

차량 주행제어를 위한 신경회로망을 사용한 주행패턴 인식 알고리즘

전순일* · 조성태* · 박진호* · 박영일** · 이장무***

Driving Pattern Recognition Algorithm using Neural Network for Vehicle Driving Control

Soon-il Jeon, Sung-tae Cho, Jin-ho Park, Yeong-il Park and Jang-moo Lee

Key Words : Driving Pattern Recognition, Neural Network, Driving Control

Abstract

Vehicle performances such as fuel consumption and catalyst-out emissions are affected by a driving pattern, which is defined as a driving cycle with the grade in this study. We developed an algorithm to recognize a current driving pattern by using a neural network. And this algorithm can be used in adapting the driving control strategy to the recognized driving pattern. First, we classified the general driving patterns into 6 representative driving patterns, which are composed of 3 urban driving patterns, 2 suburban driving patterns and 1 expressway driving pattern. A total of 24 parameters such as average cycle velocity, positive acceleration kinetic energy, relative duration spent at stop, average acceleration and average grade are chosen to characterize the driving patterns. Second, we used a neural network (especially the Hamming network) to decide which representative driving pattern is closest to the current driving pattern by comparing the inner products between them. And before calculating inner product, each element of the current and representative driving patterns is transformed into 1 and -1 array as to 4 levels. In the end, we simulated the driving pattern recognition algorithm in a temporary pattern composed of 6 representative driving patterns and, verified the reliable recognition performance.

기호설명

- C1 ~ C24 : Characteristic parameters of a driving pattern
- L1 ~ L4 : Levels of each characteristic parameter of a driving pattern

1. 서론

자동차 회사에서 제시하는 연비와 실제 주행시의 연비가 많은 차이를 나타내는 사실에서 알 수 있듯이, 연료소비와 배기가스 배출량을 비롯한 차량성능은 주행모드 및 운전자의 운전습관에 따

라 심한 편차를 나타낸다.

이런 이유로 각 주행모드에 적합한 제어전략 수립이 필수적이다. 특히 고연비 저공해를 목적으로 하는 하이브리드 차량의 경우, 기존 내연기관에 비해 주행모드 및 운전자의 운전습관에 대한 차량 성능의 민감도가 높으며, 제어전략이 부적절할 경우 연비 및 배기가스 결과가 내연기관에 비해 장점을 갖지 못할 수 있다.

이런 문제점을 해결하고 주행상황에 따라 제어전략을 유연하게 변환시키는 알고리즘을 적용하기 위해서는 주행패턴 인식이 선행되어야 한다.

일반적으로 운전자의 운전습관(악셀 또는 브레이크 사용 습관)은 주행 중의 차량 속도 및 가속도 결과로 나타나므로, 본 논문에서는 시간에 따른 차량속도 및 가속도 프로파일과 주행하는 도로의 시간에 따른 경사 프로파일을 모두 합쳐 주행패턴

* 서울대학교 기계설계학과 대학원

** 서울산업대학교 기계설계학과

*** 서울대학교 기계항공공학부

으로 정의하였다.

일반적인 주행 환경을 대표할 수 있는 6 개의 대표 주행패턴(6 representative driving patterns)을 선택하여 신경회로망에 학습시킨 뒤, 실제 주행하며 센서를 통해 얻게 되는 속도 및 가속도, 경사의 시간에 따른 프로파일을 일정 시간간격으로 분석한다. 이 분석 결과를 신경회로망의 입력으로 하여 주행패턴 인식 알고리즘을 적용하면 6 개의 대표 주행패턴 중에 가장 가까운 하나를 현재의 주행패턴으로 인식하게 된다.

2. 6 개의 대표 주행패턴의 선정

2.1 주행패턴의 특성 파라미터

주행패턴을 나타내는 특성 파라미터들은 Table 1 과 같다. 참고문헌 [3]에 따르면 연비 및 배기가스에 영향을 미치는 주요한 인자로는 C1, C2, C3, C4 들이 있으나, 본 논문에서는 경사에 관련된 파라미터들을 포함하여 24 개를 이용하였다.

Characteristic Parameters of A Driving Pattern	
C1	Average cycle velocity [km / hr]
C2	Average running velocity except stop time : $V > 0.5 \text{ km / hr}$ [km / hr]
C3	Relative duration spent at stop [%]
C4	Positive acceleration kinetic energy change per unit mass per unit distance(PKE) [m / s^2] : $PKE = \sum \frac{V_f^2 - V_i^2}{x}, \quad \frac{dV}{dt} > 0$ V_f, V_i : final and initial velocity in each acceleration x : total travel distance
C5	Average acceleration [m / s^2] : $a > 0.1 m / s^2$
C6	Average deceleration [m / s^2] : $a < -0.1 m / s^2$
C7	Average positive grade [deg.]
C8	Average negative grade [deg.]
C9	Relative duration spent at positive grade [%]
C10	Relative duration spent at negative grade [%]
C11	Number of stops per kilometer [num.]
C12	Average micro-trip time (from start to stop) [sec]
C13	Relative duration spent at acceleration [%]
C14	Relative duration spent at deceleration [%]
C15	Acceleration standard deviation [m / s^2]
C16	Deceleration standard deviation [m / s^2]
C17	Maximum velocity [km / hr]

C18	Velocity standard deviation [km / hr]
C19	Average grade [deg.]
C20	Maximum grade [deg.]
C21	Minimum grade [deg.]
C22	Grade standard deviation [deg.]
C23	Positive grade standard deviation [deg.]
C24	Negative grade standard deviation [deg.]

Table 1 Characteristic Parameters of a Driving Pattern

2.2 6 개의 대표 주행패턴의 특성

도심 주행패턴 3 개(Urban 1 [A], Urban 2 [B], Urban 3 [C]), 고속도로 주행패턴 1 개(Expressway [D]) 그리고 지방도로 주행패턴 2 개(Suburban 1 [E], Suburban 2 [F])로 6 개의 대표 주행패턴을 구성하였다.

대표 주행패턴은 Fig. 1 ~ 6 에 도시하였으며 각 파라미터에 따른 값들은 Table 2 와 같다.

[A]는 LA#4 모드(참고문헌[6])에 임의의 경사를 첨가하여, 중/저속의 평균속도와 작은 경사도를 가지는 도심 주행패턴을 대표한다.

[B]는 미국 뉴욕 모드(참고문헌[6])에 임의의 경사를 첨가하여, 저속의 평균속도 및 높은 정지율과 작은 경사도를 가지는 도심 주행패턴을 대표한다.

[C]는 한국 서울 남부순환도로 모드(참고문헌[5])로 실제 측정된 경사자료를 1.7 배로 증가 시켜, 중/저속의 평균속도와 큰 경사도 및 오르막길 주행 시간이 높은 특성을 가지는 도심 주행패턴을 대표한다.

[D]는 미국의 고속도로에서 측정된 실제 모드(참고문헌[6])로, 고속의 평균속도와 낮은 정지율 및 작은 경사도를 가지는 고속도로 주행패턴을 대표한다.

[E]는 미국의 지방도로 모드(참고문헌[6])에 임의의 경사를 첨가하여, 고속의 평균속도와 중/하의 정지율 및 경사도를 가지는 지방도로 주행패턴을 대표한다.

[F]는 한국 서울대학교 모드(참고문헌[5])로 실제 경사 자료를 1.5 배 증가 시켜, 중/저속의 평균속도와 높은 경사도 및 낮은 정지율을 가지는 지방도로 주행패턴을 대표한다.

이와 같이 본 논문에서는 여러 주행 모드 자료에 대한 통계분석을 통해, 대표성을 나타내는 모드를 사용, 또는 대표성을 나타내도록 경사도를 임의로 첨가하여 대표 주행패턴을 선정하였으므로 실제 주행패턴에 대한 대표성을 가지고 있다고 단정할 수는 없다.

따라서 차량 주행제어 알고리즘에 적용되어 제어 목적을 달성하기 위해서는 다양한 실제 주행패턴에 대한 통계분석을 수행한 뒤 대표 주행패턴을 선정하는 과정이 필수적이라 할 수 있다.

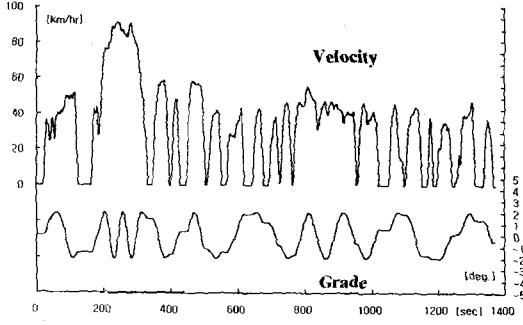


Fig. 1 Urban 1 [A]

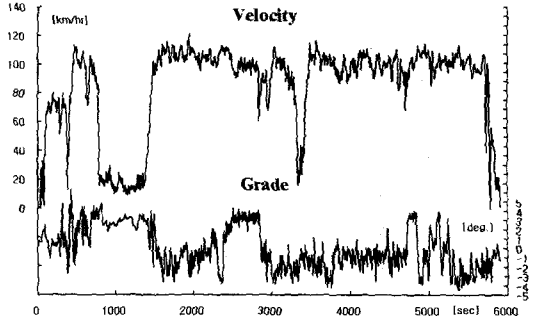


Fig. 4 Expressway [D]




Fig. 2 Urban 2 [B]

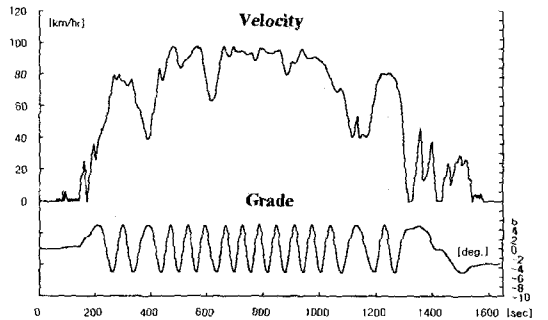


Fig. 5 Suburban 1 [E]




Fig. 3 Urban 3 [C]




Fig. 6 Suburban 2 [F]

	Urban 1 [A]		Urban 2 [B]		Urban 3 [C]		Expressway [D]		Suburban 1 [E]		Suburban 2 [F]	
C1	31.4	L3	11.4	L4	31.2	L3	84.8	L1	54.8	L1	29.3	L3
C2	39.0	L3	18.9	L4	37.0	L3	85.2	L1	61.7	L1	30.5	L4
C3	19.2	L2	39.5	L1	15.6	L2	0.4	L4	11.2	L3	3.8	L4
C4	0.34	L3	0.61	L1	0.49	L2	0.14	L4	0.11	L4	0.56	L1
C5	0.61	L1	0.72	L1	0.58	L2	0.28	L4	0.28	L4	0.57	L2
C6	-0.69	L4	-0.71	L4	-0.70	L4	-0.32	L1	-0.32	L1	-0.74	L4
C7	1.25	L4	1.98	L4	5.07	L1	2.32	L3	3.04	L3	6.41	L1
C8	-1.34	L1	-1.82	L2	-2.28	L2	-1.68	L1	-3.14	L3	-6.74	L4
C9	49.9	L3	55.0	L3	82.8	L1	40.5	L4	47.9	L3	56.5	L2
C10	44.9	L2	34.6	L3	15.6	L4	56.4	L1	46.0	L2	41.1	L2
C11	1.4	L3	9.5	L1	0.9	L3	0.0	L4	0.4	L3	0.6	L3
C12	65.2	L3	20.1	L3	108.0	L3	5892.4	L1	161.9	L3	202.5	L3
C13	32.3	L3	27.8	L4	41.1	L1	30.2	L3	26.5	L4	49.2	L1
C14	28.4	L3	28.1	L3	33.4	L1	27.2	L3	22.3	L4	37.5	L1
C15	0.44	L2	0.56	L1	0.45	L1	0.25	L4	0.15	L4	0.34	L3
C16	0.50	L2	0.53	L2	0.55	L1	0.35	L4	0.28	L4	0.60	L1
C17	91.3	L2	44.6	L4	78.2	L3	121.7	L1	97.7	L1	54.0	L4
C18	23.7	L2	12.9	L4	22.3	L3	31.4	L1	35.2	L1	13.4	L4
C19	0.02	L4	0.46	L3	3.85	L1	0.00	L4	0.01	L4	0.84	L3
C20	2.00	L4	3.00	L4	12.07	L1	6.22	L3	5.00	L3	18.00	L1
C21	-2.00	L1	-3.00	L1	-8.14	L3	-4.45	L2	-5.00	L2	-15.45	L4
C22	1.38	L4	1.95	L4	3.84	L2	2.24	L3	3.35	L3	7.59	L1
C23	0.59	L4	0.93	L4	2.92	L1	1.21	L3	1.61	L3	3.92	L1
C24	0.54	L4	0.80	L4	1.48	L3	1.05	L3	1.48	L3	4.34	L1

Table 2 6 Representative Driving Patterns

3. 주행패턴 인식 알고리즘

주행패턴 인식 알고리즘의 개요는 Fig. 7 과 같다.




Fig. 7 Schematic Diagram of the Driving Pattern Recognition Algorithm

6 개의 대표 주행패턴을 미리 신경회로망에 학습시킨 뒤, 실제 주행하며 센서를 통해 얻게 되는 속도 및 가속도와 경사도의 시간에 따른 프로파일을 일정 시간간격으로 통계 처리하여 24 개의 주행패턴 특성 파라미터에 해당하는 값을 계산한다. 이 계산 결과를 신경회로망이 인식할 수 있는 값(1 과 -1 의 조합)으로 변환시켜 신경회로망에 입력하면 6 개의 대표 주행패턴 중에 가장 비슷한 하나를 현재의 주행패턴으로 인식하게 된다.

사용된 신경회로망은 Hamming Network 로서(Fig. 8), Feed-forward Layer 에서 현재의 주행패턴과 6 개의 대표 주행패턴으로 구성된 Weight 행렬의 내적 (Inner Product)을 수행한 뒤, Recurrent Layer 에서는 내적이 가장 큰 하나(Hamming distance 가 가장 작은 경우)를 제외한 나머지 5 개의 값을 0 으로

수렴시켜 주행패턴 인식을 완료하게 된다.

현 주행패턴 및 대표 주행패턴을 실제 값 그대로 사용할 경우 상대적으로 값이 큰 몇 개의 주행패턴 특성 파라미터들에 의해 결과가 왜곡될 수

있으므로, 각 파라미터들에 의한 영향도를 동일화시키기 위해 대표 주행패턴 및 현 주행패턴 벡터의 각 파라미터는 레벨에 따라 1 과 -1로 구성된

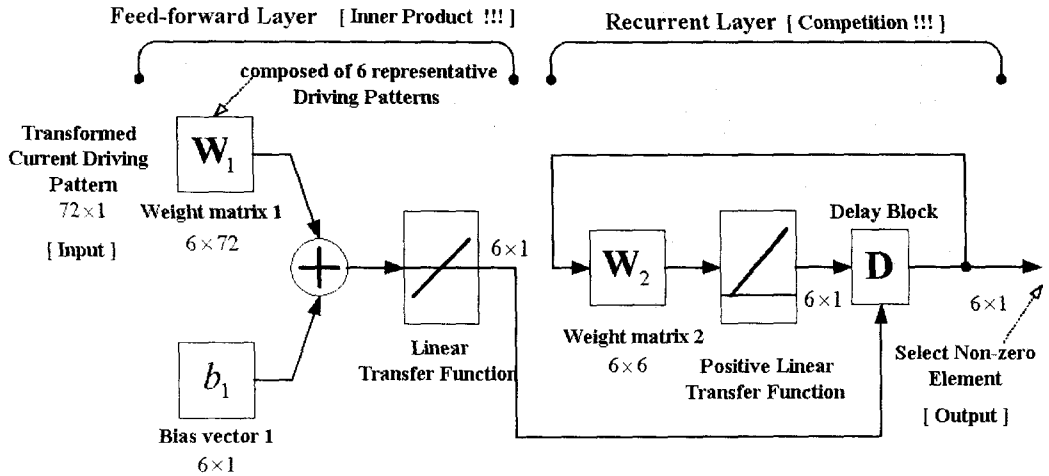


Fig. 8 Hamming Network

배열로 변환시켰다.(이렇게 함으로써 모든 주행패턴 벡터의 norm 이 동일하다.) 또한 주행패턴 특성 파라미터들의 중요도에 따라 내적 값의 가중치를 달리 적용할 수 있다.

또한 각각의 주행패턴 특성 파라미터(C1 ~ C24)에 대해 6 개의 대표 주행패턴의 평균(m)과 표준편차(std)를 구한 뒤, Table. 3에 따라 3 단계의 기준에 의해 레벨을 4 단계로 나누어 사용하였다.

L1	L2	L3	L4
{1, 1, 1}	{1, 1, -1}	{1, -1, -1}	{-1, -1, -1}
$m + \alpha \times std$	m	$m - \alpha \times std$	

Table 3 4 Levels as to 3 standards from the statistical analysis of the 6 representative driving patterns

4. 시뮬레이션 결과

대표 주행패턴 [D]의 일부와 나머지 패턴들의 임의의 조합으로 구성된 주행패턴에 대해서 300 초마다 주행패턴 인식 알고리즘을 적용하였을 때의 시뮬레이션 결과는 Fig. 9 와 같다. 파라미터의 중요도를 고려하여 C1~C10 에는 가중치 2 을 적용하였으며, 나머지 파라미터들은 가중치 1 을 적용하였다. 또한 레벨을 결정하는 기준이 될 수 있는 α 값은 0.55 를 사용하였다.

각 패턴의 내부에서는 정확하게 패턴을 인식하였으며, 경계부분에서는 섞여 있는 패턴 중 영향도가 큰 패턴으로 인식하였다.

대표 주행패턴의 특성 파라미터들이 각 패턴의 전체 시간에 대한 통계처리에서 얻어졌음에도 불구하고 300 초의 시간간격에 대해 비교적 정확하게 패턴을 인식함을 확인할 수 있으며 위의 결과로부터 각 대표 주행패턴들이 충분한 대표성을 가지고 있음을 확인할 수 있다.

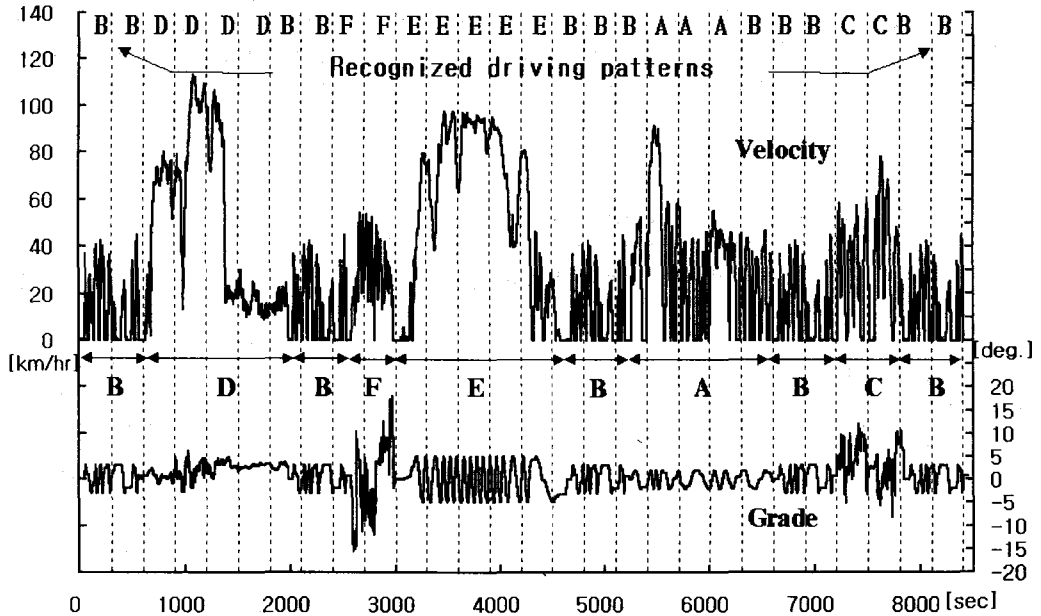


Fig. 9 Simulation result of the Driving Pattern Recognition

5. 결론

1. 주행패턴 특성 파라미터를 바탕으로 일반적인 주행상황에 대한 대표성을 갖는 도심 주행패턴 3 개, 지방도로 주행패턴 2 개, 고속도로 주행패턴 1 개로 구성된 6 개의 대표 주행패턴을 구성하였다.
2. 신경회로망의 알고리즘 중 Hamming Network 를 이용한 주행패턴 인식 알고리즘을 개발하였다. 주행 중의 속도, 가속도, 경사 신호로부터 추출한 현재의 주행패턴과 Hamming distance 가 가장 작은 하나의 대표 주행패턴을 현재의 주행패턴으로 인식하게 되며, 알고리즘의 단순성 (Simplicity)으로 인해 차량 주행 제어기에 탑재 가능할 것으로 보인다.
3. 대표 주행패턴들의 임의의 조합으로 구성된 주행패턴에 대한 시뮬레이션을 수행함으로써, 300 초의 인식 시간간격에 대해 패턴들의 경계부분을 제외한 영역에서 정확하게 패턴을 인식함을 확인하였다.
4. 그러나, 이와 같은 주행패턴 인식 알고리즘의 의미를 가지기 위해서는 차량의 주행 제어 알고리즘에 적용되어 주행 제어 목적을 달성하는 점에 초점을 맞추어야 할 것이며 이 부분은 추후에 연구를 수행할 예정이다.

후기

본 연구는 기계분야 BK-21 사업의 지원하에 수행되었으며, 이에 감사 드립니다.

참고문헌

- (1) Martin T. Hagen, Howard B. Demuth and Mark Beale, *Neural Network Design*, PWS Publishing Co., Boston, 1995.
- (2) Michel Andre, "Driving Cycles Development: Characterization of the Methods," *SAE Paper 961112*, 1996.
- (3) R. Beta, Y. Yacoub, W. Wang, D. Lyons, M. Gambino and G. Rideout, "Heavy Duty Testing Cycles : Survey and Comparison," *SAE Paper 942263*, 1994.
- (4) H.C. Watson and E.E. Milkins, "An International Drive Cycle," *SAE Paper 865042*, 1986.
- (5) 박진호, 공진형, 이진원, 조한상, 박영일, 이장부, "도로 경사도 측정 알고리즘 및 경사를 포함한 주행모드," *한국자동차공학회 춘계학술대회 99380115*, 1999.
- (6) Advanced Vehicle Simulator ADVISOR ver 2.21, National Renewable Energy Laboratory, USA, 2000.