

<요약본>

고장함수를 고려한 총수명주기간 계획정비 간격 최적화에 관한 연구

A Study on the Optimization of Planned Maintenance Intervals Considering the Life Cycle Failure Function

장비나 설비의 운용에 있어 **계획정비**는 운용중 발생 가능한 고장발생을 방지한다. 이는 생산이나 운송과정에서 발생하는 리드타임의 초과 발생과 장비 운용중의 대형사고 방지에 영향을 미친다. 적절한 계획정비 일정을 수립하기 위해서는 총수명주기 동안 장비의 고장 발생확률 즉, 고장함수를 고려해야한다. 일정기간의 운용과 정비의 패턴을 반복하는 기간 고정형 정비는 정비일정과 정비예산 계획이 편리하나 고장함수를 고려하지 않으므로 안정적인 장비운용과 정비부서 운영에 비효율적이다. 반대로 고장함수를 고려한 확률 기반형 정비는 안정적인 장비운용과 정비부서 운영에 효율적이지만 정비일정과 정비예산 계획에 있어 높은 유연성을 요구하므로 현실 적용에 한계가 발생할 수 있다. 본 연구에서는 이들의 장점을 모두 가지면서 현실적인 적용이 가능한 간격 최적화 정비 모델을 제안한다. 제안모델은 고장함수의 추세를 고려하여 구간을 분할하고, 각 구간 내에서 기간 고정형 정비를 수행한다. 먼저, 해군 함정(98척) 엔진의 고장 데이터를 이용하여 계층형 베이지안 통계기법으로 고장함수를 추정하고 기간 고정형, 확률 기반형, 3가지 간격 최적화 정비 모델들을 구축하여 Figure 1과 같이 비교하였다. 본 연구의

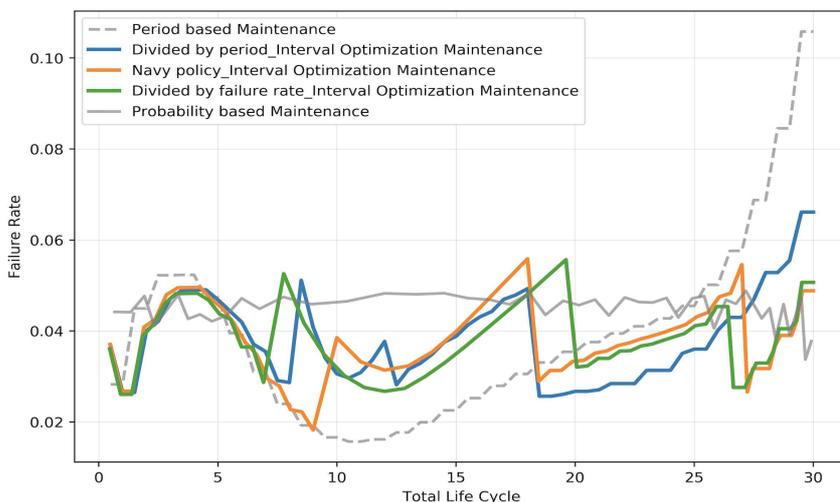


Figure 1. Model comparison

결과는 군 뿐만 아니라 장비를 운용하는 모든 산업군에 활용 가능하다. 해당 산업군에 맞는 고장함수를 추정하고 모델을 구축하여 계획정비 일정을 최적화할 수 있다.

1. 계층형 베이지안 모델 구축

정보량이 비균일하면서 구조가 유사한 데이터의 경우 계층형 베이지안 모델을 적용하면 계층간 정보 공유(Information pooling)의 특성을 이용할 수 있다. 데이터의 특징에 따라 계층을 구분할 수 있으면 계층간 정보가 풀링되어 높은 정확도의 모델을 구축할 수 있다. 본 연구를 위해 확보한 해군 함정(98척) 엔진의 고장 데이터를 확보하였다. 데이터는 크게 3개층(함정용 엔진이 공통적으로 가지는

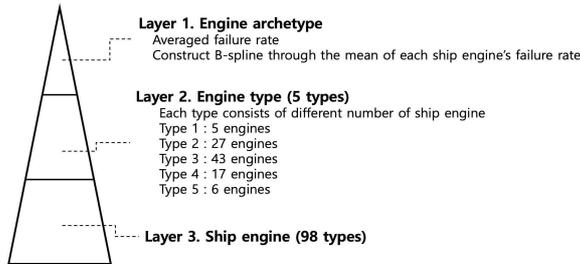


Figure 2. Hierarchical structure of ship's engine failure

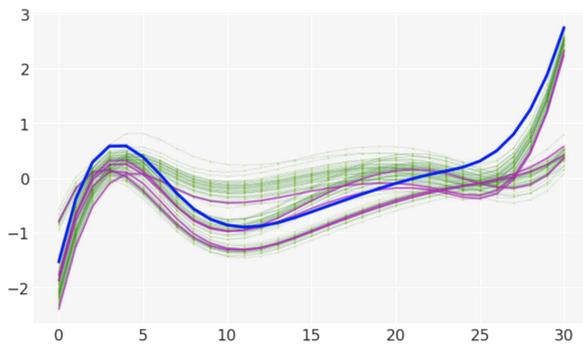


Figure 3. Failure function by hierarchical bayesian model

특성층, 함정 타입별 엔진의 특성층, 개별 함정 엔진의 고유한 특성층)으로 특성을 구분할 수 있다. 확보한 98척 함정의 엔진 고장 데이터는 수명별 데이터 수가 균등하지 않다는 비균일성의 특성을 가지며, Figure 2와 같이 3개층 구조로 구분할 수 있다. 따라서 본 연구의 고장함수 모델을 계층형 베이지안 모델로 구축하고, MCMC 샘플링을 이용하여 모수들을 추정하였다.

Figure 3은 추정된 고장함수이다. ARIMA, Prophet과 성능을 비교한 결과 계층형 베이지안 모델의 RMSE가 가장 낮아 본 연구의 모델로 사용하기에 적합하다고 판단하였다.

2. 계획정비 모델 구축

현재 해군의 정비 정책은 고장함수를 고려하지 않는 기간 고정형 정비에 해당한다. 해군은 총수명주기 30년 동안 0.5년 주기로 계획정비를 실시하고 있다. Figure 2의 고장함수에 따라 고장이 발생한다면 기간 고정형 정비를 실시하면 고장이 많은 수명 초반과 말기에는 정비량이 많아지고 고장이 적은 수명 중반(안정기)에는 정비량이 적어진다. 일정한 주기마다 정비를 실시하면 고장이 많아도 정비 주기가 도래하지 않아 적시 정비가 불가능하며, 임무에 실패할 가능성이 커지는 위험이 있다.

확률 기반형 정비는 고장 함수를 최대한 고려한 정비이다. 고장함수에 따라 일정 고장확률이 되면 계획정비를 실시하므로 함정 운용중 노출되는 최대 위험이

낮아진다. 반면, 확률 기반형 정비는 계획정비 간격에 대한 높은 유연성을 요구하므로 현실성이 떨어진다는 한계가 있다.

간격 최적화 정비는 고장 함수를 고려하여 총수명주기를 4개 구간으로 분할하고, 분할된 각 구간내에서 계획정비를 수행하는 모델이다. 4개로 분할한 이유는 총 수명주기동안 정비 총 횟수를 현재 정책과 동일하게 유지하기 위해서이다. 해군은 반년주기의 계획정비 외에도 총분해정비(OVHL)를 3회 실시중이다. 간격 최적화 모델은 총분해정비의 위치에 따라 총수명주기를 4개 구간으로 분할하고 각 구간에서 최적의 기간 고정형 계획정비 간격을 도출한다. 총 3가지 간격 최적화 모델을 구축하였다. 현재 해군에서 수행중인 총분해정비 주기를 유지하는 모델(Navy policy), 총수명주기(30년)를 균등한 간격으로 4분할한 모델(Divided by period), 총수명주기 동안 발생하는 총 고장량을 기준으로 균등하게 4분할한 모델(Divided by failure rate)까지 3가지의 간격 최적화 모델을 구축하였다. 분할된 각 구간에서 고장량 분산이 최소가 될 때가 최적의 계획정비 간격이 되므로 MINLP(Mixed Integer Non Linear Problem) 최적화를 수행했다.

Table 1. Model comparison

		Max	Std.
Period based maintenance		0.1058	0.0202
Interval optimization maintenance	Divided by period	0.0661	0.0997
	Navy policy	0.0559	0.0082
	Divided by failure rate	0.0557	0.0076
Probability based maintenance		0.0389	0.0033

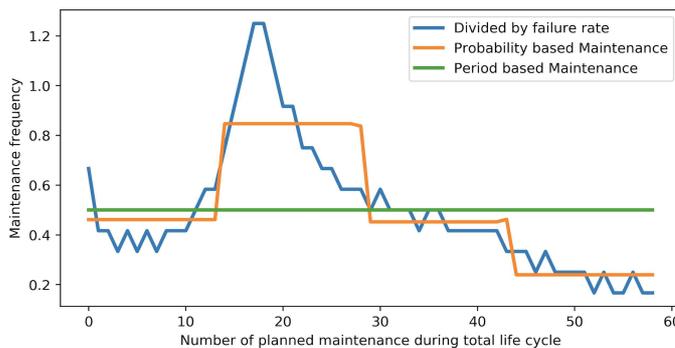


Figure 4. Maintenance frequency comparison

기간 고정형 정비, 확률 기반형 정비와 3가지 구간 최적화 모델을 비교 결과는 Figure 1, Table 1과 같다. Divided by failure rate 모델은 기간 고정형 정비 모델에 비해 운용중 노출되는 고장 위험에 최대 47%, 정비부서 운영에 62% 더 안정적이다. 한편, 확률 기반형 모델은 Divided by failure rate 모델에 비해 각각 30%, 57% 더 안정적이었다. 단, Figure 4와 같이 확률 기반형 모델은 계획정비 일정 수립과 정비예산

계획에 높은 유연성이 요구된다. 확률 기반형 정비를 실시하면 장비의 도입시기에 따라 개별 장비 모두의 계획정비 주기가 달라지기 때문이다. 스케줄링의 문제는 장비의 대수가 많을수록 복잡해져 운영의 혼선을 초래할 수 있다. 본 연구의 결과를 활용하여 각 산업군에 맞는 적절한 고장함수를 도출하고, 산업군의 성격(유연성의 정도)에 맞는 적절한 정비 계획을 수립할 수 있다.

고장함수를 고려한 총수명주기
계획정비 간격 최적화에 관한 연구

A Study on the Optimization of Planned Maintenance
Intervals Considering the Life Cycle Failure Function

최진우(Jinwoo Choi), 박사과정, 국방대학교 국방관리학과, 010-4925-8939
e-mail: chlwlsdn8570@gmail.com

충청남도 논산시 황산별로 1040(양촌면, 국방대학교), 041-732-9119

문현지(Hyunji Moon), 학부과정, 서울대학교 산업공학과, 041-732-9119
e-mail: mhj1667@gmail.com

서울특별시 관악구 봉천로 472(봉천동, 코업레지던스)

조원영(Wonyoung Cho), 석사과정, 국방대학교 국방과학학과, 010-8542-3596
e-mail: bossanova0232@gmail.com

충청남도 논산시 황산별로 1040(양촌면, 국방대학교), 041-732-9119

고장함수를 고려한 총수명주기간 계획정비 간격 최적화에 관한 연구

A Study on the Optimization of Planned Maintenance Intervals Considering the Life Cycle Failure Function

초록

장비나 설비의 운용에 있어 계획정비는 운용중 발생 가능한 고장발생을 방지한다. 이는 생산이나 운송과정에서 발생하는 리드타임의 초과 발생과 장비 운용중의 대형사고 방지에 영향을 미친다. 적절한 계획정비 일정을 수립하기 위해서는 총수명주기 동안 장비의 고장 발생확률 즉, 고장함수를 고려해야한다. 일정기간의 운용과 정비의 패턴을 반복하는 기간 고정형 정비는 정비일정과 정비예산 계획이 편리하나 고장함수를 고려하지 않으므로 안정적인 장비운용과 정비부서 운영에 비효율적이다. 반대로 고장함수를 고려한 확률 기반형 정비는 안정적인 장비운용과 정비부서 운영에 효율적이지만 정비일정과 정비예산 계획에 있어 높은 유연성을 요구하므로 현실 적용에 한계가 발생할 수 있다. 본 연구에서는 이들의 장점을 모두 가지면서 현실 적용이 가능한 간격 최적화 정비 모델을 제안한다. 제안모델은 고장함수의 추세를 고려하여 구간을 분할하고 각 구간 내에서 기간 고정형 정비를 수행한다. 해군함정의 고장 데이터를 이용하여 계층형 베이지안으로 고장함수를 추정하고 기간 고정형, 확률 기반형, 간격 최적화 정비 모델을 구축하여 성능을 비교하였다. 본 연구의 결과는 군 뿐만 아니라 장비를 운용하는 모든 산업군에 활용 가능하다. 해당 산업군에 맞는 고장함수를 추정하고 모델을 구축하여 계획정비 일정을 최적화할 수 있다.

Keyword: 고장함수(Failure function), 계층형 베이지안 통계(Hierarchical Bayesian statistics), 간격 최적화 정비(Interval optimization maintenance), 확률 기반형 정비(Probability based maintenance), 기간 고정형 정비(Period based maintenance)

1. 서론

일반적으로 산업분야에서는 무수한 많은 기계 장비들을 운용중이다. 특히 생산장비, 설비 또는 운송 장비의 고장이 발생하면 불필요한 리드타임이 발생하게 되고

전체적인 물류흐름에 치명적인 영향을 가져올 수 있다. 그러므로 기계 장비의 운용에 있어 계획정비는 장비의 정격성능 유지를 위해 필수적이다. 해군은 함정용 엔진을 운용함에 있어 함정 인수부터 퇴역까지 연 2회의 주기적인 계획정비를 수행중(기간 고정형 정비)이다. 해군에서 사용중인 엔진의 제작사 매뉴얼에는 일정 시간 사용과 정비를 MTBF(Mean Time Between Failure)의 형태로 추천한다. 해군은 제작사 매뉴얼에 기초하여 연간 2회의 기간 고정형 계획정비와 총수명기간 중 3회의 창정비(OVHL)를 수행한다(해군 정비관리 규정, 2018).

과거의 연구에서는 일반적으로 고장의 발생량은 총수명주기 동안 욕조모양(Bathtub shape)을 따른다고 알려져 있다. 장비 도입 초기에는 부속품들의 호환성 문제와 같은 많은 고장들이 발생한다. 초기의 문제들이 수정되면 고장이 적은 안정화 기간을 거치게 되고 장비가 노후화되면서 수명 말기에는 다시 고장이 많아진다. 이는 계획정비의 간격을 상수로 간주하면 안된다는 의미와 같다. 총수명동안 고장이 적게 발생하는 구간과 많이 발생하는 구간이 있음에도 불구하고 많은 산업군에서 계획정비 간격을 상수로 적용하여 비효율적인 계획정비를 실시하고 있다. 해군함정 엔진의 고장도 같은 맥락에서 이해할 수 있다. 해군은 제작사 매뉴얼에 기초하여 계획정비 간격을 상수로 취급한다. 총수명주기 동안 수명에 따라 고장확률이 다르다면 확률에 맞게 계획정비 간격을 유연하게 조정하는 것이 더 효과적인 운용방법이다.

기간 고정형 계획정비를 수행하면 정비 횟수가 고정되므로 장기간에 걸친 정비예산 계획이나 장비운용 계획을 세우는데 편리하다. 반면 고장이 많은 수명 구간에서는 고장확률이 높음에도 불구하고 정비시기가 도래하지 않아 적절한 정비시기를 놓칠 수 있다. 또 매년 계획정비 시 수행하는 정비량도 균일하지 못하여 정비인력 동원에도 문제가 발생할 수 있다. 확률에 따라 계획정비 간격을 조절(확률 기반형 정비)하면 고장이 많은 초기와 말기에는 계획정비 간격이 좁고, 고장이 적은 안정기에는 계획정비 간격이 넓어진다. 또, 계획정비시 수행하는 정비량의 편차가 적어져 정비인력 운용에 유리하고 장비 운용중의 고장 발생확률이 낮아져 장비 운용 안정성을 높일 수 있다는 장점이 있다. 반면 정비간격 설정에 높은 유연성을 요구하게 되므로 군 부대와 같이 예산 활용이나 함정 운용 일정의 유연성을 발휘하기 힘든 산업군에서는 확률 기반형 정비를 적용하는데 현실적인 한계가 따른다.

이에 본 연구에서는 기간 고정형 정비와 확률 기반형 정비의 장점들을 수용하면서 현실적인 적용이 가능한 간격 최적화 정비 모델을 제안한다. 간격 최적화 정비 모델은 총수명주기간 고장확률의 변화에 따라 수명구간을 크게 4개 구간으로

분할하고, 분할된 구간 내에서 기간 고정형 정비를 실시한다. 총수명주기 동안 실시하는 총 계획정비 횟수가 일정하다는 조건에서 분할된 각 구간의 계획정비 간격을 최적화 한다. 예를들어 4개로 분할된 수명구간의 최초구간인 7년간은 4.6개월 운용과 1개월 정비를 반복하고 두번째 구간인 12년간 9.2개월 운용과 1개월 정비를 반복하는 등으로 기간 고정형 정비의 계획성과 확률 기반형 정비의 운용 안정성의 장점을 적절하게 취할 수 있다.

본 연구는 크게 5장으로 구성되었다. 2장에서는 고장함수의 추정과정과 결과에 대해 기술하였다. 고장함수에 대한 문헌조사를 수행하였다. 해군 함정 98척의 고장 데이터를 분석하고 계층형 베이지안 모델에 적합하여 MCMC(Markov chain Monte Carlo) 샘플링을 통해 모수를 추정하였다. 도출한 계층형 베이지안 고장함수와 과거의 연구에서 정립된 모델(ARIMA, Prophet)을 비교하여 성능을 평가하였다. 3장에서는 기간 고정형 정비와 도출한 고장함수를 적용한 확률 기반형 정비를 비교하였다. 확률 기반형 정비와 기간 고정형 정비가 총수명주기 동안 동일한 횟수의 계획정비를 수행하였을 때 각 정비정책의 운용 효율성을 측정하였다. 4장에서는 총수명주기의 4분할 간격을 다르게 설정한 간격 최적화 정비 모델을 3가지 구축하여 모델간의 성능을 비교하였다. 간격 최적화 정비 모델과 기간 고정형, 확률 기반형 정비를 비교하여 정비 정책들을 평가하였다. 5장에서는 연구의 결과들을 종합하고 향후 연구방향 및 연구의 한계를 제시하였다.

2. 고장함수 추정

2.1 문헌연구

고장함수는 총수명주기에 따른 고장확률의 분포를 지칭한다. Cleveland et al.(1990), Hyndman et al.(2002), Hyndman and Athanasopoulos(2018)는 확률 예측 방법으로 지수평활(Exponential smoothing), 자기회귀 이동평균(ARIMA), 주기 및 추세 분할(Seasonal trend decomposition) 등의 여러 방법이 있다고 설명하였다. 일반적으로 과거의 연구에서 고장 발생은 수명에 따라 다른 패턴을 보인다고 알려져 있다. 초반에는 고장이 많다가 점차 줄어들어 고장이 적은 안정기를 거친 후 말기에는 노후화로 인해 고장이 다시 많아진다고 연구되었다. 고장확률의 증감 형태가 욕조모양(Bathtub)과 닮았다하여 욕조곡선(Bathtub curve)라고도 불리며 신뢰도 공학의 연구대상이 되어왔다. 과거의 연구에서는 특정 확률분포의 모수를 욕조모양과 유사하게 추정하기 위한 노력들이 있었다. Wang and Yin(2019)는

육조모양의 구간을 3구간(고장확률 감소, 유지, 증가)으로 분할하였다. 각 구간에 와이블 분포의 모수를 적합하고 이들을 연결하여 추세요소로 반영하였다. 각 구간에서 추세와의 오차는 확률적 요소로서 자기회귀 이동평균법(ARIMA)을 이용하여 추정하였다. 추세요소와 확률요소를 결합하여 총수명주기의 고장함수를 도출하였다. Sherbrooke(2006)은 포아송 분포 기반의 파레토 최적화 알고리즘(Constructive algorithm)을 제안하였는데 포아송 분포의 모수 추정시 범용으로 사용할 수 있는 일반화된 모수를 추정하지 못하였다는 한계가 있었다. Zaomori et al.(2020)은 와이블 분포의 적합으로 Sherbrooke(2006)의 문제를 해결하고자 하였으나 일반화된 모수 추정에 대한 공통적인 한계가 있었다. 특정 분포에 고장함수를 적합하는 방법 외에 다른 연구도 있었다. 시계열 데이터에 주기 성분을 반영하여 예측 정확도를 향상시키는 방법이 있었다(Dagum and Bianconcini, 2016). Taylor, S.J., and Letham, B.(2018)은 시계열 데이터를 추세(trend), 주기(seasonality) 등의 회귀 요소로 분할하여 이들을 일반화 가법 모형(General Additive Model)으로 결합하였다. Prophet이라 불리는 이 알고리즘은 SNS 기업인 Facebook에서 사용되고 있다. Dikis, K., and Lazakis, I.(2019)는 베이지안 네트워크를 이용하여 고장 영향 요소들의 상관관계를 분석하여 고장확률을 예측하고자 하였고 Yoo, J-M. et al.(2019)은 SNA(Social Network Analysis)를 이용한 계층화 분석법(Analytic Hierarchical Process)을 활용하여 해군 엔진 고장발생의 경향을 분석하였는데, 도입년도가 유사한 엔진은 유사한 고장 경향을 보인다고 밝혔다.

과거의 연구중 자기회귀 이동평균(ARIMA)은 예측방법이 단순하면서도 높은 정확도를 보인다. 특히, 고장함수 연구에도 적용되는 등 최근까지도 계속 연구되는 예측기법이다. Prophet은 비교적 최근에 나온 알고리즘이면서 높은 정확도를 보인다고 알려져 있다. 본 연구에서 추정한 고장함수의 비교모델로 두 모델을 선정하여 정확도를 비교하였다.

2.2 해군 함정 엔진의 고장 데이터

해군은 장비의 정격 성능 유지를 위해 연 2회 계획정비를 수행하고 중형함정 기준으로 약 9년마다 총분해 정비(OVHL)를 수행한다(해군규정 제2350호, 2018). 함정 운용중 고장이 발생하면 고장의 발생과 기록은 해군 장비정비정보체계에 입력된다. 그러나, 정보체계의 도입시기 자체가 늦어 많은 데이터가 축적되지 않았고 입력중 발생하는 여러 가지 문제들(오기, 누락 등)로 인해 정확한 고장

데이터의 확보가 제한된다. 최근 10년간(2010 ~ 2019년) 발생한 해군 전투용 함정(110척) 추진용 엔진의 고장 데이터를 활용하였다. 이중 누락이 많거나 현실적으로 불가능한 고장량이 기록된(오기로 간주되는) 데이터를 제외하고 총 98척의 데이터를 분석 대상으로 결정하였다.

최근 10년의 데이터에는 1900년대에 도입한 노후화된 함정부터 2010년 이후에 도입한 신형 함정도 포함되어 있다. 즉, 데이터가 확보된 2010 ~ 2019년 구간에서 각 함정의 수명은 대부분 다르다. 예를들어 2000년에 도입된 함정이라면 수명으로 10 ~ 20년차에 해당하는 데이터들이 확보되었다. 1985년에 도입된 함정의 경우 수명으로 25 ~ 30년에 해당하는 데이터가 확보되었다. 고장 데이터의 분석결과를 토대로 해군 함정의 총수명은 대략 30년인 것으로 추정할 수 있었다. 따라서 본 연구에서는 해군 함정 98척의 데이터를 수명기준으로 재배열하였다. Figure 1은 총수명 30년을 기준으로 데이터가 존재하는 구간을 표시한 것이다. 고장이 많이 발생한 부분일수록 밝은 색으로 표시하였다. 군 데이터의 보안상의 문제로 본 연구에서는 데이터의 수치를 표기하지 않거나 필요한 경우 비율 조정된 데이터(Scaled data)를 사용하였다.

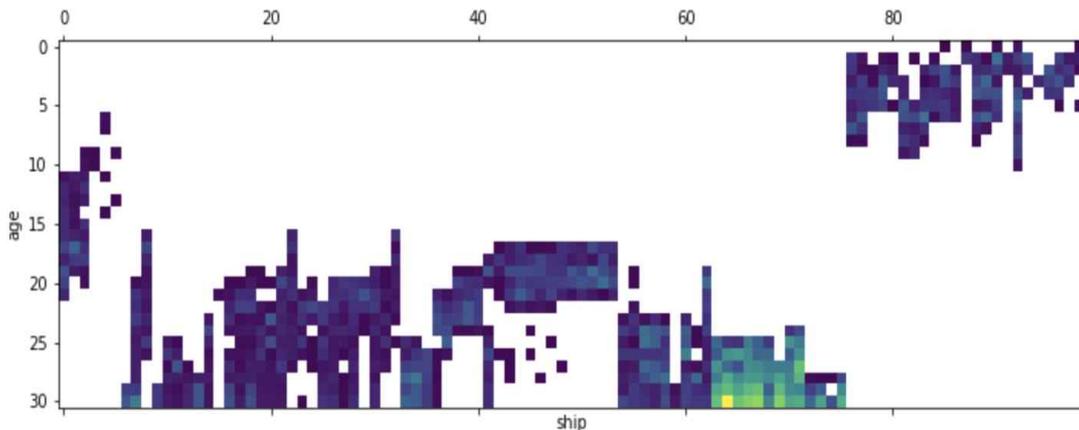


Figure 1. Data location by age and ship

2.3 계층형 베이지안 모델 구축¹⁾

정보량이 비균일하면서 구조가 유사한 데이터의 경우 계층형 베이지안 모델을 적용하면 계층간 정보 공유(Information pooling)의 특성을 이용할 수 있다(Gelman et al., 2005). 이 모델은 데이터의 특징에 따라 계층을 구분할 수 있으면 계층간

1) 본 연구에 대한 보다 자세한 내용은 Hyunji Moon, Jinwoo Choi, Hyeonseop Lee (2020), Failure prediction in hierarchical equipment system: spline fitting naval ship failure, Stancon 2020(mc-stan.org) 에서 확인 가능하다.

정보가 풀링되어 높은 정확도의 모델을 구축할 수 있다(Gelman et al, 2013; Taieb et al., 2017). 계층형 모델에서는 데이터의 일부가 변경이나 추가되는 경우에도 상위층을 포함한 전체의 모델의 모수(Hyper parameter)는 수정되지 않고 해당부분의 모수를 업데이트하는 방법으로 모델을 유지할 수 있다는 장점이 있다(Gelman, 2006a).

본 연구에서 활용된 해군의 엔진 데이터는 다음의 특징을 가진다. 해군 데이터는 크게 3개 층으로 특성을 구분(함정용 엔진이 공통적으로 가지는 특성, 함정 타입별 엔진의 특성, 개별 함정 엔진의 고유한 특성)할 수 있다. 예를들어 G1이란 함정은 G1 함정 고유의 특성을 가진다. 5개 함정 타입중 하나에 속하여 해당 함정 타입의 특성을 가지며 해군 함정이 가진 공통적인 특성을 포함한다. 다시 말하면 특정 함정은 해군 함정의 특성, 해당 함정 타입의 특성과 함정 운용에 따른 고유의 특성을 모두 가진다. 즉, 모든 함정의 엔진을 3개의 층으로 구성할 수 있으므로 ① 확보한 함정(98척)의 데이터를 동일한 구조로 표현 가능하다. 또한 ② 확보한 데이터는 수명별 데이터 수가 균등하지 않다는 비균일성을 가진다. 위 2가지의 특징에 따라 본 연구의 고장함수 모델은 계층형 베이지안 모델로 구축하였다. Figure 2는 해군함정 데이터의 구조를 도식화한 것이다.

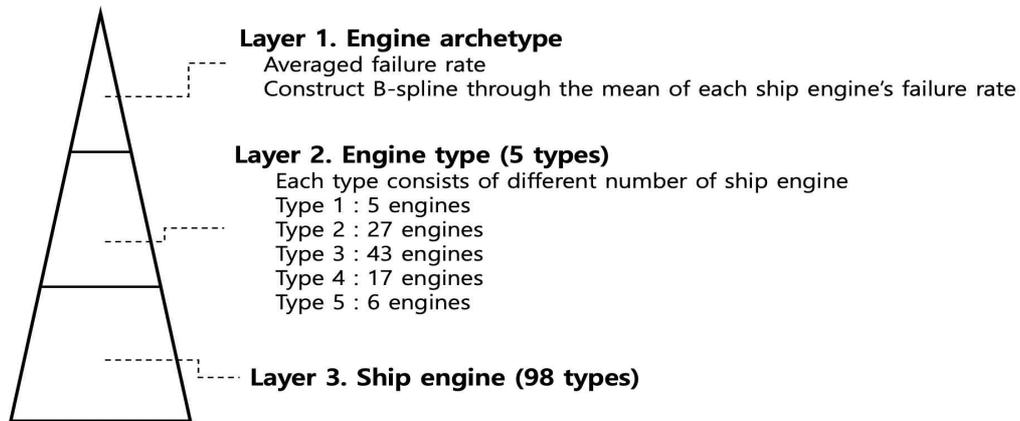


Figure 2. Hierarchical structure of ship's engine failure

Figure 2에서 최상위층은 엔진 98척의 수명별 평균값들을 선형회귀와 B-spline을 이용하여 적합한 것이다(McElreath, 2020). B-spline의 knot를 5개로 지정하여 각 수명별 기저함수와 가중치(weight)를 도출함으로써 엔진 전체의 고장 특성정보를 전체층에 공유한다. 상위층의 초모수(Hyper parameter)는 하위층과 공유되어 데이터가 적은 최하층의 개별 함정도 총수명주기의 고장확률을 도출할 수 있다. B-spline을 반영한 계층형 베이지안 모델을 식(1)과 같이 구축하였고 Python 프로그래밍과 Carpenter et al.(2017)의 Stan 패키지에서 제공하는 베이지안 MCMC

샘플링을 이용하여 모수들을 추정하였다(Hyndman et al., 2011; Tabandeh and Gardoni, 2015).

$$\begin{aligned}
 Y_s &\sim \text{Normal}(\mu_s, \sigma_y) \\
 \mu_s &= \alpha_s + \sum_{k=1}^K w_{k,s} B_k \\
 \alpha_s &\sim \text{Normal}(\bar{\alpha}_e, \sigma_\alpha) \\
 w_s &\sim \text{Normal}(\bar{w}_e, \sigma_w) \\
 \bar{\alpha}_e &\sim \text{Normal}(\bar{\alpha}_0, \sigma_{\bar{\alpha}}) \\
 \bar{w}_e &\sim \text{Normal}(\bar{w}_0, \sigma_{\bar{w}}) \\
 \sigma_\alpha &\sim \text{Gamma}(10, 10) \\
 \sigma_w &\sim \text{Gamma}(10, 10) \\
 \sigma_{\bar{\alpha}} &\sim \text{Exponential}(1) \\
 \sigma_{\bar{w}} &\sim \text{Exponential}(1) \\
 \sigma_y &\sim \text{Exponential}(1)
 \end{aligned} \tag{1}$$

2.4 고장함수 추정 결과

계층형 모델로 추정한 고장함수는 Figure 3과 같다. 파랑색 선은 최상위 계층에 해당하는 해군 엔진 전체를 대표하는 고장함수이다. 검정색 5개의 선은 중간 계층에 해당하는 각 함정 타입별 고장함수이다. 98개의 초록색 선은 각 함정의 고장함수가 된다.

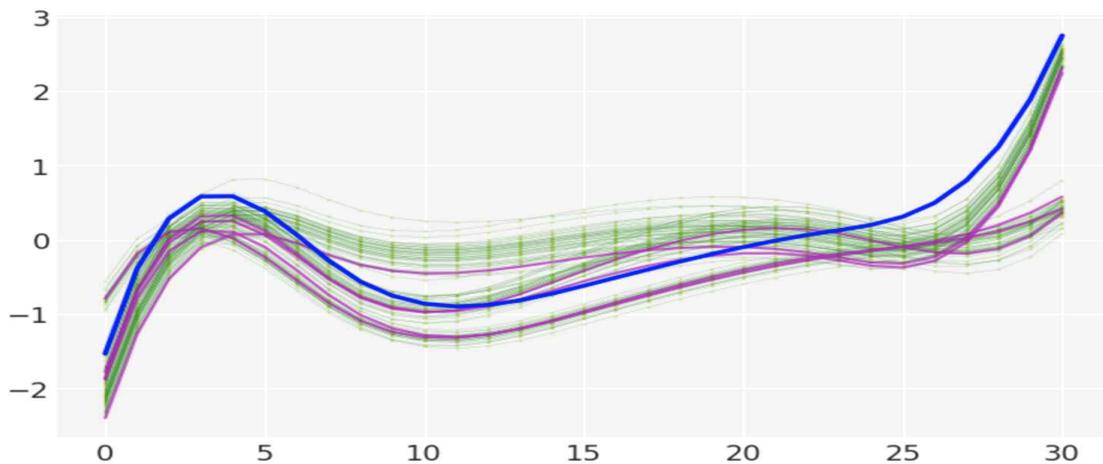


Figure 3. Failure function by hierarchical bayesian model

본 연구의 정비 간격 최적화 대상은 최상위층인 파랑색 선에 해당하는 해군 엔진 전체를 대표하는 고장함수에 해당한다. 타입별 고장함수와 개별 함정에 해당하는

고장함수에 대해서도 본 연구에서 제시하는 방법을 동일하게 적용할 수 있다.

Table 1. RMSE comparison

Hierarchical model	ARIMA	Prophet
1.0349	1.2587	1.0875

해당 고장함수와 비교모델인 ARIMA, Prophet과의 정확도 측정결과는 Table 1과 같다. 정확도 측정 척도는 RMSE(Root Mean Square Error)를 사용하였다(Hyndman and Koehler, 2006). 계층형 모델은 초모수를 통해 각 층의 정보를 공유하기 때문에 RMSE 값이 작다. 반면, 비교모델들은 정보공유가 없으므로 정확도가 상대적으로 떨어진다. 해군의 고장 데이터로 적합한 고장함수의 성능은 과거의 연구에서 입증된 모델에 비해 좋아 본 연구에 활용 가능하다고 판단하였다.

3. 확률 기반형 정비 모델 구축

총수명주기 동안 고장패턴은 고장함수를 따른다. 기간 고정형 정비를 실시하면 고장함수의 패턴을 따르지 않고 일정주기마다 계획정비를 실시하게 된다. 함정 도입 초기와 말기에는 고장 확률이 높아 운용중 높은 고장확률에 노출되고 안정기에는 고장이 적은데도 계획정비를 수행하게 된다. 계획정비시 수행하는 정비량도 매년 달라져 정비인력 운용에도 어려움이 생길 수 있다. 기간 고정형 정비를 실시하면 장비 운용의 안정성은 떨어진다고 할 수 있다. 대신 일정주기마다 계획정비를 실시하기 때문에 계획정비 일정 수립과 예산 확보에는 유리하다. 반면, 확률 기반형 정비는 고장함수에 따라 일정 누적 고장 확률에 도달하였을 때 정비를 수행한다. 기간 고정형 정비와 반대로 운용 안정성 확보에 유리하나 총수명주기간 변동되는 고장확률에 따라 계획정비 일정이 변경되므로 정비 일정 수립과 예산 확보에 있어 높은 유연성을 요구한다는 한계가 있다. 모델들의 유연성 차이에 대해서는 4.3절에서 자세히 설명한다. 본 장에서는 기간 고정형 정비와 확률 기반형 정비의 효율성을 비교하였다. 해군 함정에게는 정비 예산도 중요하지만 작전 운용중 고장을 줄이는 것이 국가 안보를 위해 더 중요한 요소로 판단되므로 본 연구에서는 정비 예산의 최적화에는 초점을 두지 않았다. 총수명주기 동안 같은 횟수의 계획정비를 실시하는 것은 같은 정비 예산을 사용하는 것과 같다고 가정하였다. 따라서 두 모델의 총수명주기간 계획정비 횟수를 동일하게 적용하였다. 현재 해군에서 시행중인 기간 고정형 정비에서 함정은 총수명 30년간 연 2회의 계획정비를 수행하므로 총 60회의 계획정비를 수행한다. 60회의 계획정비를 확률 기반형

정비로 실시하였을 때 운용중 노출되는 최대 고장량과 정비시 수행하는 정비량의 편차(고장량의 표준편차)를 비교 척도로 선정하였다. 계획정비를 실시하면 누적된 고장량이 모두 정비된다고 가정하여 고장량의 표준편차가 곧 정비량의 편차가 된다.

고장량은 양수값만을 가지므로 2장에서 도출한 고장함수를 양수값만 가지도록 비율조정(scale) 하였다. Figure 4는 비율조정된 고장함수의 누적함수(CDF)이다. 2장에서 추정된 고장함수는 연속형(continuous) 함수이나 실제로는 1년 단위의 이산형(discrete) 데이터에 대한 함수이다. 따라서 연간 고장량을 판단하기 위해서는 PDF보다 CDF의 연간 차이를 이용하는 것이 계산에 유리하다.

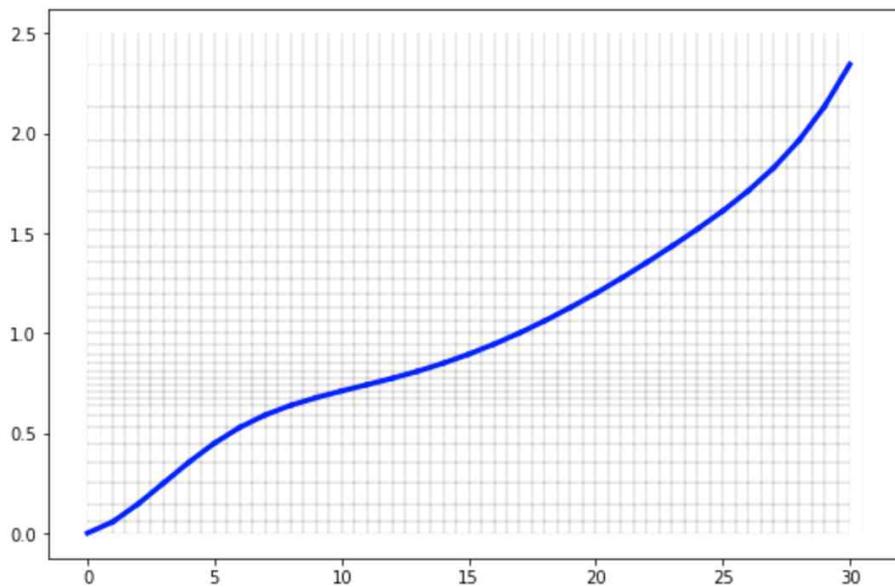


Figure 4. CDF of Failure function

기간 고정형 정비는 Figure 4의 x축(수명)을 동일한 간격으로 60분할한 것과 같고 확률 기반형 정비는 Figure 4의 y축(고장량)을 동일한 간격으로 60분할한 것과 같다. 계획정비의 종료시 누적 고장량은 0이라고 가정한다.

Figure 5는 기간 고정형 정비와 확률 기반형 정비의 계획 정비량을 비교한 것이다. 점으로 표시된 부분은 계획정비 수행지점이다. 계획정비시 실시하는 정비량은 계획정비와 계획정비 사이에 발생하는 고장의 누적량인 동시에 운용중 노출되는 고장량이 된다. 기간 고정형 정비가 계단 모양을 띄는 이유는 1년 간격의 이산형 데이터를 반년 단위로 분할하였기 때문이다. 기간 고정형 정비는 고장함수와 동일한 패턴으로 초기와 말기에 정비량이 많다. 확률 고정형 정비는 총수명기간 동안 정비량이 비교적 균일하다. 각 정비정책의 통계값은 Table 2와 같다.

두 정비정책의 평균값은 0.039로 동일하다. 총수명주기간 총 고장량(2.3457)을

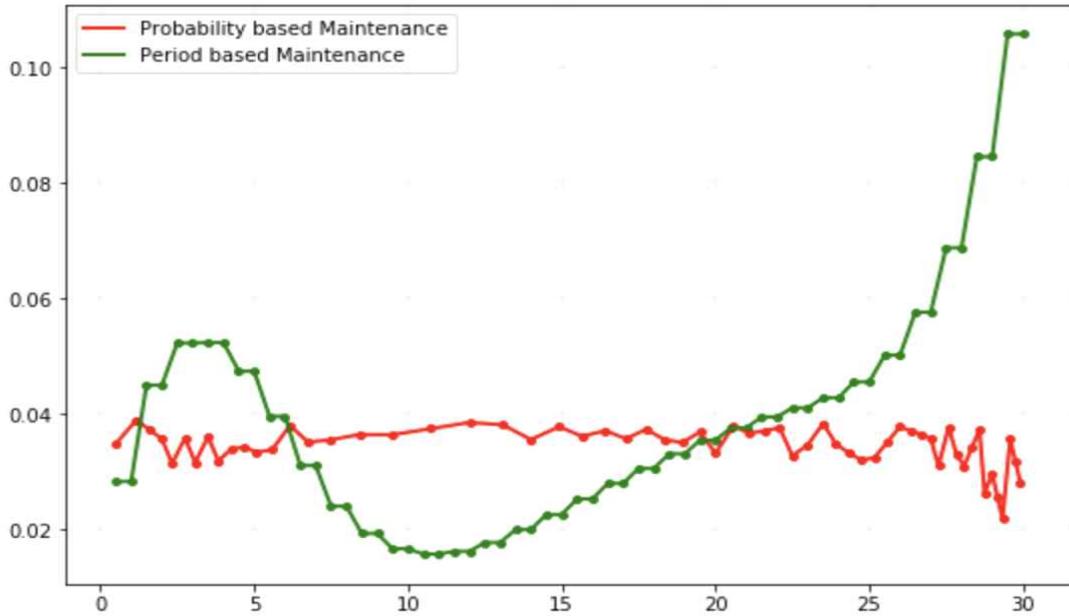


Figure 5. Probability based Maintenance and Period based Maintenance

Table 2. Probability based Maintenance and Period based Maintenance

Maintenance	Mean	Max	Std.	Period between maintenance		
				Min	Max	Std.
Probability based	0.039	0.0389	0.0033	0.1667	1.25	0.2579
Period based	0.039	0.1058	0.0202	0.5	0.5	0

계획정비 횟수 60회로 나눈 것에 해당한다. 기간 고정형 정비의 최대값(0.1058)은 확률 기반형 정비의 최대값(0.0389)의 2.7198배에 해당한다. 이는 총수명기간중 정비부서에서 수행해야할 업무량의 차이에 해당하는 동시에 함정 운용중 고장에 노출되는 최대 고장량의 차이가 2.7198배임을 뜻한다. 운용중 노출되는 고장량의 차이는 해군함정의 작전 임무 실패 가능성의 차이라고 할 수 있다. 표준편차는 기간 고정형 정비(0.0202)가 확률 기반형 정비(0.0033)에 비해 6.1212배 높다. 기간 고정형 정비를 수행하면 정비부서의 업무량 편차는 확률 기반형 정비를 수행하였을 경우에 비해 6.1212배가 높다고 할 수 있다. 이는 정비인력의 할당에 있어 문제를 일으킬 소지가 있으며 적절한 인력 분배의 실패시 정확한 정비에 실패하여 추가적인 고장으로 이어질 위험이 있다고 할 수 있다. 한편 확률 기반형 정비의 계획정비 간격은 0.1667 ~ 1.25년, 표준편차는 0.2579이다. 즉, 확률 기반형 정비를 수행하기 위해서는 정비간격 설정시 유연성이 높아야하며 이는 정비예산의 유연성 있는 할당이 가능해야 한다는 의미가 된다.

4. 간격 최적화 정비 모델 구축 및 정비 모델간 결과 비교

4.1 간격 최적화 정비 개요 및 비교모델 선정

확률 기반형 정비는 함정 운용중 노출되는 고장을 줄이고 정비 업무량도 균등하여 완전한 정비가 가능하게 한다. 하지만 확률 기반형 정비는 정비간격과 정비예산 설정에 높은 유연성을 요구한다. 기간 고정형 정비는 정비계획을 세우는데 효율적이지만 함정 운용과 정비의 안정성 측면에서 비효율적이다. 따라서 정비간격 및 예산 설정의 편리성과 함정 운용 및 정비의 안정성을 모두 확보할 수 있는 정비 정책이 필요하다. 본 연구에서는 고장함수를 반영하여 **기간 고정형 정비의 계획 편리성과 확률 기반형 정비의 함정 운용 및 정비 안정성을 최적화 하는 간격 최적화 정비**(Interval Optimization Maintenance)를 제안한다.

간격 최적화 정비는 함정의 총수명주기인 30년을 크게 **4분할**하고 분할된 각 구간에서 기간 고정형 정비를 수행할 때 각 구간에서 수행할 계획정비의 횟수를 최적화한다. 예를들어 기간 고정형 정비는 0.5년을 주기로 60회 반복되는 계획정비를 실시하지만 간격 최적화 정비는 1/4구간 9년간 19회, 2/4구간 9년간 9회, 3/4구간 9년간 19회, 4/4구간 3년간 13회의 계획정비를 수행한다. 총수명기간을 4개로 분할한 이유는 현 해군에서 시행하는 정비예산(총 정비횟수)을 그대로 유지한다는 가정을 두었기 때문이다. 해군 함정은 총수명주기 동안 총 3회의 총분해정비(OVHL)를 실시하고 총분해정비 사이에 주기적인 계획정비(60회)를 수행한다. 따라서 간격 최적화 정비의 최적화 대상은 총분해정비 사이 각 구간들에서의 기간 고정형 계획정비의 간격이다.

총분해정비의 위치는 총수명주기의 분할지점이 된다. 분할 기준에 따라 3가지 모델을 구축하고 비교하였다. 첫 번째 모델(Navy policy_Interval optimization maintenance, 이하 NP 모델)은 현재 해군에서 실시하고 있는 함정용 엔진의 총분해정비 주기를 따르고, 총분해정비 사이 구간에서 기간 고정형 정비 간격을 최적화한 모델이다. 함정용 엔진은 대략 3,300시간 운전 후 총분해정비를 수행하라는 제작사의 권고에 따라 정비가 실시되고 있다. 고장함수 도출시 확보한 데이터에서는 평균적으로 9년 주기로 총분해정비를 실시하고 있음이 확인되었다. 두 번째 모델(Divided by period_Interval optimization maintenance, 이하 DP 모델)은 총수명주기 30년을 균등하게 4분할하는 지점에서 총분해정비를 수행하고, 총분해정비 사이 구간에서 기간 고정형 정비 간격을 최적화한 모델이다. 30년의 총수명주기는 7.5년 간격으로 총분해정비를 수행했을 때 균등하게 4분할이

가능하며 각 구간의 고장함수 형태에 따라 계획정비 횟수가 최적화된다. 마지막 모델(Divided by failure rate_Interval optimization maintenance, 이하 DF 모델)은 총수명주기간 발생하는 총 고장량을 4분할하는 모델을 구축하였다. 이 모델은 Figure 4의 y축을 균등하게 4분할한 지점이 충분해정비 지점이 된다. 총수명주기간 동안의 총 고장량 2.3457을 4분할하면 0.5864가 된다. 누적 고장량이 0.5864×1, 0.5864×2, 0.5864×3인 지점에서 충분해정비를 실시하고 충분해정비 사이 구간에서는 기간 고정형 정비를 수행하는 모델이다. 누적 고장량 기준으로 4개 구간으로 분할시 충분해정비 지점은 각각 6.9년차, 19.6년차, 26.4년차이다. 3개 모델의 선정 기준을 Table 3과 같이 정리하였다.

Table 3. Interval optimization maintenance models

Interval optimization maintenance model	Division criterion	4-Divided intervals(year)			
		1 st	2 nd	3 rd	4 th
Navy policy	Manufacturer's manual	9	9	9	3
Divided by period	Equal 4 division of life cycle periods	7.5	7.5	7.5	7.5
Divided by failure rate	Equal 4 division of total failure rate	6.9	12.7	6.8	3.6

모델들의 성능 척도는 총수명기간중 고장량의 표준편차와 최대값을 선정하였다. 3장의 Table 2와 같이 표준편차는 정비인력의 업무부하 불균형의 정도가 되며 편차가 크면 정비인원의 부족으로 인한 불완전한 정비로 이어질 위험이 있다. 최대값은 함정 운용중 노출되는 최대 고장량으로 작전 임무 실패 가능성 정도가 된다.

4.2 간격 최적화 정비 모델 구축

각 간격 최적화 정비 모델의 최적화 수식을 세우기 위해 집합과 결정변수, 모수를 정의하였다. Figure 4의 CDF는 연 단위의 이산형 함수이므로 연 중간에 발생할 수 있는 최적화 지점을 찾기 위해서는 연속형 함수로 변환해야 한다. 연속형 함수로의 변환을 위해 지점과 지점사이를 선형회귀(Piecewise linear regression)로 연결하고 연결된 최종 함수를 $F(x)$ 로 정의하였다. 이때 $F(x) - F(x-1)$ 는 지점 $x-1$ 에서 x 사이 기간 동안의 고장량이 되며 x 는 실수다. 4개로 분할된 각 구간(I)의 집합을 $I = \{1, 2, 3, 4\}$ 라 하였다. 각 구간의 가장 마지막 지점(충분해정비 시작 지점)을 $a_i (\forall i \in I)$, $a_0 = 0$ 라 하면 $a_i - a_{i-1}$ 은 분할된 구간의 길이가 된다. $x_i (\forall i \in I)$ 를

i 구간에서 실시한 계획정비 횟수라고 정의하면 $\frac{a_i - a_{(i-1)}}{x_i}$ 는 분할된 i 구간에서

실시하는 기간 고정형 정비의 간격이 된다.

Belotti, P. et al.(2013)은 비선형 함수에서 이산 변수들의 최적화된 조합을 찾는 문제를 해결하기 위해 MINLP(Mixed Integer Non Linear Problem)를 사용하였다.

Choi, Y-C. et al.(2019)은 균형적인 팀의 인원수 구성 방법 연구에 있어 특성 빈도수의 분산을 최소화하는 방법으로 구하였다. 이때 팀의 인원수는 정수로 한정되고 비선형 함수에 해당하는 분산의 최소점이 최적화 지점이라는 점에서 MINLP를 적용한바 있다. 간격 최적화 정비의 문제는 4개로 분할된 각 구간에서 고장량 분산(σ^2)의 최소점을 찾는 문제인 동시에 계획정비 횟수가 정수라는 제한사항을 가지므로 MINLP를 적용하여 최적화할 수 있다.

따라서 간격 최적화 정비 모델의 최적화 문제를 식(2) ~ 식(4)와 같이 정의할 수 있다.

obj.

$$\text{Min } Z = \sum_i \sum_{j=1}^{x_i} (M - (F(a_{(i-1)} + (\frac{a_i - a_{(i-1)}}{x_i}) * j) - F(a_{(i-1)} + (\frac{a_i - a_{(i-1)}}{x_i}) * (j-1))))^2 \quad (2)$$

$$\text{s.t. } \sum_i x_i = 60 \quad \forall i \in I \quad (3)$$

$$x_i \geq 0 \quad \forall i \in I \quad (4)$$

식(2)는 목적함수이다. 간격 최적화 정비의 최적화 목적은 4개로 분할된 각 구간에서 고장량의 분산을 최소화하는 것이다. 총수명주기간 계획정비 횟수와 고장함수 $F(x)$ 가 정해져 있으므로 총수명주기간 평균 고장량(계획정비량) $M = 0.0391$ (총 고장량 2.3457 / 계획정비 횟수 60회) 식(3)과 식(4)는 제약식으로 총 계획정비 횟수는 60회로 고정된다는 조건과 결정변수(구간별 계획정비 횟수)의 비음조건을 의미한다.

4.3 모델간 결과 비교

최적화 결과 모델들은 각 구간별로 고장함수를 고려한 최적의 정비횟수를 산출하였다. 모델들의 구간별 정비횟수는 Table 4와 같다. NP 모델의 경우 1st 구간에 9년 동안 19회의 계획정비를 실시한다. 이때 계획정비 간격은 0.4737로 약 5개월 운용 후 1개월 정비를 실시하는 것이 1st 구간 최적의 기간 고정형 정비가

Table 4. Frequency for each interval of Interval optimization models

Interval optimization maintenance model	Intervals (year) / Frequency (Maintenance interval(year))			
	1 st	2 nd	3 rd	4 th
Navy policy (NP)	9 / 19 (0.4737)	9 / 9 (1)	9 / 19 (0.4737)	3 / 13 (0.2308)
Divided by period (DP)	7.5 / 16 (0.4688)	7.5 / 8 (0.9375)	7.5 / 12 (0.625)	7.5 / 24 (0.3125)
Divided by failure rate (DF)	6.9 / 15 (0.46)	12.7 / 15 (0.8467)	6.8 / 15 (0.4533)	3.6 / 15 (0.24)

된다. 2nd 구간은 고장함수에서 안정기에 해당하므로 정비간격이 길다. 이 구간에는 9년 동안 9회의 계획정비를 실시하고 11개월 운용 1개월 정비를 실시하는 것이 최적이 된다. 4th는 고장함수의 말기에 해당하여 정비간격이 짧다. 퇴역에 가까워진 수명 말기의 함정은 3년간 13회의 계획정비를 수행하고 계획정비 간격은 0.2308로 약 2개월 운용 1개월 정비를 실시하는 것이 최적이 된다. NP 모델은 해군의 충분해정비 정책을 유지하면서 계획정비 간격을 최적화하는 모델이다. 이 모델에서 2nd에 해당하는 안정기에는 연 1회의 계획정비로 고장량 통제가 가능한 것으로 확인되었다. 해군은 이 기간에도 0.5년마다 계획정비를 실시하는데 이는 과대 정비를 하는 것이므로 비효율적이라고 할 수 있다. 해군은 총수명주기 전체에 걸쳐 0.5년 주기의 계획정비를 실시중이므로 수명말기에 해당하는 4th 구간에서도 0.5년 주기의 계획정비를 실시한다. 이는 약 5개월 운용과 1개월 정비에 해당하는데 최적화 결과 2개월 운용 및 1개월 정비와 비교하면 해군은 과소정비를 수행중이라고 할 수 있다. 수명 말기에 발생하는 많은 고장량을 고려하면 계획정비를 더 자주 수행해야 정격성능을 유지할 수 있다.

Figure 6은 3장에서 확인한 기간 고정형 정비, 확률 기반형 정비와 함께 3가지 간격 최적화 모델의 총수명주기간 고장량을 도식화한 것이다. 현재 해군의 정비정책에 해당하는 기간 고정형 정비는 안정기에 고장량이 상대적으로 적고 수명 말기에 고장량은 상대적으로 많다. 수명 말기의 고장량은 다른 정비 모델의 2배 이상 경우도 있다. 간격 최적화 정비 모델들의 초반 7년 동안의 고장량은 유사한 패턴을 보이지만 충분해정비 시기를 기점으로 패턴이 조금씩 다르다. 성능척도 기준인 분산과 최대 고장량의 통계결과를 Table 5와 같이 정리하였다. 과도한 소수점 이하 단위 절삭을 위해 분산 대신 표준편차($\sqrt{\sigma^2}$)을 사용하였다.

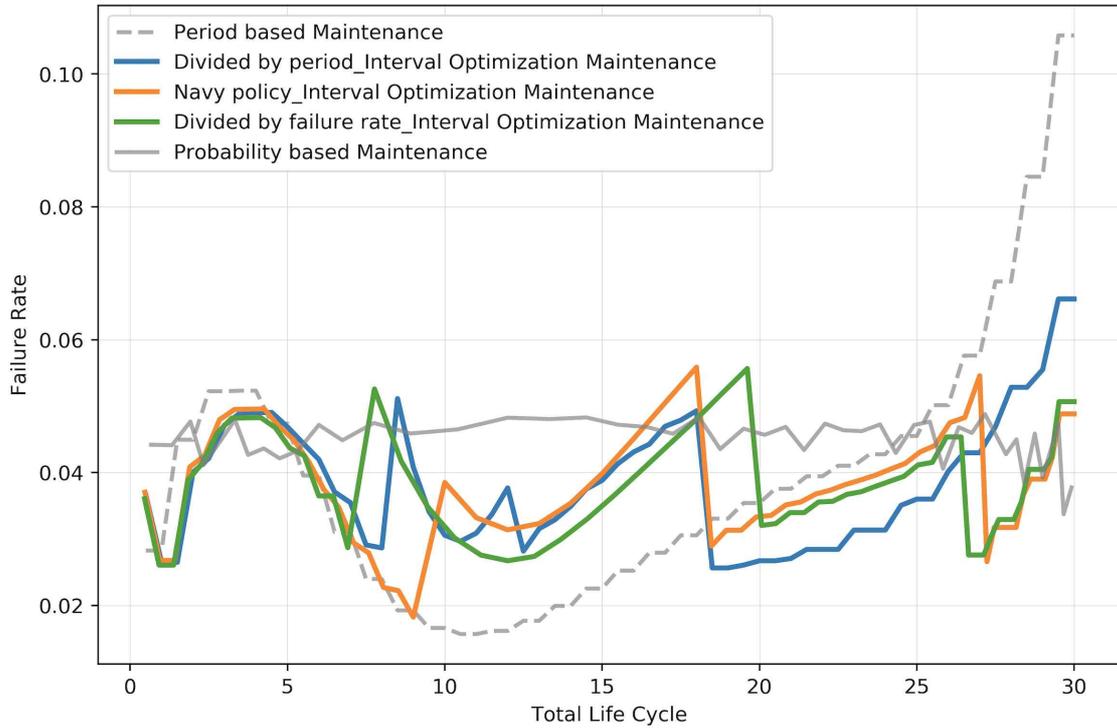


Figure 6. Model comparison

Table 5. Model comparison

		Max	Std.
Period based maintenance		0.1058	0.0202
Interval optimization maintenance	Divided by period (DP)	0.0661	0.0997
	Navy policy (NP)	0.0559	0.0082
	Divided by failure rate (DF)	0.0557	0.0076
	Average of Interval optimization maintenance	0.0592	0.0085
Probability based maintenance		0.0389	0.0033

기간 고정형 정비 모델보다 NP 모델의 최고값과 표준편차가 작다. 이는 해군에서 수행중인 충분해정비 주기를 유지하면서 충분해정비 사이의 계획정비 간격을 최적화하면 현재 해군의 정책보다 더 안정적인 함정 운용 및 정비가 가능하다는

의미가 된다. 총분해정비 사이의 계획 정비 간격이 구간마다 동일한 간격으로 유지되기 때문에 최소 몇 년 단위의 중장기적인 정비계획과 정비예산 수립이 가능하다. 정비일정과 예산사용의 유연성이 부족한 군에게 있어 최적화를 통한 정비정책 변경은 큰 이점으로 작용할 수 있다.

간격 최적화 정비 모델들은 기간 고정형 정비 모델보다 최고값과 표준편차가 작아 안정적인 운용이 가능하다. 확률 기반형 정비 모델은 간격 최적화 모델보다 더 안정적이다.

간격 최적화 정비의 3개 모델은 총분해정비 지점이 다르다는 차이가 있다는 조건 외에는 모든 조건이 동일하다. 3개의 모델은 고장함수의 특성을 많이 반영될수록 안정적인 모델이라고 할 수 있다. DP 모델은 총수명기간을 동일한 크기로 분할하였으므로 총분해정비 지점은 고장함수의 특성을 반영하지 않고 분할된 각 구간 내에서만 고장함수가 반영되었다고 할 수 있다. NP 모델은 총분해정비 주기는 9년으로 일정하다. 단, 수명말기 3년 운용을 위한 총분해정비를 수행함으로써 고장함수 수명말기의 급격한 고장량 증가에 일부 대응한다. DF 모델은 수명주기간 총 고장량을 균등하게 나누어 총분해정비 지점이 결정된 모델이므로 4분할 형태의 정비모델 구조 중 고장함수가 최대한 많이 반영된 모델이다. 3개 모델들은 총수명주기 동안 3회의 총분해정비를 실시하고 계획정비 횟수가 총 60회라는 점에서 정비계획이나 정비예산에 대한 유연성의 정도는 모두 같다고 할 수 있다. 따라서 모든 조건이 같다는 가정이 있다면 고장함수를 최대한 반영하였을 때 가장 안정적인 운용이 가능하다고 할 수 있다.

DF 모델은 최대값과 표준편차가 가장 작으므로 **가장 안정성 있는 간격 최적화 모델**이라고 할 수 있다. 이 모델과 기간 고정형 정비 모델의 차이는 고장함수와 최적화의 효과라고 할 수 있다. DF 모델은 기간 고정형 정비 모델보다 함정 운용중 노출되는 고장 위험에 있어 최대 $47\%(1 - \frac{0.0557}{0.1058})$ 더 안정적이고 정비부서 운영에 있어 약 $62\%(1 - \frac{0.0076}{0.0202})$ 더 안정적이다. DF 모델과 확률 기반형 정비 모델의 차이는 계획정비 기간을 유동적으로 변경할 수 있는 유연성이라고 할 수 있다. 확률 기반형 정비 모델은 DF 모델에 비해 함정 운용중 노출되는 고장 위험에 있어 최대 30% 안정적이고 정비부서 운영에 있어 약 57% 안정적이다. 이때 유연성의 효과는 고장함수와 최적화의 효과보다는 크지 않다.

Figure 7은 총수명주기(60회 계획정비) 동안 계획정비 주기의 변화를 나타낸 것이다. DF 모델은 계획정비 주기가 3회 변경되는데 비해 확률 기반형 정비는 28회 변경된다. 즉, 확률 기반형 정비를 실시하기 위해서는 계획 정비 주기 변경에 대한

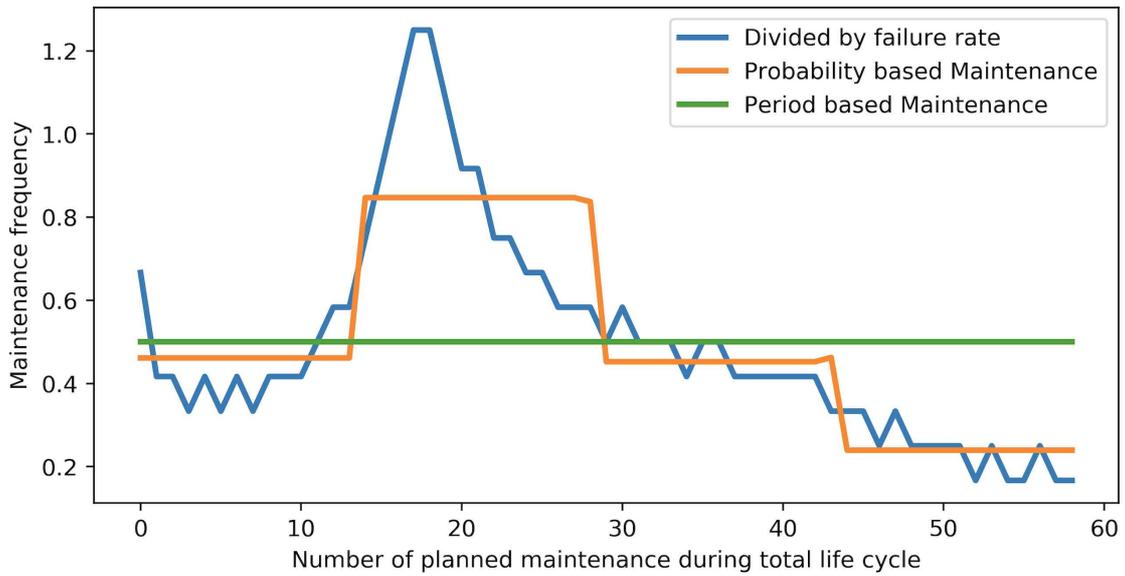


Figure 7. Maintenance frequency comparison during total life cycle

유연성이 높아야하며 정비 예산 역시 유연성 있게 조달할 수 있어야 한다. 이는 해군뿐만 아니라 다양한 산업군에서도 쉽게 적용하기 힘들다. 장비 도입 시기에 따라 모든 개별 장비들이 고장함수에서 다른 수명구간에 위치하기 때문이다. 고장함수에서 각자 다른 수명에 위치하게 되므로 모든 장비의 계획정비 주기가 다르게 운용되게 된다. 이와 같은 스케줄링(Scheduling)의 문제는 장비의 대수가 많을수록 복잡해지므로 운용의 혼선을 초래할 수 있다.

5. 결론

장비를 운용하는 모든 산업군에서는 장비의 고장이 언제 발생할 것인가에 대한 걱정으로 과도한 계획정비를 수행하기 쉽다. 과도한 계획정비는 장비 운용 효율과 정비 예산의 낭비를 초래한다는 점에서 바람직하지 않다. **총수명주기 동안 장비의 고장 발생 패턴을** 안다면 고장의 발생량에 따라 유동적으로 계획정비를 실시할 수 있다. 많은 산업군과 마찬가지로 해군은 일정 주기(0.5년)마다 계획정비를 실시하는 기간 고정형 정비를 실시하고 있다. 이는 총수명주기의 고장 발생 패턴을 전혀 고려하지 않은 형태이므로 비효율적인 정비라고 할 수 있다. 정비 정책의 개선을 위해서는 고장 발생 패턴 분석을 통한 고장함수 추정이 선행되어야 한다. 본 연구의 내용을 요약하면 다음과 같다.

해군 함정 98척의 엔진 고장 데이터를 이용하여 총수명주기 동안 발생하는 고장량의 변화 패턴을 파악하고 계층형 베이지안 통계를 이용하여 고장함수를

추정하였다. 고장함수를 반영하여 고장발생 확률에 따라 정비를 수행하는 확률 기반형 정비 모델을 구축하고 기간 고정형 정비와 비교하였다. 기간 고정형 정비를 수행하면 확률 고정형 정비를 수행하였을 때에 비해 고장 노출 최대 위험 수준이 약 2.7배 높고 정비 부서의 업무편차도 6.1배가 높았다. 확률 기반형 정비를 수행하면 함정 운용중 고장의 최대 노출이 적어지고 고장 발생 편차가 적은 안정적인 운용이 가능한 반면 계획 정비의 주기 변경이 잦아 높은 유연성을 요구한다는 한계가 발생한다.

따라서 본 연구에서는 기간 고정형 정비가 가진 정비 계획 수립에 대한 편의성과 확률 기반형 정비의 운용 안정성의 장점을 적절히 가질 수 있는 **간격 최적화 정비 모델**을 제안하였다. 간격 최적화 정비 모델은 고장함수의 패턴에 따라

총수명주기를 분할하고 분할된 구간 내에서는 **기간 고정형 정비**를 수행하는 모델이다. 분할된 각 구간 내에서 실시하는 기간 고정형 정비의 주기를 MINLP 최적화를 이용하여 산출하였다. 제안모델은 고장함수의 큰 패턴을 반영하여 총수명주기를 분할하고, 분할된 구간 내에서도 해당 수명구간의 고장함수를 고려하므로 장비 운용 안정성을 확보할 수 있다. 한편 분할된 구간 내에서는 기간 고정형 정비를 실시하므로 정비 계획 수립에 대한 편의성도 확보할 수 있다. 해군 엔진의 고장함수에서 충분해정비의 지점에 따라 총수명주기를 4분할하는 3개의 모델을 구축하고 비교하였다. 총수명주기 동안 발생하는 총 고장량을 기준으로 균등하게 4분할 하는 Divided by failure rate 모델이 간격 최적화 정비 모델 중 가장 안정성이 좋았다. 이 모델은 기간 고정형 정비에 비해 운용중 노출되는 고장 위험에 최대 47%, 정비부서 운영에 약 62% 더 안정적이었다. 확률 기반형 정비는 Divided by failure rate 모델보다 고장 위험에 대해 최대 30%, 정비부서 운영에 있어 약 57% 더 안정적이었다. 확률 기반형 정비 모델은 정비 주기 변경에 대한 높은 유연성을 요구한다. 총수명주기 동안 Divided by failure rate 모델의 계획정비 주기가 3번 변경되는 동안 확률 기반형 정비 모델은 28회 변경되었다.

본 연구는 실제 해군의 데이터를 이용하여 고장함수를 도출하고 시행중인 해군의 정비정책 모델과 개선 가능한 여러 모델을 구축하고 최적화를 통한 수리적인 개선 효과를 비교하여 제시하였다는데 의의가 있다. 본 연구는 해군의 데이터와 정비 정책을 활용하여 연구결과를 도출하였으나 해군에 한정되지 않고 장비를 운용하는 모든 산업군에 적용가능하다. 생산공정에서는 한 장비의 고장이 전체 생산 리드타임에 문제를 일으킨다. 본 연구내용을 적용하면 생산 및 물류분야에서 운용되는 생산설비나 장비운용, 운송수단의 효과적인 관리로 장비의 고장을 줄이고 과대 또는 과소 실시되는 계획정비의 최적 지점을 찾을 수 있다.

다만 본 연구는 다음의 한계점에 대해 개선 및 추가 연구가 필요하다. 첫 번째, 고장함수 추정에 적용된 해군 데이터는 데이터 수 자체가 많지 않다. 계층형 베이지안을 이용하여 정확도 높은 고장함수를 도출하였으나 수명 연도별 데이터 중 가장 적은 부분은 98척의 함정 데이터 중 5척만 해당 수명의 데이터를 가지는 경우도 있다. 이런 경우 데이터가 가진 노이즈로 인한 과대 또는 과소적합의 위험이 있으므로 많은 양질의 데이터를 확보하여 정교한 고장함수의 추정이 필요하다. 두 번째, 고장함수에 적용된 데이터는 현재 0.5개월 주기의 기간 고정형 정비를 수행하면서 발생한 고장에 대한 데이터이므로 계획정비 주기가 변경되었을 때 고장 발생량도 변경될 여지가 있다. 따라서 계획정비가 고장량에 미치는 영향을 추가적으로 연구하여 반영해야 더 정교한 고장함수 추정이 가능하다. 세 번째, 계획정비를 실시한 직후의 고장량은 0으로 가정하였다. 고장량의 편차에 따라 고장량이 많은 경우에는 계획정비를 완전하게 하지 못하는 경우도 발생할 수 있으므로 정비 인력이 수행할 수 있는 최대 정비량을 추가적으로 반영해야 한다. 네 번째, 고장함수 추정으로부터 이어지는 연구의 흐름은 장비를 운용하는 모든 산업분야에 적용이 가능하나, 실제 적용된 데이터는 해군의 데이터이므로 보다 다양한 산업군에 적용하여 효과를 검증할 필요가 있다. 다섯 번째, 본 연구는 계획정비 횟수를 최적화하였다. 고장함수를 통한 계획정비 간격 최적화는 운용중 고장을 방지하여 예산 절감에 많은 도움이 될 것이라고 기대된다. 향후 계획정비 횟수와 더불어 소모 예산에 대한 최적화를 동시에 수행한다면 정비 모델의 효과를 더 세밀하게 분석할 수 있을 것으로 기대된다.

6. 참고문헌

- Afenyo, M., Khan, F., Veitch, B., and Yang, M. (2017). Arctic shipping accident scenario analysis using Bayesian Network approach. *Ocean Engineering*, 133, 224-230.
- Belotti, P., Kirches, C., Leyffer, S., Linderoth, J., Luedtke, J., and Mahajan, A. (2013). Mixed-integer nonlinear optimization. *Acta Numerica*, 22, 1-131.
- Carpenter, B., Gelman, A., Hoffman, M., Lee, D., Goodrich, B., Betancourt, M., Brubaker, M. A., Guo, J., Li, P. and Riddell, A. (2017), Stan: Aprobabilistic programming language, *Journal of Statistical Software* 76(1).
- Choi, Y-C., Park, G-H., Lee, S-R., Cho, N-S. (2019), The study on balanced team assignment problem using the mixed integer non-linear programming, *Journal of military science and technology studies*, 12(2), 11-20.
- Cleveland, R. B., Cleveland, W. S., McRae, J. E., and Terpenning, I. (1990). STL: aseasonal-trend decomposition. *Journal of official statistics*, 6(1), 3-73.
- Dagum, E. B., and Bianconcini, S. (2016). *Seasonal adjustment methods and real time trend-cycle estimation*. Springer International Publishing.
- Dikis, K., & Lazakis, I. (2019). Dynamic predictive reliability assessment of ship systems. *International Journal of Naval Architecture and Ocean Engineering*.
- Gelman, A., Carlin, J. B., Stern, H. S., Dunson, D. B., Vehtari, A. and Rubin, D. B. (2013). *Bayesian data analysis*. Chapman and Hall/CRC.
- Gelman, A. (2006). Multilevel (hierarchical) modeling: what it can and cannot do. *Technometrics*, 48(3), 432-435.
- Hyndman, R. J. and Athanasopoulos, G. (2018). *Forecasting: principles and practice*. OTexts.
- Moon, H-J., Choi, J-W. and Lee, H-S. (2020), Failure prediction in hierarchical equipment system: spline fitting naval ship failure, *Stancon 2020*(mc-stan.org)
- Hyndman, R. J., Ahmed, R. A., Athanasopoulos, G. and Shang, H. L. (2011). Optimal combination forecasts for hierarchical time series. *Computational Statistics and Data Analysis*, 55(9), 2579-2589.
- Hyndman, R. J. and Koehler, A. B. (2006). Another look at measures of forecast accuracy. *International Journal of Forecasting*, 22, 679-688.

Hyndman, R. J., Koehler, A. B., Snyder, R. D. and Grose, S. (2002). A state space framework for automatic forecasting using exponential smoothing methods. *International Journal of forecasting*, 18(3), 439-454.

McElreath, R. (2020). *Statistical rethinking: A Bayesian course with examples in R and Stan*. CRC press.

ROK NAVY, "Ship's Maintenance System," pp. 9-10, 2018

Sherbrooke, C. C. (2006). *Optimal inventory modeling of systems: multi-echelon techniques (Vol. 72)*. Springer Science & Business Media.

Tabandeh, A. and Gardoni, P. (2015). Empirical Bayes approach for developing hierarchical probabilistic predictive models and its application to the seismic reliability analysis of FRP-retrofitted RC bridges. *ASCE-ASME Journal of Risk and Uncertainty in Engineering Systems, Part A: Civil Engineering*, 1(2), 04015002.

Taylor, S. J. and Letham, B. (2018). Forecasting at scale. *The American Statistician*, 72(1), 37-45.

Taieb, S. B., Yu, J., Barreto, M. N., and Rajagopal, R. (2017). Regularization in hierarchical time series forecasting with application to electricity smartmeter data. In *Thirty-First AAAI Conference on Artificial Intelligence*.

Wang, J., & Yin, H. (2019). Failure Rate Prediction Model of Substation Equipment Based on Weibull Distribution and Time Series Analysis. *IEEE Access*, 7, 85298-85309.

Yoo, J-M., Yoon, S-W., and Lee, S-H. (2019). SNA-based Trend Analysis of Naval Ship Maintenance. *Journal of the Korea Society of Computer and Information*, 24(6), 165-174.

Zammori, F., Bertolini, M., & Mezzogori, D. (2020). A constructive algorithm to maximize the useful life of a mechanical system subjected to ageing, with non-resuppliable spares parts. *International Journal of Industrial Engineering Computations*, 11(1), 17-34.