성분의 정규화

수직성분의 정규화는 자료변환시 원시 자료의 특성이 왜곡될 수 있는 요소가 다분히 있는 관계로 적용시 매우 신중하여야 한다. 자료의 왜곡은 수직성분의 스케일이 동일 규격화됨으로 인하여 전체 파형의 수직적 증가 혹은 감소된 결과를 초래한다. 이때 낮은 골의 파형은 동일 패턴으로 변환되기 때문에 해당 패턴이 가지고 있는 고유한 특성이 왜곡될 수 있는 단점이 있다. 이러한 왜곡은 패턴의 자료 특성상(동일 패턴의 경우 낮은 골이지만 그 편차가 상대적으로 큰 경우) 의도적인 왜곡을 필요로 할 수도 있으나 근본적인 문제점은 해결될 수 없다.

반면에 샘플링시 수평영역에서 근접된 영역의 작은 정도의 미묘한 변화는 수직성분의 정규화 과정을 통하여 상쇄시킬 수 있다는 장점이 있다. 특히 어느 정도의 비동속도 통행에 따른 자속성 변화의 파리는 이러한 수직성분의 정규화 과정을 통하여 극복될 수 있다.

이러한 수직성분의 정규화는 수직성분의 표준화 규격을 원시자료보다 작은 스케일로 변환시 효과적이라 할 수 있다. 원시자료의 수직성분보다 표준화된 규격의 수직성분이 큰 경우에는 비록 표준화를 수행하여도 왜곡된 자료의 특성이 해당 패턴의 특성을 좌우할 수 있게 된다. 또한 수직성분의 증감에 따른 미묘한 변화까지 증폭하게 되어 결국 이들 각 요소적인 영향이 왜곡된 자료의 형태로 변환하게 된다. 수직성분에 대하여 정규화하는 기본식은 다음과 같다.

$$Y(i) = (Y_{min} - 1) + \frac{(W_{ave} - W_{min})(Y_{max} - Y_{min})}{(Y_{max} - Y_{min})} \quad (식 4)$$

여기서,

- $Y(i)$  = 정규화된 수직성분의 값
- $Y_{max}$  = 표준화 규격의 수직성분 최소값
- $Y_{min}$  = 표준화 규격의 수직성분 최대값
- $W_{max}$  = 원시자료의 수직성분 최대값
- $W_{min}$  = 원시자료의 수직성분 최소값
- $W_{ave}$  = 원시자료 수직성분의 자료

3) 수평 및 수직 성분의 정규화

$$X(i) = (X_{min} - 1) + \frac{i \times (X_{max} - X_{min})}{N} \quad (식 5)$$

$$Y(i) = (Y_{min} - 1) + \frac{(W_{ave} - W_{min})(Y_{max} - Y_{min})}{(Y_{max} - Y_{min})} \quad (식 6)$$

여기서,

- $Y(i)$  = 정규화된 수직성분의 값.
- $Y_{max}$  = 표준화 규격의 수직성분 최소값.
- $Y_{min}$  = 표준화 규격의 수직성분 최대값.
- $W_{max}$  = 원시자료의 수직성분 최대값.
- $W_{min}$  = 원시자료의 수직성분 최소값.
- $W_{ave}$  = 원시자료 수직성분의 자료
- $X(i)$  = 정규화된 수평성분의 값.
- $X_{max}$  = 표준규격의 수평성분 최대값.
- $X_{min}$  = 표준 규격의 수평성분 최소값.
- $N$  = 원시자료의 샘플링 수
- $i$  = 원시자료의 샘플링 순서

이러한 정규화 과정에서 수평과 수직성분 개별적인 정규화 과정에서는 큰 문제가 없으나 수평 및 수직 성분을 동시에 정규화를 하여야 할 경우 정규화된 하나의 수평성분에 복수개의 수직성분이 있을 수 있으며, 혹은 하나의 정규화된 수직성분에 복수개의 수평성분이 있을 수 있게 된다. 이러한 문제는 근본적으로 수평 및 수직성분의 자료의 형태(정수형 혹은 실수형)에 따라 발생될 수 있는 사항이다.

수직성분의 자료특성을 대상으로 할 경우에는 수평성분의 자료를 정수화하여 자료처리를 수행하고, 반대로 수평성분의 자료특성을 대상으로 할 경우에는 수직성분을 정수화하여 처리하면 위 문제를 극복할 수 있다.

한편으로 복수개의 문제는 각 성분에 대하여 정규

화된 자료의 평균값을 산출하여 수평성분과 수직성분이 1 대 1 대응이 되도록 한다.

4. 차종 인식방법

클러스터링의 목적은 일정한 기준에 따라서, 일련의 유사성이 있는 대상자료(패턴)들을 하나의 그룹으로 구성될 수 있도록 다른 그룹들과 분리하는 것이다. 일반적으로 클러스터링을 수행하는 많은 알고리즘들이 개발되어 이용되고 있으나 본 연구에서는 고속도로를 통행하는 차종을 식별하기 위한 방법으로 통계량 추출에 의한 인식방법과 신경망 클러스터링 GLVQ(Generalized Learning Vector Quantization, Pal et. al., 1993) 방법을 이용하였다.

4.1 통계량추출방법-1

통계량 추출 방법에 의한 방법은 고전적인 클러스터링방법으로 널리 알려진 k-means 알고리즘과 유사한 관계로, 본 연구의 알고리즘 특성상 k-means 알고리즘의 특수형태라 할 수 있다.

k-means 알고리즘은 MacQueen에 의하여 제안된 알고리즘으로서, 우선 패턴을 k개의 클러스터로 나눈 후 클러스터에 포함되어 있는 패턴들의 평균으로 클러스터의 중심값을 계산하고 이 중심값과 각 패턴과의 거리를 계산한 후 가장 거리가 가까운 클러스터에 패턴을 포함시키는 방법으로 그 조건은 다음과 같다.[5]

$$x_i \in c_j \quad \|x_i - z_j\|^2 < \|x_i - z_k\|^2 \quad (식 7)$$

여기서,  $1 \leq i \leq N, 1 \leq k \leq c, j \neq k$

- $N$  = 패턴 수
- $c$  = 클러스터 수
- $z$  = 클러스터 중심값

그리고 이 계산은 각 클러스터의 중심값이 더 이상 변하지 않을 때까지 반복한다. 초기 k개의 클러스터의 중심값을 주는 방법에는 주어진 패턴에서 처음 k개의 패턴을 추출하여 중심값으로 하는 방법과 임의로 k개를 추출하여 중심값으로 하는 방법이 있는데 본 논문에서는 임의로 k개를 추출하여 클러스터의 초기 중심값으로 하였다.

통계량 추출방법은 각 대상 입력패턴을 구성하는 자료들간의 산출되는 평균값 통계량과 인식 대상의 입력값간의 거리를 기초로 하고 있다. 이 방법은 k-means에 의한 방법과 비교할 때 근본적인 접근방식은 같지만 본 통계량 추출방법이 사전에 각 그룹에 소속된 패턴의 입력자료들의 통계량을 필요로 하기 때문에 대상 입력패턴에 대한 차종정보를 알고리즘 수행전에 알고 있어야 한다는 점이 다르다.

통계량 추출에 의한 인식방법의 수행과정은 다음과 같다.

- (설정1) 인식 대상 그룹 설정,
- (설정2) 모든 입력 패턴의 수직-수평 정규화,
- (설정3) 총 9개 그룹의 개별 입력자료의 평균값 산출
- [단계1] 인식 대상 입력자료 정규화(수직-수평 정규화)
- [단계2] 인식 대상자료와 9개 그룹의 평균값 간의 거리의 합 산출
- [단계3] 최소 거리의 소속 클러스터결정

통계량 추출방법에 의한 인식과정에 있어서 평균치간의 거리는 일반적으로 비교사학습에 의한 전형적인 신경망 클러스터링 모델과 같이 유클리디안 거리(Euclidian Distance)를 의미한다.

#### 4.2 통계량추출방법-2

통계량 추출방법-2는 모든 처리과정이 방법(1)과 동일하지만 차종인식에 사용되는 최종 자료군이 제 2차 처리과정에 의하여 변환된다는 점에서 다르다.

제 2차 처리과정은 전처리과정에 의하여 정규화된 기초자료를 토대로 외곽점(extra-point)를 설정하여 설정된 지점과 각 입력값간 거리를 최종 자료로 활용한다. 외곽점에 의한 거리의 산출방식은 다음 식과 같다.

$$D_i = \sqrt{(Y_i - P_y)^2 + (i - P_x)^2}$$

여기서,

- $D_i$  = 입력치  $Y_i$ 와 외곽점간변환된값
- $Y_i$  = 정규화된 자료중  $Y$ 의 값
- $P_y$  =  $Y$ 값들과 대응되는 설정된 외곽점
- $P_x$  =  $X$ 값들과 대응되는 설정된 외곽점
- $i$  = 입력치들의 샘플링순위

따라서 각 차종별 대표되는 자료는 외곽선간 거리들의 평균치들로 산출되어 이용되며, 인식기준은 통계량 추출방법-1과 동일하게 오차제곱의 합(Sum of Square Error:SSE)를 산출하여 최소가 되는 그룹을 해당 차종으로 인식하게 된다.

통계량 추출에 의한 인식방법의 수행과정은 다음과 같다.

- (설정1) 인식 대상 그룹 설정,
- (설정2) 외곽점 설정,
- (설정3) 모든 입력 패턴의 수직-수평 정규화,
- (설정4) 총 9개 그룹의 개별 입력자료와 외곽점간 거리산출,
- [단계1] 인식 대상 입력자료 정규화(수직-수평 정규화)
- [단계2] 인식 대상자료와 9개 그룹의 평균값 간의 거리의 합 산출
- [단계3] 최소 거리의 소속 그룹결정

#### 4.3 GLVQ(Generalized Learning Vector Quantization)

Kohonen은 자기조직형태(Self Organization Feature Map:SOFM)의 개념을 입력형태의 특성들과[5-8] 학습벡터 양자화(Learning Vector Quantization, LVQ)라 하는 알고리즘에 기초를 둔 연결정도를 조정하는 알고리즘을 제안하였다.[9-12]

실제로 LVQ 알고리즘은 클러스터링을 목적으로 한 알고리즘이 아니라 데이터의 프로토타입(proto-type)을 설계하기 위하여 데이터 중에 가장 가까운 프로토타입(nearest prototype)들을 그룹화하는 알고리즘이다.[13]

이 알고리즘은 기본적으로 입력벡터들과 중심벡터들간의 평균오차제곱(Mean Square Error)을 최소화 하는 것으로 학습방법은 평균오차제곱에 대한 목적함수를 최소화를 최적화 시키므로서 양질의 분류가 가능하도록 하는 것이다. 여기서 오차의 제곱은 유클리디안 거리와 동일한 개념으로 취급될 수 있으며, LVQ의 학습규칙은 다음과 같다.

$$v_{i,1} = v_{i,1-1} + \alpha_1(x_k - v_{i,1-1}) \tag{식 9}$$

여기서,  $v_{i,1}$ 는 반복 1시점에서 승차노드와 연결된 연결강도



$x_k$ 는  $k$ 번째 패턴벡터. ( $1 \leq k \leq N$ )

그러나 LVQ는 다음과 같은 몇몇 가지의 중요한 문제점들을 가지고 있다.

첫째, LVQ의 결과가 연결강도(weight)의 초기값에 매우 민감한 영향을 받는다. 즉, 클러스터의 중심에 대한 초기치가 입력 데이터의 볼록체 외부(out of convex hall)에 있는 경우에는 승자노드에 대해서만 학습을 하므로 승자가 아닌 노드의 중심값에 대해서는 반복이 계속되더라도 초기의 연결강도값을 그대로 유지하게 된다.

둘째, 초기 학습률이 0에 가깝게 주어졌다면 반복이 계속되면서  $\alpha_t$ 는 감소하게 되어 0에 수렴하게 되므로 연결강도의 변화량이 허용오차 안에 들어오지 않았는데도 불구하고 (식 9)에서 두번째 항인  $\alpha_t(x_k - v_{i,t-1})$  값이 0에 가깝게 되어 연결강도의 조정이 이루어지지 않는다. 따라서 학습이 끝나게 되기 때문에 오분류 되는 패턴이 증가하게 된다.

이러한 문제점들을 극복하기 위한 방법으로 GLVQ 알고리즘이 Pal, Bezdek, Tsao에 의하여 제안되었다. [13] 이 방법은 LVQ에서의 학습방법을 개선한 알고리즘으로 LVQ의 승자노드학습(winner node learning)에 비 승자노드의 학습(non winner node)을 부가하여 각각의 모든 입력값들에 대하여 학습을 수행하는 방법으로 승자노드와 입력값들간에 완전한 조화가 이루어질 경우에는 GLVQ는 LVQ와 같아지며, 승자노드와 부조화가 증대되면 비승자노드의 학습과정에서 입력값들간의 충돌이 점차적으로 증대된다.

GLVQ는 손실함수(loss function)  $L_x$ 을 최소화 시키는 학습방법을 적용하였다.[13]

$$L_x = \sum_{r=1}^c g_{ir} \|x - v_r\|^2 \quad (\text{식 10})$$

$$\text{여기서, } g_{ir} = \begin{cases} 1 & , \text{ if } r=i \\ \frac{1}{\sum_{j=1}^c \|x - v_j\|^2} & , \text{ if } r \neq i \end{cases}$$

여기서 승자노드일 경우에는  $L_x$ 를  $v_i$ (winner class center)로 미분하고, 승자노드가 아닌 경우에는  $v_j$ (non-winner class center)로 미분하여 다음 식으로써 학습

을 한다.

$$v_{i,t} = v_{i,t-1} + \alpha_t(x_k - v_{i,t-1}) \frac{D^2 - D + \|x_k - v_{i,t-1}\|^2}{D^2} \quad (\text{식 11})$$

$$v_{r,t} = v_{r,t-1} + \alpha_t(x_k - v_{r,t-1}) \frac{\|x_k - v_{r,t-1}\|^2}{D^2} \quad \text{if } r \neq i \quad (\text{식 12})$$

여기서,  $D = \sum_{r=1}^c \|x_k - v_r\|^2$ ,  $k=1, 2, \dots, n$ ;  $r=1, 2, \dots, c$ 이고,  $\alpha_t$ 는 time  $t$ 에서의 학습률(learning rate)이다.

각 단계별 GLVQ 클러스터링 알고리즘은 다음과 같다.

GLVQ 클러스터링 알고리즘.

[단계 1] 패턴벡터  $X = \{x_1, x_2, \dots, x_n\} \subset R^p$

$c, T, \epsilon > 0$  결정.

여기서,  $c$ : 클러스터의 수.

$T$ : 최대 반복횟수.

$\epsilon$ :  $\|v_i - v_{i-1}\|$ 의 허용오차.

[단계 2] 초기 연결강도 결정.  $V_0 = (v_{1,0}, \dots, v_{c,0}) \in R^p$

초기 학습률 결정.  $\alpha_0 \in (1, 0)$

[단계 3] For  $t=1, 2, \dots, T$ . 반복횟수에 따라 학습률

계산  $\alpha_t = \alpha_0(1 - t/T)$

For  $k=1, 2, \dots, n$ ;

a. 승자노드의 발견

$$\|x_k - v_{i,t-1}\| = \min_{1 \leq j \leq c} \{\|x_k - v_{j,t-1}\|\}$$

b. 승자노드 및 승자가 아닌 노드의 연결강도 수정

$$v_{i,t} = v_{i,t-1} + \alpha_t(x_k - v_{i,t-1})$$

$$\frac{D^2 - D + \|x_k - v_{i,t-1}\|^2}{D^2}$$

승자노드인 경우

$$v_{r,t} = v_{r,t-1} + \alpha_t(x_k - v_{r,t-1})$$

$$\frac{\|x_k - v_{r,t-1}\|^2}{D^2} \quad (r \neq i)$$

승자노드가 아닌 경우

Next  $k$

[단계 4] 에러 계산  $E_t = \sum_{k=1}^n \sum_{r=1}^c |v_{rk,t} - v_{rk,t-1}|$

[단계 5] if  $E_t \leq \epsilon$  then STOP; Else Next t

$$u_{LVQ,i} = \begin{cases} 1 : \|x_k - v_i\| \leq \|x_k - v_j\|, 1 \leq j < c, j \neq i \\ 0 : otherwise \end{cases}$$

$1 \leq i \leq c \quad \text{and} \quad 1 \leq k \leq n$

$U_{LVQ} = [u_{LVQ,i}] : c \times n$  행렬로써  $x_k$  패턴이 클러스터  $c$ 에 포함되어 있는 상태를 나타내는 행렬

실제로 Nikhil R. Pal은 Anderson의 IRIS데이터를 가지고 반복횟수와 학습률을 변화시켜 가면서 LVQ와 GLVQ로 클러스터링 한 결과를 비교하였는데 GLVQ는 150개의 IRIS데이터중 에러의 갯수가 17개로 일정한 반면에 LVQ인 경우에는 100개에서 17개의 에러를 나타내고 있다.[13]

### 5. 실험 결과

본 논문에서 이용한 데이터는 총 9개 차종을 기준으로 1129개 패턴에 대하여 통계량 추출방법과 비교사 학습모델인 GLVQ알고리즘을 적용하였다. 실험은 팬티엄 프로세서의 IBM-PC 기종을 이용하였으며, 사용언어는 C언어로 작성하였다.

차종별 인식 실험결과가 다음 <표 4>와 같다.

<표 4> 9개 차종에 대한 차종 인식 실험결과  
<Table 4> Experimental Results of 9 vehicles

구분	통계량-1(%)	통계량-2(%)	신경망모델(%)
1종	94.0	92.8	98.0
2종	82.2	85.3	93.7
3종	97.8	87.3	100
4종	50.8	73.5	-
5종	71.0	69.0	-
6종	73.5	80.0	-
7종	77.1	86.1	-
8종	77.1	91.7	-
9종	100	89.5	-

주) (-)속성혼합으로 인식정도를 규정할 수 없음.

위 <표 4>에서 제시된 바와 같이 특징추출 방법 중 통계량 추출방법-2는 방법-1과 비교하여 전체적으로 약 5%인식률이 향상된 것으로 나타났다. 이러한 결과는 통계량 추출방법-1에 비하여 방법-2가 상대적으로 정교한 특징추출이 되었기 때문으로 사료된다.

<표 5> GLVQ에 의한 차량분포비율  
<Table 5> Distribution ratio by GLVQ

(단위 × 100%)

구분	1종	2종	3종	4종	5종	6종	7종	8종	9종
C(1)	0.22	0.01	-	-	-	-	-	-	-
C(2)	0.29	-	-	-	-	-	-	-	-
C(3)	-	0.05	-	0.92	0.94	1.0	1.0	1.0	1.0
C(4)	-	-	0.3	-	-	-	-	-	-
C(5)	0.01	0.52	-	0.08	0.06	-	-	-	-
C(6)	0.22	-	-	-	-	-	-	-	-
C(7)	0.25	-	-	-	-	-	-	-	-
C(8)	0.01	0.42	-	-	-	-	-	-	-
C(9)	-	-	0.70	-	-	-	-	-	-

<표 5>는 ILD를 통과한 차량의 신호에서 10개의 샘플로 특징 추출한 데이터를 신경망의 GLVQ알고리즘으로 클러스터링한 결과이다. GLVQ로 클러스터링을 할 때 초기 학습률을 0.4, 최대반복횟수를 2500회를 하여 그 결과를 산출하였다. <표 5>에 제시된 바와 같이 신경망 모형에 의한 방법은 9개 차종에 대하여 승합차종(승용차, 봉고, 버스)의 경우 효과적으로 인식이 가능하지만 그의 트럭군(승합차량군을 제외한 6개 차종)에 대해서는 각 클러스터별 속성들이 혼진되어 인식효과가 매우 낮게 나타났다. 이는 정규화 과정에서 산출된 데이터가 각 차종의 특징을 충분히 반영하지 못하였기 때문이다. 특히 트럭군(2t, 5t, 11t, 15t, 8t, trailer)은 파형의 유사성으로 인하여 그 특징을 인식할 수 없기 때문에 거의 하나의 클러스터에 혼합되어 있음을 알 수 있다.

### 6. 결 론

본 연구에서는 도로를 통행하는 차종들을 실시간으로 인식하기 위하여 3개의 적용가능한 방법들을 제

시하였다. 이들에 관한 결론은 다음과 같다.

첫째, 본 연구에서 적용된 두 통계량 추출방법은 경쟁적이며 좌우 대칭적 패턴들을 대상으로 효과적인 인식이 어렵다. 따라서 통계량 추출방법은 자료의 전처리과정에서 특징점 추출을 위한 새로운 처리과정이 필수적으로 요구된다.

둘째, 통계량 추출방법-2는 통계량 추출방법-1과 비교시 약 4%의 인식을 증가 효과가 있었으며, 방법-1에서의 단점을 어느정도 극복할 수 있었으나 전처리과정에서 명확한 특징점을 추출하는데 여전히 문제점을 안고 있다.

셋째, 신경망 모델인 GLVQ 알고리즘에 의한 방법은 차종별 불균형적인 자료의 수와 알고리즘에서의 정지규칙(stopping rule)의 약화로 인식이 통계량추출방법 보다는 매우 낮은 결과를 얻는다. 그러나 세분화된 축차적인 방법을 적용함으로써 보다 향상된 인식결과를 얻을 수 있을 것으로 판단된다.

넷째, GLVQ 방법 적용결과 승합차량군과 트럭군의 대분류 효과와 승합차량군들중 승용차, 봉고, 버스의 인식이 약 93.7% 수준에 이르고 있어 무인자동감시체계구축의 가능성을 보여주고 있다.

이상의 결론으로 향후 다양한 신경망 모델의 응용으로 우수한 차종인식 모델의 구축이 가능하리라 판단되며, 이를 기반으로 국내 고유의 무인자동감시체계 구축이 가능하다. 이를 위해서는 전처리과정에 해당되는 특징점 추출에 관한 연구가 필수적으로 요구된다.

## 참 고 문 헌

[1] 국토개발연구원, 도로교통량조사 및 관리제도개선 연구 최종보고서, 1993.  
 [2] 도로교통안전협회, 서울특별시 교통신호제어시스템 연구용역시행 2차년도 결과보고서, 1993.  
 [3] 도로교통안전협회, 서울특별시 교통신호제어시스템 연구용역시행 3차년도 결과보고서, 1993.  
 [4] 한국도로공사, 고속도로교통관제시스템(FTMS) 구축을 위한 소프트웨어개발 및 시스템관리 용역 중간보고서(1차), 1993. 12.  
 [5] 민준영, "신경망 클러스터링의 성능평가", 성균관대학교 박사학위 논문, 1994.


[6] M.A.Ismail and M.S.Kamel, "Multidimensional Data Clustering Utilizing Hybrid Search Strategies", *Pattern Recognition*, Vol. 22, No. 1, 1989, pp.75-89.  
 [7] James L. McClelland, Daid E. Rumelhart, *Experiments In Parallel Distributed Processing*, 3rd Ed., 1988.  
 [8] Laurence Fausett, *Fundamentals of Neural Networks*, Prentice-Hall, 1994.  
 [9] T. Kohonen, *Self-Organization and Associative Memory*, Berlin, Germany:Springer-Verlag, 3rd Ed., 1989.  
 [10] T. Huntberger and P. Aimarangsee, *Parallel Self-Organization Feature Maps for Unsupervised Pattern Recognition*, *Int. J. General Systems*, Vol. 16, 1989, pp.357-372.  
 [11] Helge Ritter, Thomas Martinets, Klaus Schulten, "*Neural Computation and Self-Organizing Maps*", *Addison-Wesley Publishing Co. Inc.*, 1992.  
 [12] John Hertz, Anders Krogh, Richard G. Palmer, "*Introduction to the Theory Neural Computation*", *Addison-Wesley Publishing Co. Inc.*, 1991.  
 [13] Nikhil R. Pal, James C. Bezdek, Eric C.-K. Tsao, "Generalized Clustering Networks and Kohonen's Self-Organizing Scheme," *IEEE Transactions on Neural Networks*, Vol. 4, No. 4, July 1993.



**조 형 기**

- 1987년 아주대학교 산업공학과 졸업(학사)
- 1989년 아주대학교 대학원 산업공학과(석사)
- 1994년~현재 아주대학교 대학원 박사과정
- 1991년~현재 아주대학교 교통연구소 전임연구원

1993년~현재 상명여자대학교 정보처리학과 강사  
관심분야: 신경회로망, IVHS.



**민 준 영**

- 1982년 아주대학교 산업공학과 졸업(학사)
- 1989년 성균관대학교 경영대학원 정보처리학과(석사)
- 1995년 성균관대학교 대학원 전산통계전공(박사)

1993년~현재 상지대학교병설전문대학 전자계산과 전임강사  
관심분야: 신경회로망, 패턴인식



**최 종 욱**

- 1982년 2월 아주대학교 공과대학 산업공학과 졸업(학사)
- 1982년 8월 서울대학교 대학원 경영학 석사과정 I 학기 수료
- 1988년 Univ. of South Carolina MIS

1985년~1986년 Institute of Information Management and Policy at Univ. of South Carolina Research Assistant

1986년~1987년 Johnson C. Smith Univ. Computer System Specialist

1988년~1991년 KIST 시스템공학센터 인공지능연구부 지식처리연구실 실장

1992년~현재 상명대학교 정보처리학과 교수  
주요관심분야: 전문가시스템, Neural Network, 멀티미디어.