

운전수행도와 생리학적 신호를 이용한 신경망 기반 인지부하의 감지

오 호 상¹⁾·손 준 우^{*1)}

대구경북과학기술원 Humanlab¹⁾

Detection of Cognitive Workload based on Neural Network Method using Driving Performance and Physiological Measure

Hosang Oh¹⁾ · Joonwoo Son^{*1)}

¹⁾ DGIST HumanLAB, 50-1 Sang-ri, Hyeonpung-Myeon, Dalseong-Gun, Daegu, 711-873, KOREA

Abstract : The paper suggests an algorithm for detecting driver's high cognitive workload using driving performance and physiological data. The algorithm adopts radial basis probabilistic neural network (RBPNN) to construct estimation models. In order to train and test the models, combinations of two driving performance data including velocity and steering wheel reversal rate(SRR), and three physiological signals including inter-beat interval(ABI), skin conductance level(SCL) and skin temperature were considered as measures of cognitive workload. The training and testing data were collected from on-road driving experiments of 13 subjects who were asked to complete three levels of difficulty of a delayed digit-recall task (n-back task). As a result, The best performance was achieved from a combination of measures including SCL, skin temperature and velocity over 10 seconds time window with an average accuracy of 94.2%. It is expected that the accuracy can be improved applying more sophisticated algorithms and various window sizes and combinations.

Key words : Neural Network(신경망), Driving Performance(운전수행도), Physiology(생리학), Cognitive Workload(인지부하)

1. 서론

최근 운전 중 휴대전화와 같은 전자 제품의 사용으로 인해 교통사고 발생이 증가함에 따라 도로 교통법에 의거하여 운전 방해가 되는 전자 제품의 사용을 위법사항으로 제한하고 있다. 뿐만 아니라 네비게이션, 지능형 정속주행장치 등의 다양한 운전자지원장치의 사용이 증가되고 있는데, 과

도하게 설계된 자동차 인터페이스는 운전자의 안전을 저해할 수 있다는 연구들이 보고되고 있다. ^{1), 2)}

따라서 운전자의 안전을 위협하는 원인이 되는 운전자의 부하를 고려해 안전 운전을 지원하는 지능형 자동차를 개발이 이루어지고 있다. 지능형 자동차는 운전자의 특성을 고려해 운전자의 정신적 부하 수준에 따라 경고음 같은 운전자 부하 모니터링 시스템 등을 적시에 제공해 주는 운전자 친화적 차세대 자동차이다. 운전자의 부하 정도는 자동차의 주행 정보나 생체신호 등을 통해 파악이 가능하며, 이와 같은 정보를 분류하기 위해서 데이터마이닝 기법을 이용할 수 있다. 실시간으로 운전자 상태를 파악하는 것은 지능형 자동차 개발을 위한 핵

* 손준우, E-mail: json@dgist.ac.kr

심 기술이며 이전 연구들을 통해 운전자의 의도나 부하를 파악하는 연구들이 수행되고 있다.³⁾

본 연구에서는 안전을 위한 지능형 자동차 적용을 위해 실제 차량운전실험을 통해 운전 수행도(Driving performance)와 생리학적 신호(Physiological signal)를 데이터마이닝 기술 중 하나인 신경망을 사용하여 운전자의 인지부하를 감지하고자 한다.

2. 방법

2.1 실험 설계

인지 부하의 정도를 평가하기 위한 운전 실험의 설계를 위한 단계는 실험 환경, 피실험자 선정, 실험 절차로 구성된다.

2.1.1 실험 환경

데이터를 수집하기 위한 실험은 국내 H사의 G차량에서 수행되었고, 데이터는 운전자의 운전 수행도와 생체 정보로 구분된다.

운전 수행도는 G차량의 내부 네트워크를 이용하여 획득하였다. 국제 차량 네트워크 표준으로 적용된 CAN 프로토콜에서 주기적으로 제공되는 주행, 제동 및 조향에 관련된 차량 정보 메시지를 Kvaser사의 Leaf SemiPro 인터페이스를 이용하여 획득하였다. 제동 및 조향에 대한 정보는 HS_CAN(500Kbps) 메시지를 통하여 획득하고 주행에 관련된 정보는 LS_CAN(100 Kbps) 메시지를 통하여 주기적으로 획득하였다.

운전자 생체 정보는 차량의 트렁크에 상용 장비(MEDAC System/R)를 설치하여 획득하였다. 상용 장비는 운전자의 근전도, 혈류량, 호흡도와 피부전도도를 실시간으로 표시하고 저장하는 기능을 가지고 있다. 운전자의 생체 신호 정보는 Main Control PC의 동기화 신호에 따라 주기적으로 저장된다.⁴⁾

2.1.2 피실험자 선정

주 3회 이상 운전을 하며 신체적, 정신적으로 문제가 없는 20대 남자 13명을 선정하여 실험을 수행하였다. 또한 기본적인 인지능력을 검사하기 위하여 MMSE(Mini Mental Status Exam)를 시행하였으며, 30점 만점에 27점 이상을 획득한 사람을

피실험자로 선정하였다. (M=27.9, SD=3.13).

2.1.3 실험 절차

실험절차는 주행 실험을 중심으로 주행 전 단계와 주행 후 단계로 구성하였다.

실험 단계에서는 운전 중에 인지 부하를 주는 Secondary task로 음성으로 제시된 숫자를 기억하며 대답하는 N-back task를 사용하였다.⁵⁾ 본 실험에서 N-back task는 3단계의 난이도로 구성되며, 가장 낮은 난이도로 숫자를 듣고 말하는 0-back, 중간 난이도로 한 숫자 전에 제시된 숫자를 기억하며 말하는 1-back, 그리고 가장 높은 난이도로 두 숫자 전에 제시된 숫자를 말하는 2-back을 이용하였다. 한 번의 실험에서 세 개의 난이도를 모두 수행하였는데, 각 난이도를 수행하는 순서는 무작위이며 각각 난이도마다의 수행 시간은 2분이며, 한 단계가 끝나면 2분을 휴식하고 다음 단계를 수행하였다. 운전자에게 안전을 가장 우선 순위로 두고, N-back task보다는 운전 집중할 것을 요구하였다. 실험 주행 구간은 중부내륙지선 달성 2터널로부터 영산 IC까지 약 38km의 편도 2차선 고속도로로 구성되었다. N-back task는 mp3 플레이어를 차량 오디오에 연결하여 특정한 위치가 되면 시작하도록 하였다.

2.2 모델 특징

2.2.1 인지 부하의 정의

난이도에 따른 인지 부하(cognitive workload)의 분류를 위해 본 연구에서는 2개의 단계(level), 즉 N-back의 수행 없이 운전을 수행하는 구간(Normal driving)과 가장 높은 난이도(2-back)의 구간을 이용하여 인지 부하의 유무를 정의(Definition)하였다.

2.2.2 입력 특징 선택

난이도에 따른 인지 부하의 분류를 위해 운전 수행도(driving performance)와 생체 정보(Biosignal)를 입력 특징(input features)으로 사용하였다.

운전 수행도는 차량의 속도, 조향각(Steering wheel angle)을 바탕으로 계산되었다. 실험 구간에서의 평균속도를 종방향의 평가 지표로 사용하였고, 조향 반전 비율인 SRR(Steering wheel reversal

rate)을 횡방향의 평가지표로 사용하였다. SRR을 계산하기 위해서는 먼저 일정 시간 동안 수집된 조향각 데이터를 2차 Butterworth-filter를 이용하여 Low-pass 필터링을 하며, 2Hz의 cut-off 주파수를 사용하였다. 필터링 된 데이터들에서 조향반전 횟수를 계산하여 SRR을 구하는데, 꺾이는 정도를 판단하는 임계치를 0.1도로 하였다.⁶⁾

생체 정보는 Medac System/3 (NeuroDyne Medical Corp.)을 사용하여 획득되며, 심전도 (Electrocardiogram, ECG), 피부 전도도 (Skin Conductance)와 온도(Temperature) 정보로 구성된다. 심전도를 이용하여 RR 간격(R-R interval)을 획득하며, 피부 전도도 센서와 온도 센서는 손가락으로부터 피부의 전기적 활동(Electrodermal activity)과 온도 변화를 측정한다.⁷⁾

운전 수행도와 생체 정보는 모두 평균값(average)을 이용하였다.

2.2.3 Window Size 설정

본 논문에서는 윈도우 크기(Window size)를 10, 20 및 30초로 선정하였으며, 입력 특징을 추출하기 위한 윈도우 크기를 이용하여 운전 수행도와 생체 정보를 각각 평균을 내어 계산하였다.

2.2.4. 특징 조합

입력 특징은 RR 간격을 1, SCL을 2, skin temperature를 3, SPD를 4, SRR을 5로 하여 31가지 조합을 생성하였다<표 1>.

Table 1 Feature Combination

	Feature no.	Feature combination
1	1	RRI
2	2	SCL
3	3	SKT
4	4	SPD
5	5	SRR
6	12	RRI, SCL
7	13	RRI, SKT
	⋮	
16	123	RRI, SCL, SKT
	⋮	
31	12345	RRI, SCL, SKT, SPD, SRR

2.2.5. 모델 학습과 평가

운전자의 인지 부하의 분류를 위한 알고리즘으로 RBPNN (Radial basis probabilistic neural networks)을 사용하였다. RBPNN 알고리즘은 매트랩 (MATLAB) 소프트웨어의 NEWPNN function을 사용하여 학습 및 평가가 이루어졌다.

모델의 학습 및 평가는 윈도우 크기를 통해 다수의 부분(segment)으로 나뉘게 된다. 예를 들어, 윈도우 크기가 10초 일 경우 2분의 실험 구간은 12개의 윈도우를 가지게 되며, 20초 일 경우 6개, 30초는 4개의 윈도우를 가지게 된다. 각각의 실험 구간은 cross-validation scheme을 사용하여 입력 특징의 절반은 학습을 위해, 나머지 절반은 평가를 위해 사용된다. 따라서 RBPNN모델은 30초 윈도우 크기일 경우, 학습과 평가에 각각 13 (subjects) x 2 (levels) x 2 (segments) = 52개를 가지게 된다. 마찬가지로 20초의 모델은 13 x 2 x 3 = 78, 30초 모델은 13 x 2 x 6 = 156개를 가지게 된다.

본 논문에서는 성능 평가를 위해 분류 알고리즘의 성능 평가 기준으로 민감도(sensitivity), 특이도(specificity), 분류율(accuracy)을 사용하였다. TP(true positive)는 인지부하가 있을 때 인지부하가 있는 것으로 분류되는 것을, FP(false positive)는 인지부하가 없을 때 인지부하가 있는 것으로 분류되는 것을 의미한다. TN(true negative)은 인지부하가 없을 때 인지부하가 없는 것으로 분류되는 것을 의미하며 FN(false negative)은 인지부하가 있을 때 인지부하가 없는 것으로 분류되는 것을 의미한다.⁸⁾

$$\text{민감도} = \frac{TP}{TP + FN} \times 100$$

$$\text{특이도} = \frac{TN}{TN + FP} \times 100$$

$$\text{분류율} = \frac{TP + TN}{TP + FN + TN + FP} \times 100$$

3. 결과

<표 2>는 RBPNN을 적용한 31개 조합에 따른 결과를 나타낸다. 성능 평가 기준을 나타내는 분류율, 민감도 및 특이도는 윈도우 크기와 입력 특징에 따라 다양한 결과를 나타낸다. 실험 결과 중, 가장

Table 2 Accuracy, sensitivity, specificity on window size and feature combination

feature	10s window size			20s window size			30s window size		
	Accuracy	Sensitivity	Specificity	Accuracy	Sensitivity	Specificity	Accuracy	Sensitivity	Specificity
1	80.77	80.77	80.77	84.62	88.57	81.40	86.54	88.00	85.19
2	87.18	90.28	84.52	89.74	89.74	89.74	78.85	77.78	80.00
3	80.77	81.58	80.00	83.33	86.11	80.95	69.23	66.67	72.73
4	68.59	67.47	69.86	64.10	64.10	64.10	65.38	62.50	70.00
5	58.97	58.54	59.46	46.15	46.81	45.16	51.92	52.17	51.72
12	82.69	82.28	83.12	85.90	88.89	83.33	88.46	85.71	91.67
13	82.05	78.41	86.76	80.77	78.57	83.33	75.00	69.70	84.21
14	78.85	78.48	79.22	79.49	76.74	82.86	84.62	82.14	87.50
15	73.08	72.50	73.68	80.77	81.58	80.00	73.08	68.75	80.00
23	88.46	87.50	89.47	84.62	84.62	84.62	76.92	73.33	81.82
24	85.26	85.71	84.81	84.62	86.49	82.93	86.54	85.19	88.00
25	81.41	81.01	81.82	79.49	79.49	79.49	78.85	80.00	77.78
34	81.41	80.25	82.67	70.51	73.53	68.18	75.00	72.41	78.26
35	76.92	77.63	76.25	79.49	82.86	76.74	73.08	68.75	80.00
45	63.46	64.00	62.96	67.95	66.67	69.44	57.69	56.67	59.09
123	90.38	87.95	93.15	88.46	85.71	91.67	80.77	76.67	86.36
124	87.18	86.25	88.16	87.18	83.72	91.43	88.46	85.71	91.67
125	84.61	83.75	85.53	87.18	85.37	89.19	90.38	88.89	92.00
134	82.05	79.76	84.72	85.90	83.33	88.89	75.00	72.41	78.26
135	83.97	81.18	87.32	83.33	84.21	82.50	75.00	70.97	80.95
145	70.51	68.60	72.86	82.05	77.78	87.88	78.85	80.00	77.78
234	91.67	92.21	91.14	84.62	84.62	84.62	84.62	82.14	87.50
235	82.05	80.49	83.78	82.05	83.78	80.49	75.00	76.00	74.07
245	82.69	81.48	84.00	79.49	79.49	79.49	92.31	92.31	92.31
345	80.13	80.52	79.75	75.64	79.41	72.73	73.08	70.00	77.27
1234	89.74	88.75	90.79	88.46	87.50	89.47	82.69	79.31	86.96
1235	87.18	84.52	90.28	89.74	87.80	91.89	80.77	78.57	83.33
1245	87.18	86.25	88.16	87.18	85.37	89.19	94.23	96.00	92.59
1345	78.85	77.11	80.82	84.62	81.40	88.57	78.85	77.78	80.00
2345	86.54	85.19	88.00	87.18	87.18	87.18	84.62	80.00	90.91
12345	87.82	86.42	89.83	87.18	85.37	89.19	86.54	82.76	91.30
Mean	81.37*	80.54*	82.36	81.35*	81.19*	81.83	78.78*	76.75*	81.65
SD	7.65	7.63	7.93	8.94	8.71	9.80	9.41	9.79	9.42

높은 성능을 보이는 모델은 1245(RRI, SCL, SPD, SRR)로 나타났다. 1245모델은 94.23%의 높은 분류율을 나타냈으며, 민감도는 96.00%, 특이도는 92.59%로 안정성 있는 결과를 보였다. 이 결과는 RR interval, Skin conductance level, speed, SRR의 입력 특징의 조합이 인지 부하를 분류함에 있어 좋은 지표임을 나타낸다.

10, 20 및 30초의 윈도우 크기에 대한 각각의 대응 표본 결과를 살펴보면, 윈도우 크기가 10초일 때 30초 보다, 20초일 때 30초 보다 더 좋은 분류율이 나타났으며($p < .05$), 같은 조건에서 더 좋은 민감도를 나타냈다($p < .05$). 하지만 최고의 성능은 윈도우 크기가 30초일 때로 반대의 결과가 나타났다.

단일 입력 특징에 대한 분류율은 10, 20 및 30초일 때 생리학적 데이터가 운전 수행 데이터보다 대체적으로 분류율이 높게 나타났다. 이러한 결과는 본 실험이 실제 차량의 고속도로 주행을 바탕으로 수행되어 주변 차량 환경이나 차선 변경에 따라 차량의 speed나 SRR이 유동적이기 때문에 운전 수행도는 낮은 분류율을 보인 것으로 판단된다. 하지만 다수의 입력 특징 조합에서의 성능은 10초의 윈도우 크기에서 234조합, 20초에서 1235조합, 30초에서 1245조합이 가장 좋은 성능을 보여줬는데 이것은 생리학적 신호와 운전수행 신호의 조합이 인지 부하를 분류하는데 있어 훌륭한 입력 특징 조합으로 사용될 수 있음을 의미한다.

4. 결론

본 연구에서는 실제 차량운전실험을 통해 추출된 운전 수행도와 생체 정보를 이용하여 인지 부하를 분류하고자 하였다. 인지 부하의 분류를 위해 n-back task를 수행하였으며, 이 중 n-back task를 수행하지 않는 운전 구간과 가장 어려운 난이도의 2-back task가 수행되는 운전 구간을 부하가 없을 때와 높은 부하로 정의하였다. 인지 부하의 분류는 데이터마이닝 기술 중 하나인 RBPNN 알고리즘을 사용하여 운전 수행도와 생리학적 신호를 10, 20 및 30초의 윈도우 크기로 평균하여 학습 및 평가를 실시하였다. 결과는 30초의 윈도우 크기일 때 RR interval, Skin conductance, Speed, SRR의 합친 조합에서 가장 좋은 성능을 나타냈다.

추후 연구에서는 인지 부하를 다양한 윈도우 크기와 입력 특징 조합을 적용하여 더 높은 성능을 기대해볼 수 있다.

Acknowledgements

This research was supported in part by Daegu Gyeongbuk Institute of Science and Technology (DGIST) Research Program of the Ministry of Education, Science, and Technology (MEST), and Establishment Program of Industrial Original Technological Base of the Ministry of Knowledge Economy (MKE).

References

- 1) Wang, J., Knipling R.R., and Goodman, M.J., "The role of inattention in crashes; new statistics from the 1995 crashworthiness data system (CDS)", 40th Annual Proceedings: Association for the Advancement of Automotive Medicine, pp.377-392, 1996.
- 2) Stutts, J. C. and Hunter, W. W. "Driver inattention, driver distraction and traffic crashes", ITE Journal, Vol. 73, No. 7, pp. 34-45, 2003.
- 3) Lee, Y., Kim, M.H., and Son, J., "The impact of cognitive workload on older driver's behavior", KSAE Annual Conference, pp. 982-987, 2009.
- 4) Kim, M.H., Son, J., Lee, Y., and Shin, S.H., "Development of Vehicle Environment for Real-time Driving Behavior Monitoring System", Journal of the Ergonomics Society of Korea, pp. 17-24, 2010.
- 5) Son, J., Reimer, B., Mehler, B., Pohlmeier, A.E., Godfrey, K.M., Orszulak, J., Long, J., Kim, M.H., Lee, Y. and Coughlin, J. F., "Age and cross-cultural comparison of drivers' cognitive workload and performance in simulated urban driving", International Journal of Automotive Technology, Vol. 11, No. 4, pp. 533-539, 2010.

- 6) Östlund, J., Peters, B., Thorslund, B., Engström, J., Markkula, G., Keinath, A., Horst, D., Juch, S., Mattes, S. and Foehl, U., "Driving performance assessment methods and metrics", Information Society Technologies, No. IST-1-507674-IP, pp. 118-129, 2004.
- 7) Son, J., Park, M. and Oh, H. S., "Sensitivity of Multimodal Cognitive Workload Measures: A Field Study Considering Environmental Factors", AutoUI 4th International Conference, 2012.
- 8) Shin, D. K., Lee, S. H. and Lim, J. S., "Selecting Minimized Input Features for Detecting Automatic Fall Detection Based on NEWFM", Korean Society for Internet Information, 10(3), 2009.