

## 최소수리 블록교체 모형을 활용한 상태기반 보전 정책 연구\*

임준형<sup>1</sup> · 원동연<sup>1</sup> · 심현수<sup>1</sup> · 박철홍<sup>1</sup> · 고관주<sup>1</sup> · 강준규<sup>2</sup> · 김용수<sup>3†</sup>

<sup>1</sup>경기대학교 일반대학원 산업경영공학과<sup>2</sup>성결대학교 산업경영공학과

<sup>3</sup>경기대학교 산업경영공학과

---

## A Study on Condition-based Maintenance Policy using Minimum-Repair Block Replacement\*

Jun Hyoung Lim<sup>1</sup> · Dong-Yeon Won<sup>1</sup> · Hyun Su Sim<sup>1</sup> · Cheol Hong Park<sup>1</sup>  
· Kwan-Ju Koh<sup>1</sup> · Jun-Gyu Kang<sup>2</sup> · Yong Soo Kim<sup>3†</sup>

<sup>1</sup>Department of Industrial and Management Engineering, Kyonggi University Graduate School

<sup>2</sup>Department of Industrial and Management Engineering, Sungkyul University

<sup>3</sup>Department of Industrial and Management Engineering, Kyonggi University

**Purpose:** This study proposes a process for evaluating the preventive maintenance policy for a system with degradation characteristics and for calculating the appropriate preventive maintenance cycle using time- and condition-based maintenance.

**Methods:** First, the collected data is divided into the maintenance history lifetime and degradation lifetime, and analysis datasets are extracted through preprocessing. Particle filter algorithm is used to estimate the degradation lifetime from analysis datasets and prior information is obtained using LSE. The suitability and cost of the existing preventive maintenance policy are each evaluated based on the degradation lifetime and by using a minimum repair block replacement model of time-based maintenance.

**Results:** The process is applied to the degradation of the reverse osmosis (RO) membrane in a seawater reverse osmosis (SWRO) plant to evaluate the existing preventive maintenance policy.

**Conclusion:** This method can be used for facilities or systems that undergo degradation, which can be evaluated in terms of cost and time. The method is expected to be used in decision-making for devising the optimal preventive maintenance policy.

**Keywords:** Prognostics, Particle Filter, CBM, Degradation Data

---

\* 본 연구는 국토교통부 플랜트연구사업의 연구비지원(과제번호 17IFIP-B089908-04)에 의해 수행되었음.

† 교신저자 kimys@kyonggi.ac.kr

2018년 4월 10일 접수, 2018년 5월 30일 수정본 접수, 2018년 5월 31일 게재 확정.

## 1. 서론

최근 과학기술의 발전으로 시스템은 하나의 기능만을 작동하는 것이 아닌 복합 기능으로 이루어져 있으며 복잡해지고 있다. 또한, 시스템의 유지보수 난이도는 점차 높아지고 있으며, 항공, 플랜트 등 시스템이나 설비의 교체비용 또는 고장발생에 대한 리스크가 큰 산업에서는 이를 방지하기 위해 시스템 또는 설비의 고장이 발생하기 전에 점검 및 수리하는 예방보전이 수행되고 있다. 그러나 대부분의 산업 현장에서의 예방보전은 관리자의 경험에 기반하여 실시되거나 예방정비 주기를 시스템의 특성을 반영하지 않고 결정하는 경우가 많으며 이에 따라 과도한 비용 발생 및 가용도 저하 문제가 나타날 수 있다[1].

시스템 또는 설비의 예방정비 정책의 적절성을 평가하고 적절한 예방정비 정책을 수립하기 위해서는 필드 데이터에 기반한 체계적인 신뢰도 기반의 분석과 시스템의 정확한 수명예측이 요구된다. 이를 위해, 최근 제조업 전반에 사물인터넷과 빅데이터 처리기술을 활용한 지능형 생산체계가 구축하여 데이터 수집에 용이한 환경을 갖추었으나 이를 잘 활용하지 못하고 있는 실정이다.

예방보전 정책은 수리가능 시스템에서 일반적으로 활용되며 이에 대한 연구로는 Lee *et al.*[2]가 수리가능한  $n$  중  $k$  구조 시스템의 예방정비 주기를 산출하기 위해 비용모형을 활용하여 시스템 모델링을 실시하고 이를 유전 알고리즘(genetic algorithm)을 통해 휴리스틱 최적해를 도출하였다. Cho and Yum[3]은 고장 데이터가 구간 데이터인 경우에 적용가능한 수리가능 시스템의 분석 절차를 수립하고 이를 바탕으로 경향성 검정 방법을 제안하였다. 또한, Mun and Bae[4]는 단조 추세를 가지는 수리가능 시스템의 고장패턴을 모형화할 수 있는 Power Law Process를 현실적인 상황에 맞추어 복합 추세를 고려하는 모델을 제안하고 이를 실제 데이터에 적용해보았다.

상태기반 보전은 최근 고장예지 및 건전성 관리 기술이 발전함에 따라 많은 연구가 이루어지고 있다. 특히 모니터링 시스템 및 센서기술의 발전으로 인해 데이터 수집이 용이해지면서 수집 데이터를 활용한 다양한 예측 방법이 등장하고 있다. An *et al.*[5]는 고장예지 기법을 물리기반 모델과 데이터 기반 모델로 분류하고 상태 모니터링 데이터에 대한 대표적인 알고

리즘을 소개하였으며, 데이터의 잡음, 물리모델 존재 여부 등 주어진 조건에 따라 활용 알고리즘의 가이드 라인을 제시하였다. Macaluso[6]은 Hydraulic servo-actuator를 대상으로 결함 감지를 위해 nominal band, percentual error, Euclidean distance의 세 가지 기법을 활용하여 성능을 비교하였으며 인공지능망을 활용하여 잔여수명을 예측하였다. Xu and Zhao[7]은 다변량의 열화 데이터를 기반으로 로지스틱 함수를 활용하여 새로운 성능 지표를 만들고 이를 기반으로 신뢰도 함수를 추정하였다. 자동차 분야에서는 고장 데이터, dynamic time-series data 등을 기반으로 다수의 고장진단 모형과 Cox 위험비례모형을 활용하여 잔여수명을 예측하는 프레임워크를 정의하였다[8].

기존 연구에 따르면, 예방정비 주기 산출 연구에서는 일반적으로 수리가능 시스템에서 시스템 구조와 비용모형에 따라 예방정비 주기를 산출하였으며, 상태기반 보전 연구에서는 모니터링 데이터를 통해 잔여수명을 예측하고 이에 대한 정확도를 분석하였다. 따라서, 본 연구에서는 수리가능 시스템이 열화특성이 존재한다는 가정 하에 필드 데이터의 열화 특성을 활용하여 고장시점(열화수명)을 예측하고, 시간기반 보전과 상태기반 보전을 활용하여 시간 및 비용 관점에서 기존의 예방정비 정책 평가는 물론 과학적 분석에 기반한 최적 예방정비 주기를 산출하고자 한다.

제2장에서는 예방보전의 기본개념은 물론 본 연구에서 제안하는 분석 프로세스 및 사용되는 방법론을 소개하고 설명한다. 제3장에서는 앞서 제안한 프로세스를 기반으로 플랜트 사례연구를 진행하여 결과를 도출한다. 마지막으로 제4장에서는 결론 및 기대효과에 대하여 제시한다.

## 2. 최소수리 블록교체 모형을 활용한 상태기반 보전 연구

유지보수의 한 종류인 예방보전은 시스템이 고장이 발생하지 않은 작동상태에서 시스템의 상태를 개선하는 활동으로 다양한 방법으로 분류가 가능하다. 예방보전은 시스템이 작동상태에 있지만 미래에 발생할 고장을 예방하기 위해 정해진 기준을 토대로 보전을 실시하게 된다. 이러한 예방보전을 실시하기 위해서는 시스템의 고장모형 비용 등 다양한 정보가 필

요하다. 예방보전의 종류는 시간기반 보전 수명기반 보전, 상태기반 보전 기회 보전이 있으며[9], 본 연구에서는 열화특성을 가지는 시스템에 대한 최적 예방보전 정책을 수립하기 위해 시간기반 보전과 상태기반 보전을 활용하였다.

**2.1 최소수리 블록교체 모형**

시간기반 보전은 정해진 시점에서 예방보전을 실시하는 정책으로 블록교체 모형과 최소수리 블록교체 모형으로 구분되며, 이는 지정된 시점에서의 예방보전이 계획적으로 수행됨으로써 다른 보전 정책보다 관리가 수월하다는 장점을 가지고 있다.

블록교체 모형은 블록교체 기간 내에 발생한 고장에 대하여 고장교체를 실시하고 블록교체 시점에는 수명에 관계없이 예방교체가 이루어지는 교체모형으로 운용 중인 부품이 유사하고 수가 많을 경우에 주로 활용된다. 그러나 수명을 고려하지 않는 교체로 인해 비용이 낭비되는 경향이 있다. 이와 다르게, 최소수리 블록교체 모형은 계획된 예방교체 사이의 고장에 대하여 최소수리를 실시하여 고장교체를 예방교체 시점까지 지연시키는 정책이다. 수리비용이 교체비용보다 비용적 우위가 존재할 경우 최소수리를 실시하는 것이 더 합리적이며 블록교체의 비용 부담을 해결할 수 있는 모형이다.

최소수리 블록교체 모형은 수리 후 시스템의 상태가 고장 직전의 상태로 복구되고 수리나 교체 시 소요되는 시간은 무시한다고 가정한다. 최소수리 블록교체 모형의 시간당 평균 비용은 식(1)과 같다. 이 때, 블록주기는  $t_0$ , 교체비용은  $c$ , 최소수리비용은  $k$ , 고장률 함수는  $h(t)$ 로 나타낸다.

$$C_B(t_0) = \frac{c + k \int_0^{t_0} h(t) dt}{t_0} \tag{1}$$

와이블분포는 형상모수 값에 따라 다양한 고장모드를 표현할 수 있으므로 신뢰성 분석에서 가장 폭넓게 사용되는 확률분포 중 하나이다[10]. 이에 따라, 시스템이 와이블분포를 따른다고 가정할 때, 최소수리 블록교체 모형의 시간당 평균 비용은 식(2)와 같다. 이 때, 와이블분포는 척도모수  $\alpha$ 와 형상모수  $\beta$ 를 따른다.

$$C_B(t_0) = \frac{c + k \left(\frac{t_0}{\alpha}\right)^\beta}{t_0} \tag{2}$$

또한, 식 (3)을 통해 최적 블록교체 주기를 다음과 같이 유도할 수 있다. 와이블분포를 따를 때 최적 블록교체 주기는 식(6)과 같이 도출된다.

$$\frac{dC_B(t_0)}{dt_0} = \frac{\beta k \left(\frac{t_0}{\alpha}\right)^{\beta-1} \times t_0 - \left(c + k \left(\frac{t_0}{\alpha}\right)^\beta\right)}{t_0^2} = \tag{3}$$

$$\beta k \left(\frac{t_0}{\alpha}\right)^\beta - k \left(\frac{t_0}{\alpha}\right)^\beta - c = 0 \tag{4}$$

$$\left(\frac{t_0}{\alpha}\right)^\beta = \frac{c}{(\beta-1)k} \tag{5}$$

$$t_0^* = \alpha \left(\frac{c}{(\beta-1)k}\right)^{\frac{1}{\beta}} \tag{6}$$

**2.2 상태기반 보전**

상태기반 보전은 시스템의 마모나 성능감소에 영향을 미치는 하나 또는 그 이상의 변수 값을 측정하여 이를 기준으로 보전 실시 여부를 결정하는 보전정책이다. 일반적으로 부식 정도, 온도 또는 압력 등 열화 특성을 갖는 물리적 변수나 시스템 효율 지표, 부품의 품질 등 시스템의 성능에 관련된 변수를 사용한다. 이러한 변수는 시간에 따른 열화량 또는 성능변수의 정보를 활용하여 고장시간에 대한 추론과 예측이 가능하며 제품의 특성이 치명적 수준에 도달하면 고장이라 판단한다. 물리적 변수는 시간에 따른 열화량의 변화를 통해 증가형과 감소형으로 구분한다.

상태기반 보전은 고장진단과 고장예지인 두 단계로 구분된다. 고장진단은 모니터링 시스템을 활용하여 설비 또는 제품의 고장정보를 수집하는 것으로 고장정보는 고장(또는 사건) 데이터와 상태 모니터링 데이터로 분류된다. 모니터링 시스템의 발전에 따라 실시간 또는 주기적인 데이터 수집이 가능해지면서 상태 모니터링 데이터를 많이 활용하고 있다. 고장예지는 측정된 상태 모니터링 변수를 기반으로 시스템

의 마모과정을 예측할 수 있는 수학적 모델을 활용하여 고장까지의 잔여수명을 추정한다[11].

고장예지 접근방법으로는 데이터 중심(data-driven)과 물리기반(physics-based) 접근법이 존재한다. 데이터 중심 접근법은 수학적 모델을 기반으로 머신러닝 및 통계적 기법을 활용하며 최근에는 인공신경망(neural network), 가우시안 프로세스 등 머신러닝 기법이 많이 활용되고 있다. 물리기반 접근법은 물리적 모델을 기반으로 물리적 모델의 모수를 추정하여 고장을 예측하는 방식이다. 모수추정 방법으로는 베이저안 추론(Bayesian inference)에 기반한 particle filter와 베이저안 방법이 많이 활용된다. 물리적 모델은 대표적으로 선형, 지수, 대수, 멱승 함수를 활용하며 일부 균열과 같은 물리적 변수는 균열성장모델 등 해당 물리적 변수를 위한 모델이 존재한다.

### 2.2.1 Particle filter

Particle filter는 베이저안 추론에 기반한 통계적 방법이다. 베이저안 추론은 알려지지 않은 대상의 사전 정보와 추가적인 관측데이터를 통해 대상의 사후 확률을 추론하는 방법이다. 사후확률은 베이즈 정리를 통해 산출할 수 있으며 베이즈 정리는 식 (7)과 같다 [12].

$$p(\theta|Z) = \frac{p(Z|\theta)p(\theta)}{p(Z)} \propto L(Z|\theta)p(\theta) \quad (7)$$

식 (7)에서  $\theta$ 는 알려지지 않은 모수,  $Z$ 는 관측 데이터,  $p(\theta)$ 는 모수  $\theta$ 에 대한 사전분포,  $p(Z|\theta)$ 는 모수  $\theta$ 가 알려진 확률변수  $Z$ 에 대한 조건부 확률,  $L(Z|\theta)$ 는 모수  $\theta$ 가 알려진 확률변수  $Z$ 에 대한 확률밀도함수의 우도함수,  $p(\theta|Z)$ 는  $\theta$ 의 사후분포를 의미한다.  $p(\theta|Z)$ 는 우도함수  $L(Z|\theta)$ 와 사전분포  $p(\theta)$ 의 곱으로 표현될 수 있다[13].

Particle filter 알고리즘은 알려지지 않은 모수의 사전정보(사전확률)를 가진 파티클들을 관측 데이터의 우도함수를 통해 연속적으로 베이저안 업데이트를 진행하여 모수의 사후확률을 얻는 방식이며 세 단계로 이루어져 있으며 다음 <Fig. 1>과 같다.

사전정보를 기반으로 한 사전확률 또는 이전 단계에서 추정된 사후분포를 현재 단계의 사전분포  $p(\theta)$




Fig. 1 Particle filter process

로 사용한다. 관측값의 우도함수  $L(Z|\theta)$ 와 사전분포  $p(\theta)$ 의 곱을 통해 업데이트가 진행된다. 이후 낮은 비율의 파티클은 제거하고 높은 비율의 파티클은 복제하는 재배열(resampling)이 실시되어 현재 단계의 상태 변수와 모수를 추정하고 사후분포  $p(\theta|Z)$ 를 도출한다.

시간  $t$ 에 대하여 상태 모니터링 변수  $Z$ 가 물리 모델  $\eta(t; \beta_0, \beta_1, \sigma)$ 를 따를 때 모수  $\beta_0, \beta_1, \sigma$ 에 대한 사전정보를 기반으로 사전분포를 정해야 한다. 여기서,  $\beta_0$ 는 초기값,  $\beta_1$ 는 기울기,  $\sigma$ 는 관측값의 오차를 나타낸다. 사전정보가 부족한 경우 최대값과 최소값만을 요구하는 균일분포(Uniform distribution)를 많이 활용하며 관측값의 오차를 나타내는  $\sigma$ 는 정규분포로 주로 가정한다.

### 2.3 예방정비 분석 프로세스

열화 데이터를 활용한 시스템의 예방정비 정책 평가 및 최적 예방정비 주기 산출을 위한 프로세스는 3 단계로 구분할 수 있으며 다음 <Fig. 2>와 같다.

먼저, 프로세스의 step 1에서는 필드의 모니터링 시스템을 통하여 열화 데이터를 수집하고 예방정비 이력을 기반으로 데이터 셋을 추출한다. 추출된 데이터 셋을 데이터 전처리를 통하여 분석 데이터 셋을 확보한다. 다음 step 2에서는 열화모델링 및 분석 단계로 열화 데이터에 적합한 열화모델을 찾고 모수추정을 위한 사전정보를 확보하여 particle filter를 통해 잔여수명 분포 및 수명을 추정한다. 파괴역학에서의 피로 균열 성장(fatigue crack growth)모델과 같이 열화데이터에 따른 전형적인 피해모델(damage model)이 알려진 경우는 드물다. 따라서, 본 연구에서는 수집된 열화데이터를 이용해 기본적인 함수 중 평균제곱근오차(root mean square error, RMSE)가 제일 작은 것을

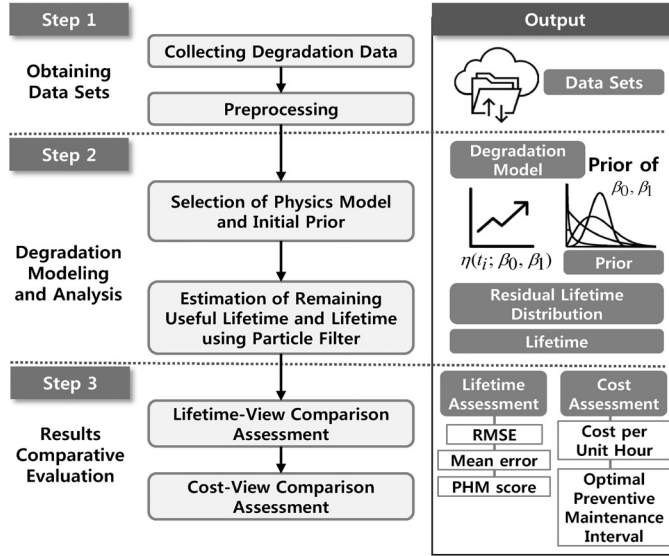


Fig. 2 Procedure of preventive maintenance analysis process

선정하여 모델링 한다. 마지막으로, step 3에서는 수명의 정확도를 통해 현재 예방정비 시점의 적절성을 수명관점으로 평가하고 수명분포 하에서의 단위시간당 비용과 총 비용을 고려한 최적 예방정비 주기를 활용하여 예방정비 정책을 비교하는 비용관점으로 분석결과를 평가한다.

수명관점에서는 참값과 추정값과의 평균 차이, RMSE, 고장예지 및 건전성 관리(prognostics and health management, PHM) score, 총 세 가지 척도를 활용한다. 여기서 PHM score는 2012년도 PHM challenge에서 사용한 채점 방식으로 예방정비 관점에 맞춰 예측값을 평가하는 척도이다. 예를 들어, 실제값과 추정값 사이의 오차 크기가 같더라도 예방정비 시점을 늦게 추정하는 것이 일찍 추정하는 것보다 점수가 더 낮게 산출된다. 먼저, PHM score 산출을 위해 추정된 RUL(remaining useful life)결과를 기반으로 식(8)과 같이 예측 오류의 백분율(percent errors of predictions, %Er<sub>i</sub>)을 산출하고 식(9)에 따라 산출된 모든 점수(G<sub>i</sub>)의 평균으로 PHM score가 정의되며 식(10)과 같다.

$$p(\theta|Z) = \frac{p(Z|\theta)p(\theta)}{p(Z)} \propto L(Z|\theta)p(\theta) \quad (7)$$

$$\%Er_i = 100 \times \frac{ActRUL_i - \widehat{RUL}_i}{ActRUL_i} \quad (8)$$

$$G_i = \begin{cases} \exp\left(-\ln(0.5) \times \frac{Er_i}{5}\right), & \text{if } Er_i \leq 0 \\ \exp\left(+\ln(0.5) \times \frac{Er_i}{20}\right), & \text{if } Er_i > 0 \end{cases} \quad (9)$$

$$Score = \frac{1}{n} \sum_{i=1}^n (G_i) \quad (10)$$

식(8)에서 우변은 실제 RUL은 ActRUL<sub>i</sub>로, 예측된 RUL의 추정값은  $\widehat{RUL}_i$ 로 표현되며 초기 예측(%Er<sub>i</sub> > 0) 또는 늦은 예측(%Er<sub>i</sub> ≤ 0) 여부에 따라 식(9)와 같이 가중치를 고려한 점수(G<sub>i</sub>)가 산출된다.

비용관점에서는 최소수리 블록교체 모형을 활용하기 위해 확률분포를 산출하고 이를 기반으로 정비이력 기준 수명, 열화 수명, 추정값 간의 단위시간당 평균비용과 최적 블록교체 주기를 비교한다.

### 3. 사례연구

플랜트 산업은 초기 설비 투자비용과 운용비용이 많이 소요되는 산업이다. 특히, 운용 시에는 단일 사고 및 설비가동 정지로 인한 막대한 인적, 재산적 피해가 발생하기 때문에 운용방식에 따른 운용비용의 차이가 크게 나타날 수 있다. 본 사례연구에서는 SWRO

플랜트를 대상으로 제2.3절에서 제안된 프로세스를 적용했다.

일반적으로 플랜트 운용비용을 제외한 플랜트 유지보수 비용에서 감소시킬 수 있는 요인으로는 멤브레인(membrane)과 유지보수이다. 20~25년 단위로 운용을 관리 및 보증하는 플랜트 산업에서는 연간 운용비용을 감소시키는 것이 큰 이익이 될 수 있으며 이를 위한 신뢰도 기반의 예방정비 정책이 필요하다[14].

연구대상인 membrane은 열화특성을 가지는 시스템으로 그 중 하나인 차압을 통해 열화과정을 분석할 수 있다. 사용 시간에 따라 membrane의 내부 압력 차이가 발생하게 되며 일정 수준을 넘어설 경우 해수담수화 플랜트의 가동을 중지해야 한다. 이를 방지하기 위한 유지보수는 CIP(cleaning in place), Flushing, Replacement 총 세 가지 형태로 실시되고 있다.

먼저, DCS(distributed control system)을 통해 차압의 데이터를 수집하고 정비이력(CIP, Flushing, Replacement)에 기반하여 데이터 셋을 추출하고 전처리를 통해 분석 데이터 셋을 확보한다.

확보된 분석 데이터 셋을 활용하여 차압의 최적 열화모델을 선정한다. 차압의 물리적 모델은 존재하지 않기 때문에 기본 함수인 선형 함수, 대수, 멱승 함수를 중 RMSE가 가장 작은 모델을 선정한다. 41개의 데이터 셋을 기반으로 RMSE 산출 결과, 지수함수가 최적 모델로 선정되었으며 선형함수가 그 다음으로 적합했다.

최소제곱법을 활용하여 각 데이터 셋에 대한 지수 모델의 모수를 추정하고 particle filter의 사전정보로 활용한다. 사전분포는 정규분포를 활용하며 모수의 추정값과 표준오차를 각각 위치모수와 척도모수로 사용한다. 각 데이터 셋에 대해 잔여수명 분포의 백분위수와 열화수명 간의 오차가 제일 작은 % 백분위를 산출하여 membrane의 대표 % 백분위로 사용하였다. 제일 적합이 잘 된 % 백분위는 40%로 각 데이터 셋의 잔여수명분포의 40% 백분위수를 활용하여 수명을 도출하였다.

열화 수명을 기준으로 정비이력 기준 수명 particle filter로 추정된 열화수명과 차이 <Fig. 3>과 같다. <Fig. 3>의  $x$ 축은 데이터 셋을 의미하며  $y$ 축은 각 수명과의 오차를 나타낸다. 정비이력 기준 수명은 열화 수명을 기준으로 예방정비를 더 늦은 시점에 실시한 경우가 많았으며 추정 수명은 열화 수명과 차이가 없거나 대부분 이른 시점으로 추정하였다. 예방정비 관점에서는 늦은 예방정비보다 이른 예방정비가 비용적 손실이 적기 때문에 현재 예방정비가 적절히 이루어지지 않고 있다고 판단할 수 있다.

이를 수치적으로 평가하기 위해 수명관점 평가척도인 평균 차이, RMSE, PHM score로 비교하였으며 결과는 <Table 1>와 같다. 정비이력 기준 수명은 평균적으로 열화 수명 보다 4.8일 더 늦게 예방정비를 실시하였으며, 추정 수명은 0.4일 늦게 예방정비 시점을 추정하였다. 분산 척도인 RMSE는 정비이력 기준 수




Fig. 3 Error distribution of degradation life(D\_life) for maintenance-history lifetime(M\_life) and estimated degradation lifetime(PF\_life)

**Table 1** Comparison for degradation lifetime

lifetime	Mean error	RMSE	PHM score
maintenance-history lifetime	4.8	8.517	0.9215
estimated degradation lifetime(75% data)	0.4	3.143	0.9901

**Table 2** Estimated parameters of the Weibull distribution for lifetime

Type of Lifetime	Scale parameter	Shape parameter
maintenance-history lifetime	19.931	1.475
degradation lifetime	14.205	1.294
estimated degradation lifetime(75% data)	14.280	1.184

**Table 3** Results of minimum-repair block replacement for lifetime

lifetime	mean cost per day	optimal cycle
maintenance-history lifetime(minimum repair: Flushing)	1.272	251.6
maintenance-history lifetime(minimum repair: CIP)	0.872	355.7
degradation lifetime	0.822	549.7
estimated degradation lifetime(75% data use)	0.655	1153.1

명이 8.517, 추정 수명이 3.143으로 추정 수명이 정확도 또한 높다고 판단할 수 있다. 마지막으로 PHM score는 추정 수명이 정비이력 기준 수명보다 0.0696 점 높았다. 세 가지 척도를 비교하였을 때 모든 지표에서 추정된 열화수명이 더 우월한 것으로 나타났다.

비용관점 평가에서는 각 수명에 대한 확률분포를 가정하여 최소수리 블록교체 모형으로 시간 당 평균 비용과 최적 주기를 산출한다. 먼저, 확률분포는 신뢰성분석에서 가장 많이 활용되고 고장모드를 파악할 수 있는 와이블분포로 가정하였으며 그에 대한 분석 결과는 <Table 2>를 통해 확인 가능하다.

최소수리 블록교체 모형을 활용하기 위해서는 교체비용과 최소수리비용 설정이 우선적으로 이루어져야 하므로 본 사례연구는 아래와 같이 가정하였다.

- 교체비용(Replacement) 100(백만 원)
- CIP에 대한 최소수리비용 3(백만 원)
- Flushing에 대한 최소수리비용 5(백만 원)
- 고장판정기준 이후의 예방정비는 Flushing 실시
- 현재 블록교체 주기( $t_0$ ) 365일

각 수명에 대한 단위 시간당 평균비용과 최적 블록교체 주기는 <Table 3>과 같다. 열화수명은 단위 시간당 평균비용이 0.822로 정비이력 기준 수명(Flushing)보다

0.45 낮았으며, 정비이력 기준 수명(CIP)과 비교하여도 0.05 낮게 산출되었다. 이는 열화값에 기반하여 예방정비를 실시하는 것이 비용을 더 낮춘다는 결과를 보여준다. 또한, 최적 블록교체 주기는 열화수명의 경우 549.7일로 현재 블록교체 주기인 365일보다 약 182일 정도 더 사용할 수 있으며 정비이력 기준 수명(Flushing)은 251.6일로 나타나 현재 블록교체 주기는 부적절하다고 평가할 수 있다.

#### 4. 결론

운영 리스크가 큰 산업에서는 유지보수가 필요할 경우 즉시 실행하는 것이 중요하다. 그러나 대부분의 관리자들은 과거의 운영 경험을 토대로 예방보전을 수행하고 있다. 따라서, 현재의 예방정비 정책에 대해 시간, 비용을 고려한 평가가 요구된다.

본 연구에서는, 시스템이 열화특성을 가지고 있을 경우 이를 활용한 예방정비 정책 수립 프로세스를 제안한다. 제안된 프로세스는 3단계로 구성되어 있으며 먼저 분석 데이터 셋 수집에서는 수집 데이터를 전처리 리를 통해 데이터 셋을 추출하고 정비이력 기준 수명과 열화특성의 고장판정기준 수명(열화 수명)으로 구

분하여 추정수명과 비교할 비교군을 생성한다. 2단계에서는, 열화데이터에 적합한 열화모델을 찾고 최소제곱법을 활용하여 particle filter 분석을 위한 사전정보를 확보한 후, particle filter를 통해 잔여수명 분포를 산출하고 이를 통해 수명을 추정한다. 마지막으로, 시간관점에서 열화수명을 기준으로 정확성을 평가하고 시간기반 보전의 최소수리 블록교체 모형을 활용하여 비용관점에서 예방정비 정책을 평가하고 최적 예방정비 주기를 산출한다.

제안된 프로세스는 실제 SWRO 플랜트의 열화 특성을 가지는 RO membrane에 적용하여 예방정비 정책을 평가는 사례연구를 통해 검증이 수행하였다. 세 가지 시간관점 평가척도를 통해 기존 예방정비 정책의 정확성, 적합성을 비교하고 평가할 수 있었으며 비용관점에서는 가정된 확률분포를 기반으로 단위 시간당 평균비용과 최적 정비교체 주기를 산출하였다.

본 연구에서 제안된 예방정비 분석 프로세스는 열화특성을 갖는 시스템이면서 고장에 대한 리스크가 큰 항공, 플랜트, 철도와 같은 산업에 적용할 수 있으며 시스템에 대한 최적의 예방정비 정책 수립을 위한 의사결정에 활용될 수 있을 것으로 기대된다.

## References

- [1] Lee, Y., Lee, I., Lee, D., and Sohn, K. (2011). "Optimal Preventive Maintenance Period in Complex Systems in Considering Components Reliability Characteristic". *Journal of the Korean Institute of Industrial Engineers*, Vol. 37, No. 4, pp. 390-399.
- [2] Lee, Y., Jung, K., Yoon, T., and Kwon, K. (2014). "Optimal Reliability Strategy for  $k-out-of-n$  System Considering Redundancy and Maintenance". *Journal of the Korean Institute of Industrial Engineers*, Vol. 40, No. 1, pp. 118-127.
- [3] Cho, C. and Yum, B. (2011). "Development of Reliability Analysis Procedures for Repairable Systems with Interval Failure Time Data and a Related Case Study". *Journal of the Korea Institute of Military Science and Technology*, Vol. 14, No. 5, pp. 859-870.
- [4] Mun, B. M. and Bae, S. J. (2009). "Research for Modeling the Failure Data for a Repairable System with Non-monotonic Trend". *Journal of Applied Reliability*, Vol. 9, No. 2, pp. 121-130.
- [5] An, D., Kim, N. H., and Choi, J. (2015). "Practical options for selecting data-driven or physics-based prognostics algorithms with reviews". *Reliability Engineering and System Safety*, Vol. 133, pp. 223-236.
- [6] Macaluso, A. (2016). "Prognostic and Health Management System for Hydraulic Servoactuators for Helicopters Main and Tail Rotor". pp. 733-736.
- [7] Xu, D. and Zhao, W. (2005). "Reliability prediction using multivariate degradation data". In *Reliability and Maintainability Symposium, Proceedings, Annual, IEEE*, pp. 337-341.
- [8] Sankavaram, C. et al. (2016). "An Inference-based Prognostic Framework for Health Management of Automotive Systems". *International Journal of Prognostics and Health Management*, Vol. 7, pp. 1-16.
- [9] Kwon, O. and Lee, H. (2003). "A Research on the Determining Model of the Optimizing Maintenance Interval in TBM for the Preventive Maintenance of Facilities". *Spring Conference of the Korean Operations and Management Science Society*, pp. 106-118.
- [10] George, F. (2014). "A comparison of shape and scale estimators of the two-parameter Weibull distribution". *Journal of Modern Applied Statistical Methods*, Vol. 13, No. 1, pp. 23-35.
- [11] Sutharssan, T., Stoyanov, S., Bailey, C., and Yin, C. (2015). "Prognostic and health management for engineering systems: a review of the data-driven approach and algorithms". *The Journal of Engineering*, Vol. 1, No. 1.
- [12] Zio, E. and Peloni, G. (2011). "Particle filtering prognostic estimation of the remaining useful life of nonlinear components". *Reliability Engineering and System Safety*, Vol. 96, No. 3, pp. 403-409.
- [13] An, D., Choi, J., and Kim, N. H. (2013). "Prognostics 101: A tutorial for particle filter-based prognostics algorithm using Matlab". *Reliability Engineering and System Safety*, Vol. 115, pp. 161-169.
- [14] Jung, K. M. (2014). "Preventive Maintenance Policy Following the Expiration of Extended Warranty Under Replacement-Repair Warranty". *Journal of Applied Reliability*, Vol. 14, No. 2, pp. 122-128.