

SVDD 기법을 이용한 하이브리드 전기자동차의 고장검출 알고리즘

Fault Detection Algorithm of Hybrid electric vehicle using SVDD

나상건* · 전종현** · 한인재** · 허 훈†

Sanggun Na, Jonghyun Jeon, Injae Han, Hoon Heo

Key Words : SVDD(Support Vector Data Description), Fault Detection(고장 검출), one-class classification(한 클래스 분류), incremental data learning(점증적 데이터 학습), Hybrid Electric Vehicle(하이브리드 전기 자동차)

ABSTRACT

In this paper, in order to improve safety of hybrid electric vehicle a fault detection algorithm is introduced. The proposed algorithm uses SVDD techniques. Two methods for learning a lot of data are used in this technique. One method is to learn the data incrementally. Another method is to remove the data that does not affect the next learning. Using lines connecting support vectors selection of removing data is made. Using this method, lot of computation time and storage can be saved while learning many data. A battery data of commercial hybrid electrical vehicle is used in this study. In the study fault boundary via SVDD is described and relevant algorithm for virtual fault data is verified. It takes some time to generate fault boundary, nevertheless once the boundary is given, fault diagnosis can be conducted in real time basis.

1. 서 론

원유 가격 급등과 환경문제의 중요성으로 인해 현재 자동차 시장은 기존의 내연기관으로 구성된 자동차를 대체하기 위한 한가지 대안으로 HEV(Hybrid EV) Vehicle 을 내놓았다⁽¹⁾. HEV 는 모터의 저속 고토크의 장점을 활용하여 ICE(내연기관)의 단점을 보완하는 개념으로 개발되었다. HEV 의 핵심부품 중 배터리가 있다. 현재 개발된 많은 HEV 차량에는 Ni-MH 배터리를 많이 쓰고 있으나 성능 및 수명 등의 한계로 현재 리튬 이차 전지(Li-Ion, Li-Polymer)의 개발이 많이 진행되었다. 그러나 리튬 이차전지 역시 가격이 비싸고, 전기 자동차에 활용하기 위해서는 백 개 또는 그 이상의 셀을 직렬로 연결하여야 한다. Li-ion 의 경우는 폭발 위험성도 대포하고 있어⁽²⁾ 배터리의 고장 검출/진단 기술이 필요하다. 자동차의 발달에 따른 진단기술의 다양화는 그 수요에 미치지 못하고 있는 실정이다⁽³⁾.

자동차 산업 외에 현재 플랜트에서 사용하는 이상 진단의 일반적인 기법들은 통계적인 방법과 신호처리법으로 구분할 수 있다. 통계적 방법은 RMS, peak-peak, crest factor, Kurtosis, PDF 등의 변화

를 관측하여 이상발생 유무를 감지하는 간이진단 역할을 하였다. 신호처리기법으로는 스펙트럼, 케스트럼, ANC, filtering 등의 정밀진단법이 있다. 이러한 신호처리기법의 주목적은 시스템의 이상상태와 정상상태를 적절히 진단하는데 있다⁽⁴⁾. 또한, 진공펌프 시스템에서는 자기진단을 위해 통계기법인 다중주성분분석(MPCA) 혹은 독립성분분석(ICA) 통계기법이 쓰이고 있다⁽⁵⁾.

이 기법들 중에서 비정상상태 탐지 문제에 대한 고전적인 방법은 학습 데이터를 이용하여 확률밀도 함수(probability density function)를 추정한 후, 시험용 개체(test objects)에 대한 밀도 값(density value)이 정해진 문턱 값(threshold value) 미만이 되는 경우에 비정상 클래스로 판정하는 전략이 있다. 그러나 이러한 전략은 확률밀도함수의 정확한 추정에 기반을 두고 있으므로, 일반적으로 다양한 학습 데이터를 필요로 한다. 따라서 제한된 개수의 학습 데이터만이 주어진 경우에는, 확률밀도함수의 추정을 이용하여 정상클래스의 데이터가 존재하는 영역을 간접적으로 구하는 것보다는 정상 클래스가 존재하는 영역을 직접적으로 구하고자 하는 전략이 오히려 유리할 수 있다. 이러한 전략을 활용하는 방법들 중 가장 대표적인 예로 SVDD(support vector data description)를 들 수 있다. SVDD 기법의 기본 전략은 확률밀도함수의 추정을 사용하는 대신, 정상 클래스를 구성하는 학습 데이터의 존재 영역을 볼을 이용하여 직접 근사하는 방안을 사용하는 것이다.

† 고려대학교 제어계측공학과

E-mail : heo257@korea.ac.kr

Tel : (02) 3290-3995, Fax : (02) 929-7808

* 고려대학교 대학원 제어계측공학과

** 고려대학교 대학원 제어계측공학과

이 기법은, 패턴 분류(pattern classification)나 함수 근사(function approximation) 등의 분야에서 널리 사용되고 있는 방법과 유사한 형태를 띠고 있다. Tax 와 Duin 에 의해 다루어져 온 SVDD 기법은 학습과정에서 정상 클래스의 존재 영역을 특정공간 (feature space) 위에서 정의되는 일정한 볼(ball)로 근사하며, 적용과정에서는 볼 내부에 속하는 개체를 정상으로 분류하고 그렇지 아니한 개체들은 비정상으로 판정하게 된다^(6,7).

본 연구에서는 입력 공간 위에서 정의되는 볼을 찾는데 있어서, 많은 데이터를 학습하려면 시도를 하였다. 한번에 많은 데이터를 학습하려면 메모리공간이나 많은 학습시간 등의 제약이 따른다. 점진적으로 데이터를 학습하고, 다음 학습에서 영향을 주지 않는 데이터를 제거하면 메모리공간의 제약과 학습시간을 줄일 수 있다.

본 논문의 구성은 다음과 같다: 2 장에서는 SVDD에 관한 기초 이론과 점증적 학습 방법을 소개한다. 그리고, 3 장은 상용 HEV 의 정상상태 배터리 동작 데이터를 이용해 정상/비정상 경계를 근사 한다. 4 장에서는 로그함수를 이용해 배터리 고장을 모사해 검증하고, 5 장에서는 결론을 제시한다.

2. 고장판별 알고리즘

2.1 SVDD 기법

정상 영역에 속하는 물체의 서포트(support)를 근사하는 SVDD 방법론은 다음과 같이 구해진다. 중심이 $a \in R^d$ 이고, 반경이 R , 그리고 데이터 집합 D 를 가지는 구 B 가 있다고 하자. 학습 데이터들은 노이즈의 영향을 받기 쉽기 때문에 학습 데이터들 중 일부는 비정상 데이터가 될 수도 있다. SVDD 의 주된 목적은 다음의 상충되는 두 가지 목적을 동시에 달성하는 것이다. 하나는 가능한 구가 작아야 하고, 또 다른 하나는 가능한 많은 학습 데이터를 포함해야 한다. 이러한 목적을 만족하는 구는 다음의 최적화 문제를 풀면 얻을 수 있다.

$$\begin{aligned} \min L_o(R^2, a, \xi) &= R^2 + C \sum_{i=1}^N \xi_i \\ \text{s.t. } \|x_i - a\|^2 &\leq R^2 + \xi_i, \quad \xi_i \geq 0, \quad i = 1, \dots, N. \end{aligned} \quad (1)$$

위의 식에서, 변수 ξ_i 는 구 밖으로 벗어난 i 번째 학습 데이터와 관련된 별점이다. 위의 식에서 목적 함수는 상충되는 두 항인 반지름의 제곱 R^2 과 총 별점 $\sum_{i=1}^N \xi_i$ 로 구성되어 있다. Trade-off 상수 C 는 상

충되는 두 항의 상대적인 중요도를 조절한다.

라그랑지 함수와 쌍대문제(dual problem), 그리고 커널 트릭을 이용해서 위의 식(1)를 풀면 다음과 같은 식을 얻을 수 있다.

$$\begin{aligned} \min_{\alpha} \sum_{i=1}^N \sum_{j=1}^N \alpha_i \alpha_j K(x_i, x_j) - \sum_{i=1}^N \alpha_i \\ \text{s.t. } \sum_{i=1}^N \alpha_i = 1, \quad \alpha_i \in [0, C], \quad \forall i. \end{aligned} \quad (2)$$

입력공간에서 라그랑지 함수의 최적 해를 만족시키는 안장점(saddle point)의 조건은 다음식이 된다.

$$a = \sum_{i=1}^N \alpha_i x_i \quad (3)$$

판단 경계면(decision boundary) 위에 있는 각각의 서포트 벡터 x_i 의 평균값과 구의 반경 R^2 을 다음과 같은 식으로 구할 수 있다.

$$R^2 - \|x_i - a\|^2 = 0 \quad (4)$$

또한 위의 식을 통해 테스트 데이터 x 가 정상/비정상 데이터인지 판별 할 수 있다⁽⁸⁾.

2.2 점증적 데이터 학습과 저장

SVDD 기법에서 학습하는 데이터는 여러 가지 상황을 대표하는 데이터들만 사용하면 가장 이상적일 것이다. 하지만, 실제로 중복되는 데이터가 있고, 여러 가지 상황의 그것을 학습하려면 부득이하게 많은 데이터를 학습해야 한다. 한정된 데이터 저장공간을 이용해 많은 데이터를 학습시키기 위해서는, 점증적으로 일정한 데이터를 학습하고, 이미 학습한 데이터 중에서 다음 학습에 영향을 주지 않는 데이터는 제거해야 한다. 다음 학습에 영향을 주지 않는 데이터는 크게 두 부류로 볼 수 있다. 한 부류는 중복되는 데이터이다. 이와 같은 경우는 중복되는 데이터 중 하나만 남기고 제거하면 된다. 다른 부류는 경계 내부에 존재하면서 다음 학습할 때 경계 근사에 영향을 주지 않는 데이터이다. 본 연구에서 제거할 경계 내부의 데이터는 서포트 벡터와 그것들을 연결하는 선을 사용했다. 서포트 벡터는 경계 원 위에 존재함으로 위의 선은 경계 원의 현(chord, 弦)이 된다. 이 현보다 안쪽에 있는 데이터가 제거될 데이터이다. 제거과정은 서포트 벡터의 개수에 따라 다음

과 같이 나누어진다.

(1) 서포트 벡터가 2 개 일 때

서포트 벡터가 2 개 일 경우는 현이 1 개가 만들어지는데, 이 현(이때는 원의 지름)은 경계 원의 중심을 지난다. 따라서 현과 만나는 데이터 점들을 제거한다.

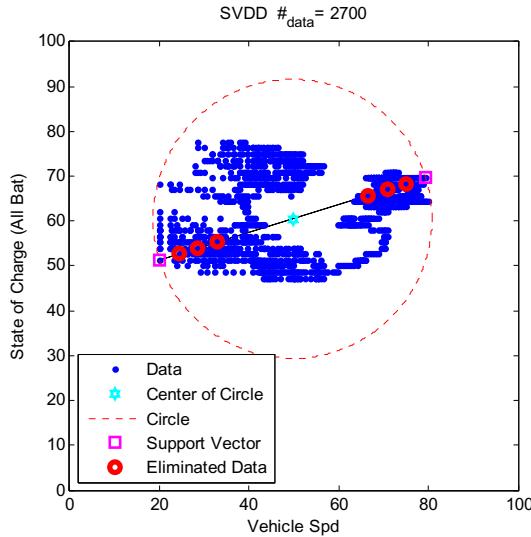


Fig. 1 Having 2 Support Vectors

(2) 서포트 벡터가 3 개 이상일 때

서포트 벡터가 3 개 이상일 경우는 현도 3 개 이상이 만들어지는데, 이 현들을 연결하면 다각형을 얻을 수 있다. 이 다각형 내부의 데이터 점들을 제거한다.

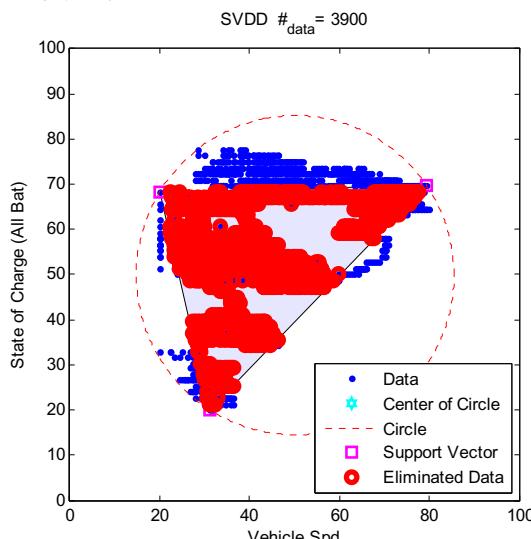


Fig. 2 Having 3 or more Support Vectors

위의 과정을 반복하여 학습과 저장을 하며, 알고리즘 순서도를 보면 다음과 같다.

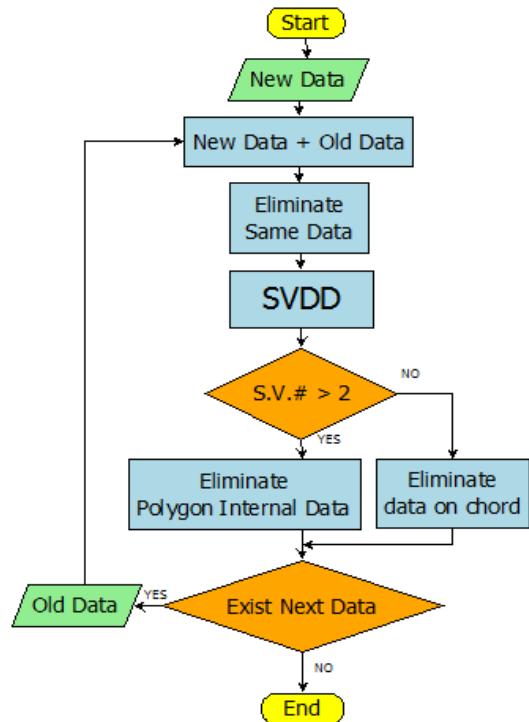


Fig. 3 Flow chart of incremental learning

3. 고장판별 경계 근사

정상 데이터가 분포하는 영역을 찾고 이 영역을 최소화하는 원의 중심점과 반지름을 SVDD 기법을 통해 구한다. 구한 원은 정상/비정상을 나누는 경계로 사용한다.

사용할 데이터는 정상상태에서 주행한 하이브리드 전기자동차의 속도와 배터리 충전상태(State of Charge)이다.

약 5,484 초 동안 측정한 63,813 개의 속도데이터와 배터리 충전상태 데이터를 1 초 주기로 샘플링한 5,484 개의 데이터가 Fig. 4 와 Fig. 5 에 표현했다.

속도데이터의 최소값은 0 km/h, 최대값은 107 km/h이고, 배터리 충전상태의 최소값은 47 %, 최대값은 65 %이다. 샘플링 한 속도와 배터리 충전상태 데이터는 다시 다음으로 스케일링 한다.

$$\text{scaling data} = \frac{60 \times (\text{data} - \min(\text{data}))}{(\max(\text{data}) - \min(\text{data}))} + 20 \quad (5)$$

스케일링 한 데이터는 20~80 사이의 값이 되며 Fig. 6에 그렸다.

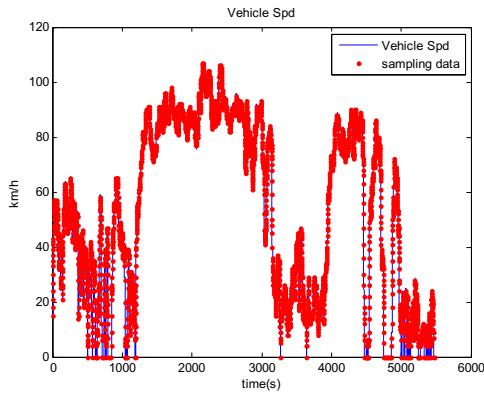


Fig. 4 Vehicle Speed and sample data

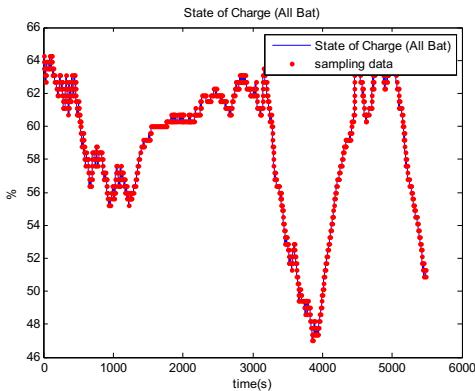


Fig. 5 State of Battery Charge and sample data

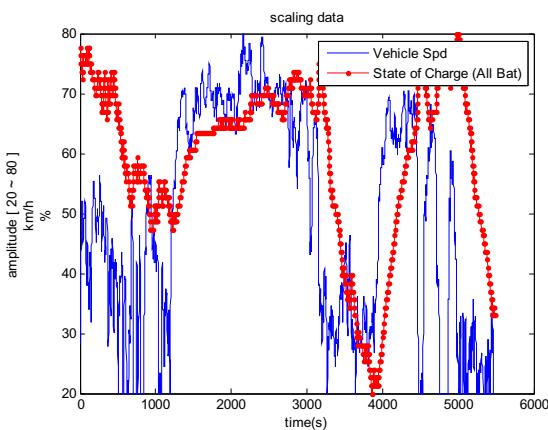


Fig. 6 Scaled data of Vehicle Speed and State of Battery Charge

스케일링을 하기 전의 차량 속도 데이터를 x 축, 배터리 충전상태데이터를 y 축에 그리면 각 속도마다 충전상태의 분포를 볼 수 있고 Fig.7과 같이 나타난다.

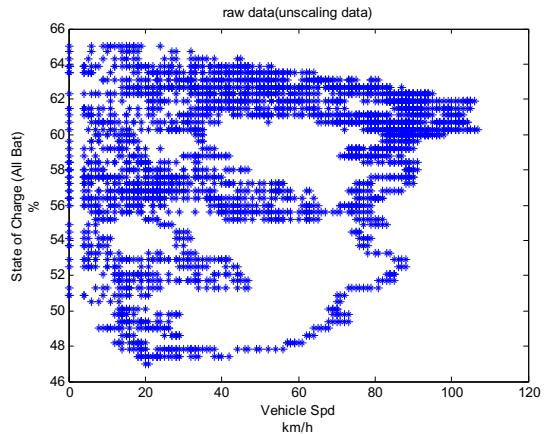
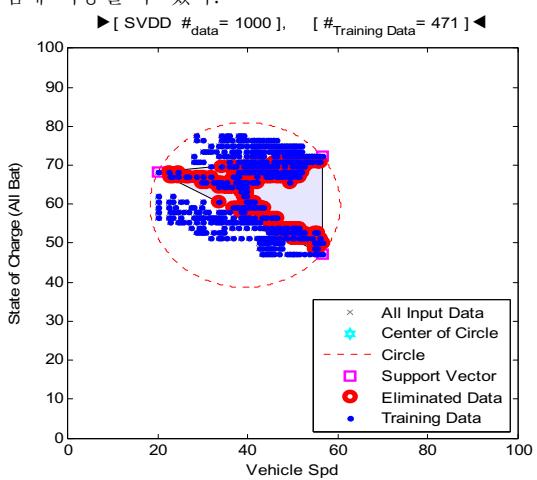
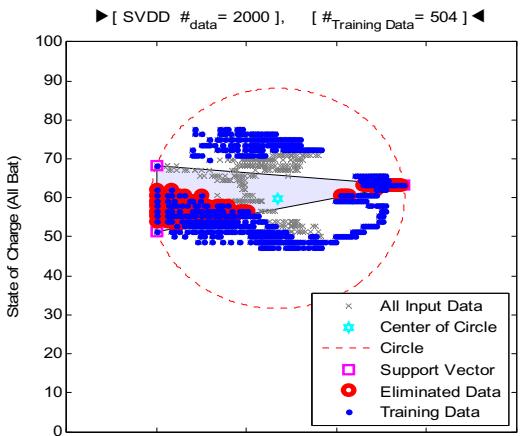


Fig. 7 Distribution of Vehicle Speed and State of Battery Charge

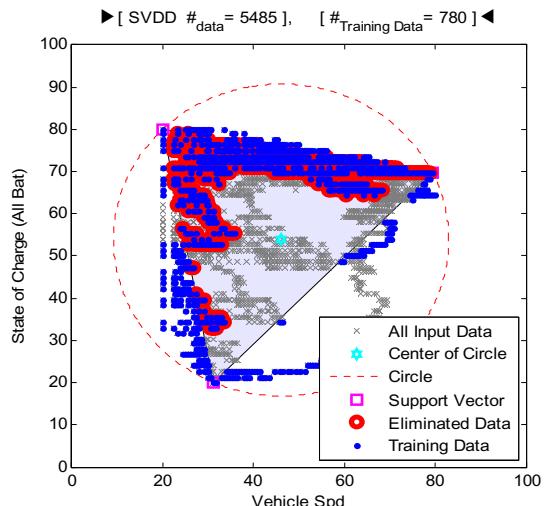
스케일링 한 차량 속도와 배터리 충전상태 데이터를 SVDD를 통해 고장/비고장 경계를 구하면 Fig.8과 같이 구할 수 있다.

앞의 Fig.8 (e)에서 SVDD를 통해 구한 원이 고장/비고장 경계가 된다. 스케일 한 데이터 분포에서 고장/비고장 경계인 원의 중심은 (46.07, 53.82), 반지름은 36.94 가 나왔다. SVDD의 경우 고장/비고장 경계를 정하면 경계의 안쪽에 위치하는지 바깥에 위치하는지 확인하는 연산시간은 짧게 걸리기 때문에 실시간으로 동작하는 고장 모니터링 임베디드 시스템에 적용할 수 있다.



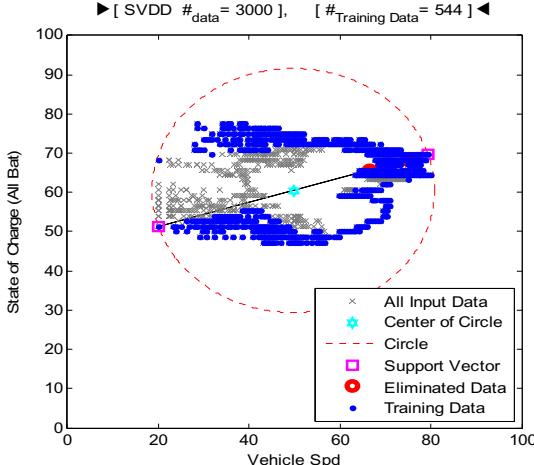


(b) Result of the SVDD having 2000 data

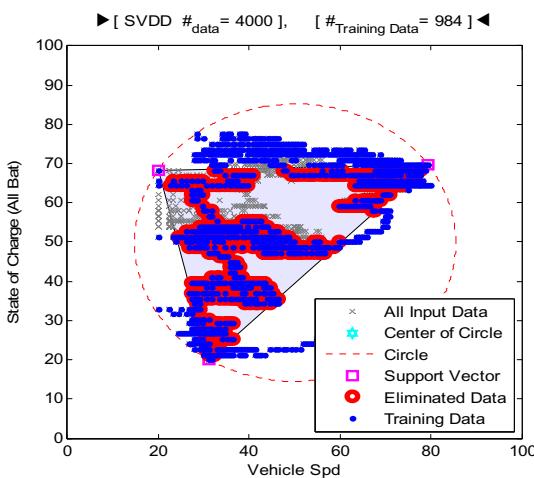


(e) Result of the SVDD having 5485 data

Fig. 8 Results of the incremental learning SVDD



(c) Result of the SVDD having 3000 data



(d) Result of the SVDD having 4000 data

4. 고장 모사를 이용한 알고리즘 검증

앞 장에서 구현한 고장진단 알고리즘을 고장상황모사를 통해 유효성을 검증한다.

자동차의 속도와 배터리 충전상태에서 4,050 초부터 주행 중 배터리가 충전되지 않는 상황을 모사했다. 배터리는 4,050 초 이후부터 식(6)와 같이 로그 함수적으로 감소한다고 가정한다.

$$Data_{Batt} = \left\{ Data_{Batt}|_{t=4050} - 2 \log \left(\frac{t-4050}{5} + 1 \right) \right\}_{t \geq 4050} \quad (6)$$

식(b)를 이용해 배터리가 충전되지 않는 고장모사를 다음과 같이 Fig.9로 나타낼 수 있다.

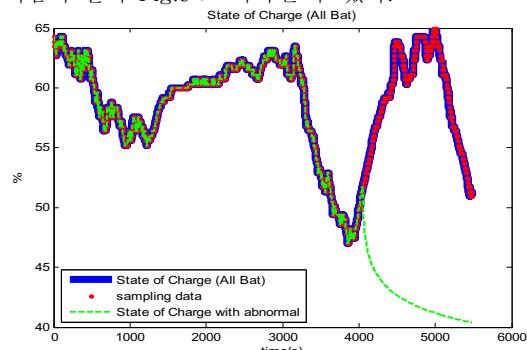


Fig. 9 Virtual data of uncharged Battery

SVDD를 이용해 구한 고장/비고장 경계에서 보면 Fig.10과 같다.

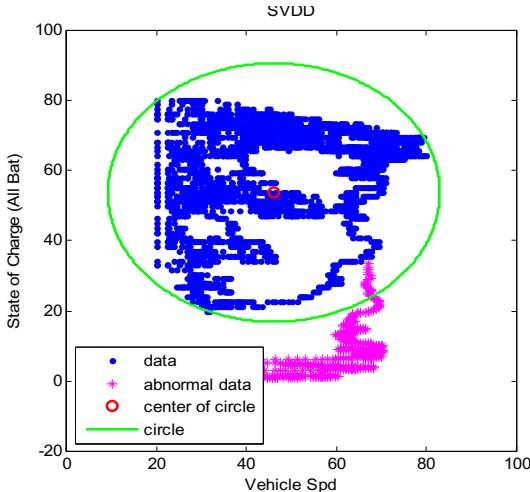


Fig.10 The normal/abnormal Boundary and fault data distribution

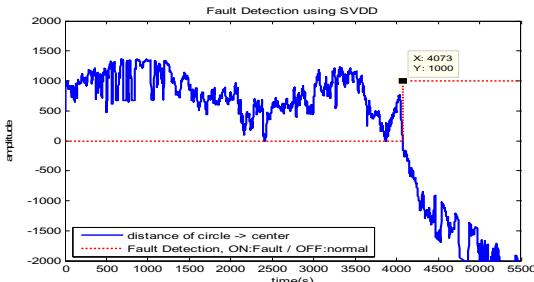


Fig.11 The Result of the fault detection using SVDD

식(4)가 음수가 된다면 경계 밖에 있는 고장 데이터이다.

고장/비고장 경계에서 벗어나는 시간이 4073 초로 검출되는 것을 확인 할 수 있었다.

Peak-peak 방법을 통해 구한 고장검출 시간은 4097 초로 SVDD로 구한 고장 검출이 더욱 우수하다는 것을 확인했다.

5. 결 론

본 논문에서는 SVDD 기법을 이용해 하이브리드 전기자동차 배터리 고장검출 알고리즘을 제안했다. 정상 상태인 상용 하이브리드 전기 자동차의 배터리 데이터와 차량 속도 데이터를 사용했다. 많은 데이터를 학습을 하기 위하여 데이터를 점진적으로 학습하였으며, 동일한 데이터를 제거했다. 또한, 서포트 벡터 점들을 이용해 다음 SVDD 경계 근사에 영향이 없는 데이터를 찾아 제거했다. 최종적으로 얻은 고장/비고장 경계를 이용해 배터리가 충전되지 않는 상황을 가상으로 모사 하여 제안한 알고리즘의 타당

성을 검증했다.

추후 연구로는 RBF 커널 등을 이용하여 본 연구에서 보인 원형인 경계를 다른 형태를 가지는 경계로 바꾸어 보는 것이 필요하다. 또한 임베디드 시스템으로 제작하여 실시간 작동을 확인하는 것도 중요하다고 하겠다. 마지막으로 통계적 해석인 만큼 많은 상황을 학습하고, 실제 고장 데이터를 획득하여 적용할 계획이다.

후 기

본 연구는 지식경제부에서 시행하는 산업원천기술 개발사업 실시간 주행모니터링 기반의 그린카 핵심 부품 신뢰성 평가 기술 개발 과제(10033174)의 지원으로 수행되었음.

참 고 문 헌

- (1) S.G. Na, Y.H. Lee, J.S. Kim, S.M. Park, H. Heo, "A Study on the Hybrid Electric Vehicle Fault Diagnosis Algorithm", The Korean Society of Automotive Engineers Conference, pp2935-2942, November, 2010.
- (2) K.J. Joo, S.R. Jang, Farag. Kamel. Abo-Elus, Mostafa, G.H. Rim, "Technical Trend of Electric Vehicle", The Korean Institute of Electrical Engineers, pp947-948, 2009.
- (3) S.G. Park, W.S. Park, H.J. Lee, W.G. Hong, J.E. Oh, "Fault Signal Analysis of the Automotive Components using Experimental Method, Part 1- Consideration of the Engine Signals", Korean Society for Noise and Vibration Engineering Fall Conference, 2007.
- (4) S.G. Park, W.S. Park, Y.Y. Lee, D.S. Kim, J.E. Oh, "A Fault Diagnosis on the Rotating Machinery Using MTS", Transactions of the Korean Society for Noise and Vibration Engineering, Vol.18, No.6, pp.619-623, 2008.
- (5) K.H. Lee, B.H. Kong, W.S. Cheung, S.G. Lee, "System-Diagnosis Algorithm by Using MPCA and ICA", the Korean Society for Noise and Vibration Engineering Fall Conference, pp.213-214, 2009.
- (6) K.W. Ko, Y.S. Oh, Q.Y. Jung, H. Heo, "Abnormal Diagnostics of Vibration System using SVM", The Korean Society for Noise and Vibration Engineering Spring Conference, pp.932-937, 2003.
- (7) Jooyoung Park, C.H. Leem, "Support Vector Learning for Abnormality Detection Problems", Korean Institute of Intelligent Systems, vol.13,no.3,pp266-274, 2003.
- (8) Daesung Kang, Jooyoung Park, "Pattern Denoising based on One-Class Support Vector Machines", M. S. Thesis, Korea University, 2006.