

SVDD기법을 이용한 하이브리드 전기자동차 충-방전시스템의 고장검출 알고리즘

Fault Detection Algorithm of Charge-discharge System of Hybrid Electric Vehicle Using SVDD

나 상 건*. 양 인 범**. 허 훈†

Sanggun Na, Inbeom Yang and Hoon Heo

(2011년 5월 2일 접수 ; 2011년 10월 17일 심사완료)

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), Data Reduction Technique(데이터 감소 기법)

ABSTRACT

A fault detection algorithm of a charge and discharge system to ensure the safe use of hybrid electric vehicle is proposed in this paper. This algorithm can be used as a complementary way to existing fault detection technique for a charge and discharge system. The proposed algorithm uses a SVDD technique, which additionally utilizes two methods for learning a large amount of data; one is to incrementally learn a large amount of data, the other one is to remove the data that does not affect the next learning using a new data reduction technique. Removal of data is selected by using lines connecting support vectors. In the proposed method, the data processing speed is drastically improved and the storage space used is remarkably reduced than the conventional methods using the SVDD technique only. A battery data and speed data of a commercial hybrid electrical vehicle are utilized in this study. A fault boundary is produced via SVDD techniques using the input and output in normal operation of the system without using mathematical modeling. A fault detection simulation is performed using both an artificial fault data and the obtained fault boundary via SVDD techniques. In the fault detection simulation, fault detection time via proposed algorithm is compared with that of the peak-peak method. Also the proposed algorithm is revealed to detect fault in the region where conventional peak-peak method is never able to do.

1. 서 론

† 교신저자; 정회원, 고려대학교 제어계측공학과
E-mail : heo257@korea.ac.kr

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

* 고려대학교 대학원 제어계측공학과

** 고려대학교 대학원 제어계측공학과, 자동차부품연구원
지능제어시스템연구센터

이 논문의 일부는 2011년 춘계 소음진동 학술대회에서
발표되었음.

원유 가격 급등과 환경문제의 중요성으로 인하여 현재 자동차 시장은 기존의 내연기관으로 구성된 자동차를 대체하기 위한 한 가지 대안으로 HEV(hybrid EV)을 내놓았다⁽¹⁾. HEV는 모터의 저속 고 토크의 장점을 활용하여 ICE(내연기관)의 단점을 보완하는 개념으로 개발되었다. HEV의 핵심부품 중 배터리가 있다. 현재 개발된 많은 HEV 차량에는 Ni-MH

배터리를 많이 쓰고 있으나 성능 및 수명 등의 한계로 현재 리튬 이차전지(Li-Ion, Li-Polymer)의 개발이 많이 진행되었다. 그러나 리튬 이차전지는 고가이며, 전기자동차에 활용하기 위해서는 백 개 또는 그 이상의 셀을 직렬로 연결하여야 하며 또한 Li-ion의 경우는 폭발 위험성도 내포하고 있어⁽²⁾ 배터리관련 충-방전 시스템의 고장 검출/진단기술이 필요하다. 그러나 자동차의 발달에 따른 진단기술의 다양화는 그 수요에 미치지 못하고 있는 실정이다⁽³⁾.

자동차 산업 외에 현재 플랜트에서 사용하는 이상진단의 일반적인 기법들은 통계적인 방법과 신호처리법으로 구분할 수 있다. 통계적 방법은 RMS, peak-peak, crest factor, Kurtosis, PDF 등의 변화를 관측하여 이상발생 유무를 감지하는 간이진단 역할을 하였다. 신호처리기법으로는 스펙트럼, 켈스트럼, ANC, filtering 등의 정밀진단법이 있다. 이러한 신호처리기법의 주목적은 시스템의 이상상태와 정상상태를 적절히 진단하는데 있다⁽⁴⁾. 또한, 진공펌프 시스템에서는 자기진단을 위하여 통계기법인 다중주성분분석(MPCA) 혹은 독립성분분석(ICA) 통계기법이 쓰이고 있다⁽⁵⁾.

이 기법들 중에서 비정상상태 탐지 문제에 대한 고전적인 방법은 학습 데이터를 이용하여 확률밀도함수(probability density function)를 추정한 후, 시험용 개체(test objects)에 대한 밀도 값(density value)이 정해진 문턱 값(threshold value) 미만인 되는 경우에 비정상 클래스로 판정하는 전략이 있다. 그러나 이러한 전략은 확률밀도함수의 정확한 추정에 기반을 두고 있으므로, 일반적으로 다량의 학습 데이터를 필요로 한다. 따라서 제한된 개수의 학습 데이터만이 주어진 경우에는, 확률밀도함수의 추정을 이용하여 정상 클래스의 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 볼(ball)을 이용하여 직접 근사 하는 방안을 사용하는 것이다. 이 기법은, 패턴 분류(pattern classification)나 함수 근사(function approximation)

등의 분야에서 널리 사용되고 있는 방법과 유사한 형태를 띠고 있다. Tax와 Duin에 의해 다루어져 온 SVDD 기법은 학습과정에서 정상 클래스의 존재 영역을 특징공간(feature space) 위에서 정의되는 일정한 볼(ball)로 근사하며, 적용과정에서는 볼 내부에 속하는 개체를 정상으로 분류하고 그렇지 아닌 개체들은 비정상으로 판정하게 된다^(6,7).

이 연구에서는 입력 공간 위에서 정의되는 볼을 찾는데 있어서, 많은 양의 데이터를 학습하려는 시도를 하였다. 현재 SVDD기법에서 한 번에 많은 데이터를 학습하려면 메모리공간이나 많은 학습시간 등의 제약이 따른다. 이 문제를 해결하기 위하여 점진적으로 데이터를 학습하고, 새로운 데이터 감소기법을 고안하여 적용하였다. 다음 학습에서 영향을 주지 않는 데이터를 제거하면 메모리공간의 제약과 학습시간을 줄일 수 있다⁽¹⁰⁾.

새로운 데이터 감소기법을 사용하여 SVDD기법을 적용한 고장 검출 기법은 배터리 관리시스템(battery management system, BMS) 등에 보조적으로 사용될 수 있고 배터리 셀이나 발전기, 정류회로 등 각 세부부품의 정상작동을 확인이 하는 것이 아니라, 충-방전 시스템 전체의 정상작동을 확인하고 감시하는 역할을 수행하는 기법이다. 모델링 없이 정상작동 데이터만으로 고장의 경계를 생성하므로 다른 시스템의 고장 검출 알고리즘으로 확장 및 변경이 용의하다.

이 논문의 구성은 다음과 같다. 2장에서는 SVDD에 관한 기초 이론과 점증적 학습 방법을 소개한다. 그리고, 3장은 상용 HEV의 정상상태 배터리 동작 데이터를 이용하여 정상/비정상 경계를 근사 한다. 4장에서는 로그함수를 이용하여 배터리 충-방전 시스템의 고장 검출 시뮬레이션을 수행하고, 5장에서는 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. SVDD의 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.

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

위의 식 (1)에서, 변수 ξ_i 는 구 밖으로 벗어난 i 번째 학습 데이터와 관련된 벌점이다. 위의 식에서 목적 함수는 상충되는 두 항인 반지름의 제곱 R^2 과 총 벌점 $\sum_{i=1}^N \xi_i$ 로 구성되어 있다. Trade-off 상수 C 는 상충되는 두 항의 상대적인 중요도를 조절한다.

라그랑지 함수와 쌍대문제(dual problem), 그리고 커널 트릭을 이용해서 위의 식 (1)을 풀면 다음과 같은 식 (2)를 얻을 수 있다.

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

입력공간에서 라그랑지 함수의 최적 해를 만족시키는 안장점(saddle point)의 조건은 식 (3)이 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 식 (4)로 구할 수 있다.

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

또한 위의 식 (4)를 통하여 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 상황에서는 부득이하게 많은 데이터를 학습해야 한다. 많은 데이터는 여러 가지 상태에 놓인 테스트 시스템의 입출력 특징을 보여주어 고장 경계생성에 도움을 준다. 한정된 데이터 저장공간을 이용하여 많은 데이터를 학습시키기 위해서는, 점증적으로 일정한 양의 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. 중복되는 데이터는 SVDD 기법이 경계를 생성하는데 오류를 발생시키는 바, 하나만 남기고 제거한다. 다른 부류는 경계 내부에 존재하면서 다음 학습할 때 경계 근사에 영향을 주지 않는 데이터이다. 이 연구에서 제거할 경계 내부의 데이터는 서포트 벡터와 그것들을 연결하는 선을 사용하였다. 서포트 벡터는 경계 원 위에 존재함으로써 위의 선은 경계 원의 현(chord, 弦)이 된다. 점진적 학습에서 추가된 데이터로 인하여 원이 확장되더라도 과거의 학습에서 구성된 현들은 항상 원의 내부에 존재하게 된다. 서포트 벡터로 만들어진 현의 개수가 3개 이상일 때(이때는 서포트 벡터가 3개 이상 존재) 현으로 구성되는 다각형이 만들어진다. 이 다각형 내부의 데이터들은 다각형의 꼭지점 데이터(서포트 벡터)가 존재하는 한 다음 학습에서 경계형성에 영향을 주는 서포트 벡터가 될 수 없다. 반면에 원의 호와 현의 사이에 존재하는 데이터들은 원이 확장되면 경계형성에 영향을 주는 서포트 벡터가 될 확률이 있다. 따라서, 현보다 안쪽에 있는 데이터가 제거될 수 있다. 제거과정은 서포트 벡터의 개수에 따라 다음과 같이 나누어진다.

(1) 서포트 벡터가 2개 일 때

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

(2) 서포트 벡터가 3개 이상일 때

서포트 벡터가 3개 이상일 경우는 현도 3개 이상이 만들어지는데, Fig. 2와 같이 이 현들을 연결하면 다각형을 얻을 수 있다. 이 다각형 내부의 데이터 점들을 제거한다.

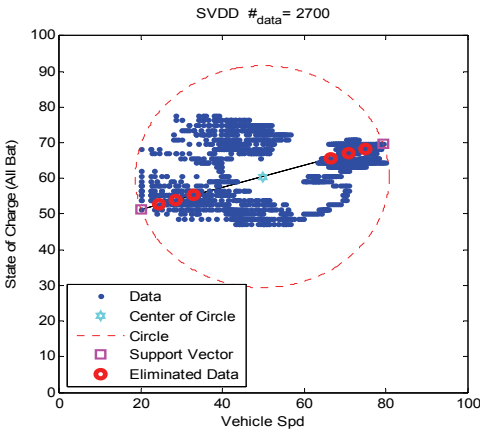


Fig. 1 Data reduction in case of 2 support vectors

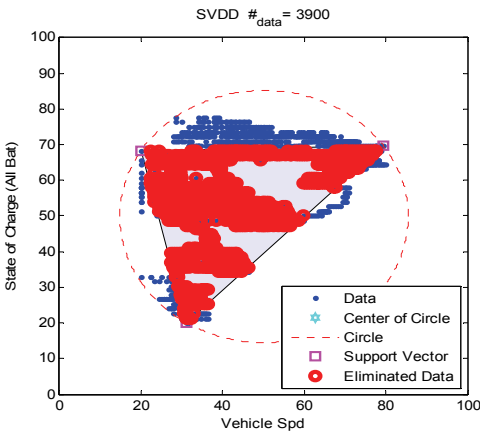


Fig. 2 Data reduction in case of more than 3 support vectors

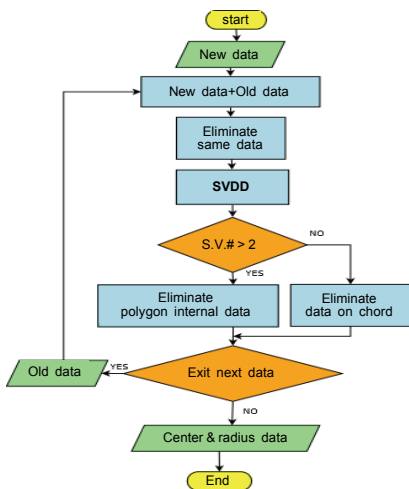


Fig. 3 Flow chart of incremental learning algorithm

위의 과정을 반복하여 학습과 저장을 하게 되며, 알고리즘 순서도를 보면 Fig. 3과 같다.

3. 고장판별 경계 근사

정상 데이터가 분포하는 영역을 찾고 이 영역을 최소화하는 원의 중심점과 반지름을 SVDD기법을 통하여 구하는 바, 이때 구한 원은 정상/비정상을 나누는 경계로 사용된다.

사용할 데이터는 정상상태에서 주행한 하이브리드 전기자동차의 속도와 배터리 충전상태(SOC : state of charge)이다.

약 5,484초 동안 측정, 수집한 63,813개의 속도 데이터와 배터리의 SOC 데이터를 1초 주기로 샘플링 하여 획득한 5,484개의 데이터를 Fig. 4와 Fig. 5에 표현하였다.

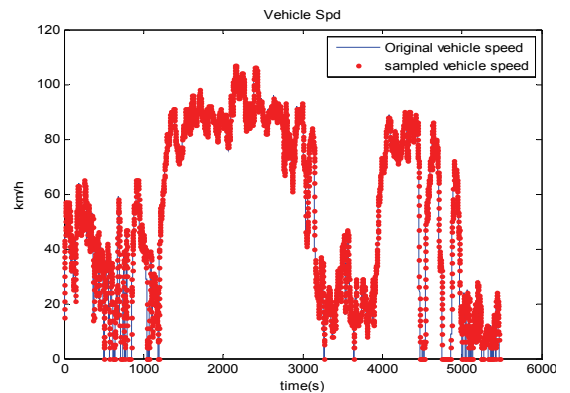


Fig. 4 Original vehicle speed vs sampled vehicle speed

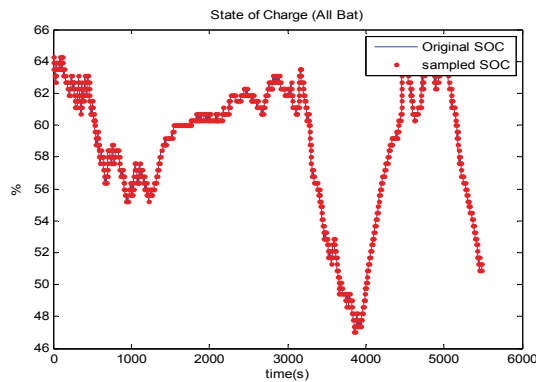


Fig. 5 Original SOC vs. sampled SOC

속도데이터의 최소값은 0 km/h, 최대값은 107 km/h 이고, 배터리 SOC의 최소값은 47 %, 최대값은 65 %이다. 가시성(可視性)과 가해성(可解性)을 높이고 두 데이터의 크기를 맞추기 위하여 샘플링 한 속도와 배터리 SOC 데이터는 다시 다음 식 (5)로 스케일링 한다.

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

스케일링 한 vehicle speed와 SOC 데이터는 20~80(km/h, %) 사이의 값이 되며 Fig. 6에 그렸다. 스케일링을 하기 전의 차량 속도 데이터를 x축, 배터리 SOC 데이터를 y축에 그리면 각 속도마다 SOC의 분포가 Fig. 7과 같이 나타나는 바, 여기서는

두 데이터간의 상호 관련성이나 특징을 파악하기가 곤란하다.

이에 식 (5)를 사용하여 스케일링한 차량속도와 배터리 SOC 데이터를 SVDD를 통하여 고장/비고장 경계는 Figs. 8(a), (b), (c), (d), (e)와 같이 구할 수 있다.




Fig. 6 Scaled vehicle speed and SOC






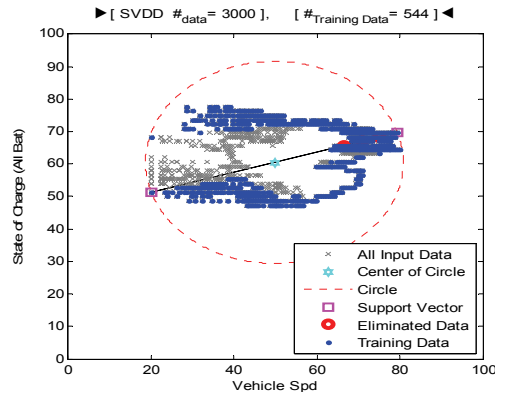
Fig. 7 Original vehicle speed vs. SOC



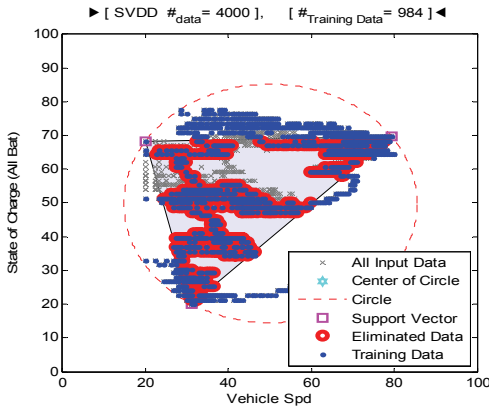
(a) Fault boundary using 1000 data




(b) Fault boundary using 2000 data



(c) Fault boundary using 3000 data



(d) Fault boundary using 4000 data



(e) Fault boundary using 5485 data

Fig. 8 Fault boundary based on incremental learning SVDD technique

앞의 Fig. 8(e)에서 SVDD를 통하여 구한 원이 고장/비고장 경계가 된다. 스케일 한 데이터 분포에서 고장/비고장 경계인 원의 중심은 (46.07, 53.82), 반지름은 36.94가 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.

4. 고장검출 시뮬레이션

앞 장에서 구한 고장경계를 사용하여 고장검출 시뮬레이션을 수행한다.

자동차의 속도와 배터리 SOC에서 4,050초부터 주행 중 충전시스템의 고장으로 배터리가 충전되지 않는 상황을 가정하였다. 배터리가 방전되는 과정이




Fig. 9 Battery failure scenario for simulation

긴 하나 순수 방전이 아닌 고장상태의 방전이므로 기존의 연구⁽¹¹⁾가 되어오던 Li-ion 배터리의 순수 방전 모델링 식은 적절하지 않은 바, 이를 사용하더라도 저항 값과 전류를 알아야 하기 때문에 그대로 사용하기는 곤란하다. 따라서 기존의 배터리 방전 곡선의 형태를 가지며 이 연구에 사용된 배터리가 방전되는 상태일 때의 SOC 데이터 곡선에 가까운 로그함수를 사용하였다. 즉 배터리의 SOC는 4,050초 이후부터 식 (6)와 같이 로그함수적으로 감소한다고 가정한다.

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

식 (6)을 이용하여 배터리가 충전되지 않는 고장 모사에 대한 시나리오는 Fig. 9와 같다. Fig. 9에서 4,097초에 배터리의 SOC가 약 47%까지 감소하며 정상상태의 최소값을 벗어난다. 이와 같은 상황은 최소값을 기준으로 고장 검출을 하면 되겠지만, 고장난 상황임에도 불구하고 배터리의 SOC가 최소값을 벗어나지 않고 있다면 고장을 검출 할 수 없다. 이때 정상상태와 비정상상태를 나누는 새로운 고장 경계를 적용할 필요가 있다.

이에 SVDD 기법을 이용하여 구한 고장/비고장 경계를 보면 Fig. 10과 같이 구해진다.

식 (4)가 음수가 된다면 경계 밖에 있는 고장 데이터이다. 고장/비고장 경계에서 벗어나는 시간이 4,073초로 검출되는 것을 확인 할 수 있었고, Fig. 11에 표시하였다. 최대값과 최소값을 기준으로 하여

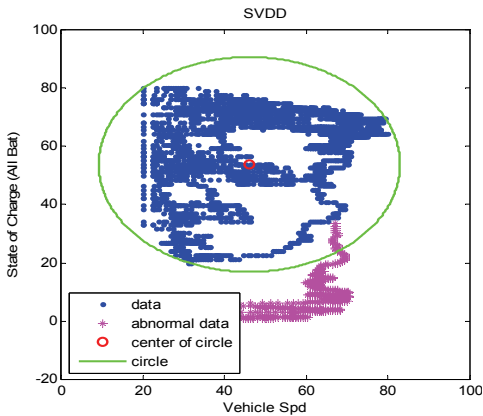


Fig. 10 Fault boundary and relevant data distribution for SOC vs. vehicle speed

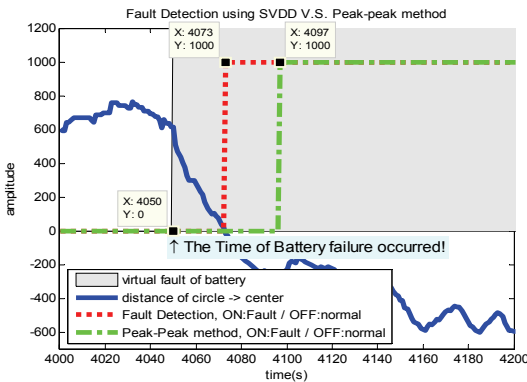


Fig. 11 Fault detections using SVDD technique and peak-peak method

벗어남을 확인하는 peak-peak 방법을 통하여 구한 고장검출 시간은 4,097초로, SVDD기법을 이용한 알고리즘의 고장발생시점으로부터 검출되는 시간이 51%정도 빠른 것을 확인하였다. 이 시나리오에서는 peak-peak 방법도 늦게나마 검출할 수 있지만, 충전계통에 이상이 생겼음에도 불구하고 Fig. 9에 보인 것과 같이 배터리의 SOC가 최소값 이하로 내려가지 않았을 경우에는 peak-peak 방법으로 검출할 수 없다. 이러한 상황에서는 보조적으로 SVDD 기법을 사용하여 생성한 비정상경계를 이용하면 고장을 검출하는 것이 가능하다.

5. 결 론

이 논문에서는 SVDD 기법을 이용한 하이브리드

전기자동차 배터리 충-방전 시스템의 고장검출 알고리즘을 제안하였다. 상용 하이브리드 전기 자동차의 배터리 데이터와 차량 속도 데이터를 사용하였는 바, 많은 데이터를 점진적으로 학습하였으며, 동일한 데이터는 제거하였다. 또한, 새로운 데이터 감소 기법을 이용하여 다음 SVDD경계 근사에 영향이 없는 데이터를 찾아 제거하였다. 최종적으로 얻은 고장/비고장 경계를 이용하여 배터리가 충전되지 않는 상황을 모사한 고장 검출 시뮬레이션을 수행하였다. 여기서 배터리 충-방전 시스템의 고장 검출에 SVDD기법의 성공적인 적용과 그 효율적인 기능을 확인할 수 있었다.

추후 연구로는 RBF커널 등을 이용하여 이 연구에서 보인 원형인 경계를 보다 효과적인 다른 형태의 경계로 바꾸고, 실제 고장 데이터를 획득하여 연구에 적용할 계획이다.

후 기

이 연구는 지식경제부에서 시행하는 산업원천기술개발사업 실시간 주행모니터링 기반의 그린카 핵심부품 신뢰성 평가 기술 개발 과제(10033174)의 지원으로 수행되었음.

참 고 문 헌

- (1) Na, S. G., Lee, Y. H., Kim, J. S., Park, S. M. and Heo, H., 2010, A Study on the Hybrid Electric Vehicle Fault Diagnosis Algorithm, The Korean Society of Automotive Engineers Conference, pp. 2935~2942.
- (2) Joo, K. J., Jang, S. R., Mostafa, F. K. A. and Rim, G. H., 2009, Technical Trend of Electric Vehicle, The Korean Institute of Electrical Engineers, pp. 947~948.
- (3) Park, S. G., Park, W. S., Lee, H. J., Hong, W. G. and Oh, J. E., 2007, Fault Signal Analysis of the Automotive Components Using Experimental Method, Part 1-consideration of the Engine Signals, Proceedings of the KSNVE Annual Autumn Conference, pp. 238~242.
- (4) Park, S. G., Park, W. S., Lee, Y. Y., Kim, D.

S. and Oh, J. E., 2008, 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.

(5) Lee, K. H., Kong, B. H., Cheung, W. S. and Lee, S. G., 2009, System-diagnosis Algorithm by Using MPCA and ICA, Proceedings of the KSNVE Annual Autumn Conference, pp.213~214.

(6) Ko, K. W., Oh, Y. S., Jung, Q. Y. and Heo, H., 2003, Abnormal Diagnostics of Vibration System Using SVM, Proceedings of the KSNVE Annual Spring Conference, pp. 932~937.

(7) Park, J. Y. and Leem, C. H., 2003, Support Vector Learning for Abnormality Detection Problems, Korean Institute of Intelligent Systems, Vol. 13, No. 3, pp. 266~274.

(8) Kang, D. S. and Park, J. Y., 2006, Pattern

Denoising based on One-class Support Vector Machines, M. S. Thesis, Korea University.

(9) Na, S. G., Jeon, J. H., Han, I. J. and Heo, H., 2011, Fault Detection Algorithm of Hybrid Electric Vehicle Using SVDD, Proceedings of the KSNVE Annual Spring Conference, pp. 224~229.

(10) Na, S. G., Han, I. J. and Heo, H., 2011, Fault Detection Algorithm Using SVDD and Data Reduction Techniques for Battery of Hybrid Electric Vehicle, Computer Applications and Network Security Spring Conference, pp. 293~297.

(11) Kim, H. G., Heo, S. J. and Kang, G. B., 2009, Modeling and Characteristic Analysis of HEV Li-ion Battery Using Recursive Least Square Estimation, Transactions of KSAE, Vol. 17, No. 1, pp. 130~136.