

상태기반 유지보수 기법을 적용한 차량고장 진단 및 예측 시스템 연구

A Study on the Diagnosis and Prediction System of Vehicle Faults Using Condition Based Maintenance Technique

송길종* · 임재종**

* 주저자 : ㈜엔제로 기업부설연구소 교통팀

** 교신저자 : ㈜엔제로 기업부설연구소

Gil jong Song* · Jae Jung Lim**

* Transportation Team, Research Institute, NZERO Corporation

** Research Institute, NZERO Corporation

† Corresponding author : Jae Jung Lim, jjlim@nzero.kr

Vol.18 No.4(2019)

August, 2019

pp.80~95

pISSN 1738-0774

eISSN 2384-1729

<https://doi.org/10.12815/kits.2019.18.4.80>

2019.18.4.80

Received 19 March 2019

Revised 11 April 2019

Accepted 3 August 2019

© 2019. The Korea Institute of Intelligent Transport Systems. All rights reserved.

요약

최근 들어 센서 및 통신기술의 발달로 국내외 연구자들은 장비나 시스템의 상태정보를 수집하여 진단 및 예측 기법을 통한 유지보수를 결정하는 방법론에 대해 연구를 활발히 진행하고 있다. 본 연구에서는 이러한 연구 문헌 고찰을 통해 현시점의 차량부품 상태를 바탕으로 미래 시점까지의 차량부품 상태변화 추이를 예측하여 유지보수 의사결정을 수행하는 시스템 프레임워크를 제시하였다. 또한, 유지보수 활동에 따른 전과 후의 차량부품 상태변화 추적을 통해서 상태 진단 및 예측 데이터 조정이 가능하도록 구성하였다. 향후 본 연구 결과의 적용을 통해 대중버스를 이용하는 시민들의 안전과 차량의 상태기반 유지보수 체계 활성화에 조금이나마 기여할 수 있기를 기대한다.

핵심어 : 데이터 정제, 진단, 예측, 마르코프 모델, 상태기반 유지보수

ABSTRACT

Recently, with the development of sensor and communication technology, researchers at home and abroad have actively conducted research on methodologies for determining maintenance through diagnosis and prediction techniques by collecting information on the status of equipment or systems. Based on the status of vehicle parts at this point in time, this study presented a system framework for making maintenance decisions by predicting the change in vehicle part status to a future date based on the current state of vehicle parts. In addition, condition diagnosis and predictive data adjustment was configured through tracking the status of vehicle parts before and after maintenance activities. We hope that the application of the results of this study will contribute a little to the safety of citizens using public buses and to the activation of the condition-based maintenance system of vehicles.

Key words : Data cleaning, Diagnosis, Prognostics, Markov model, Condition-based maintenance

I. 서론

1. 개요

국내 대중교통 시장의 발전 및 변화에 따라 대중교통 차량 유지보수 기법 또한 발전을 이루어 왔다. 차량, 시스템은 더욱 복잡해지고 있고, 이에 따라 이용자의 안전 및 신뢰도에 대한 기대치도 점점 높아지고 있다. 국내 대중교통의 경우, 차량운행 증가와 크고 작은 차량의 고장으로 인해 운행지연 및 승객불편 사례가 증가하고 있다. 현재 서비스되고 있는 원격 차량 진단 시스템과 차량 정보 제공시스템은 단순한 차량 센서의 측정값을 통해 차량 내 세부 장비의 고장 상태를 제공할 뿐 고장에 대한 예측 정보 제공에는 한계가 있다. 해외 여러 대중교통 선진국에서는 대중교통 차량의 운행 신뢰성 점검에 있어 실시간 모니터링을 통한 진단기법을 도입하고 있으며, 유지보수 측면에서도 결함의 조기감지 및 방지를 위해 차량 상태 모니터링 시스템을 도입하고 있다.

최근 들어 몇몇 연구자들은 기존의 CM¹⁾ 및 PM²⁾의 양분화된 보전방식의 분류체계에서 탈피하여 CBM³⁾을 따로 독립적으로 언급하기 시작하였다. 즉, 보전방식을 크게 1) 고장 난 이후 조치를 취하는 Breakdown Maintenance, 2) 자산의 수리 주기를 결정하고 일정 수리 주기로 보전을 수행하는, 시간기준 예방보전 방법인 Preventive Maintenance, 그리고 3) 자산의 상태 모니터링을 바탕으로 이상 유무를 진단하고 고장 시기를 예지하여 수리 시기를 결정하는 CBM으로 분류하였다. 시간기준 예방보전 활동에 대한 연구들은 그동안 많이 제시되었지만 CBM과 관련해서는 그 중요성에도 불구하고, 산업용 자산의 사용기간 동안 자산의 상태정보를 파악할 환경이 갖추어져 있지 않아 관련 연구가 많이 진행되지 못했다. 하지만 최근 들어 이를 극복할 수 있는 센서 및 무선통신기술과 같은 정보통신기술의 발달로 인해, 상태정보에 관한 가시성을 확보할 수 있었고, 이를 바탕으로 CBM에 관한 연구가 새로이 조명을 받고 있는 실정이다. CBM 연구는 다양한 센서 데이터의 가공, 처리, 대상 시스템의 상태 데이터에 대한 분석, 진단 및 확률 예측, 보전 비용 모델 수립, 보전 의사결정 최적화, 의사결정 시스템 구축 기술 등 폭넓은 다학제간 지식을 요구하고 있다(Shin et al., 2014).

본 연구에서는 대중교통 차량 유지보수에 있어 상태기반 유지보수 방법론을 도입하기 위해 차량의 상태를 파악할 수 있는 데이터를 실시간으로 수집하고 분석할 수 있는 시스템 개발을 위한 방안 제시를 목적으로 하고 있다. 이를 위해 자산에 대한 상태기반 유지보수에 적용되는 방법론 및 알고리즘에 대한 기존 문헌 고찰을 통해, 현시점의 차량부품 상태를 바탕으로 미래 시점까지의 차량부품 상태변화 추이를 확률적 열화 모델 추론을 통해 예측하고, 유지보수 활동에 따른 전과 후의 차량부품 상태변화 추적을 통해 상태 진단 및 예측 알고리즘 조정을 수행하는 시스템 프레임워크를 제시하였다. 또한, 하이브리드 전기차량의 배터리 관련 실험데이터를 획득하여 본 연구에서 제시한 프레임워크에 대한 적용 타당성 실험을 수행하였다. 그리고 본 연구의 성과, 한계 및 향후 연구 방향에 대해 논하였다.

1) CM : Corrective Maintenance, 사후보전

2) PM : Preventive Maintenance, 예방보전

3) CBM : Condition Based Maintenance, 상태기반 유지보수

II. 기존 연구 고찰

이 장에서는 본 연구에서 제시하는 시스템에 상태기반 유지보수 방법론을 적용하기 위해 상태기반 유지보수 방법론 및 진단과 예측 알고리즘 등에 관련된 기존 연구를 고찰하였다.

1. 상태기반 유지보수 방법론 및 절차 고찰

Thurston(2001)은 상태기반 유지보수를 위한 개방형 시스템 구조인 OSA-CBM⁴⁾을 제시하면서 총 7가지의 계층으로 구성하였다. 해당 계층의 모듈은 센서 정보를 수집하는 센서 모듈, 수집된 센서 정보로부터 오류정보 제거 및 분석에 용이한 데이터로의 정제 등 데이터 처리를 수행하는 신호처리 모듈, 수집 정보에 대해 적절한 임계값을 설정한 뒤, 상태 모니터링을 수행하고 설정된 임계값을 벗어나는지를 감시하는 상태 모니터링 모듈, 장비 고장에 대한 진단을 수행하는 진단 모듈, 장비에 대한 현 상태 진단으로부터 미래 상태 예측을 수행하는 예측 모듈, 미래 상태 예측 결과를 이용해 장비에 대한 적절한 유지보수 행동을 결정하는 의사결정 모듈, 그리고 진단, 예측, 의사결정 모듈로부터 전달된 데이터를 기반으로 머신 인터페이스를 구성하는 구현 모듈로 구성되어 있다.

Shin et al.(2014)은 CBM 관련 사례 연구를 통해 유지보수 의사결정 과정 후, 사후분석 결과를 바탕으로 CBM 전 과정을 보완하는 구조인 Closed-loop CBM⁵⁾ 절차를 제시하였다. 센서 과정은 수집 데이터의 종류 결정, 전송방식 및 주기 결정에 따라 데이터를 수집하고, 신호처리 과정은 센서 데이터 결함치를 제거하거나 분석에 용이하게 원래 데이터로 변환하고, 상태 모니터링 과정은 자산의 상태를 파악할 수 있는 적절한 지표를 정의한 후, 지표에 대한 임계값을 모니터링하다가 임계값을 넘어갈 때 적절한 대응을 수행한다. 진단 과정은 유지보수 대상 시스템의 이상 징후의 원인, 현상에 대한 식별을 수행하고 예지 과정은 현시점까지의 상태 데이터들을 바탕으로 경향을 파악하여 앞으로 대상 시스템의 고장이 언제쯤 발생 될지, RUL⁶⁾을 추정하거나, 남은 성능을 추정하고, 의사결정 과정은 유지보수 방법 및 유지보수 시점을 결정한다. 유지보수 실행 및 사후 분석과정은 의사결정 과정에서 내려진 유지보수 방법 및 시기에 맞춰 유지보수를 실행하고 난 후, 사후분석을 통해 CBM 시스템 개선을 수행한다.

Poongodai(2013)은 진단 및 예측 방법으로 센서로부터 수집된 정보에 대한 이상 여부를 발견, 이상 발견 장비 결정, 이상 현상과 고장 모드가 무엇인지 결정, 그리고 미래 시점의 상태 결정을 하는 단계를 제시하였다. 그리고 규칙기반 접근법, 모델기반 접근법, 데이터기반 접근법 등의 3가지 접근법을 제시하였다.

Palem(2017)은 고속으로 운행되는 비행기, 차량 등과 같은 자산에 대한 상태기반 유지보수 시스템을 설계하는 접근법으로 M2M⁷⁾ 접근방식의 빅데이터 상태 기반 유지관리 시스템을 소개하였다. 여기서는 원격 센서 데이터 취득, 데이터 처리, 이상 탐지, 상태 진단, 예지, 유지보수 지원으로 단계를 구분하였다. 시스템 솔루션 설계 및 구현 관점에서 대용량 M2M 데이터를 실시간으로 처리하기 위해서 대용량 병렬 아키텍처의 설계 방법론을 제시하기도 하였다.

4) OSA-CBM : Open System Architecture for Condition Based Maintenance, 개방형 상태기반 유지보수

5) Close-loop CBM : Close-loop Condition Based Maintenance, 재귀적 상태기반 유지보수

6) RUL : Remaining Useful Life, 잔여수명

7) M2M : Machine-to-Machine, 기계 vs 기계

2. 상태 진단 및 예측 알고리즘 적용사례 고찰

Jun et al.(2006)은 자동차 부품에 대한 예측정비의 핵심은 자동차의 성능저하 상태를 분석하고 예측정비 결정을 내릴 수 있는 알고리즘을 개발하는 것이라고 하면서, 자동차 엔진 오일의 예측 유지보수를 실시하기 위해 자동차 엔진 오일의 분해 상태를 미션 프로파일 데이터로 분석하여 적절한 변화 시간을 결정하는 알고리즘을 제안하였다. 이를 위해 요인 분석, 차별 및 분류 분석, 회귀분석과 같은 몇 가지 통계 방법을 사용하였다. 즉, 요인 분석을 통해 미션 프로파일과 엔진 오일 품질의 주요 요인을 확인한 후 회귀분석을 통해 자동차의 미션 프로파일 유형을 고려한 주요 요소들 간의 관계를 규정하였다.

Jardine et al.(2006)은 상태 모니터링 데이터 처리 및 유지관리 의사결정을 위한 모델, 알고리즘 및 기술에 중점을 두고 CBM을 구현하는 기계 시스템의 진단 및 예측에 관한 연구 및 개발방법론을 요약하고 검토하였으며, 상태 모니터링에서 다중 센서를 사용하는 경향이 증가하고 있으므로 다중 센서 데이터 융합을 위한 기술에 대해 논하였다.

Rabiner et al.(1989)은 은닉 마르코프 모델링의 통계적 방법을 이용한 음성 인식 기술을 제시하였다. 은닉 마르코프 모델링의 통계적 방법은 수학적 구조가 매우 풍부하고 광범위한 분야에 적용이 가능한 이론적 근거를 형성했으며 실제 통계적 분석이 필요한 응용에 적용하여 매우 잘 작동하는 사례들로 이론적 증명도만 들어져 있어 통계적 분석에 많이 사용되는 모델이라고 하였다.

Kim et al.(2018)은 조직에서 수행하는 절차에서 비정상적인 활동을 탐지하기 위해 마르코프 체인 모델을 사용하였다. 마르코프 체인 모델은 이전 이벤트의 영향을 받는 임의의 변수를 통해 다음 상태 값을 보여준다. 마찬가지로 활동에 대한 이전 활동을 기반으로 현재 활동을 예측할 수 있다고 하였다. 상태에 대한 변경 항목을 전환 확률에 의해 정의하는 방법을 연구하고 확률 변수에 대한 값을 통한 내부 활동 위협의 이상 징후 검출로 분류하였다. 또한, 마르코프 체인의 속성을 이용하여 시간이 지남에 따라 행동들을 나열하고 이에 속한 상태를 분류하였다.

Lim et al.(2015)은 많은 서버 시스템으로 구성되어 복잡하지만, 제한적인 상황에서 반복적인 운용이 이뤄지는 열차 시스템의 특성을 고려하여 고장을 예측하기에 적절한 방법론으로서, 스스로 데이터를 분석하여 숨겨진 특성, 즉 패턴을 발견하는 학습 모델인 머신 러닝과 실제 열차 운용 상태를 고려할 경우 복잡한 신경망 이론이나 인공지능 기법 등은 막대한 양의 이벤트 데이터들을 실시간으로 분석하기에 한계점이 존재하기 때문에 매우 효율적인 통계기법으로 적용할 수 있는 베이지안 방법론을 제시하였다. 또한, 머신 러닝의 기법과 베이지안 방법론을 통해 고장을 예측하기 위한 표준 모델을 만드는 과정과 생성된 표준 모델이 갖는 특징에 관한 설명을 함께 제시하였다.

Park et al.(2012)은 고속도로 터널 구간을 대상으로 교통사고 특성을 다각적으로 분석하여 다양한 독립변수를 선정하고 종속변수를 다양화하여 다중선형회귀모형을 개발하였다. 그리고 개발된 모형들은 상호 비교 검토하여 최종적으로 교통사고 영향요인으로 구성된 신뢰성 있는 교통사고 예측모형을 결정하였다. 교통사고 예측모형은 모형의 검증 통계량 등 모형검증과정을 수행했고 터널 구간의 교통사고 특성 반영 여부 등을 검토하여 최종적으로 터널 길이에 따라 총 2개의 모형을 선정하였다. 추정모형은 RMSE⁸⁾, MAE⁹⁾를 이용하여 예측한 값과 실제 관측값과의 차이를 분석하여 터널 구간의 교통사고를 설명하였다.

Cha et al.(2015)은 국내 항만시설물의 정밀 점검 및 정밀안전진단 보고서를 통해 시설물을 지역별, 구조형식별, 시공상태 수준별, 유지관리 수준별, 취급화 종별로 구분하고, 구분된 시설물의 전체상태 등급 데이터를

8) RMSE : Root Mean Square Error, 평균 제곱근 오차

9) MAE : Mean Absolute Error, 평균 절대 오차

수집하여 상태열화 이력이 있는 동해안 지역의 부두를 시범대상 시설물로 선정하였다. 시범대상 시설별 부재별 노후화와 성능저하를 유발하는 주요 영향 인자로는 선박충돌하중, 염해, 적재·적하하중, 선박접안 에너지 선정하였고 이를 고려한 다중 회귀분석 모델을 개발하였다. 또한, 상태이력 데이터의 확률론적 모델인 마르코프 체인 이론을 이용한 모델을 함께 개발하였다. 각 케이스별 개발된 모델은 상태열화모델과 정밀 점검 및 정밀안전진단 보고서의 전체 상태등급 이력 데이터로 산출된 추세선과 비교 및 분석하여 적용성을 검증하였다.

3. 기존 방법론과의 비교

기존의 시스템 및 자산의 상태기반 유지보수 방법론과 본 연구에서 제시하는 방법론과의 각 절차 단계의 비교 테이블은 <Table 1>과 같다. 이 테이블에서의 각 단계는 유사한 업무라고 판단되는 것끼리 구분 지어 비교하였다. 기계류 장비에 대한 모니터링 및 진단에 관한 국제표준인 ISO 13374에서는 데이터 취득, 진단, 예측, 제시 및 조치, 사후분석으로 구분 지었고, 진동 신호 상태기반 유지보수 방법과 관련된 ISO 13374-1 표준 문서에서는 데이터 취득 단계를 데이터 취득과 데이터 조작, 진단 단계를 상태탐지와 적합평가로 구분하고 사후분석단계를 생략하였다. Thurston(2001)이 제안한 상태기반 유지보수를 위한 개방형 시스템 구조인 OSA-CBM은 제시 및 조치단계를 의사결정과 조치로 나누었고 Palem(2017)이 제안한 비행기, 차량과 같은 고속으로 운행하는 자산에 대한 상태기반 유지보수 관리 방법은 ISO 13374-1에서 제안한 절차를 적용하였다.

<Table 1> The CBM procedure comparison

| ISO 13374 | ISO 13374-1 | Thurston(2001) | Palem(2017) | Proposed Methodology |
|-----------------------|------------------------|-------------------|---------------------|--|
| Data Acquisition | Data Acquisition | Sensor Module | Data Acquisition | Data Acquisition & Monitoring |
| | Data Manipulation | Signal Processing | Data Manipulation | Data Cleaning Data Normalization |
| Diagnostics | State Detection | Condition Monitor | Condition Detection | Abnormal Detection |
| | Health Assessment | Health Assessment | Health Assessment | State Assessment |
| Prognostics | Prognostics Assessment | Prognostics | Prognostics | Transition Probability Derivation Deterioration Model Inference |
| Presentation, actions | Advisory Generation | Decision Support | Maintenance Support | Maintenance Cost Calculation |
| | | Presentation | | Maintenance Decision |
| Postmortems | | | | State Tracking |
| | | | | Adjustment |

본 연구에서는 <Table 1>에서와 같이 데이터 취득 단계를 데이터 수집 및 모니터링, 데이터 정제, 데이터 정규화로 구분하고, 진단 단계를 이상 탐지와 상태 진단으로, 예측 단계를 상태 전이확률 도출과 열화모델 추론으로, 제시 및 조치단계를 유지보수 활동 기대비용 산출, 유지보수 결정으로, 사후분석단계는 상태 추적, 조정으로 구분하였다. 다음 장에서 본 연구에서 제시한 각 단계 과정별 상세 내용에 대해 논하였다.

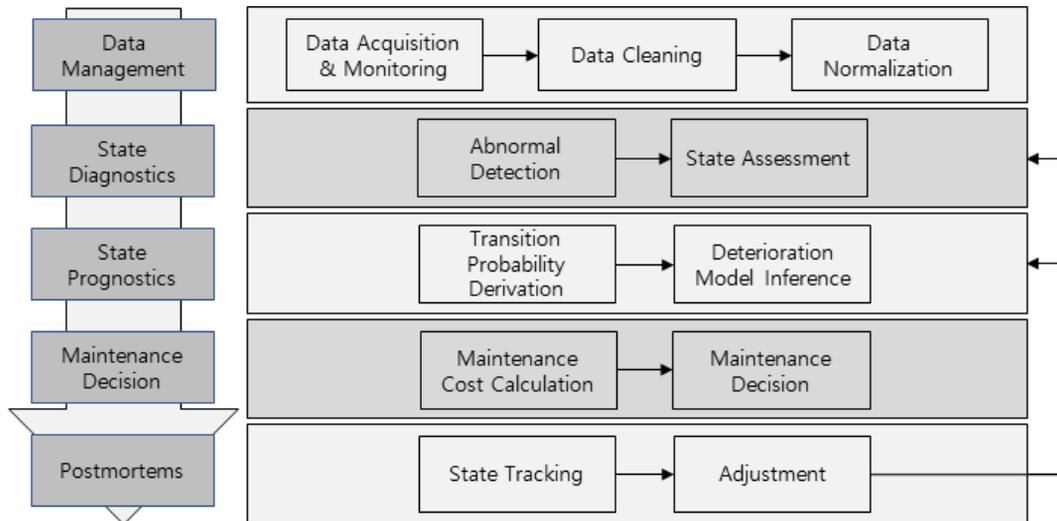
Ⅲ. 차량 상태기반 진단예측 시스템

본 연구에서는 실시간 차량 센서 데이터 모니터링을 통해 차량부품의 상태를 가늠할 수 있는 데이터를 지속적으로 수집하고, 수집된 차량부품 데이터의 특성을 파악하여 차량고장 진단 및 예측을 수행하고, 이를 바탕으로 유지보수 활동에 따른 차량부품 성능 변화 및 비용을 예측할 수 있는 차량 상태기반 진단예측 시스템 설계 및 개발을 위한 방법론과 그 프레임워크를 제시하였다.

1. 시스템 프레임워크 정의

차량 상태기반 진단예측 시스템의 프레임워크는 <Fig. 1>과 같이 크게 데이터 관리, 상태 진단, 상태 예측, 유지보수 결정, 사후분석의 5단계로 구성하였다. 그리고 데이터 관리 단계를 데이터 수집 및 모니터링, 데이터 정제, 데이터 정규화 과정으로 세분화하였고, 상태 진단 단계는 이상 탐지, 상태 진단으로, 상태 예측 단계는 상태 전이확률 도출, 열화모델 추론으로, 유지보수 결정 단계는 유지보수 비용 산출, 유지보수 결정으로, 사후분석 단계는 상태 추적, 조정 과정으로 구성하였다.

본 연구에서 제시하는 시스템 프레임워크와 방법론은 현시점의 차량부품 상태를 바탕으로 확률적 열화모델 추론을 통해 미래 시점까지의 차량부품 상태변화 추이를 예측하고, 유지보수 활동에 따른 전과 후의 차량부품 상태변화 추적을 통해 상태 진단 및 예측 알고리즘 조정을 지속적으로 수행하는 특징을 가지고 있다.



<Fig. 1> Framework of diagnosis prediction system based on vehicle condition

2. 프레임워크 주요 내용 및 내부 절차

1) 데이터 관리

데이터 관리 단계는 데이터 수집 및 모니터링, 데이터 정제, 데이터 정규화 과정으로 이루어져 있다. 먼저, 데이터 수집 및 모니터링 과정에서 수집되는 센서 데이터는 속도, 가속도, 진동, 하중, 전압, 온도 등 차량부품의 상태를 가늠할 수 있는 데이터로서, 실시간 모니터링을 통해 데이터를 지속적으로 얻을 수 있는 차량

부품에 대해 수집한다. 차량부품의 특성과 수집 데이터의 특성을 사전에 인지하여, 데이터 정제 과정에서 활용할 수 있는 원시 형태의 데이터를 획득하는 과정으로 시간대별로 차량부품 성능의 변화를 관찰하고, 나아가 성능을 수치화할 수 있는 지속적인 데이터 수집 과정이 반드시 필요하다.

데이터 분석을 위해 고급 분석기법을 적용하였다 하더라도 데이터 정제가 이루어지지 않은 데이터를 분석에 사용하게 되면 의미 없는 결과물이 도출될 수 있으므로 데이터의 정제 과정을 수행한다. 이 과정에서는 모순된 데이터를 발견하고, 데이터의 불일치성을 교정하기 위해 결측치 보정과 데이터 평활화를 수행한다. 결측치 보정은 관측 센서의 오작동 및 관측범위의 한계에 의해 발생하는 결측치를 보정하여 정보의 손실 및 왜곡을 최소화하는 과정으로 식(1)과 같은 방법을 사용한다.

$$A_t = \frac{(A_{t-1} + A_{t-2} + A_{t-3} + \dots + A_{t-n})}{n} \tag{1}$$

여기서,

A_t = 결측치가 발생한 지점 t에서 추세를 이용한 추정값 n = 추세를 이용한 추정값 계산을 위한 주기
 A_{t-n} = 결측치가 발생한 지점으로부터 t-n 지점에서 수집한 데이터

데이터 평활화를 통해서 데이터 추출 시 노이즈로 인한 바람직하지 않은 불규칙적 변동이 있을 때, 이러한 변동이나 불연속성을 약하게 하거나 제거하여 매끄럽게 한다.

$$A_{t-1} - A_{t-1} \times 0.5 < A_t < A_{t-1} + A_{t-1} \times 0.5 \tag{2}$$

여기서,

A_t = 현재 주기에 수집된 데이터 A_{t-1} = 이전 주기 t-1 때 수집된 데이터

$$A_m = \omega_1 \times A_t + \omega_2 \times A_{t-1} + \omega_3 \times A_{t-2} \tag{3}$$

여기서,

A_m = 현 주기와 이전 주기 데이터의 가중평균 A_t = t 주기 때에 수집된 데이터
 ω = 가중치

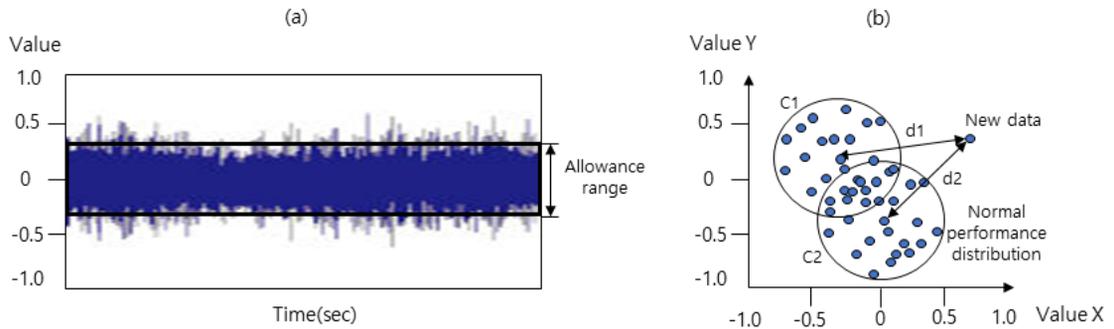
식(2)와 같이 이전 주기의 데이터를 기준으로 현재 주기에 수집된 데이터가 일정 범위(±50%)의 변화폭 이 내가 아닌 경우, 식(3)에서와 같이 이전 주기의 데이터와 현재 주기에 수집된 데이터를 가중치에 의한 이동 평균으로 평활화를 수행한다.

데이터 정규화 과정에서는 서로 다른 2개 이상의 센서 데이터를 융합하여 상태 진단 및 예측을 수행하는 경우에 데이터의 단위와 범위가 서로 다르면 분석에 어려움이 있으므로 이런 경우에 하나의 단위와 범위로 데이터 정규화를 수행한다. 이때의 정규화 범위로는 -1 ~ 1 사이의 값을 사용한다.

2) 상태 진단

상태 진단 단계는 데이터 분석을 통해 차량부품의 현재 상태를 파악하는 단계로서, 데이터 기반 이상 탐지, 상태 진단 과정으로 이루어져 있다. 데이터 기반 이상 탐지 과정에서는 진단대상 데이터가 단일 요소로

구성된 경우에는 시계열 데이터의 정상 성능 범위를 벗어난 데이터를 구별하는 방법을 사용하고, 진단대상 데이터가 복합 요소로 구성된 경우에는 데이터가 정상 성능 군집분포 범위를 벗어난 데이터를 구별하는 방법을 사용한다. 단일 요소로 구성된 데이터 기반 이상 탐지는 차량부품의 정상 성능 범위 값을 미리 정하고 <Fig. 2>의 (a)와 같이 데이터가 이 값의 범위를 이탈하는 경우 변칙값으로 판단한다. 복합 요소로 구성된 데이터 기반 이상 탐지는 차량부품 각각의 정상 성능 범위 값을 미리 정하고 <Fig. 2>의 (b)와 같이 동일 좌표에서의 정상 성능 군집을 파악한 후, 새로운 데이터와 군집 간의 거리 $d1$ 또는 $d2$ 값이 $C1, C2$ 의 정상 성능 분포 영역을 벗어 나는 경우 변칙값으로 판단한다. 정상 성능 범위 값은 차량부품별로 제조사에서 정한 성능 허용 기준을 따른다.



<Fig. 2> Data-based anomaly detection method

상태 진단 과정에서는 미리 정해져 있는 상태별로 상태등급 패턴데이터를 정하고, 진단대상 데이터와 각 상태등급 패턴데이터를 패턴 매칭을 통해 유사도 분석을 수행한다. 상태등급 패턴데이터는 과거 상태 진단과 유지보수 활동 전과 후의 상태변화 이력데이터를 이용해 조정 및 학습된 데이터이다. 본 과정에서의 데이터 기반 패턴 매칭을 통한 유사도 분석은 식(4)를 이용해 진단대상 데이터와 각 상태별 상태등급 패턴데이터의 유사도 값을 계산하고, 이 중에서 유사도 값이 가장 작게 나오는 상태등급 패턴데이터의 상태를 진단대상 데이터의 최종 상태로 결정한다.

$$d(V_s, V_p) = \sqrt{(V_{s,1} - V_{p,1})^2 + \dots + (V_{s,n} - V_{p,n})^2} \tag{4}$$

여기서,

$d(V_s, V_p)$ = 진단대상 데이터와 상태등급 패턴데이터 간의 유사도 값

V_s = 상태등급 패턴데이터

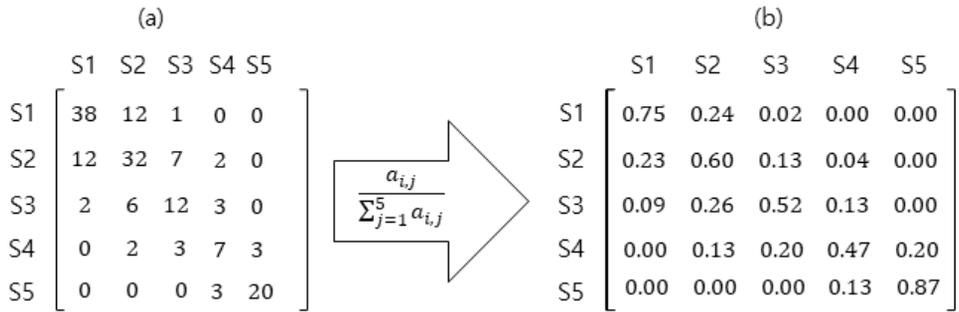
V_p = 진단대상 데이터

$V_{s,n}$ = 상태등급 패턴데이터의 n 번째 데이터

$V_{p,n}$ = 진단대상 데이터의 n 번째 데이터

3) 상태 예측

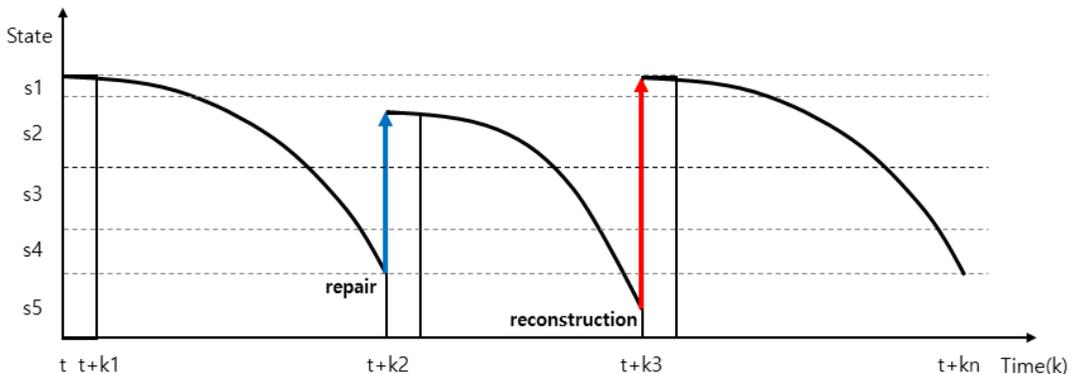
상태 예측 단계는 마르코프 프로세스 모델을 사용하여 상태 전이확률행렬을 도출하고, 유지보수 활동에 따른 차량부품의 열화모델을 추론하는 과정으로 이루어져 있다.



<Fig. 3> Derivation of the state transition probability matrix

상태변화 이력데이터로부터 상태전이 발생빈도수를 계산하여 상태 전이빈도행렬을 만들고, 각각의 행별로 발생빈도 총합 대비 각 요소의 비율을 계산하여 상태 전이확률행렬을 도출하는 과정을 <Fig. 3>에 도식화하여 표현하였다. 그림에서 (a)와 (b) 행렬의 좌측과 상단에 표시한 s_n 은 차량부품 상태등급을 나타낸다. 그리고 상태 전이확률행렬 계산의 예로써, S1에서 S2로의 상태전이 발생빈도수 12를 S1이 다른 상태(S1 ~ S5)로 전이한 총 빈도수인 51로 나누면 0.24(24%)의 확률값을 얻는다는 것을 보여주고 있다.

열화모델 추론 과정에서는 향후 차량부품의 시간에 따른 성능 변화를 예측하고 차량부품의 상태를 항상 사용 가능한 상태로 유지하기 위해서 차량부품의 성능저하 양상을 확률적 추론을 통해 열화모델을 도출한다. 이러한 열화모델은 <Fig. 4>와 같은 열화곡선으로 표현할 수 있다. 그림에서의 열화곡선은 각각의 상태별 성능 유지시간이 지난 후 상태 4일 때 수리, 상태 5일 때 교환 유지보수 활동 계획에 의한 차량부품의 열화 진행 과정을 예로 표현한 것이다. 가로축은 시간 주기를, 세로축은 차량부품의 상태를 나타내며, t 는 현시점, $t+k1$ 은 상태 점검을 수행하는 최소 주기, $t+kn$ 은 차량부품의 마지막 생애 시점을 나타낸다. 또한, 시간 흐름에 따라 부품의 열화로 인해 상태등급이 떨어지며, $t+k2$ 시점에서 수리 유지보수 활동을 통해 상태등급이 $s2$ 로 상승하고 $t+k3$ 시점에서는 교환 유지보수 활동으로 인해서 최상의 상태등급인 $s1$ 로 상승하여 $t+kn$ 시점까지 성능 유지가 이루어지고 있는 것을 보여주고 있다.



<Fig. 4> The deterioration elevation

상태 예측 단계에서의 열화모델은 차량부품에 대해 유지보수 활동에 따른 <Fig. 3>과 같은 상태 전이확률행렬과 차량부품 상태가 다른 상태로 전이하는데 걸리는 시간 정보, 그리고 계획대상 기간까지의 유지보수

활동 계획에 의해 추론되어 진다. 이러한 열화모델은 시스템 프레임워크의 다음 단계인 유지보수 결정 단계에서 계획대상 기간까지의 유지보수 활동에 따른 최소 기대비용 산출에 이용된다.

4) 유지보수 결정

유지보수 결정 단계는 유지보수 활동에 따른 유지보수 기대비용 산출과 유지보수 결정 과정으로 이루어져 있다. 유지보수 활동에 따른 유지보수 기대비용 산출과정에서는 Yeo et al.(2010) 연구에서 부품 단위 유지보수 기대비용 산출 방법으로 제시한 식(5)를 이용해 유지보수 활동에 따른 최소 기대비용을 계산한다.

$$V(i,t) = \min_a (C(a,i) + r \sum_{j=1}^{10} V(j,t+1)P_a(i,j)) \tag{5}$$

여기서,

$V(i,t)$ = 상태가 i 일 때, t 시점부터 계획대상기간 T 까지의 최소 기대비용

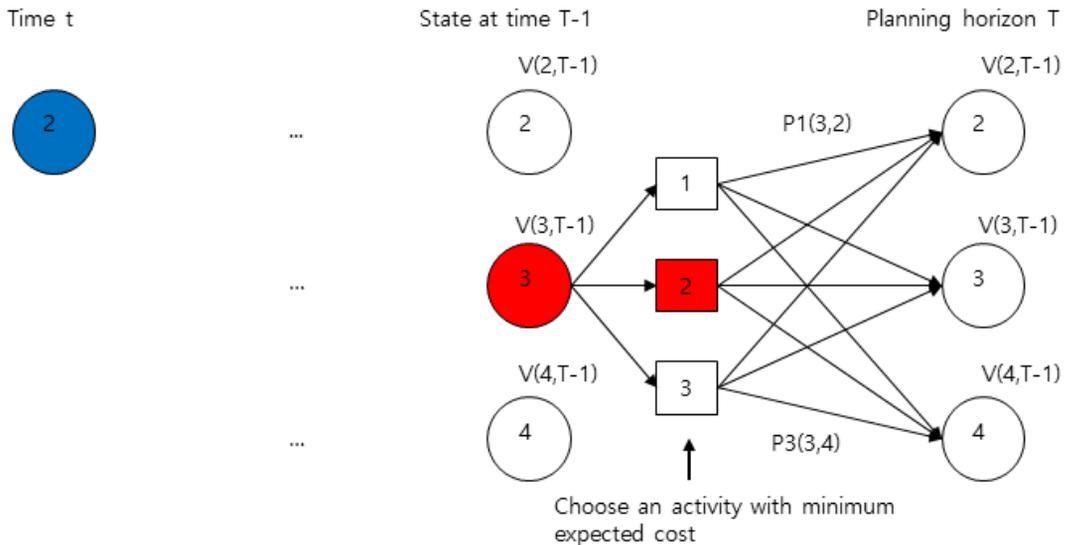
a = 유지보수 활동(1=미대응, 2=수리, 3=교환) r = 할인율

i = 현재 시점의 차량부품 상태 j = 다음 시점의 차량부품 상태

$P_a(i,j)$ = 차량부품이 유지보수 활동 a 에 의해 상태 i 에서 j 로 전이할 확률

$C(a,i)$ = 상태 i 에서 유지보수 활동 a 를 수행하였을 때의 행동비용

<Fig. 5>는 식(5)를 이용해 현재 시점에서 유지보수 활동에 따른 최소 기대비용을 계산하는 예를 도식화한 것이다. 시점 $T-1$ 에 있는 부품 상태 3은 3가지 유지보수 활동(미대응 = 1, 수리 = 2, 교환 = 3)이 존재하며, 각각의 유지보수 활동에 대한 비용을 비교했을 때 두 번째 활동이 최소 기대비용($V(3,T-1)$)을 가지는 것으로 계산되어 두 번째 유지보수 활동을 최적의 방안으로 선택하는 것을 보여준다. 이처럼 계획대상 시점(T)부터 현재 시점($Time t$)까지 동적 계획법을 이용해 각각의 상태에 대한 유지보수 활동에 따른 최소 기대비용을 선택하는 방식으로 최적의 유지보수 활동을 결정해 나간다.



<Fig. 5> Maintenance optimization process

유지보수 결정 과정에서는 유지보수 활동에 따른 계획대상 기간까지의 최소 기대비용, 유지보수 활동 우선순위 등의 결과를 도출하여 시스템 운영자에게 유지보수 의사결정을 할 수 있도록 정보를 제공한다.

5) 사후분석

사후분석 단계에서는 유지보수 활동에 따른 전과 후의 차량부품 상태변화를 추적하고 상태 진단과 예측 단계의 알고리즘 관련 데이터를 조정하는 과정으로 이루어져 있다. 상태 추적 과정에서는 차량부품에 대한 시스템 운영자의 유지보수 의사결정이 이루어지고 유지보수 대응이 완료된 후, 해당 차량부품에 대한 유지보수 활동에 따른 전과 후의 차량부품의 상태 변화를 추적하고 차량부품 상태변화 이력데이터를 생성한다.

조정 과정에서는 상태 진단 단계에서 사용되는 상태등급 패턴데이터, 상태 예측 단계에서 도출하는 상태 전이확률행렬 데이터, 열화모델 추론 데이터 등을 조정 및 학습되도록 하여 차량 상태기반 진단예측 시스템의 상태 진단 및 예측 정확도를 점진적으로 높여 시스템 신뢰도가 향상되도록 한다.

3. 프레임워크 및 방법론 실험

앞서 서술한 차량 상태기반 진단예측 시스템의 프레임워크 및 방법론에 대한 적용 타당성 확인을 위해서 하이브리드 전기 자동차의 배터리 엔진으로만 운행한 자료를 취득하여 배터리 부품의 상태가 확률적으로 열화 과정을 겪는다고 가정하고 상태 진단, 상태 예측, 유지보수 결정 단계별로 실험을 진행하였다.

1) 실험데이터 구성 및 가설

실험데이터는 차량 동력원으로 20개의 배터리 블록으로 구성된 배터리 부품에 대한 데이터로 총 3,293개의 레코드로 구성되어 있다. <Table 2>와 같이 수집된 배터리 부품 관련 데이터는 배터리 충전량, 배터리 전류, 20개 배터리 블록 각각의 전압으로 구성되어 있다.

<Table 2> The configure collection data for battery

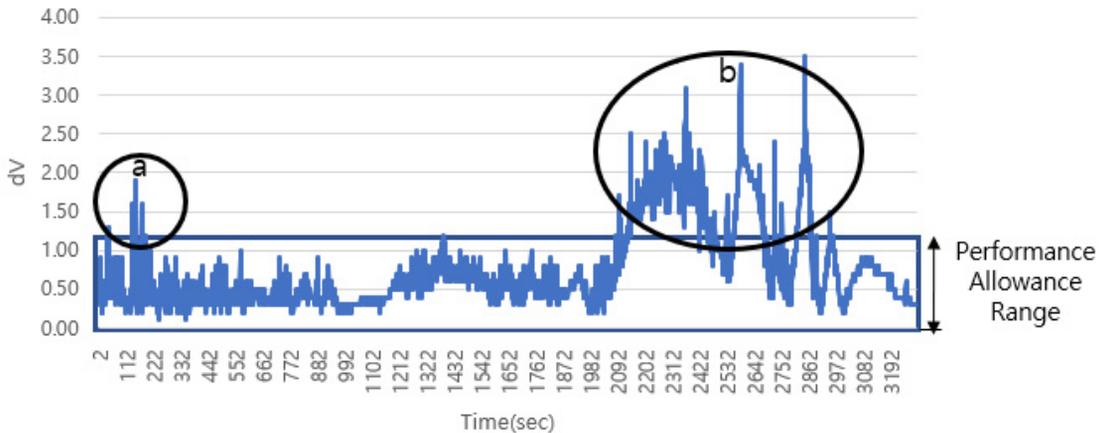
| index | SoC | Current | V01 | V02 | V03 | V04 | V05 | ... | V16 | V17 | V18 | V19 | V20 |
|-------|------|---------|-------|-------|-------|-------|-------|-----|-------|-------|-------|-------|-------|
| 0001 | 66.3 | -24.405 | 17.10 | 17.20 | 17.20 | 17.10 | 17.10 | ... | 17.10 | 17.10 | 17.10 | 17.10 | 17.20 |
| 0002 | 66.3 | -24.405 | 16.90 | 16.70 | 16.60 | 16.50 | 16.50 | ... | 17.10 | 17.10 | 17.10 | 17.10 | 17.20 |
| 0003 | 66.3 | -24.405 | 17.00 | 16.80 | 16.80 | 16.70 | 16.60 | ... | 16.50 | 16.50 | 16.50 | 16.50 | 16.80 |
| ... | ... | ... | ... | ... | ... | ... | ... | ... | ... | ... | ... | ... | ... |
| 3291 | 49.8 | -25.585 | 14.50 | 14.30 | 14.00 | 13.90 | 13.80 | ... | 14.40 | 14.30 | 14.40 | 14.30 | 14.80 |
| 3292 | 49.8 | -25.585 | 15.40 | 15.00 | 14.80 | 14.60 | 14.50 | ... | 14.40 | 14.30 | 14.40 | 14.60 | 15.20 |
| 3293 | 49.8 | -25.585 | 15.40 | 15.00 | 14.80 | 14.60 | 14.50 | ... | 14.40 | 14.30 | 14.50 | 14.60 | 15.10 |

배터리 부품의 열화 과정은 새 배터리일수록 배터리 블록 간의 전압의 차이가 작게 나타나고 노화가 진행될수록 배터리 블록 간의 전압 차이가 크게 나타난다고 가정하고, 배터리 블록 전압의 최대값과 최소값의 차이를 dV 라고 정의하였다. 실험데이터 각각의 레코드별로 dV 값을 구하여 시계열 데이터로 구성한 후, 배터리 부품의 상태 진단, 상태 예측, 유지보수 결정 단계에서 사용하였다.

2) 상태 진단 실험

배터리 블록 전압의 최대값과 최소값의 차이로 정의된 dV 값으로 구성된 실험데이터를 대입하여 미리 정의된 각각의 상태별로 진단을 수행하고 그 정확도를 측정하였다. 배터리 부품 상태등급을 dV 값을 이용해 총 5등급으로 구분하였다. 정상 성능을 유지하는 상태로는 dV 값이 0.45V 이하, 0.70V 이하, 0.95V 이하, 1.2V 이하 총 4개의 상태로 구분하고 이상 상태로는 1.2V 초과 1개의 상태로 구분하여 3,293개의 dV값으로 상태등급별 패턴데이터를 구성하였다.

dV 값은 단일 요소의 시계열 데이터이므로 성능 허용 기준값의 범위 이탈 여부로 배터리 부품 이상 탐지를 수행하였다. <Fig. 6>과 같이 dV 성능 허용 기준값을 1.2V로 정의하고 배터리 부품 이상 탐지를 수행한 결과는 총 3,293개 중 524개가 성능 허용 기준을 초과한 것으로 나타났다. dV 값은 차량 시동, 악셀레이터와 브레이크 조작 등 차량운행 상황에 따라 일시적으로 스파크가 발생하여 성능 허용 기준 범위를 초과할 수 있으므로 배터리 부품 이상으로 판단하기 위해서는 일정 주기 동안 dV 값이 1.2V 초과한 값으로 유지되었을 때 부품 이상으로 판단할 필요가 있다. <Fig. 6>의 a 영역에서는 6주기 동안 dV 값이 1.3V ~ 1.9V로 나타났고 그 이후는 정상 성능 기준으로 유지되었으므로 배터리 부품 이상으로 판단하지 않는다. 하지만 b 영역에서는 772주기 동안 dV 값이 1.2V 이하의 값으로 일부에서는 나타나지만, 대부분 1.3V ~ 3.5V 로 유지되었으므로 이 경우에는 배터리 부품 이상으로 판단할 수 있다. 실제로 실험데이터의 배터리 전류 변화폭이 b 영역을 제외하면 -50.0A ~ 20.0A 범위를 유지하고 있는 반면에 b 영역에서는 -80.0A ~ 150.0A 범위로 배터리 전류의 변화폭이 매우 심하게 나타났다.



<Fig. 6> The performance allowable range for dV

상태 진단에서는 진단대상 데이터와 각각의 상태등급별 패턴데이터를 이용해 데이터 기반 패턴 분석을 수행한다. 진단대상 데이터는 실시간으로 수집되는 새로운 데이터를 대신하기 위해 실험데이터에서 시계열로 20개 데이터씩 골라서 새로운 데이터로 가정하였고, 각각의 상태등급별 패턴데이터는 100개 데이터씩 임의로 추출하였다. 그리고 식(4)를 이용해 패턴 유사도 분석을 수행하여 최소 유사도 값을 나타내는 상태등급 패턴데이터가 속한 상태등급을 진단대상 데이터의 상태등급으로 진단하였다. <Table 3>은 상태 진단을 위한 패턴 매칭 유사도 분석 결과이다. 총 165개의 진단대상 데이터는 상태1이 53건, 상태2가 52건, 상태3이 23건, 상태4가 14건, 상태5가 23건으로 진단되었다.

<Table 3> The result of data-based matching

| Diagnostic Target Data (index) | | Pattern Data by State Grade | | | | | |
|-----------------------------------|-----|-----------------------------|-----------------|----------|-----------------|-----------------|---------------|
| | | State 1 | State 2 | State 3 | State 4 | State 5 | Current State |
| Similarity | 1 | 0.866025 | 0.984886 | 1.670329 | 2.84605 | 5.9279 | 1 |
| | 2 | 1.780449 | 1.363818 | 1.363818 | 2.289105 | 5.106858 | 2 |
| | 3 | 0.67082 | 0.4 | 1.349074 | 2.495997 | 4.988988 | 2 |
| | | ... | ... | ... | ... | ... | ... |
| | 141 | 3.667424 | 2.758623 | 1.920937 | 1.004988 | 2.808914 | 4 |
| | 142 | 7.031358 | 6.166036 | 5.005996 | 3.977436 | 1.555635 | 5 |
| | 143 | 9.569744 | 8.71493 | 7.664203 | 6.542935 | 3.487119 | 5 |

<Table 4> The result of data-based matching for precision verification

| Diagnostic Target Data | Pattern Data by State Grade(State Diagnosis Count/Total Number of Actions) | | | | |
|------------------------|--|---------|---------|---------|---------|
| | State 1 | State 2 | State 3 | State 4 | State 5 |
| State 1 | 100/100 | 0/100 | 0/100 | 0/100 | 0/100 |
| State 2 | 1/100 | 96/100 | 3/100 | 0/100 | 0/100 |
| State 3 | 0/100 | 0/100 | 100/100 | 0/100 | 0/100 |
| State 4 | 0/100 | 0/100 | 0/100 | 92/100 | 8/100 |
| State 5 | 0/100 | 0/100 | 0/100 | 0/100 | 100/100 |

상태 진단 정확도를 검증하기 위해서 상태 진단이 완료된 진단대상 데이터 중에서 상태등급별로 하나씩 진단대상 데이터를 선정하고, 각각의 상태등급별 패턴데이터는 임의로 추출하여 데이터 기반 패턴 매칭을 수행하였다. 이 작업을 상태등급별로 100회 반복하였으며 그 결과는 <Table 4>와 같았다. 상태1의 경우 100건중 100건을 올바르게 진단하였으며, 상태2의 경우 96건, 상태3의 경우 100건, 상태4의 경우 92건, 상태5의 경우 100건을 각각 올바르게 진단하였다. 그러나 상태2 진단대상 데이터의 경우에 1건은 상태1로 진단하고, 3건은 상태3으로 진단하였으며, 상태4 진단대상 데이터의 경우에 8건을 상태5로 진단하는 오진 사례가 발생하였다. 정상 상태를 이상 상태로 잘 못 진단하는 것에 대해서는 알고리즘의 보완이 필요한 부분이다.

3) 상태 예측 실험

배터리 부품에 대한 열화모델 추론을 통해 미래 상태에 대한 예측을 수행하기 위해서는 장기간 지속적인 데이터 수집과 부품 상태 진단 및 유지보수 활동(미대응, 수리, 교환)에 따른 전과 후의 상태변화 이력데이터를 확보하고 있어야만 가능하다.

| | | | | | | | | | | | | | | | | | |
|-----|------|------|------|------|------|----|------|------|------|------|------|----|------|------|------|------|------|
| (a) | | | | | (b) | | | | | (c) | | | | | | | |
| S1 | S2 | S3 | S4 | S5 | S1 | S2 | S3 | S4 | S5 | S1 | S2 | S3 | S4 | S5 | | | |
| S1 | 0.75 | 0.24 | 0.02 | 0.00 | 0.00 | S1 | 1.00 | 0.00 | 0.00 | 0.00 | 0.00 | S1 | 1.00 | 0.00 | 0.00 | 0.00 | 0.00 |
| S2 | 0.23 | 0.60 | 0.13 | 0.04 | 0.00 | S2 | 0.90 | 0.10 | 0.00 | 0.00 | 0.00 | S2 | 1.00 | 0.00 | 0.00 | 0.00 | 0.00 |
| S3 | 0.09 | 0.26 | 0.52 | 0.13 | 0.00 | S3 | 0.10 | 0.85 | 0.05 | 0.00 | 0.00 | S3 | 1.00 | 0.00 | 0.00 | 0.00 | 0.00 |
| S4 | 0.00 | 0.13 | 0.20 | 0.47 | 0.20 | S4 | 0.00 | 0.00 | 0.31 | 0.69 | 0.00 | S4 | 1.00 | 0.00 | 0.00 | 0.00 | 0.00 |
| S5 | 0.00 | 0.00 | 0.00 | 0.13 | 0.87 | S5 | 0.00 | 0.00 | 0.00 | 0.00 | 1.00 | S5 | 1.00 | 0.00 | 0.00 | 0.00 | 0.00 |

<Fig. 7> The state transition probability matrix by maintenance activity

여기서는 상태 진단 과정에서 사용한 165개의 진단대상 데이터의 상태 진단 시점을 기준으로 전과 후의 상태 전이 결과를 이용해 <Fig. 7>과 같은 상태 전이확률행렬을 도출하였다. 즉, 진단대상 데이터의 상태 진단 시점을 기준으로 전과 후의 배터리 부품 상태를 비교하여 상태전이 있는 경우, 해당 요소에 1을 더하는 방식으로 계산하여 상태 전이빈도행렬을 구하고, 이를 이용해 각 행 단위로 상태전이 발생빈도 총합 대비 각 요소의 비율을 계산하여 <Fig. 7>의 (a)와 같은 미대응 유지보수 활동에 따른 상태 전이확률행렬을 도출하였다. 실험데이터로는 수리와 교체 유지보수 활동에 따른 상태 전이확률행렬을 도출할 수 없어서 (b), (c)와 같이 임의로 정하였다.

<Fig. 7>과 같은 미대응, 수리, 교환 유지보수 활동에 따른 상태 전이확률행렬과 각각의 상태별 성능 유지 시간을 알면 확률적 열화모델 추론을 통한 배터리 상태추이 예측이 가능하다. 각각의 상태별 성능 유지 시간을 1 ~ 4 등급까지 각각 $t+4$, $t+3$, $t+2$, $t+1$ 로 가정하여 <Fig. 8>과 같은 열화곡선을 추론하였다. 그림을 보면, 계획대상 기간이 $t+22$ 이라고 할 때, 현시점(t)을 기준으로 $t+7$ 시점에 상태 S3가 되었을 때, 수리 유지보수 활동으로 인해서 상태 S2로 전이되었다가 $t+12$ 시점에 상태 S4가 되었을 때, 교환 유지보수 활동으로 인해서 상태 S1이 되고 난 후, 유지보수 활동 없이 $t+22$ 시점까지 성능이 유지되고 있다.

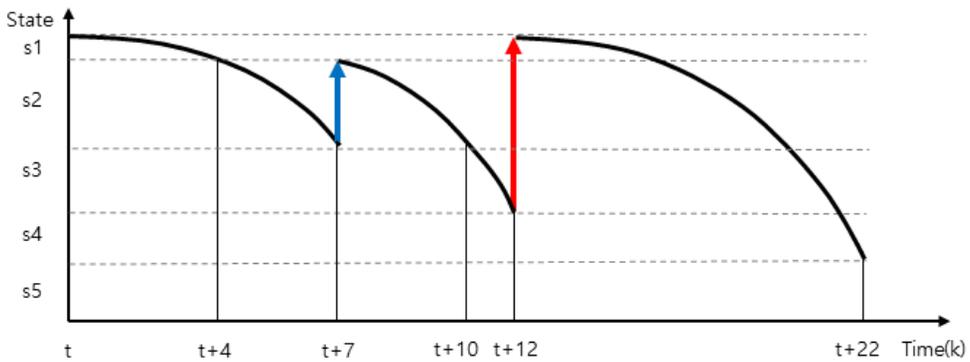


Fig. 8> The deterioration elevation by interfere

4) 유지보수 결정 실험

유지보수 결정 실험을 위해 계획대상 기간, 할인율, 상태등급별 유지보수 활동 비용, 계획대상 기간 때의 상태등급별 잔존가치를 정하고 앞서 상태 예측 실험에서 도출한 유지보수 활동에 따른 상태 전이확률행렬을 식(5)에 대입하여 계획대상 기간부터 현시점까지 역추적하는 방법으로 현시점에서의 최적 유지보수 활동을 우선순위별로 <Table 5>와 같이 구하였다.

<Table 5> The result of maintenance priority

| Current State | Minimum State | Maintenance Actions | | | | | | | | |
|---------------|---------------|---------------------|-----------|-----------|------------|-----------|-----------|------------|------|-----------|
| | | Priority 1 | | | Priority 2 | | | Priority 3 | | |
| | | Action | Cost | LCC | Action | Cost | LCC | Action | Cost | LCC |
| 2 | 3 | 2 | 8.5853652 | 8.5732452 | 3 | 60 | 60.464645 | 1 | 0 | 0 |
| 2 | 3 | 2 | 8.6658301 | 8.7337792 | 3 | 60 | 60.539471 | 1 | 0 | 0 |
| 3 | 4 | 2 | 23.462417 | 23.896854 | 3 | 60 | 60.497939 | 1 | 0 | 0 |
| 3 | 4 | 1 | 0 | 0 | 2 | 23.623670 | 24.967230 | 3 | 60 | 60.573686 |
| 3 | 4 | 2 | 23.501544 | 23.637553 | 3 | 60 | 60.465575 | 1 | 0 | 0 |

여기서, 계획대상 기간 = 40주기, 할인율 = 0.05, 상태등급별 유지보수 활동 비용(무대응 = 0, 상태 1~5에 대한 수리 = 0.5, 8.5, 14.5, 55.5, 58.5, 교환 = 60), 계획대상 기간 때의 상태등급별 잔존가치(상태 1~5 = -0.5, -128, -230, -300, -354)를 임의로 정하고, 유지보수 활동에 따른 상태 전이확률행렬은 식(5)를 실행할 때마다 행렬의 각 항에 랜덤값으로 미세한 조정이 되도록 하였다. 이는 유지보수 활동 결정 전과 후의 차량부품 상태변화 추적을 통해 조정 과정을 거쳤다고 가정하는 것이다. <Table 5>를 구성하는 정보는 Current State = 현시점의 상태등급, Minimum State = 최저 허용 상태, Action = 현시점에서의 최적 유지보수 활동(1=미대응, 2=수리, 3=교환), LCC = 유지보수 활동에 따른 생애 주기비용, Cost = 유지보수 활동에 따른 비용을 나타낸다.

5) 실험 결과

차량 상태기반 진단예측 시스템은 차량부품에 대해 장기간 지속적인 데이터 수집과 부품 상태 진단 및 유지보수 활동(미대응, 수리, 교환)에 따른 전과 후의 상태변화 이력데이터를 확보하고 있어야만 차량부품에 대한 진단, 예측, 유지보수 결정의 정확성을 담보할 수 있다. 본 실험의 한계는 유지보수 활동에 따른 전과 후의 상태변화 이력데이터와 장기간에 걸쳐 수집된 데이터의 부재로 인하여 실험을 위한 일부 데이터를 임의로 정의하고 그것을 실험에 사용한 것이다. 하지만, 실험을 통해 본 연구에서 제시한 상태기반 진단 및 예측에 대한 프레임워크와 방법론으로 배터리 부품에 대한 상태 진단과 확률적 열화모델 추론 및 유지보수 활동 결정을 할 수 있는 가능성을 확인하였다는 점에서 의미가 있었다.

IV. 결 론

본 연구에서는 차량 상태기반 진단예측 시스템 개발을 위해서 차량, 시스템 등 자산 관리 및 유지보수 효율성을 높이기 위한 연구가 활발히 진행되고 있는 CBM 방법론을 적용하였다. 이를 위해 CBM 방법론과 관련 통계분석 알고리즘에 대한 문헌 고찰을 통해 본 시스템에 적용할 절차 및 알고리즘을 선정하였다. 차량의 상태를 파악할 수 있는 데이터를 실시간으로 수집하고 이를 분석하여 최적의 유지보수에 활용할 수 있는 시스템 개발을 위한 방안과 시스템 프레임워크 및 알고리즘을 제시하였다. CBM 방법론을 적용하여 신뢰성이 있는 최적의 차량 유지보수 결과를 도출하기 위해서는 장기간에 걸쳐 수집된 차량의 상태정보와 이를 분석한 결과 정보 등이 관리되고 재활용을 할 수 있어야 가능하다. 이러한 이유로 본 시스템에서는 차량 상태 점검 절차마다 해당 로그를 관리하고 최종 유지보수 결과에 대한 정보를 분석하여 진단 및 예측 과정에서 사용되는 알고리즘 및 데이터를 조정할 수 있도록 하였다.

하이브리드 전기자동차의 배터리 관련 데이터를 이용한 실험을 통해 본 연구에서 제시한 상태기반 진단 및 예측에 대한 프레임워크와 방법론의 적용 타당성을 확보하였지만, 유지보수 활동에 따른 전과 후의 상태변화 이력데이터와 장기간에 걸쳐 수집된 데이터의 부재로 인하여 실험을 위한 일부 데이터를 임의로 정의하고 그것을 실험에 사용하는 한계가 있었다.

향후에는 본 연구의 결과인 차량 상태기반 진단예측 시스템 프레임워크를 기반으로 실제 대중교통 차량의 상태기반 유지보수 방법론과 알고리즘이 적용된 시스템 개발을 진행하고 그 결과를 분석하여 한층 고도화된 시스템 개발이 가능토록 하고자 한다. 더불어 자율주행차의 각종 센서류에 대한 적용도 고려하여 다가오는 자율주행 대중버스 시대에 시민의 안전과 차량의 상태기반 유지보수 체계의 활성화에 조금이나마 기여할 수 있기를 기대한다.

ACKNOWLEDGEMENTS

This research was supported by the Ministry of Land, Infrastructure, and Transport (MOLIT, KOREA)[Project ID : 19TLRP-B146733-02, Project Name : Connected and Automated Public Transport Innovation(National R&D Project)].
본 연구는 국토교통부 교통물류연구사업의 연구비지원(19TLRP-B146733-02)에 의해 수행되었습니다.

REFERENCES

- Andrew K., Jardine S., Daming L. and Dragan B.(2006), "A Review on Machinery Diagnostics and Prognostics Implementing Condition-Based Maintenance," *Mechanical Systems and Signal Processing*, vol. 20, pp.1483-1510.
- Cha K. H., Kim S. W., Kim J. H., Park M. Y. and Kong J. S.(2015), "Development of the Deterioration Models for the Port Structures by the Multiple Regression Analysis and Markov Chain," *J. Comput. Struct. Eng. Inst. Korea*, vol. 28, no. 3, pp.229-239.
- Jun H. B., Dimitris K., Mario G. and Paul X.(2006), "Predictive Algorithm to Determine the Suitable Time to Change Automotive Engine Oil," *Computers & Industrial Engineering*, vol. 51, pp.671-683.
- Kim D. W., Hong S. S. and Han M. M.(2018), "A Study on Classification of Insider Threat Using Markov Chain Model," *KSII Transactions on Internet and Information Systems*, vol. 12, no. 4, pp.1887-1898.
- Lawrence R. R.(1989), "A Tutorial on Hidden Markov Models and Selected Applications in Speech Recognition," *Proceedings of the IEEE*, vol. 77, no. 2. pp.257-286.
- Lim J. K., Kang M. K. and Jang G.(2015), "Methodology of Failure Prediction of Train by BAYESIAN Statistics and Preventive Maintenance by Interworking FRACAS," *Journal of Korean Society for Urban Railway*, vol. 3, no. 2, pp.361-366.
- Palem G. K.(2017), "Designing Condition-Based Maintenance Management Systems for High-Speed Fleet," *International Journal of Computer Science and Business Informatics*, vol. 17, no. 1, pp.28-40.
- Park J. H. and Kim S. G.(2012), "Development of Accident Forecasting Models in Freeway Tunnels Using Multiple Linear Regression Analysis," *J. Korea Inst. Intell. Transp. Syst.*, vol. 11, no. 6, pp.145-154.
- Poongodai A. and Reader S. B.(2013), "AI Technique in Diagnostics and Prognostics," *Proceedings of 2nd National Conference on Future Computing*.
- Shin J. H., Jun H. B. and Kim D. G.(2014), "A Study on Several Aspects of Condition Based Maintenance(CBM) Approach and Introduction of Relevant Case Studies," *Entrue Journal of Information Technology*, vol. 13, no. 3, pp.123-138.
- Thurston M. G.(2001), "An Open Standard for Web-Based Condition-Based Maintenance Systems," *Proceedings from the IEEE System Readiness Technology Conference*, Autotestcon Proceedings 2001 USA, Valley Forge, PA.
- Yeo H. S., Youn Y. J. and Samer M.(2010), "Maintenance Optimization for Heterogeneous Infrastructure Systems: Evolutionary Algorithms for Bottom-Up Methods," *Sustainable & Resilient Critical Infrastructure Sys.*, pp.185-199.