

머신러닝 기법을 이용한 납축전지 열화 예측 모델 개발

최근호

한밭대학교 경영회계학과
(keunho@hanbat.ac.kr)

김건우

한밭대학교 경영회계학과
(gkim@hanbat.ac.kr)

현재 전세계 배터리 시장은 이차전지 개발에 박차를 가하고 있는 실정이지만, 실제로 소비되는 배터리 중 가격 대비 성능이 좋고 재충전을 통해 다시 재사용이 가능한 납축전지(이차전지)의 소비가 광범위하게 이루어지고 있다. 하지만 납축전지는 복잡한 셀(cell)을 묶어 하나의 배터리를 구성하여 활용하는 배터리의 특성상 하나의 셀에서 열화가 발생하면 전체 배터리의 손상을 가져와 열화가 빨리 진행되는 문제가 존재한다. 이를 극복하기 위해 본 연구는 기계학습을 통한 배터리 상태 데이터를 학습하여 배터리 열화를 예측할 수 있는 모델을 개발하고자 한다. 이를 위해 실제 현장에서 배터리 상태를 지속적으로 모니터링 할 수 있는 센서를 골프장 카트에 부착하여 실시간으로 배터리 상태 데이터를 수집하고, 수집한 데이터를 이용하여 기계학습 기법을 적용한 분석을 통해 열화 전조 현상에 대한 예측 모델을 개발하였다. 총 16,883개의 샘플을 분석 데이터로 사용하였으며, 예측 모델을 만들기 위한 알고리즘으로 의사결정나무, 로지스틱, 베이지언, 배깅, 부스팅, RandomForest를 사용하였다. 실험 결과, 의사결정나무를 기본 알고리즘으로 사용한 배깅 모델이 89.3923%이 가장 높은 적중률을 보이는 것으로 나타났다. 본 연구는 날씨와 운전습관 등 배터리 열화에 영향을 줄 수 있는 추가적인 변수들을 고려하지 못했다는 한계점이 있으나, 이는 향후 연구에서 다루고자 한다. 본 연구에서 제안하는 배터리 열화 예측 모델은 배터리 열화의 전조현상을 사전에 예측함으로써 배터리 관리를 효율적으로 수행하고 이에 따른 비용을 획기적으로 줄일 수 있을 것으로 기대한다.

주제어 : 배터리 열화, 납축전지, 열화 예측, 머신러닝, 데이터 마이닝

논문접수일 : 2018년 6월 12일 논문수정일 : 2018년 6월 21일 게재확정일 : 2018년 6월 25일
원고유형 : 일반논문(급행) 교신저자 : 김건우

1. 서론

1.1 연구 배경 및 필요성

납축전지 (Lead-Acid Battery)는 1859년에 프랑스의 Gaston Plante에 의해 개발된 이후, 1890년도의 Flooded형 납축전지의 공업화, 1900년대 초·중반 Sealed형 VRLA(Valve Regulated Lead Acid) 납축전지 등과 같은 다양한 이론적 연구와

기술개발이 진행되어 왔다.

이와 같이 오랜 기간에 걸친 지속적인 기술 발전과 자동차에 적용되어 운용환경에서 지속적인 검증이 수행됨에 따라, 현재에는 자동차용 축전지로 요구되는 많은 특성 및 높은 신뢰도를 만족하는 수준의 제품 안정성을 보유하고 있다.

납축전지는 다른 전지들에 비해 비용 대비 전력효율과 안정성이 매우 우수하여 가장 많이 사용되고 있다. 납축전지의 장점은 수용성 전해질

* 이 논문은 2017년도 한밭대학교 교내학술연구비의 지원을 받았음.

전지들 중 가장 높은 셀 전압을 가지고 있으며, 넓은 온도 범위의 환경에서 우수한 동작 특성을 제공한다. 자동차에 사용되고 있는 납축전지의 실사용 온도는 $-40 \sim 75^{\circ}\text{C}$ 로 매우 넓은 범위에서 운용이 가능하다. 에너지 전환 효율은 약 80%이며 충전된 후 전기에너지 유지 수준이 높다. 납축전지는 재생 비율이 99% 이상으로 자원의 재사용 측면에서 친환경적이라는 장점도 있다. 이런 장점들로 볼 때, 앞으로의 납축전지 시장이 성장을 지속할 것으로 보고 있다.

그러나 최근 각종 편의장치 및 안전장치의 추가와 다양한 전장시스템의 구현으로 차량 내에서 요구되는 전력소모가 점차 증가함에 따라 납축전지는 빈번한 충·방전을 반복하게 되고, 엔진의 발열로 인한 온도 영향, 사용자의 운행 행태 및 운용조건에 따른 악영향 등으로 인해 납축전지의 성능이 저하되고 수명이 단축되는 현상이 발생하고 있다(김성태 외, 2013).

반면, 시장에서는 납축전지에 대한 고수명, 고출력, 고용량, 소형/경량화, 고내열 특성 및 고안정성 등 다양한 특성들을 지속적으로 요구하고 있어, 안정성 및 신뢰성이 높은 납축전지를 개발하는 것과 더불어 개발된 납축전지가 적용하고자 하는 차량 환경에서 지니게 되는 수명과 열화를 명확히 예측할 수 있는 방법이 절실히 요구되고 있다.

이러한 납축전지의 수명 및 열화에 대한 연구는 납축전지 자체에 대한 수명 예측 뿐만 아니라, 사용자가 자동차를 운행하면서 발생할 수 있는 납축전지의 열화 시점을 가늠할 수 있어, 보증기간 이상의 시점까지 적절히 동작하도록 납축전지 및 차량환경을 설계함으로써 기술적 부분과 더불어 상업적인 부분에서의 많은 이점을 지니게 된다.

1.2 연구 목적

본 연구는 배터리 열화 예측 모델을 개발하는 것이 목적이다. 본 연구는 연구의 목적 달성을 위해, 골프장 카트의 배터리(이차 납축전지)를 지속적으로 모니터링하여 배터리 사용 정보와 배터리 열화 정보를 실시간으로 수집하고, 이를 활용하여 배터리 열화 메커니즘을 분석한다. 또한 이를 토대로, 데이터 마이닝(data mining) 기법을 활용하여 배터리 열화 예측 모델을 개발하고자 한다.


본 연구에서 제시되는 배터리 열화 예측 모델은 향후 지능형 배터리 센서 모듈 시스템 장비에 탑재되어 배터리의 상태를 모니터링하여 최적의 조건을 유지하고, 배터리에서 발생하는 문제를 선제적으로 조치함으로써, 효율적인 배터리 관리를 달성하는데 의의가 있다.

2. 문헌연구

2.1 자동차용 납축전지의 전기화학 특성

납축전지는 두 가지의 상이한 전극을 전해액 속에 담귀 각 전극의 활물질과 전해액이 갖는 화학에너지를 변환시키고, 양극과 음극에 연결된 외부 회로를 통해 전극의 변환된 물질을 다시 본래의 물질로 환원시키는 것을 원리로 한다.


<Figure 1>은 납축전지 단면의 개략도이다. 납축전지는 양극의 PbO_2 와 음극의 Pb 가 황산이온과 반응하여 PbSO_4 와 물을 만드는 방전반응을 통해 화학에너지를 전기에너지로 변환한다. 또한 PbSO_4 와 물이 분해되어서 PbO_2 와 Pb 로 환원되는 충전반응을 통해 본래의 방전가능 상태로 복귀한다.




(Figure 1) An outline of a slice of a lead-acid battery(Kim et al., 2013)

다음은 납축전지 내부에서 일어나는 화학반응을 표시한 반응식이다(Kim et al., 2013).


(납축전지 양극에서의 반응)



(납축전지 음극에서의 반응)



(납축전지 전체의 반응)



납축전지를 과도하게 충전하게 되면 가스발생으로 인해 물 부족 현상이 발생하며, 이에 따라 납축전지의 성능저하가 발생할 수 있어 정기적으로 증류수를 보충하는 것에 주의할 필요성이 있다.

이를 고려하여 최근에는 납축전지에 벨브가 추가되고 흡수성 그라스 매트(Absorbent Glass Mat; AGM)나 이산화물 실리콘을 사용한 겔과

같이 전해액을 고체화시켜 어떤 위치에서도 사용이 가능하면서도, 밀폐된 셸드(Sealed) 타입으로 제작되어 가스의 방출을 억제함으로써 유지보수가 필요없는 형태의 VRLA(Valve Regulated Lead Acid) 납축전지가 사용되고 있다. <Figure 2>는 배터리 셀 내부에서의 충전시 화학반응을 나타낸다.

2.2 납축전지 열화와 노화 메커니즘

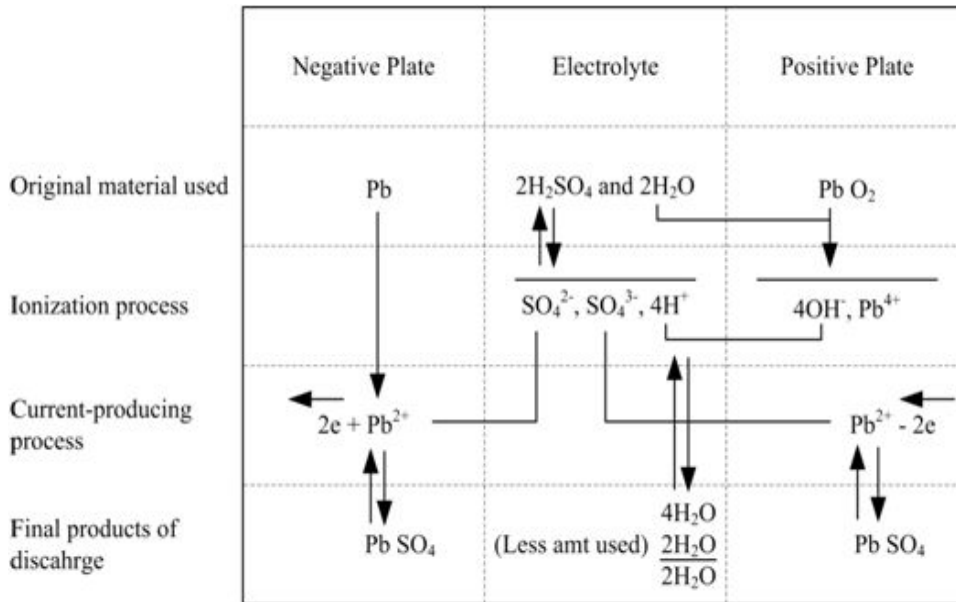
자동차용 납축전지의 열화를 예측하기 위해서는 납축전지 노화 메커니즘과 열화에 영향을 미치는 환경 인자를 살펴볼 필요가 있다.

자동차는 산업용 축전지가 운용되는 환경에 비해 온도 및 습도 환경, 진동 특성 등이 매우 열악하기 때문에, 납축전지의 수명 예측에 있어서도 이러한 가혹한 환경에 대한 검토가 요구된다.

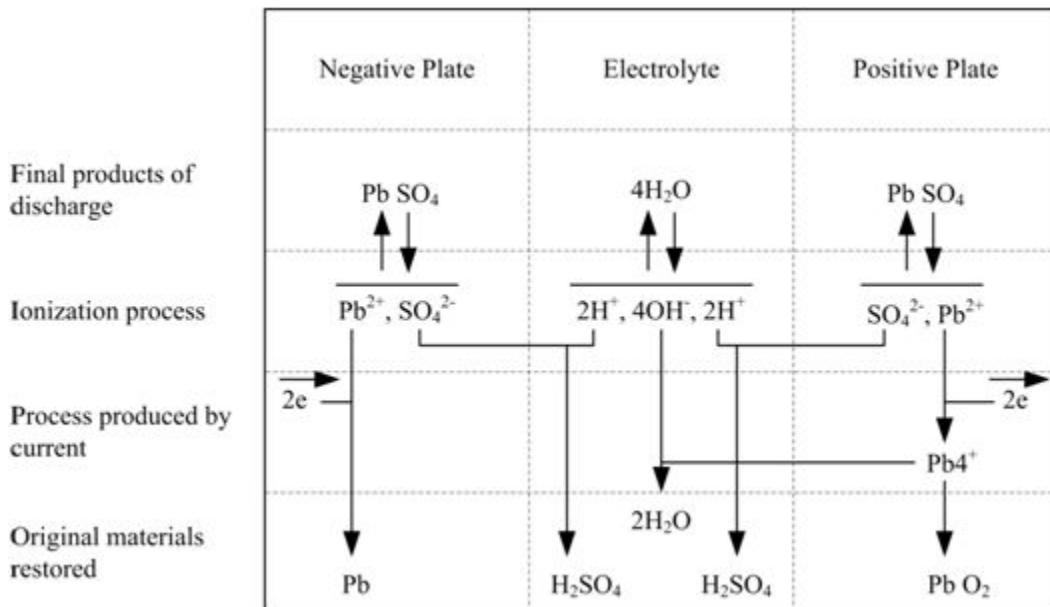
자동차 업체에서는 지속적인 고객관리 및 서비스 측면에서 자동차용 납축전지 수명 종료품에 대한 분석결과를 살펴보면, 재충전시, 성능회복이 가능한 형태의 과방전에 따른 일시적인 성능저하가 많은 부분을 차지하고 있었으나, 이를 제외한 실질적인 납축전지의 수명종료 및 고장 발생은 부식, 활물질 탈락, 감액, 누수 등의 다양한 원인이 존재하고 있는 것으로 보고되고 있다. 특히, 고장 발생의 여러 현상 중, 부식으로 인한 고장발생이 전체 수명종료 제품의 2/3를 차지하고 있어 부식을 야기하는 환경 인자가 자동차용 납축전지의 수명을 저하시키는 주요 원인을 알 수 있다(Lee, 2012).

2.2.1 열화 인자

납축전지의 노화에 영향을 끼치는 요인들은 여러 가지가 있다. 그 중 열화인자(stress factor)



(a) Charge reaction



(b) Discharge reaction

〈Figure 2〉 Chemical reaction when charging and discharging

는 납축전지 운영 조건에 따른 노화 조건을 보다 쉽게 규명할 수 있다(Kim et al., 2013). 그 예로는 방전율, 충전의 시간, 완전충전 시간 그리고 납축전지의 온도를 이용하여 배터리의 잔존 수명을 시간으로 정량적으로 나타낼 수 있다.

2.2.2 납축전지 노화 메커니즘

납축전지의 노화 메커니즘은 납축전지가 수명의 영향을 미치는 화학적, 기계적 거동이다. 이러한 거동 들은 퇴화의 긴 시간을 통한 반응이나 짧은 시간 내에 큰 변화를 갖는 반응으로 발생하며 때로는 두 가지 반응이 동시에 노화를 일으키기도 한다. 여기서는 잘 알려져 있지만 완벽하게 규명되지 않은 납축전지에 관한 노화 메커니즘을 다음과 같이 정리하였다(Kim, 2016).

(1) 양극 기관 부식(Corrosion of the positive grid)

양극에서 산화작용은 Pb 를 PbO 와 PbO_2 로 변형시킨다. 낮은 전도를 갖는 얇은 막은 배터리 노화가 진행되면서 양극 주위에서 생성된다. 이 낮은 전도를 갖는 얇은 막은 막의 두께가 증가할수록 전기적 저항을 증가시키고, 또한 이 막은 배터리 내의 기계적인 스트레스를 발생시킨다. 축전지는 내부 저항이 증가함에 따라 용량 감소가 일어난다. 부식에 영향을 끼치는 주요 인자 3가지는 배터리 전압, 산의 농도 그리고 온도가 있다.

(2) 비가역적인 황산 결정화 (Hard/irreversible sulphation)

황산 결정은 방전전체에서 양극과 음극 두 곳에서 형성된다. 지속적인 충·방전 중에 충전 시에 황산이 결정화된다. 납 황산 결정은 시간이

지남에 따라서 좀 더 큰 결정화된다. 이 결정화는 납축전지의 거동을 어렵게 만든다.

(3) 양극 활물질 탈락(Shedding)

탈락(Shedding) 부식과 활성 물질 퇴화의 결과로 인한 기계적인 스트레스는 축전지 구조로부터 활물질의 결합을 탈락시킨다. 이 공정을 탈락이라고 하며 그 결과는 활성물질의 감소이다. 그 예로 과충전은 활물질을 탈락시킨다.

(4) 수분 감소(Water loss / drying out)

축전지가 높은 SOC로 충전될 때 전해질 안의 물은 수소와 산소는 빠져나간다. 축전지의 케이스를 빠져나갈 수 있다. 일반적인 납축전지는 극판의 위 부분들은 활물질들의 건조를 일으킬 수 있고 영구히 배터리에 손상을 준다. 포장된 납축전지가 수분을 잃어 버리면 이용할 수 있는 전해질을 감소시키게 되어 배터리의 가용용량을 감소하게 만든다.

(5) 양극 활물질 퇴화(Active materials degradation)

노화는 충·방전 중에 생기는 활물질의 감소이다. 극판의 기계적으로 인한 구조 변화는 다공도 감소시키고, 이온이 거동할 수 있는 표면적 감소로 이어지고, 면적 감소는 화학 반응에 영향을 끼치고 전해질 확산을 감소시킨다. 이러한 현상은 축전지의 충전 효율을 떨어뜨린다. 반복되는 충·방전 사이클에 의해서 활물질은 결정화되고, 결국 극판에서 탈락된다.

(6) 전해질 층화(Electrolyte stratification)

전해질 층화는 직접적으로 노화를 시키지 않지만, 부식이나 용량감소를 촉진하게 된다. 충전

지의 충·방전이 일어나는 화학 공정 동안 전해질의 농도는 오르내린다. 비중은 다른 전해질의 농도에 영향을 끼친다. 더 높은 밀도의 전해질은 바닥으로 내려앉고 전해질 구배가 생기게 된다. 배터리의 과충전으로 인하여 전해질과 섞이는 기포가 형성되고 충화를 일으킨다.

2.3 납축전지 열화 관련 선행연구 검토

많은 선행연구들에서는 납축전지의 열화(degradation) 메커니즘을 규명하기 위해 많은 연구가 진행되어 왔다.

관련된 연구들을 살펴보면, 생산자의 입장에서 납축전지 품질 향상을 목표로 진행한 연구들이 주를 이루고 있다. 기존 연구들은 납축전지의 열화 뿐만 아니라, 납축전지의 신뢰성 평가, 납축전지 고장예지 및 건전성 평가, 납축전지의 잔존 수명 예측 등 열화와 관련성이 깊고, 유사한 맥락의 주제들로 연구되어 왔다.

기존 연구의 방법론은 크게 신뢰성 접근 방법, 전기적 특성 접근 방법, 화학적 특성 접근 방법으로 분류된다.

2.3.1 신뢰성 접근 방법

기존의 신뢰성 접근 방법의 방향은 납축전지의 고장모드와 고장 메커니즘을 파악하거나, 배터리의 수명을 연장시키기 위함이었다. 이러한 연구의 진행은 납축전지 생산자의 입장을 고려하는 취지로 적용된 것으로 배터리의 품질 향상과 관련이 있었다.

반면, 운전자가 실제로 자동차를 운영하면서 배터리의 상태를 알 수가 없어서 정비 시점을 지나치는 경우가 발생하고 이는 배터리 고장으로 인한 자동차 운영 불능 상태에 직면하게 된다.

이러한 문제를 해결하고자 자동차 기업에서는 소비자 입장에서의 배터리 신뢰성 연구를 진행하는 추세이고, 이와 관련된 신뢰성 연구 분야가 바로 고장예지 및 건전성 평가(Prognostics and Health Management; PHM) 기법이다.

PHM이란 지속적인 모니터링을 통해 얻은 실제 조건의 데이터로부터 제품의 잔존수명을 미리 예보하는 기술이다(Vichare & Pecht, 2006). PHM은 대상의 유지보수 전략이 용이해지고 치명적인 고장에 대하여 미연에 방지할 수 있어 최근 다양한 산업분야에서 각광받는 추세이다. 센서 기술력이 미흡했던 과거에는 비행기나 탱크, 헬리콥터, 플랜트와 같이 고가의 시스템에 적용하여 진행한 반면, 최근에는 센서의 가격과 크기가 감소하면서 자동차 및 전기자동차, 풍력발전기와 같은 분야에도 적용되는 추세이다.

PHM과 관련한 대표적인 연구로는 Culpin & Rand(1991), Gu et al.(1987), Wenzl et al.(2005), Sauer et al.(2007), Thele et al.(2007) 등이 있으며, 이들 연구들을 살펴보면, Gu et al.(1987)은 납축전지의 수명 모델링에 운영 조건, 시스템 크기 및 배터리 기술의 영향 등과 같은 요인들을 추가하여 연구하였고, Wenzl et al.(2005)은 납축전지 열화를 예측할 때 필요한 요인들을 정리하였다. 또한 Sauer et al.(2007)은 납축전지의 다양한 충전 조건이 효율적인 운영과 열화에 미치는 영향을 다양한 관점으로 연구하였으며, Thele et al.(2007)은 전기화학 모델링을 통하여 과충전이 납축전지 수명에 미치는 영향을 연구하였다. 이 뿐만 아니라, 납축전지의 열화 메커니즘에 대한 분석과 납축전지 잔존수명에 대한 연구도 있다. 대표적 연구로는 Rüetschi(1992)와 Rüetschi(2004)가 있다. 이들 연구에서는 납축전지 양극에서 발생하는 결정화 반응과 극판의 활

물질이 접촉하였을 때 납축전지의 용량에 미치는 연구를 진행하였으며, 납축전지의 열화 메커니즘과 수명에 관하여 정리하였다.

2.3.2 전기적 특성 접근 방법

전기적 특성 접근 연구는 납축전지의 열화 과정에서 발생하는 임피던스의 변화를 분석하여 납축전지의 상태를 파악하는 연구이다.

대표적 연구로는 Huet(1998)와 Rodrigues et al.(2000)가 있다. 또한 Singh & Reisner(2002) 연구에서는 UPS(Uninterruptible Power Supply)에 사용되는 납축전지의 건강상태를 파악하기 위하여 임피던스를 측정하고, 이를 퍼지 로직(fuzzy logic)에 적용하였다.

2.3.3 화학적 특성 접근 방법

화학적 특성 접근 방법에 대한 연구들을 살펴보면, 배터리의 기본 구조는 화학적 반응을 통하여 전기 에너지를 발생시키는 것이기 때문에, 배터리의 전기 발생 메커니즘 자체에 초점을 두었다.

Lander(1956)은 납축전지의 부식 반응을 총·방전 결과에 근거하여 열 역학적으로 규명하였으며, Armenta-Deu & Donaire(1996)는 납축전지에 관한 열화 요소 중 전기화학 반응이 미치는 영향에 관하여 연구하였다. 또한 Shiomu et al.(1997)은 납축전지 내부에 사용되는 음극판에 탄소 함유량을 상승시키면 음극판에 달라 붙는 황산납이 감소하게 되어 납축전지의 수명을 증가시킬 수 있다는 연구를 하였고, Lehockey et al.(1998)은 납축전지 음극판이 부식으로 받는 손상 정도를 파악하고, 이를 해결하기 위한 연구를 진행하였다.

3. 연구 방법

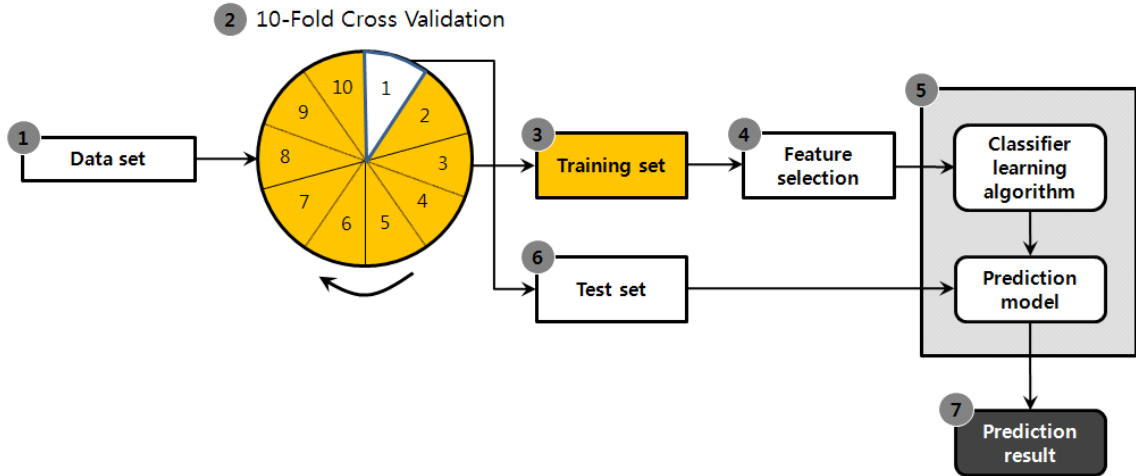
3.1 배터리 열화 예측 프레임워크

2장에서 언급한 배터리 열화 예측 관련 선행 연구들은 주로 열화 메커니즘을 규명하기 위한 연구들이 많았다. 본 연구에서와 같이 데이터를 이용하여 열화 예측을 시도한 연구들은 그리 많지 않았으며, 이를 시도한 연구들도 대부분 실험실 환경에서 얻어진 데이터를 분석하여 수행되었다. 하지만, 본 연구에서는 이들 선행연구들과 달리 실제 운영 중인 골프장 카드에 센서를 부착하여 얻은 데이터를 분석하여 보다 현실적인 배터리 열화 예측 모델을 개발하고자 한다.

본 연구는 이를 위해 <Figure 3>과 같은 프레임워크를 제안한다. 배터리 열화 예측 프레임워크는 다음과 같은 과정을 갖는다.

① 우선, 골프장 카드에 부착된 센서로부터 데이터를 수집하고, 전처리 작업을 수행하여 분석용 데이터 셋을 구축한다.

② 구축된 데이터 셋을 10-Fold Cross Validation을 한다. 10-Fold Cross Validation은 초기의 데이터 셋을 무작위로, 크기가 비슷한 10개의 데이터 셋으로 나누어 측정하는 방법이다. 따라서, 데이터 셋이 {1, 2, 3, ..., 8, 9, 10}의 10개 데이터 셋이 생성된다. 생성된 데이터 셋을 {1}과 {2, 3, 4, ..., 8, 9, 10}으로 구분하여, {2, 3, 4, ..., 8, 9, 10}의 9개 데이터 셋은 훈련 셋(training set)으로 사용하고, 나머지 {1} 데이터 셋은 테스트 셋(test set)으로 사용한다. 그 다음은 {1, 3, 4, ..., 8, 9, 10}을 훈련셋으로 하고, 나머지 {2} 데이터 셋을 테스트셋으로 사용한다. 이러한 방식으로 10번까지 진행을 하는 것이다. 다시 말해, 하나만 테스트 셋으로 선정하고, 나머지 전체를



<Figure 3> Research Framework

훈련 셋으로 사용하는 ‘하나 빼기(leave-one-out)’ 방식으로 진행되는 측정을 말한다. 이렇게 10개의 데이터 셋에서 10개의 예측 모델이 만들어지고, 그 결과로 10개의 예측 결과가 생성된다. 10-Fold Cross Validation은 이 결과들의 평균값을 최종적으로 택하게 된다.

본 연구에서 10-Fold Cross Validation을 택한 이유는 우선, 절차의 결정성(deterministic)을 띄어 무작위 표본 추출(randomization)을 하지 않아도 되는 면이 있고, 교차된 검증을 통해 예측 모델의 강건성(robustness), 확장성(scalability) 그리고 예측 정확성(accuracy)의 향상을 기대할 수 있기 때문이다.

③ 10-Fold Cross Validation을 통해 10개 데이터 셋에서 1개는 테스트 셋으로 사용되고, 나머지 9개는 훈련 셋으로 사용된다.

④ 배터리 열화 예측 모델을 만들기 위한 변수를 선택을 한다.

⑤ 분류 학습 알고리즘(classifier learning algorithm)을 통해 배터리 열화 예측 모델을 만

든다.

⑥ 예측 모델의 타당성 검증을 위해, 훈련 셋으로부터 만들어진 배터리 열화 예측 모델을 테스트 셋으로 검증한다.

⑦ 마지막으로, 예측 결과를 얻는다.


3.2 변수의 정의

본 연구에서는 배터리 열화 예측 모델을 개발하기 위해 배터리 열화와 관련한 선행연구들을 검토하였으며, 이러한 검토를 통해 <Table 1>의 변수들을 초기 독립변수로 사용하였다. 이 중, 주요 독립변수가 배터리 열화에 어떠한 방식으로 영향을 미치는 지에 대해 살펴보면 다음과 같다. 충전효율의 경우, 충전효율이 85%면 만충을 의미하며, 85% 초과는 충전부족, 85% 미만은 과충전을 의미한다. 만약 충전이 부족하면 더 빨리 최저전압에 도달하게 된다. 운행 중 배터리 최저 온도의 경우, 최저 전압 기록 시 주변 온도로서 온도가 영하로 내려가면 배터리 성능이 일시적

(Table 1) Initial Independent Variables

Variable		Description
Ao_inDateTime		Inbound time of a cart
Ao_outDateTime		Outbound time of a cart
Duration		From outbound time to charge time (Min)
CharAh		Charge amount (AH)
UsedAh		Used amount (AH)
Percent		Charge efficiency (%)
BatteryTemp 1~6	BatteryTemp1	Lowest temperature of battery 1 during operation
	BatteryTemp2	Lowest temperature of battery 2 during operation
	BatteryTemp3	Lowest temperature of battery 3 during operation
	BatteryTemp4	Lowest temperature of battery 4 during operation
	BatteryTemp5	Lowest temperature of battery 5 during operation
	BatteryTemp6	Lowest temperature of battery 6 during operation
MinV1~6	MinV1	Lowest voltage of battery 1 during operation
	MinV2	Lowest voltage of battery 2 during operation
	MinV3	Lowest voltage of battery 3 during operation
	MinV4	Lowest voltage of battery 4 during operation
	MinV5	Lowest voltage of battery 5 during operation
	MinV6	Lowest voltage of battery 6 during operation
MaxV1~6	MaxV1	Highest voltage of battery 1 during operation
	MaxV2	Highest voltage of battery 2 during operation
	MaxV3	Highest voltage of battery 3 during operation
	MaxV4	Highest voltage of battery 4 during operation
	MaxV5	Highest voltage of battery 5 during operation
	MaxV6	Highest voltage of battery 6 during operation
StartV1~6	StartV1	Voltage of battery 1 at the beginning of operation
	StartV2	Voltage of battery 2 at the beginning of operation
	StartV3	Voltage of battery 3 at the beginning of operation
	StartV4	Voltage of battery 4 at the beginning of operation
	StartV5	Voltage of battery 5 at the beginning of operation
	StartV6	Voltage of battery 6 at the beginning of operation
EndV1~6	EndV1	Voltage of battery 1 at the end of charge
	EndV2	Voltage of battery 2 at the end of charge
	EndV3	Voltage of battery 3 at the end of charge
	EndV4	Voltage of battery 4 at the end of charge
	EndV5	Voltage of battery 5 at the end of charge
	EndV6	Voltage of battery 6 at the end of charge
Wh1~6	Wh1	Used amount of battery 1 during operation (WH)
	Wh2	Used amount of battery 2 during operation (WH)
	Wh3	Used amount of battery 3 during operation (WH)
	Wh4	Used amount of battery 4 during operation (WH)
	Wh5	Used amount of battery 5 during operation (WH)
	Wh6	Used amount of battery 6 during operation (WH)
Max_Min		Used amount of battery during operation (WH) (Max-Min)
RealDuration		Duration of battery use (Min)
MaxA		Highest current during operation (A)
Degradation		Whether batter is degraded(1) or not(0)

으로 떨어지게 된다. 운행 중 배터리 최저 전압의 경우, 배터리의 상태가 나쁠수록 최저 전압이 낮게 나타나게 된다. 운행 중 배터리 최고 전압의 경우, 배터리의 상태가 나쁠수록 최고 전압이 높게 나타나게 된다. 운행 시 사용량(최고-최저)의 경우, 6개의 배터리 중 최고-최저의 Wh 차이 값으로 배터리 열화 증상으로 편차가 더 커지게 된다. 마지막으로 운행 중 최대 전류의 경우, 차량 고장시 전류값이 비정상적으로 치솟는 현상을 보인다.



〈Figure 4〉 Data Collection Framework

3.3 데이터

본 연구는 배터리 전문 회사의 xBMS 시스템에서 DCS(Data-Carrier System)가 수집한 데이터를 사용한다. 본 연구에서 수집된 데이터는 XBMS 시스템의 프로세스를 통해 얻어졌으며, 데이터 수집 프로세스는 다음과 같다(〈Figure 4〉 참조).

- ① DCS는 카트 내부에 설치되어 있어 전압, 전류, 온도를 수집한다.
- ② 골프 카트가 운행을 마치고 충전기를 꼽으면 DCS가 전류를 감지하여 수집한 배터리 정보를 Network Adaptor로 무선으로 전송한다.
- ③ 인터넷이 연결된 Network Adaptor에서 그 레포트를 받아서 Communication Server로 전송한다.
- ④ Communication Server는 TCP/IP, 80 Port를 이용해 레포트를 항상 수신대기 하다가 레포트를 수신하여 DB에 저장한다.
- ⑤ End User는 웹 브라우저를 이용하여 〈Figure 5〉와 같이 웹사이트 형태로 배터리 정보를 수신한다.



〈Figure 5〉 End User's Web Page

본 연구에서는 위와 같은 과정을 통해 70대의 골프장 카트를 대상으로 데이터를 수집하였고, 1대의 카트에는 6개의 배터리가 들어있어, 총 420개의 배터리 데이터를 수집하였다. 본 연구에서는 배터리 관찰기간이 약 9개월 정도이며, 1대당 약 250개 정도의 정보가 담겨있다.

따라서, 본 연구는 데이터 전처리 과정을 거쳐, 데이터 분석을 위한 배터리 표본 16,883개를 수집하였다.

4. 실험 설계 및 결과

4.1 표본의 특성

본 연구에서 사용한 데이터의 총 표본 수는 16,883개이고, 정상 클래스는 11,807개(69.9%), 열화 클래스는 5,076개(30.1%)이다.

본 연구에서는 배터리 열화에 대한 학습을 많이 시켜, 배터리 열화에 대한 예측 정확성을 높이기 위해 전체 표본 중 각 카트별로 열화 빈도수가 30%가 넘는 카트들을 대상으로 분석용 데이터 셋을 만들었다. 그 결과, 최종 분석용 데이터 셋의 총 표본 수는 7240개였으며, 정상 클래스는 3191개(44.1%), 열화 클래스는 4049개(55.9%)로 나타났다.

4.2 차원 축소 및 변수 선택

본 연구에서 사용된 BatteryTemp1~6(운행 중 최저온도 배터리1~6), MinV1~V6(운행 중 최저 전압 배터리1~6), MaxV1~V6(운행 중 최고 전압 배터리1~6), StartV1~V6(운행 시작시 전압 배터리1~6), EndV1~V6(충전 종료 직전 전압 배터리1~6), Wh1~6(운행 시 사용량 배터리1~6) 변수들은 배터리 셀1~셀6까지의 변수값을 의미한다.

배터리 셀에 대한 변수 값들을 보면 거의 비슷한 양상을 보이고 있다. 이는 향후, 배터리 예측 모델 개발시에 독립변수 서로 간의 상관성이 높아 데이터 분석시에 결과의 편의(bias) 줄 수 있다. 다시 말해, 다중공선성(multiple collinearity)

문제가 우려될 수 있다. 또한 배터리 열화 예측 모델의 스피드를 향상시키기 위해서도 차원감소가 필요하다.

따라서, 본 연구는 차원축소를 위해 베리맥스 직각회전(Verimax orthogonal rotation)을 활용한 주성분 분석(principal component analysis)을 실시하였다. 또한 고유값(eigenvalue) 1 이상의 요인을 추출하였다.

본 연구는 이상의 주성분 분석 결과를 토대로, 앞의 6개 변수의 평균값을 새로운 변수로 만들었다. 새롭게 만들어진 변수들은 BatteryTemp_mean(운행 중 최저 온도 평균), Min_mean(운행 중 최저 전압 평균), Max_mean(운행 중 최고 전압 평균), Start_mean(운행 시작시 전압 평균), End_mean(충전 종료 직전 전압 평균), Wh_mean(운행시 사용량 평균)이다.

또한 이 변수들에 대한 신뢰성 분석 결과, Cronbach의 알파값이 모두 0.9 이상으로 나와 신뢰성도 확보된 것을 볼 수 있다(<Table 2> 참조).

본 연구는 새롭게 만들어진 BatteryTemp_mean(운행 중 최저 온도 평균), Min_mean(운행 중 최저 전압 평균), Max_mean(운행 중 최고 전압 평균), Start_mean(운행 시작시 전압 평균), End_mean(충전 종료 직전 전압 평균), Wh_mean(운행시 사용량 평균)의 6개 변수를 기존 변수들에 추가하여 배터리 열화 예측 모델 개발을 위한 최종 13개의 독립변수를 <Table 3>과 같이 구성하였다.

〈Table 2〉 Dimension Reduction using Principal Component Analysis

Variable	Description	Cronbach's α
BatteryTemp1	Lowest temperature of battery 1 during operation	0.99
BatteryTemp2	Lowest temperature of battery 2 during operation	
BatteryTemp3	Lowest temperature of battery 3 during operation	
BatteryTemp4	Lowest temperature of battery 4 during operation	
BatteryTemp5	Lowest temperature of battery 5 during operation	
BatteryTemp6	Lowest temperature of battery 6 during operation	
MinV1	Lowest voltage of battery 1 during operation	0.955
MinV2	Lowest voltage of battery 2 during operation	
MinV3	Lowest voltage of battery 3 during operation	
MinV4	Lowest voltage of battery 4 during operation	
MinV5	Lowest voltage of battery 5 during operation	
MinV6	Lowest voltage of battery 6 during operation	
MaxV1	Highest voltage of battery 1 during operation	0.987
MaxV2	Highest voltage of battery 2 during operation	
MaxV3	Highest voltage of battery 3 during operation	
MaxV4	Highest voltage of battery 4 during operation	
MaxV5	Highest voltage of battery 5 during operation	
MaxV6	Highest voltage of battery 6 during operation	
StartV1	Voltage of battery 1 at the beginning of operation	0.978
StartV2	Voltage of battery 2 at the beginning of operation	
StartV3	Voltage of battery 3 at the beginning of operation	
StartV4	Voltage of battery 4 at the beginning of operation	
StartV5	Voltage of battery 5 at the beginning of operation	
StartV6	Voltage of battery 6 at the beginning of operation	
EndV1	Voltage of battery 1 at the end of charge	0.992
EndV2	Voltage of battery 2 at the end of charge	
EndV3	Voltage of battery 3 at the end of charge	
EndV4	Voltage of battery 4 at the end of charge	
EndV5	Voltage of battery 5 at the end of charge	
EndV6	Voltage of battery 6 at the end of charge	
Wh1	Used amount of battery 1 during operation	0.99
Wh2	Used amount of battery 2 during operation (WH)	
Wh3	Used amount of battery 3 during operation (WH)	
Wh4	Used amount of battery 4 during operation (WH)	
Wh5	Used amount of battery 5 during operation (WH)	
Wh6	Used amount of battery 6 during operation (WH)	

주 1) 요인추출은 주성분 분석을 하였고, 베리맥스 회전을 함
 2) ***는 유의수준 0.01 이내

〈Table 3〉 Final Independent Variables

	Variable	Description
Independent Variable	Duration	From outbound time to charge time (Min)
	CharAh	Charge amount (AH)
	UsedAh	Used amount (AH)
	Percent	Charge efficiency (%)
	BatteryTemp_mean	Lowest temperature of battery during operation (mean)
	Min_mean	Lowest voltage of battery during operation (mean)
	Max_mean	Highest voltage of battery during operation (mean)
	Start_mean	Voltage of battery at the beginning of operation (mean)
	End_mean	Voltage of battery at the end of charge (mean)
	Wh_mean	Used amount of battery I during operation (mean)
	Max_Min	Used amount of battery during operation (WH) (Max-Min)
	RealDuration	Duration of battery use (Min)
Target Variable	MaxA	Highest current during operation (A)
	Degradation	Whether batter is degraded(1) or not(0)

4.3 분류 알고리즘

배터리 열화 예측 모델에 대한 선행연구 (Anton et al., 2013; Chen et al., 2011; Junping, 2006; Kang, 2014; Morita et al., 2006; Shen, 2007; Weigert, 2011)들을 살펴보면, 통계적 방법과 함께 귀납적 알고리즘(induction algorithm) 기반인 데이터마이닝(datamining) 기법을 활용하여, 배터리 예측 모델을 개발해왔다.

데이터마이닝은 1980년대 이후, 인공지능과 함께 폭발적으로 성장해 왔으며 또한 모델의 예측률을 향상시키기 위한 연구(예: 앙상블 또는 하이브리드 모델 등)가 지속적으로 진행되어져 왔다. 단일 분류자 알고리즘은 모델의 단순성(simple), 해석력(interpretability) 등의 장점이 존재하나, 데이터의 따라, 모델의 강건성(robustness) 및 확장성(scalability)가 떨어지는 경우가 있다. 이러한 경우, 모델의 예측 성과에 부(-)의 영향을 미치게 된다. 그러나 앙상블

(ensemble) 또는 하이브리드(hybrid) 모델의 경우, 여러 가지 다양한 모델의 조합을 통해 바이어스(bias)를 줄임으로써, 좀 더 개선된 예측 성과를 얻을 수 있다.

본 연구는 단일 분류자 알고리즘부터 앙상블 기법 순으로 실험을 하였으며, 단일 분류자 알고리즘으로는 의사결정나무(decision tree), 로지스틱(logistics), 베이저언 네트워크(bayesian network)를 사용하였고, 앙상블 기법으로는 부스팅(boosting), 배깅(bagging), RandomForest를 사용하였다. 부스팅과 배깅의 경우 단일 분류자 알고리즘으로 사용한 의사결정나무, 로지스틱, 베이저언 네트워크를 베이스 분류 모델로 사용하였다.

4.4 분석 툴

본 연구에서는 데이터 마이닝 분석 툴로 많은 연구들에서 널리 사용되고 있는 WEKA(Waikato Environment for Knowledge Analysis) v.3.8.0을

활용하였으며, 모델의 테스트 모드로는 10-fold cross-validation을 하였다.

알고리즘을 사용하여 개발한 배터리 열화 예측 모델의 예측 결과는 각각 <Table 4>, <Table 5>, <Table 6>과 같다.

4.5 실험 결과

4.5.1 단일 분류자 알고리즘을 이용한 예측 결과

의사결정나무, 로지스틱, 베이지언 네트워크

우선, 의사결정나무 알고리즘의 경우, 적중률 (Hit ratio)은 87.0304%로 나타났고 AUC는 0.884로 나타났다. 정상 클래스의 precision, recall, F1-Measure는 각각 0.863, 0.839, 0.851로 나타났

<Table 4> The Results of Prediction Model Using Decision Tree

Decision Tree				
Total Samples	7,240		Confusion Matrix	
Hit ratio	87.0304	6,301개		Normal
	Normal	Degrade		
Precision	0.863	0.876	Normal	2,678
Recall	0.839	0.895		
F-Measure	0.851	0.885	Degrade	426
AUC	0.884			

<Table 5> The Results of Prediction Model Using Logistic

Logistic				
Total Samples	7,240		Confusion Matrix	
Hit ratio	68.7569	4978개		Normal
	Normal	Degrade		
Precision	0.666	0.701	Normal	1,861
Recall	0.583	0.770		
F-Measure	0.622	0.734	Degrade	932
AUC	0.742			

<Table 6> The Results of Prediction Model Using Bayesian Network

Bayesian Network				
Total Samples	7,240		Confusion Matrix	
Accuracy	77.4448	5607개		Normal
	Normal	Degrade		
Precision	0.779	0.771	Normal	2,174
Recall	0.681	0.848		
F-Measure	0.727	0.808	Degrade	616
AUC	0.857			

고, 열화 클래스의 precision, recall, F1-Measure는 각각 0.876, 0.895, 0.885로 나타나 높은 예측 정확성을 보였다. 특히, 정상 클래스와 열화 클래스를 모두 균형적으로 잘 예측하는 것으로 나타났다.

로지스틱 알고리즘의 경우, 적중률(Hit ratio)은 68.7569%로 나타났고 AUC는 0.742로 나타났다. 정상 클래스의 precision, recall, F1-Measure는 각각 0.666, 0.583, 0.622로 나타났고, 열화 클래스의 precision, recall, F1-Measure는 각각 0.701, 0.770, 0.734로 나타났다. 앞서 수행한 의사결정나무 알고리즘보다 예측 정확성이 떨어지는 것으로 나타났다. 또한, 의사결정나무 알고리즘과는 달리 정상 클래스와 열화 클래스를 균형적으로 잘 예측하지 못하고, 정상 클래스의 예측 정확성이 상대적으로 떨어지는 것으로 나타났다.

베이지언 네트워크의 경우, 적중률(Hit ratio)은 77.4448%로 나타났고 AUC는 0.857로 나타났다. 정상 클래스의 precision, recall, F1-Measure는 각각 0.779, 0.681, 0.727로 나타났고, 열화 클래스의 precision, recall, F1-Measure는 각각 0.771, 0.848, 0.808로 나타나 로지스틱과 마찬가지로 앞서 수행한 의사결정나무 알고리즘보다 예측 정확성이 떨어지는 것으로 나타났다. 로지스틱 알고리즘의 경우처럼 정상 클래스와 열화 클래스 각각의 예측 정확성이 많은 차이를 보이는 것은 아니지만, 상대적으로 정상 클래스에 대한 예측 정확성이 떨어지는 것으로 나타났다. 특히, recall의 경우 더 두드러지게 나타났다.

4.5.2 앙상블 기법(Ensemble Method)

본 연구는 앞서 수행한 단일 분류자 알고리즘 모델뿐만 아니라, 앙상블 기법인 부스팅, 배깅,

Random Forests를 활용하여 배터리 열화 예측 모델을 개발하였는데, 그 결과는 <Table 7>, <Table 8>, <Table 9>와 같다.

부스팅 기법을 활용해 만든 배터리 예측 모델의 결과를 살펴보면, 의사결정나무 알고리즘을 베이스 모델로 사용한 경우, 적중률이 89.2541%로 나타났고 AUC는 0.956으로 나타났다. 정상 클래스의 precision, recall, F1-Measure는 각각 0.890, 0.863, 0.876으로 나타났고, 열화 클래스의 precision, recall, F1-Measure는 각각 0.895, 0.916, 0.905로 나타나 높은 예측 정확성을 보였다. 또한, 의사결정나무 알고리즘을 단일 분류자로 사용했을 경우에 비해 적중률은 약 2.2%p 높아졌다. 정상 클래스와 열화 클래스 각각의 예측 정확성도 모두 균형적으로 높게 나타났다.

로지스틱 알고리즘을 베이스 모델로 사용한 경우, 적중률이 68.7569%로 나타났고 AUC는 0.692로 나타났다. 정상 클래스의 precision, recall, F1-Measure는 각각 0.666, 0.583, 0.622로 나타났고, 열화 클래스의 precision, recall, F1-Measure는 각각 0.701, 0.770, 0.734로 나타나 의사결정나무 알고리즘을 베이스 모델로 사용한 경우에 비해 예측 정확성이 떨어지는 것으로 나타났다. 또한, 로지스틱 알고리즘을 단일 분류자로 사용했을 경우와 동일한 적중률을 보이는 것으로 나타났다.

베이지언 네트워크 알고리즘을 베이스 모델로 사용한 경우, 적중률이 79.7514%로 나타났고 AUC는 0.887로 나타났다. 정상 클래스의 precision, recall, F1-Measure는 각각 0.788, 0.740, 0.768로 나타났고, 열화 클래스의 precision, recall, F1-Measure는 각각 0.805, 0.843, 0.823로 나타나 의사결정나무 알고리즘을 베이스 모델로 사용한 경우에 비해 예측 정확성이 떨어지는 것

〈Table 7〉 The Results of Prediction Model Using Boosting

Boosting						
	Decision Tree		Logistic		Bayesian Network	
Accuracy	89.2541	6,462	68.7569	4,978	79.7514	5,774
	Normal	Degrade	Normal	Degrade	Normal	Degrade
Precision	0.890	0.895	0.666	0.701	0.788	0.805
Recall	0.863	0.916	0.583	0.770	0.740	0.843
F-Measure	0.876	0.905	0.622	0.734	0.763	0.823
AUC	0.956		0.692		0.887	

〈Table 8〉 The Results of Prediction Model Using Bagging

Bagging						
	Decision Tree		Logistic		Bayesian Network	
Accuracy	89.3923	6,472	68.895	4,988	78.0249	5,649
	Normal	Degrade	Normal	Degrade	Normal	Degrade
Precision	0.893	0.895	0.668	0.702	0.789	0.775
Recall	0.863	0.918	0.586	0.770	0.684	0.856
F-Measure	0.878	0.906	0.624	0.735	0.733	0.813
AUC	0.958		0.745		0.862	

〈Table 9〉 The Results of Prediction Model Using RandomForest

RandomForest		
Accuracy	88.3702	6,398
	Normal	Degrade
Precision	0.900	0.872
Recall	0.828	0.928
F-Measure	0.863	0.899
AUC	0.956	

으로 나타났다. 하지만, 로지스틱 알고리즘과는 달리, 베이지안 네트워크 알고리즘을 단일 분류자로 사용했을 경우에 비해 적중률은 약 2.3%p 높아졌다.

배깅 기법을 활용해 만든 배터리 예측 모델의 결과를 살펴보면, 의사결정나무 알고리즘을 베

이스 모델로 사용한 경우, 적중률이 89.3923%로 나타났고 AUC는 0.958으로 나타났다. 정상 클래스의 precision, recall, F1-Measure는 각각 0.893, 0.863, 0.878로 나타났고, 열화 클래스의 precision, recall, F1-Measure는 각각 0.895, 0.918, 0.906으로 나타나 높은 예측 정확성을 보였다.

또한, 의사결정나무 알고리즘을 단일 분류자로 사용했을 경우에 비해서는 적중률이 약 2.4%p, 부스팅을 활용할 경우에 비해서는 적중률이 약 0.1% 높아졌다. 정상 클래스와 열화 클래스 각각의 예측 정확성도 모두 균형적으로 높게 나타났다.

로지스틱 알고리즘을 베이스 모델로 사용한 경우, 적중률이 68.895%로 나타났고 AUC는 0.745로 나타났다. 정상 클래스의 precision, recall, F1-Measure는 각각 0.668, 0.586, 0.624로 나타났고, 열화 클래스의 precision, recall, F1-Measure는 각각 0.702, 0.770, 0.735로 나타나 의사결정나무 알고리즘을 베이스 모델로 사용한 경우에 비해 예측 정확성이 떨어지는 것으로 나타났다. 또한, 로지스틱 알고리즘을 단일 분류자로 사용했을 경우와 부스팅을 활용했을 경우에 비해 적중률이 약 0.1% 높아졌다. 여전히 정상 클래스에 대한 예측 정확성이 상대적으로 떨어지는 것으로 나타났다.

베이지언 네트워크 알고리즘을 베이스 모델로 사용한 경우, 적중률이 78.0249%로 나타났고 AUC는 0.862로 나타났다. 정상 클래스의 precision, recall, F1-Measure는 각각 0.789, 0.684, 0.733으로 나타났고, 열화 클래스의 precision, recall, F1-Measure는 각각 0.775, 0.856, 0.813으로 나타나 의사결정나무 알고리즘을 베이스 모델로 사용한 경우에 비해 예측 정확성이 떨어지는 것으로 나타났다. 베이지언 네트워크 알고리즘을 단일 분류자로 사용했을 경우에 비해서는 적중률이 약 0.6%p 높아졌으나, 부스팅을 활용한 경우에 비해서는 약 1.7%p 낮아졌다.

RandomForest를 활용해 만든 배터리 예측 모델의 결과를 살펴보면, 적중률이 88.3702%로 나타났고 AUC는 0.956으로 나타났다. 정상 클래스

의 precision, recall, F1-Measure는 각각 0.900, 0.828, 0.863으로 나타났고, 열화 클래스의 precision, recall, F1-Measure는 각각 0.872, 0.928, 0.899로 나타나 의사결정나무 알고리즘을 베이스 모델로 사용한 부스팅과 배깅 다음으로 높은 예측 정확성을 보였다. 또한, 정상 클래스와 열화 클래스 각각의 예측 정확성도 모두 균형적으로 높게 나타났다.

5. 결론

본 연구는 배터리 열화 예측 모델 개발을 목적으로 연구를 진행하였다. 본 연구의 목적 달성을 위해, 골프장 카트 70대의 배터리(이차 납축전지)를 대상으로 약 9개월 정도의 배터리 사용 정보와 배터리 열화 정보를 수집하였다. 그리고 이를 토대로, 데이터마이닝(datamining) 기법을 활용하여 배터리 열화 예측 모델을 개발하였다.

본 연구에서는 주성분 분석을 통해 차원감소 후 총 13개의 독립변수를 사용하여 의사결정나무, 로지스틱, 베이지언 네트워크 등 단일 분류자 알고리즘부터 앙상블 기법 등을 적용하여 배터리 열화 예측 모델을 개발하였다.

본 연구의 실험 결과를 정리하면, 의사결정나무 알고리즘이 적중률(Hit ratio) 87~89% 이상으로 가장 높은 예측정확성을 보였으며, 의사결정나무 알고리즘을 베이스 모델로 사용한 배깅 모델이 89.3923%의 적중률을 보여 모든 모델들 중 가장 높은 예측 정확성을 보였고, 다른 분류 알고리즘들에 비해 정상 클래스와 열화 클래스를 모두 균형 있게 잘 예측하는 것으로 나타났다.

본 연구는 기존 배터리 열화와 관련한 대부분

의 연구들이 실험실에서 얻어진 데이터를 이용하여 분석했던 한계를 극복하고, 실제 운영 환경에서 얻어진 데이터에 기반하여 분석을 수행하였기에 연구 결과에 대한 신뢰성을 보다 높였으며, 여러 알고리즘을 적용하여 모델을 구축한 결과, 의사결정 나무 알고리즘을 베이스 모델로 사용한 배깅 방법이 가장 좋은 예측 성능을 보여준다는 것을 밝혔다는 점에서 이론적 시사점이 있다고 판단된다.

또한, 본 연구에서 제시하는 배터리 열화 예측 모델은 향후 지능형 배터리 센서 모듈 시스템 장비에 탑재되어 배터리의 상태를 모니터링 하여 최적의 조건을 유지하고, 배터리에서 발생하는 문제를 선제적으로 조치함으로써, 효율적인 배터리 관리를 달성하는데 도움을 줄 수 있다는 점에서 실무적 시사점이 있다고 판단된다.

다만, 본 연구에서 사용한 변수들 이외에 배터리 열화에 영향을 미칠 수 있는 날씨, 운전습관 등 다른 환경요인들을 데이터 수집과 관련한 기술적 한계로 인해 충분히 고려하지 못했다는 점은 본 연구의 한계점으로 볼 수 있다. 이러한 한계점은 향후에 보다 정교하고 다양한 데이터 수집을 통해 보완해 나가고, 이를 바탕으로 보다 정확한 예측 모델을 개발하고자 한다.

참고문헌(References)

- Anton, J. A., P. G. Nieto, F. J. de Cos Juez, F. S. Lasheras, M. G. Vega, and M. R. Gutierrez, "Battery state-of-charge estimator using the SVM technique," *Applied Mathematical Modelling*, Vol.37, No.9(2013), 6244-6253.
- Armenta-Deu, C., and T. Donaire, "Determination of an ageing factor for lead/acid batteries. 1. Kinetic aspects," *Journal of power sources*, Vol.58, No.2(1996), 123-133.
- Chen, Z., S. Qiu, M. A. Masrur, and Y. L. Murphey, "Battery state of charge estimation based on a combined model of extended Kalman filter and neural networks," *In Neural Networks (IJCNN), The 2011 International Joint Conference on IEEE*, (2011), 2156-2163.
- Culpin, B., D. A. J. Rand, "Failure modes of lead/acid batteries," *Journal of power sources*, Vol.36, No.4(1991), 415-438.
- Gu, H., T. V. Nguyen, and R. E. White, "A Mathematical Model of a Lead-Acid Cell Discharge, Rest, and Charge," *Journal of The Electrochemical Society*, Vol.134, No.12 (1987), 2953-2960.
- Huet, F., "A review of impedance measurements for determination of the state-of-charge or state-of-health of secondary batteries," *Journal of power sources*, Vol.70, No.1 (1998), 59-69.
- Kang, L., X. Zhao, and J. Ma, "A new neural network model for the state-of-charge estimation in the battery degradation process," *Applied Energy*, Vol.121, (2014), 20-27.
- Kim, S. T., *Modeling of the dynamic behavior and the life time prediction of a 12-V lead-acid battery in automotive driving conditions*, Suwon: Ajou University, 2016.
- Kim, S. T., J. B. Lee, U. S. Kim, C. B. Shin, "Modeling of the lifetime prediction of a 12-V automotive lead-acid battery," *Energy Engineering*, Vol.22, No.4(2013), 338-346.
- Lander, J. J., "Further studies on the anodic

- corrosion of lead in H₂SO₄ solutions,” *Journal of the Electrochemical Society*, Vol.103, No.1(1956), 1-8.
- Lee, H. J., *A study on the development of life-time prediction process for lead-acid battery with considering driving condition environmental temperature*, Seoul: Seoul National University of Science & Technology, 2012.
- Lehockey, E. M., G. Palumbo, A. Brennenstuhl, and P. Lin, “Mitigating intergranular attack and growth in lead-acid battery electrodes for extended cycle and operating life,” *Metallurgical and Materials Transactions A*, Vol.29, No.1(1998), 387-396.
- Morita, Y., S. Yamamoto, S. H. Lee, and N. Mizuno, “On-Line Detection Of State-Of-Charge In Lead Acid Battery Using Radial Basis Function Neural Network,” *Asian Journal of Control*, Vol.8, No.3(2006), 268-273.
- Rodrigues, S., N. Munichandraiah, and A. K. Shukla, “A review of state-of-charge indication of batteries by means of ac impedance measurements,” *Journal of power Sources*, Vol.87, No.1(2000), 12-20.
- Rüetschi, P., “Influence of crystal structure and interparticle contact on the capacity of PbO₂ electrodes,” *Journal of The Electrochemical Society*, Vol.139, No.5(1992), 1347-1351.
- Rüetschi, P., “Aging mechanisms and service life of lead-acid batteries,” *Journal of Power Sources*, Vol.127, No.1(2004), 33-44.
- Sauer, D. U., E. Karden, B. Fricke, H. Blanke, M. Thele, O. Bohlen, and R. Kaiser, “Charging performance of automotive batteries—An underestimated factor influencing lifetime and reliable battery operation,” *Journal of power sources*, Vol.168, No.1(2007), 22-30.
- Shen, W. X., “State of available capacity estimation for lead-acid batteries in electric vehicles using neural network,” *Energy conversion and management*, Vol.48, No.2(2007), 433-442.
- Shiomi, M., T. Funato, K. Nakamura, K. Takahashi, and M. Tsubota, “Effects of carbon in negative plates on cycle-life performance of valve-regulated lead/acid batteries,” *Journal of Power Sources*, Vol.64, No.1(1997), 147-152.
- Singh, P., and D. Reisner, “Fuzzy logic-based state-of-health determination of lead acid batteries,” *In 24th Annual International Telecommunications Energy Conference on IEEE*, (2002), 583-590.
- Thele, M., J. Schiffer, E. Karden, E. Surewaard, and D. U. Sauer, “Modeling of the charge acceptance of lead-acid batteries,” *Journal of Power Sources*, Vol.168, No.1(2007), 31-39.
- Wenzl, H., I. Baring-Gould, R. Kaiser, B. Y. Liaw, P. Lundsager, J. Manwell, and V. Svoboda, “Life prediction of batteries for selecting the technically most suitable and cost effective battery,” *Journal of power sources*, Vol.144, No.2(2005), 373-384.

Abstract

Building battery deterioration prediction model using real field data

Keunho Choi* · Gunwoo Kim**

Although the worldwide battery market is recently spurring the development of lithium secondary battery, lead acid batteries (rechargeable batteries) which have good-performance and can be reused are consumed in a wide range of industry fields. However, lead-acid batteries have a serious problem in that deterioration of a battery makes progress quickly in the presence of that degradation of only one cell among several cells which is packed in a battery begins. To overcome this problem, previous researches have attempted to identify the mechanism of deterioration of a battery in many ways. However, most of previous researches have used data obtained in a laboratory to analyze the mechanism of deterioration of a battery but not used data obtained in a real world. The usage of real data can increase the feasibility and the applicability of the findings of a research. Therefore, this study aims to develop a model which predicts the battery deterioration using data obtained in real world. To this end, we collected data which presents change of battery state by attaching sensors enabling to monitor the battery condition in real time to dozens of golf carts operated in the real golf field. As a result, total 16,883 samples were obtained. And then, we developed a model which predicts a precursor phenomenon representing deterioration of a battery by analyzing the data collected from the sensors using machine learning techniques. As initial independent variables, we used 1) inbound time of a cart, 2) outbound time of a cart, 3) duration(from outbound time to charge time), 4) charge amount, 5) used amount, 6) charge efficiency, 7) lowest temperature of battery cell 1 to 6, 8) lowest voltage of battery cell 1 to 6, 9) highest voltage of battery cell 1 to 6, 10) voltage of battery cell 1 to 6 at the beginning of operation, 11) voltage of battery cell 1 to 6 at the end of charge, 12) used amount of battery cell 1 to 6 during operation, 13) used amount of battery during operation(Max-Min), 14) duration of battery use, and 15) highest current during operation. Since the values of the independent variables, lowest temperature of battery cell 1 to 6, lowest voltage of battery cell 1 to

* Department of Business & Accounting, Hanbat National University

** Corresponding Author: Gunwoo Kim

Department of Business & Accounting, Hanbat National University
125 Dongseo-daero, Yuseong-gu, Daejeon, 34158, Republic of Korea
Tel: +82-42-821-1290, Fax: +82-821-1597, E-mail: gkim@hanbat.ac.kr

6, highest voltage of battery cell 1 to 6, voltage of battery cell 1 to 6 at the beginning of operation, voltage of battery cell 1 to 6 at the end of charge, and used amount of battery cell 1 to 6 during operation are similar to that of each battery cell, we conducted principal component analysis using verimax orthogonal rotation in order to mitigate the multiple collinearity problem. According to the results, we made new variables by averaging the values of independent variables clustered together, and used them as final independent variables instead of origin variables, thereby reducing the dimension. We used decision tree, logistic regression, Bayesian network as algorithms for building prediction models. And also, we built prediction models using the bagging of each of them, the boosting of each of them, and RandomForest. Experimental results show that the prediction model using the bagging of decision tree yields the best accuracy of 89.3923%. This study has some limitations in that the additional variables which affect the deterioration of battery such as weather (temperature, humidity) and driving habits, did not considered, therefore, we would like to consider the them in the future research. However, the battery deterioration prediction model proposed in the present study is expected to enable effective and efficient management of battery used in the real filed by dramatically and to reduce the cost caused by not detecting battery deterioration accordingly.

Key Words : Battery Deterioration, Lead Acid Battery, Battery Deterioration Prediction, Machine Learning, Data Minin

Received : June 12, 2018 Revised : June 21, 2018 Accepted : June 25, 2018

Publication Type : Regular Paper(Fast-track) Corresponding Author : Gunwoo Kim

저 자 소개



최근호

현재 대전에 소재한 국립한밭대학교에서 경영회계학과 조교수로 재직하고 있다. 고려대학교 경영학과에서 박사 학위(MIS 전공)를 받았으며, 근로복지공단 근로복지연구원에서 데이터 분석 업무를 총괄하는 책임연구원으로 근무하였다. 주요 관심분야는 추천 시스템, 의료 빅데이터 분석, 딥러닝, 머신러닝, 데이터마이닝 등이다.



김건우

현재 대전에 소재한 국립한밭대학교에서 경영회계학과 부교수로 재직하고 있다. 연세대학교 공과대학에서 컴퓨터 사이언스를 전공하였으며 고려대학교 경영학과에서 석사를 졸업하고 동대학에서 박사 학위를 받았다. 현재 한국창업학회 부회장을 맡고 있으며 ICT플랫폼학회 빅데이터분과 위원장을 맡고 있다 그 외 다수의 학회에서 편집위원 및 이사로서 활동하고 있다. 주요 관심분야는 비즈니스 온톨로지 모델, 빅데이터 분석 및 핀테크 기술 및 전략 등이다.