

신경망을 이용한 루프검지기 차종분류 알고리즘

(ILD Vehicle Classification Algorithm using Neural Networks)

기 용 곁^{*} 백 두 권^{**}

(Yong-Kul Ki) (Doo-Kwon Baik)

요 약 본 논문은 루프검지기를 이용한 차종분류 방법의 성능 향상을 위해 신경망 패턴인식 기술을 이용한 차종분류 알고리즘을 제안하였다. 기존의 루프검지기 차종분류 방법은 차량의 길이 정보만을 이용해서 차종을 분류하는 것이다. 그러나 루프검지기의 특성상 차종에 따른 길이 정보가 정확하지 않으므로 길이가 비슷한 차종에 대해서는 차종분류 오류가 자주 발생하고 있는 실정이다. 이와 같은 문제점을 개선하기 위해 본 연구에서는 루프검지기 시스템에 신경망 패턴 인식 기술을 적용하였다. 제안된 알고리즘은 차량이 검지영역을 통과할 때 발생하는 루프검지기 공진주파수 값 변화율과 점유시간 정보를 신경망의 입력자료로 활용하여 차량을 5가지 종류로 분류하는 방식이다. 개발된 알고리즘의 성능을 평가하기 위하여, 현장실험을 통해 자료를 수집하고 신경망 학습 및 실험을 실시한 결과 차종분류 정확도가 91.3%였으며, 이는 기존의 연구결과와 비교할 때 매우 높은 것이다.

키워드 : 차종분류, 루프검지기, 신경망

Abstract In this paper, we suggested a vehicle classification algorithm using pattern recognition method. At present, Inductive Loop Detector is rarely used for vehicle classification because of its low accuracy. To improve the accuracy, we suggest a new algorithm for Loop Detector using neural networks. In the developed algorithm, the inputs to the neural networks are the variation rate of frequency and occupancy-time. The output is classified vehicles. The developed algorithm was assessed at test sites and the recognition rate was 91.3percent. The results verified that the proposed algorithm improves the vehicle classification accuracy compared to the conventional method based on Loop Detector.

Key words : Vehicle classification, Loop Detectors, Neural Networks

1. 서 론

도로상의 차량흐름 상태를 파악하고, 각종 교통정보를 수집하기 위하여 도로 표면이나 측면에 설치되는 것이 교통정보 수집용 검지기이다. 교통정보 수집용 검지기에서 수집된 차량의 속도, 교통량, 점유율, 차종 등에 관한 정보는 교통운영 및 교통계획 등 교통의 거의 모든 분야에서 사용되는 중요한 기초 자료가 된다. 루프검지기(Inductive Loop Detector : 이하 ILD라 함)는 1969년 Automatic Traffic System Laboratory(ATSL)에서 개

발된 검지기로 교통정보를 수집하기 위하여 적용된 이래 최근에 이르기까지 세계적으로 가장 많이 이용되고 있는 교통정보 수집용 검지기이다[1,2].

도로상을 주행하고 있는 차량의 종류(차종)에 관한 정보는 ITS(지능형 교통시스템) 및 각종 교통분야에서 다인승 전용차로의 단속체계, 중차량 구성비, 도로용량 분석, 신호제어, 도로 설계 및 유지관리 등의 각종 교통분석 및 지표로 활용될 수 있는 기초 데이터이며 이 데이터에 오류가 있을 경우 이를 바탕으로 한 각종 시스템 및 정책이 잘못된 결과를 산출하게 된다. 따라서, 차종에 관한 정보의 신뢰도를 확보하는 것이 매우 중요하다. 국내에서는 차량 분류 정보가 아직 많이 사용되지 못하고 있는 실정이며[3-5], 이는 차종 정보를 정확히 검지하고 이용할 수 있는 기술이 발전되지 못하였기 때문이

^{*} 정 회 원 : 고려대학교 컴퓨터학과

kiyongkul@rtsa.or.kr

^{**} 종신회원 : 고려대학교 컴퓨터학과 교수

dkbaik@korea.ac.kr

논문접수 : 2005년 11월 22일

심사완료 : 2006년 3월 15일

다. 현재 사용중인 ILD의 차종분류 알고리즘은 차량의 주행 속도 및 점유시간을 측정하여 차량의 길이를 산출하고 차종을 분류하는 방식이다. 이러한 방식을 이용한 ILD가 일부 고속도로에서 사용중에 있으나 차종분류 정보의 신뢰도가 낮은 것으로 알려져 있다[6,7].

역전파 신경망(Backpropation Neural Network)은 패턴 인식, 음성 인식, 자연언어 이해 등의 응용분야에 많이 적용되고 있으며, 그 효과가 뛰어난 것으로 알려져 있다[8,9]. ILD의 차종분류 방식도 일종의 패턴 인식으로 볼 수 있으며, 신경망 패턴 인식 기술을 ILD 차종분류 알고리즘에 적용한다면 성능이 크게 개선될 수 있을 것이다. 이러한 착안점에서 국내 교통정보 수집을 위해 다수 설치되어 운영중인 ILD에 신경망 패턴 인식 기술을 적용하여 차종분류 알고리즘을 개선하는 것이 본 연구의 목적이다.

2. 관련 연구

ILD는 일반적으로 미국의 NEMA(National Electrical Manufactures Association : NEMA) 표준에 의하여 설치되며 주요 구성 요소는 다음 그림 1과 같이 루프 코일, 도입선, 검지부이다. 루프 코일은 도로면에 매설되며, 일반적으로 직경이 약 5mm의 전선을 2~4회 회전시켜 설치된다. 도입선(lead-In-Cable)은 루프 코일과 현장제어기 내에 있는 검지부 장치(Detection Device Unit)까지 연결하는 케이블로 루프 코일과 검지부 장치간 거리가 짧을 경우 도입선과 검지부 장치를 직접 연결하기도 한다. 검지부 장치는 루프 코일에 10KHz~200KHz의 주파수를 갖는 교류 전류를 전송한다. 루프 코일에 전류가 흐르면 교번자장(Alternative Magnetic Field)이 형성된다. 이러한 전기적 특성(저항, 인덕턴스, 커패시턴스)이 상호 작용하여 통과 차량을 검지한다[1].

ILD가 실제로 루프의 인덕턴스를 측정할 수는 없으며 ILD의 주파수 성분 또는 위상의 변화를 측정함으로써 인덕턴스의 변화를 검지하게 된다. 그림 2는 차량이 루프 코일의 검지 영역에 존재하지 않을 때와 존재할 때의 ILD 주파수 값의 변화를 나타낸다. 차량이 루프 코일의 검지 영역 내에 존재할 때의 ILD가 더 높은 주파수 값을 가지고 있음을 알 수 있다.

ILD 기반의 차종분류에 관한 연구사례는 많지 않으며, 국내/외에서 몇 건의 연구사례가 발표되었다. 2000년 Gajda는 한 개의 ILD를 통과하는 차량에 의해 발생하는 인덕턴스 신호를 Signal pattern matching 기술을 이용하여 차종을 분류하는 방식을 제안하였다[10]. 국내의 경우 2002년 박종연은 Fuzzy논리를 ILD 차종분류 기술에 적용하여 차량의 종류를 4종으로 분류하는 알고리즘을 제안하였다[11].





그림 1 ILD의 구성



(a)



(b)

그림 2 차량 진행에 따른 주파수 값의 변화. (a) 차량이 ILD 검지영역에 진행, (b) 주파수 값의 변화

현재 사용되고 있는 ILD 차종분류 기술은 차량의 길이를 산출하여 차량의 종류를 소형차, 중형차, 대형차의 3종으로 분류하는 것이며, 박종연이 제안한 알고리즘은

기존의 ILD 차종분류 방식에 Fuzzy논리를 적용하여 차량의 길이 측정 정확도를 개선하는 것이다. Fuzzy 알고리즘을 적용한 현장실험에서 분류 대상 차량을 4종으로 분류하는 실험을 실시하였으며, 실험 결과 인식률은 85.4%였다[11].

3. 차종분류 알고리즘 개발

3.1 차종분류 기준 설정

국내에서 차종분류 정보를 수집하고 사용하고 있는 곳은 한국도로공사가 대표적이며, 그 외에는 차종 정보가 별로 사용되지 못하고 있는 실정이다. 한국도로공사는 고속도로 유지보수계획, 교통사고 분석, 인적/물적 자원 이동 및 영업시설 개선자료로 활용하기 위해 차량의 종류를 소형차, 중형차, 대형차로 구분하여 사용하고 있다.

이러한 분류법은 진출/입이 통제되는 고속도로의 특성상 고속도로 틀게이트에서 취득하기 쉬운 자료를 위주로 작성된 것으로, 고속도로 유지/관리 등의 목적에는 유용할 것으로 보인다. 그러나 오토바이 등 이륜차가 빠져 있고 승용차, 승합차, 2.5톤 미만 트럭이 같은 차종(소형차)으로 분류되는 등 시가지 및 지방부 도로에서 사용되는 교통정보로는 적합하지 않다.

따라서, 본 연구에서는 국내/외 차종분류 현황조사 결과를 바탕으로 교통공학 분야에서 보다 일반적이며, 효과적으로 사용될 수 있는 차종분류 기준을 표 1과 같이 제시하고, 이 기준에 따라 차량을 크게 5가지(승용차, 승합차, 버스, 트럭, 오토바이)로 구분하여 분류하는 방식을 사용하였다.

표 1 차종분류 기준표

차종	대표차량
1종(승용차)	소나타, 마티스, 엑센트, 그랜저, 옵티마, 렉스턴, 쉐로퍼, 산타모, 산타페 등
2종(승합차)	그레이스, 베스타, 이스타나, 프레지오, 스타렉스 등
3종(버스)	중형버스, 대형버스 등
4종(트럭)	5톤 이하 트럭
	5톤 초과 대형 트럭
	트레일러 등 특수차량
5종(오토바이)	오토바이

3.2 ILD 차종분류 기술의 문제

현재 한국도로공사는 고속도로에서 ILD, 영상검지기 등의 교통정보 수집용 검지기를 이용하여 차종 정보를 수집 및 사용하고 있다. 고속도로에서 사용중인 ILD 차종분류 기술의 핵심 알고리즘은 그림 3과 같다. 그림 3에서 거리 A와 시간($T_2 - T_1$)을 측정하여 차량의 속도




그림 3 ILD 차종분류 알고리즘

를 구하고, 점유시간($T_3 - T_1$)을 그림에 표시된 것과 같이 구한다. 차량의 점유시간과 속도 값을 기준으로 차량의 길이를 산출하며, 차량의 길이를 가지고 차량 종류를 소형, 중형, 대형으로 분류하여 사용한다[12]. 이러한 방식의 차종분류 알고리즘은 차종 정보 산출하는 데 있어 다음과 같은 오류 요인을 포함[13,14]하게 된다.

첫째, 차량 길이 산출 식에 포함된 오류이다. 기존의 ILD 차종분류 알고리즘은 차량의 속도 및 점유시간 정보를 차량 길이 산출 식에 입력하여 차종을 분류한다. 그러나 차량의 길이를 산출하는 식은 경험적인 실험 값에 의한 것이며, 과학적이며 정확한 관계식이 알려져 있지 않은 실정이다.

둘째, ILD 점유시간 오차에 따른 차종분류 오류이다. 지면으로부터 차량 밀면까지의 높이가 높은 차량(트럭 등)은 타 종류의 차량(승용차 등)보다 점유시간이 상대적으로 짧아지게 되며, 차종분류 오류가 발생될 소지가 있다. 이는 도로에 설치된 루프 코일과 차량 바닥 면까지의 거리가 크면 차량의 도체 성분이 검지기 검지영역에 영향을 적게 주게 되고, ILD 주파수 값의 변화가 작아지게 되어 점유시간이 짧아지기 때문이다.

셋째, 차량 속도측정 오차 요인이다. 기존의 ILD 차종분류 방식은 차량의 속도측정 신뢰도를 높이기 위해 2개의 루프 코일을 사용하고 있으나, ILD는 Sampling Time 간격, 검지기간 거리, 환경적 요인 등에 의해 속도측정 오차를 원천적으로 포함하게 된다. 이러한 오차는 차량의 길이를 잘못 계산하는 결과를 초래한다.

넷째, 기존의 ILD 차종분류 방식은 속도를 정확히 측정을 위하여 2개의 ILD를 사용하여야 하며, 이는 단일 ILD를 이용한 차종분류 방식보다 설치 및 유지, 관리 비용이 많이 든다.

3.3 역전파 신경망을 이용한 ILD 차종분류 알고리즘

본 연구에서는 3.2절에서 설명한 기존의 차종분류 알

고리즘의 한계를 극복하고자 다음 그림 4와 같은 차종 분류 방식을 제안하였다. 즉 신경망을 이용한 ILD 차종 분류 알고리즘은 도로에 설치된 1개의 루프 코일을 이용하며, 차량이 ILD 검지영역을 통과할 때 발생하는 공진 주파수 파형의 특성을 분석하는 것이다. ILD 공진 주파수 파형의 차종별 특징을 분류하기 위하여 신경망 패턴 인식 기술을 이용하였으며, 분류 분야에서 탁월한 효과를 보이는 역전파 신경망(Backpropagation Neural Network)을 사용하였다.

역전파 신경망을 이용한 패턴 인식 알고리즘은 그림 5와 같다. ILD 공진 주파수 파형의 특징 값을 추출하고 이를 특징 벡터로 구성하여 역전파 신경망에 입력 벡터로 사용한다. 역전파 신경망은 입력된 특징 벡터 값을 이용하여 차량의 종류를 승용차, 승합차, 버스, 트럭, 오토바이의 5종으로 분류하는 것이다. 이중 가장 중요한

것은 신경망 패턴 인식을 위해 어떠한 특징 값을 사용할 것인가를 결정하는 것이다. 일반적으로 인식 대상의 특징 값으로 어떤 것을 사용하느냐에 따라 패턴 인식의 성패가 달려 있기 때문이다. 본 연구에서는 패턴 인식의 특징 추출을 위하여 현장실험을 실시하여 차종별로 주파수 값을 수집하였다. 수집한 ILD 주파수 파형의 차종별 특징을 분석하고 차종분류에 사용될 수 있는 특징 값을 결정하였다.

본 연구에서 사용한 특징 값은 차량이 ILD 검지영역에 진행할 때 발생하는 주파수 값 변화율과 점유시간 정보이다. 두가지 정보를 ILD에서 검지하고, 특징 벡터를 구성하였으며, 역전파 신경망에 입력 벡터로 사용하였다.

제안된 차종분류 알고리즘의 순서를 그림으로 표시하면 그림 6의 순서도와 같다. ILD는 일정 시간 간격(Sampling Time)으로 공진 주파수 값을 계속 측정하고 있으며, 차량이 ILD 검지영역에 진입하면 주파수 값이 증가하게 된다. 이때 제안된 알고리즘은 주파수 파형의 특성을 분석하고, 주파수 변화율과 점유시간 정보를 추출하여 신경망의 특징 벡터를 구성한다. 구성된 특징 벡터 값은 역전파 신경망에 입력되며, 신경망의 패턴 인식 결과 출력된 값은 분류된 5종의 차종분류 결과이다.




그림 4 신경망 차종분류 방식의 ILD 구성

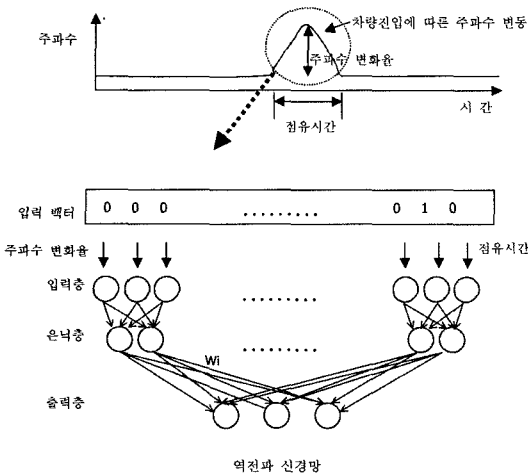


그림 5 신경망을 이용한 차종분류 알고리즘

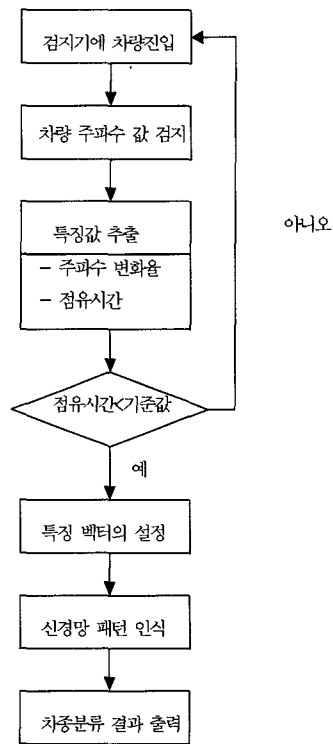


그림 6 차종분류 알고리즘 순서

4. 신경망 구성을 위한 ILD 주파수 특성 분석

4.1 차종별 주파수 파형의 특성

ILD가 설치된 2개 지점(충청북도 청주시 정화사거리, 제주도 서부산업도로)에서 그림 7의 실험 장치(Sampling Time 2.38ms)를 이용하여 현장실험을 실시하였으며, ILD 공진 주파수 자료를 수집하였다. 동시에 실험 기간 중 측면에서 비디오 촬영을 하여 차종을 확인하였다. 수집된 자료를 분석하여 차종별 주파수 파형의 특성을 파악하고, 신경망 패턴 인식에 사용할 특징을 추출하였으며, 5장의 신경망 학습 및 실험 자료로 사용하였다.

차종별 주파수 파형의 특성을 분석한 결과 공진 주파수 값 변화율이 차종별로 현저히 다른 것으로 나타났다.

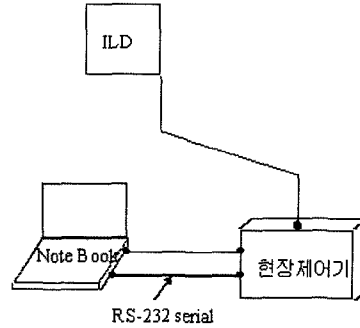
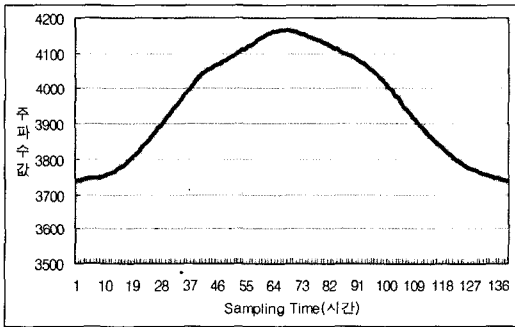



그림 7 실험장비의 구성


이는 차종별로 차량 밑면의 지면으로부터 높이가 다르




(a) 승용차




(b) 승합차



(c) 버스



(d) 트럭



(e) 오토바이

그림 8 차종별 주파수 특성

기 때문이다. ILD는 검지기위에 형성된 전자장의 영역에 차량이 진입할 경우 이를 검지하게 되며, 차량 밑면의 높이가 높을 경우 검지영역과의 거리가 멀어져 검지기에 영향을 적게 주게 되고 주파수 변화도 작아지게 된다. 따라서 차체 밑면의 높이가 낮은 승용차나 승합차는 주파수 변화율이 크고, 차체 밑면의 높이가 높은 트럭이나 버스의 경우 주파수 변화율이 낮은 것이 일반적인 특성이다.

또 한가지의 특성은 차종별로 점유시간이 다르다는 것이다. 승용차나 오토바이는 점유시간이 짧고, 트럭이나 버스는 점유시간이 길며, 승합차는 승용차와 트럭의 중간 정도의 점유시간을 나타낸다. 차종별로 점유시간이 다른 이유는 일반적으로 차량의 길이와 속도가 다르기 때문이다. 차량의 길이가 짧고 속도가 높은 승용차의 경우 ILD 검지영역에 존재하는 시간이 짧아 차량의 점유시간이 짧아지는 경향을 보이며, 차체의 길이가 길고 상대적으로 저속으로 주행하는 버스와 트럭의 점유시간은 길어지는 경향이 있다. 한편, 오토바이의 경우 길이가 짧아 점유시간이 매우 짧은 특성을 나타냈다. 공진 주파수 파형의 특성을 보면 승용차는 포물선 형태의 좌우대칭형의 모양을 나타내나, 트럭이나 버스의 경우 상대적으로 불규칙한 형태를 보이며 따라서 특징 추출에 적합하지 않았다. 승합차의 경우는 승용차와 비슷한 형태를 나타내나 최고점에서의 점유시간이 승용차보다 긴 특성을 보인다. 이는 차량의 길이 및 차축과 같은 차량하부의 모양에 의해 발생하는 현상이다.

4.2 특징 벡터 구성

신경망을 이용하여 차량을 5종으로 분류하려면, 분류 대상의 특징 값을 추출하여 특징 벡터를 구성해야 한다. 현장실험을 통해 수집한 주파수 파형의 패턴을 분류대상 5개 차종으로 나누어 분석한 결과 ILD 주파수 변화율, 차량이 검지기에 존재하는 시간을 나타내는 점유시간, 주파수 파형의 모양 등이 차종별로 다른 패턴을 나타내는 것을 알 수 있었다. 주파수 값의 변화율은 차량하부의 높이 및 모양과 관계가 있으며, 차량의 점유시간은 차량의 길이와 속도에 따른 종속변수이고, 주파수 파형의 모양은 차량 하체의 형태, 차축의 위치 등에 영향을 받는 항목이다.

제한된 알고리즘을 실제로 적용하기 위해서는 적절한 특징을 사용하여야 하며 주파수 값 변화율과 점유시간은 특징이 명확하고 특징벡터 산출이 용이하나, 주파수 파형의 모양은 버스와 트럭의 경우 변화가 많아 특징 추출이 용이하지 않았다. 따라서 본 연구에서는 주파수 값 변화율과 차량 점유시간을 추출하여 신경망의 특징 벡터를 구성하였다.

신경망의 입력자료 중 주파수 값 변화율(F_v)은 식 (1)

에 의하여 구하였으며 이를 표 2에 대입하여 특징 벡터 값을 결정하였다.

$$F_v = \left[\frac{F_p - F_l}{F_m - F_l} \right] \times 100\% \quad (1)$$

여기서

F_v : 주파수 값 변화율(단위 %)

F_l : ILD 검지 영역에 차량이 없을 때 기본 주파수 값

F_p : 차량이 검지영역에 진행하여 변화한 주파수 값 중 최고값

F_m : 모든 차량의 F_p 값중 최고값

점유시간은 차량이 ILD 검지영역에 진입하여 빠져나가기까지 걸리는 시간을 말한다. 점유시간의 특징 벡터 값은 측정된 점유시간을 표 2의 기준에 따라 산출하였다. 표 2의 기준은 현장실험에서 수집된 차량의 ILD 주파수 값 중 신경망 학습 데이터(Training Set)로 사용한 160개 자료의 특성을 분석하여 산출하였다.

표 2 특징 벡터의 구성기준

특징 번호	주파수 변화율(%)	점유 시간 (ms)
1	0 - 15.6	0 - 214
2	15.7 - 22	215 - 309
3	22.1 - 26.3	310 - 404
4	26.4 - 30.6	405 - 476
5	30.7 - 40	477 - 547
6	40.1 - 43.4	548 - 618
7	43.5 - 49.8	619 - 714
8	49.9 - 54.1	715 - 833
9	54.2 - 58.3	834 - 952
10	58.4 - 100	953 - 1500

4.3 신경망 구성

본 연구에서 사용된 역전파 신경망은 그림 9와 같이 입력층 20개의 유니트, 은닉 1층에 유니트 10개, 출력층 5개의 유니트로 구성되었다. 입력 벡터는 차량의 주파수 값 변화율과 점유시간 자료를 이용하여 추출한 특징 벡터값 20개 유니트이며 출력값은 승용차, 승합차, 버스, 트럭, 오토바이의 5개로 분류된 차량의 종류이다.

5. 차종분류 실험 및 결과

5.1 실험 환경

본 연구에서 제한한 신경망을 이용한 ILD 차종분류 알고리즘의 성능을 평가하기 위하여, 4.1절의 현장실험에서 수집한 차량별 주파수 값 자료를 이용하여 특징 추출 및 차종분류 실험을 수행하였다. 실험에 사용된 자료의 수는 표 3과 같으며 실험 기간에 통행차량의 구성




그림 9 차종분류 신경망의 구성

표 3 학습 및 실험에 사용된 차종별 자료

구분 \ 차종	승용차	승합차	버스	트럭	오토바이	총계
학습 데이터 수	70	16	9	62	3	160
실험 데이터 수	149	22	9	72	3	255

비율에 따라 사용된 데이터의 수도 차종별로 다른 분포를 가진다. 자료수집을 위한 현장실험은 제안된 알고리즘의 현장 적용성을 높이기 위해 도시부도로(충북 청주시 정화사거리)와 지방부도로(제주도 서부산업도로) 각 1개소에서 실시하였다.

현장실험에서 수집한 차량 415대에 대한 주파수 값

자료를 2개 그룹으로 나누어 먼저 160개의 차량 주파수 값을 학습 데이터(Training Set)로 사용하였고, 나머지 255개의 차량 주파수 값을 실험 데이터(Test Set)로 사용하였다. PENTIUM IV에서 Visual C++을 이용하여 특징 벡터를 추출하는 알고리즘을 구현하였으며, 추출된 특징 벡터는 역전파 신경망(Backpropagation Neural Network)을 이용하여 학습 및 분류 실험을 실시하였다. 본 실험에 이용한 역전파 신경망은 입력층 유니트 20개, 은닉층 1개층 유니트 10개, 출력층 5개 유니트로 구성하였으며, 전체 신경망의 구조는 그림 9와 같다.

5.2 신경망 학습 및 실험 결과

차종분류 실험을 수행하기에 앞서 먼저 표 3의 학습 데이터를 이용하여 신경망 학습을 수행하였다. 그림 10은 학습율, 오류 목표값, 모멘텀을 각각 1.0, 0.05, 0.8로 하고 13회 학습을 수행한 결과 오류가 특정 값으로 수렴됨으로써 학습이 수행되는 과정 및 결과를 보여준다.

$$\text{인식율} = \frac{i\text{종으로 분류된 차량수}}{i\text{종 실험 차량수} - \text{미분류 차량수(불량 자료)}} \quad (2)$$

13회의 학습을 수행한 후 표 3의 255개 실험 데이터를 이용하여 차종분류 실험을 수행하였으며 그 결과는 표 4와 같다. 실험 결과의 평가를 위한 평가지표로 인식율을 사용하였으며, 인식율은 총 시험차량 중 미분류 차량을 제외하고 분류대상 차량중 정확하게 분류된 차량수를 말한다. 이를 식으로 나타내면 식 (2)와 같다.

실험 결과 전체 시험대상 차량 255대 중 230대의 차량의 종류를 정확하게 분류하여 전체 인식율은 91.3%로 나타났다. 국내에 설치된 ILD의 차종분류 성능에 대한




그림 10 학습에 따른 오차율

표 4 역전과 신경망 차종분류 실험결과

		실제 차종					합계
		1종 승용차	2종 승합차	3종 버스	4종 트럭	5종 오토바이	
분류된 차종	1종 승용차	136	1	1	2		140
	2종 승합차	7	17	1	1		26
	3종 버스			7			7
	4종 트럭	5	4		67		76
	5종 오토바이					3	3
	미분류	1			2		3
	합계	149	22	9	72	3	255
인식률(%)		91.9	77.3	77.8	95.7	100	91.3

평가결과가 구체적으로 제시된 것은 없으며, 건설기술 연구원이 97년도에 영상, 초단파, 적외선, WIM(Weigh-In-Motion) 등의 검지기를 평가한 결과 WIM장비를 제외한 모든 검지기의 차종분류 성능이 현저히 떨어지는 것[6]으로 나온 것에 비추어 볼 때 제안된 알고리즘이 성능이 매우 뛰어난 것임을 알 수 있다.

차종별로 실험 결과를 살펴보면 1종 승용차의 경우 테스트 데이터 149개중 136개의 차량을 승용차로 분류하여 91.9%의 인식율을 보였다. 반면, 12대의 차량을 오분류(다른 차종으로 분류) 하였으며, 그중 7대의 차량은 2종(승합차)으로 분류하였고, 5대는 4종(트럭)으로 분류하였다. 오분류한 데이터는 주로 승용차를 승합차로 분류한 경우가 많았는데, 이는 승용차 중 지프형 차량의 특성과 승합차의 특성이 비슷한 경우가 있어 발생하는 것으로 보인다.

2종 승합차의 경우 총 22대의 실험 데이터중 5개의 차종이 잘못 분류되었으며, 이중 4대가 트럭으로 분류되었고, 1대가 승용차로 분류되었다. 3종 버스의 경우 실험 데이터 9대중 2대가 승용차와 승합차로 잘못 분류되었다. 4종 트럭은 72개의 실험 데이터 중 67대를 정확히 분류하여 95.7%라는 높은 인식율을 나타냈으며, 승용차로 2대 승합차로 1대가 잘못 분류되었다. 트럭의 경우 전반적으로 다른 종류의 차량보다 주파수 변화율이 전반적으로 낮고 점유시간이 길어 차종분류가 용이한 것으로 보인다. 5종 오토바이의 경우 주파수 변화율이 매우 작고 점유시간도 짧아 다른 종류의 차종과 ILD 주파수 특성이 매우 상이한 특성을 보이며 따라서 인식율이 매우 높게(100%) 나왔다.

5.3 차종분류 알고리즘 평가

본 연구에서 제안한 신경망을 이용한 ILD 차종분류 알고리즘을 기존의 ILD 차종분류 기술, 박종연이 제안한 Fuzzy 논리를 이용한 ILD 차종분류 기술[11], Gajda의 모델[10]과 비교하여 분석하면 표 5와 같다. 기존의 ILD 차종분류 기술 및 Fuzzy 논리를 이용한 차종분류 기술은 루프 코일 2개를 이용하여 차종을 분류하는 방식

표 5 ILD 차종분류 기술 비교

특징	방식	기존 방식	Fuzzy 방식	Gajda 모델	신경망 방식
분류 기준		차량의 길이	차량의 길이	신호 패턴	주파수 파형
알고리즘		점유시간, 속도	Fuzzy 논리	Signal pattern matching	역전파 신경망
분류 차종		3종	4종	4종	5종
루프 코일 수		2개	2개	1개	1개
인식률		낮음	85.4%	83%	91.3%

식이나, Gajda의 모델과 신경망을 이용한 기술은 루프 코일 1개를 이용하여 차종을 분류하는 방식이다.

4가지 차종분류 방식의 핵심 알고리즘을 살펴보면, 기존의 차종분류 방식은 차량의 점유시간 및 속도를 이용하여 차량 길이를 산출하고 차량의 종류를 소형, 중형, 대형의 3종으로 분류하는 것이며, Fuzzy 논리를 이용한 차종분류 방식은 기존의 차종분류 방식에 Fuzzy 논리를 이용하여 차량의 길이 값을 보다 정확하게 산출하여 차종을 4종으로 분류하는 것이다[11]. 또한, Gajda의 모델은 루프의 출력 신호를 패턴매칭 기법을 이용하여 차량을 4종으로 분류하는 것이며, 본 연구에서 제안한 신경망을 이용한 ILD 차종분류 방식은 ILD 주파수 파형의 특징을 추출하여, 신경망 패턴 인식 기술을 이용하여 차량을 5종으로 분류하는 것이다.

현재 사용중인 ILD 차종분류 기술의 신뢰도가 구체적으로 평가된 것은 없으나 일반적으로 교통정보 수집용 검지기의 차종분류 기술 신뢰도가 매우 낮은 것으로 알려져 있으며[6], 박종연이 제안한 Fuzzy 논리를 이용한 ILD 차종분류 알고리즘은 차량을 4종으로 분류하며, 현장실험 결과 차종 인식율이 85.4%로 나타났다[10]. 또한 2000년 Gajda는 1개의 루프코일에서 얻어진 신호의 패턴매칭 기법을 이용하여 83%의 인식률로 차량을 4종으로 분류하였다.

본 연구에서 제안한 신경망을 이용한 ILD 차종분류

알고리즘은 현장실험에서 수집한 자료를 이용하여 신경망 학습 및 실험을 실시한 결과 차량을 5종으로 분류하는데 인식율이 91.3%였다. 이는 본 연구에서 제안한 알고리즘이 다른 방식의 차종분류 기술에 비해 성능이 매우 뛰어난 것을 나타낸다.

6. 결론

본 연구에서는 차량이 ILD 검지영역을 통과할 때 발생하는 공진주파수 파형의 차종별 특성을 분석하였으며, 그 특징 값으로 특징벡터를 구성하고 역전파 신경망에 입력하여 차량의 종류를 분류하는 알고리즘을 제안하였다. 개발된 알고리즘의 주요 착안점은 차량의 종류별로 ILD 공진 주파수 파형(변화율)이 상이하고 일반적으로 차량의 길이 및 속도에 따라 점유시간이 상이하다는 특성을 이용한 것이다. 제안된 알고리즘을 현장실험을 통해 평가하였으며 그 결과를 종합하여 다음과 같이 결론을 내릴 수 있다.

첫째, 역전파 신경망(Backpropagation Neural Network)을 이용한 ILD 차종분류 알고리즘의 실험에서 분류대상 차량을 정확히 분류한 정도를 나타내는 지표인 인식율이 91.3%에 이르는 등 제안된 알고리즘의 차종분류 성능이 탁월한 것으로 나타났다. 이 결과는 건설기술 연구원이 97년도에 실시한 검지기 기술 평가결과에서 WIM(Weigh-In-Motion)장비를 제외한 모든 검지기의 차종분류 성능이 현저히 떨어지는 것으로 나온 것[6]과 Gajda의 모델이 83%의 인식율을 나타낸 것에 비교하여 그 효과가 매우 뛰어난 것임을 알 수 있다[10].

둘째, 본 연구에서 제안한 알고리즘을 이용하여 승용차, 승합차, 버스, 트럭, 오토바이의 차종을 분류한 결과 트럭(95.7%) 및 오토바이(100%)의 인식율이 가장 높게 나타났으며, 그 다음으로 승용차(91.9%)의 인식율이 높게 나타났다. 반면에 승합차와 버스는 인식율이 77.3%와 77.8%로 상대적으로 낮게 나타났다. 승용차, 트럭, 오토바이의 차종 분류 정확도가 높게 나온 이유는 동차종의 주파수 파형의 특성이 다른 종류의 차량과 매우 상이하기 때문이다.

셋째, 기존의 ILD의 차종분류 방법은 2개의 ILD를 이용하여 차량의 속도 및 점유시간을 일차적으로 측정하고 이를 바탕으로 차량의 길이를 산출하여 분류대상 차량을 소형, 중형, 대형의 3개 차종으로 분류하는 방식이었으나, 본 연구에서 제안한 알고리즘은 단일 ILD를 이용하여 승용차, 승합차, 버스, 트럭, 오토바이의 5개 차종으로 차량을 분류하는 방식으로 비용 및 실용성이 기존의 방법보다 뛰어나다.

결과적으로 제안된 알고리즘은 ILD 차량분류 기술의 신뢰성을 확보하는데 크게 기여할 수 있을 것으로 판단된다.

참고 문헌

- [1] *Traffic Detector Handbook*, 2nd ed. Institute of Transportation Engineers, Washington, D.C., 1990.
- [2] B. Coifman. "Using Dual Loop Speed Traps To Identify Detector Errors," In *Transportation Research Record: Journal of the Transportation Research Board*, No. 1683, TRB, National Research Council, Washington, D.C., pp. 47-58, 1999.
- [3] J. Gajda, R. Sroka, M. Stencel, A. Wajda, T. Zeqlen. "A Vehicle Classification Based on Inductive Loop Detectors," In *Proc. Of the 18th IEEE Conf. IMTC*, Vol. 1, pp. 460-464, May 2001.
- [4] S. Gupte, O. Masoud, R. F. K. Martin, N. P. Papanikolopoulos, "Detection and Classification of Vehicles," *IEEE Trans. Intelligent Transportation Systems*, Vol. 3, No. 1, pp 37-47, Mar 2002.
- [5] W. Wu, Z. QiSen, W. Mingjun., "A Method of Vehicle Classification Using Models and Neural Networks," In *Proc. Of IEEE VTS 53rd, VTC*, Vol. 4, pp. 3022-3026, May 2001.
- [6] "수도권 도로 교통정보 관리체계 구축 기본설계 및 평가 연구 최종보고서", 건설교통부, 1997.
- [7] S. Tropartz, E. Hrber, K. Grner. Experiences and Results from Vehicle Classification Using Infrared Overhead Laser Sensors at Toll Plazas in New York City. In *Proc. IEEE /IEEJ/JSAI Conf. Intelligent Transportation Systems*, pp. 686-691, Oct 1999.
- [8] E. Gose, R. Johnsonbaugh, S. Jost. *Pattern Recognition and Image Analysis*. Prentice Hall PTR, Upper Saddle River, New Jersey, 1996.
- [9] H. M. Abdelbaki, K. Hussain, E. Gelenbe. "A Laser Intensity Image Based Automatic Vehicle Classification System," in *Proc. of IEEE Conf. Intelligent Transportation Systems*, pp. 460-465, Aug 2001.
- [10] J. Gajda, R. Sroka, M. Stencel, T. Zeqlen, "An Eastern European example of the identification of moving vehicle parameters using the tried and trusted method of weigh in motion," *Traffic Technol. Int.*, pp. 87-90, Aug/Sept. 2000.
- [11] 박종연, "Fuzzy 논리를 이용한 루프검지기의 차종분류 알고리즘 개발", 서울대학교 석사학위논문, 2002.
- [12] M. Pursula, I. Kosonen, "Microprocessor and PC-based Vehicle Classification Equipments Using Induction Loops," In *proc. of IEE 2nd Int. Conf. Road Traffic Monitoring*, pp. 24-28, 1989.
- [13] C. Sun, S. G. Ritchie, K. Tsai. "Algorithm Development for Derivation of Section-Related Measures of Traffic System Performance Using Inductive Loop Detectors," In *Transportation Research Record: Journal of the Transportation Research Board*, No.1483, TRB, National Research Council, Washington D.C., pp. 171-180, 1995.

- [14] Y. K. Ki, D. K. Baik, "A model for accurate speed measurement using double loop detectors," *IEEE Trans. Veh. Technol.*, Vol. 55, No. 3, May 2006, In Press.



기용길

1992년 경희대학교 전자공학과(학사). 2003년 고려대학교 소프트웨어공학(석사). 2006년 고려대학교 컴퓨터공학 박사수료. 1991~1992년 삼성전자(주). 1994년~현재 도로교통안전관리공단 교통과학연구원, 관심분야는 메타데이터, 모델링, ITS, 시뮬레이션 등



백두권

1974년 고려대학교 수학과 학사. 1977년 고려대학교 대학원 산업공학과 석사. 1983년 Wayne State Univ. 전산학 석사. 1986년 Wayne State Univ. 전산학 박사. 1986년~현재 고려대학교 컴퓨터학과 교수. 1989년~현재 한국정보과학회 이사/학술위원장/편집위원장/평의원. 1991년~현재 한국시뮬레이션학회 이사/부회장/감사/회장/고문. 1992년~현재 ISO/IEC JTC1/SC32 국내위원회 위원장. 1996년~1997년 고려대학교 컴퓨터과학기술연구소 초대소장. 2001년~현재 도산아카데미연구원 원장. 2002년~2004년 고려대학교 정보통신대학 초대학장. 2004년~현재 한국정보처리학회 부회장. 관심분야는 메타데이터, 소프트웨어 모델링, 모델링/시뮬레이션, 정보기술표준 등