

해군 전투함정의 확률기반 계획정비 효과성 연구

최진우¹, 문성암^{1†}, 조원영²

¹국방대학교 국방관리학과 / ²국방대학교 국방과학학과

A Study on the Probability-Based Planned Maintenance Effectiveness of Naval Combat Ships

Jinwoo Choi¹, Seongam Moon^{1†}, Wonyoung Cho²

¹Department of Defense Management, Korea National Defense University

²Department of Defense Science, Korea National Defense University

최진우(현직위: 국방대학교 국방관리학과 대학원생): 최진우는 해군사관학교 전산과학과에서 2009년 학사, 국방대학교에서 2019년 국방관리학과 석사학위를 취득하고 박사과정에 재학 중이다. 연구분야는 Failure function, Bayesian statistics이다.

문성암(현직위: 국방대학교 국방관리학과 교수): 문성암은 연세대학교 경영학과에서 92년 학사, 94년 석사, 99년 박사학위를 취득하였다. 현재 국방대학교 국방관리학과 교수로 재직중이며, 안보문제연구소 국방관리센터장, 국방부 정책자문위원, 로지스틱스 학회 및 생산관리 학회 부회장을 겸임하고 있다. 연구분야는 Behavior Operational Management, Supply Chain Management이다.

조원영(현직위: 국방대학교 국방과학학과 대학원생): 조원영은 해군사관학교 전기공학과에서 2009년 학사학위를 취득하고 국방대학교 국방과학학과 석사과정에 재학 중이다. 연구분야는 확률모형, Markov Chain이다.

† 연락처 : 문성암 교수, 주소 : 충남 논산시 황산별로 1098번길 40 국방대학교, Tel : 010-4925-8939, E-mail : chlwnsdn8570@gmail.com

2020년 0월 0일 접수; 2020년 0월 0일 수정본 접수; 2020년 0월 0일 게재 확정.

해군 전투함정의 확률기반 계획정비 효과성 연구

A Study on the Probability-Based Planned Maintenance Effectiveness of Naval Combat Ships

Planned-Maintenance prevents major accidents that may occur during equipment operation and reduces maintenance budgets. Therefore, Planned-Maintenance should be performed at the right time. The failure probability distribution can be a criterion for establishing the planned maintenance timing. In previous studies, it is known that equipment failure takes the form of a bathtub. This means that the probability of failure depends on its lifetime. In this study, we propose Probability-Based-Maintenance(PBM). PBM performs Planned Maintenance when the probability of failure is accumulated over a certain level. The engine failure data of 98 naval ships were used to derive the failure function by life, and derived by the hierarchical bayesian estimate. The failure function was applied to the system dynamics simulation and compared with the Period-Fixed-Maintenance(PFM) being implemented by the navy. The maintenance efficiency of both models(PBM, PFM) was measured.

Keywords: Failure rate, Maintenance, System dynamics, Naval ship engine data, Probability based, Period fixed

1. 서론

1.1 연구배경

해군 함정은 일반적으로 연 2회의 주기적인 계획정비를 수행한다. 이는 인수부터 퇴역까지 반복된다. 일정기간의 작전 운용과 계획정비를 반복하는 운용과 정비의 패턴을 가진다. 작전 임무 수행 일정에 따라 계획정비 시작 시기가 조금씩 다르지만 큰 차이는 없다. 해군에서 사용중인 엔진의 제작사 매뉴얼에는 MTBF(Mean Time Between Failure)에 따라 최소 300시간 엔진 운용 후에는 부분적인 정비 수행을 추천한다. 해군은 매뉴얼에서 추천하는 300시간 운용에 약 반년이 걸린다는 경험적인 근거에 의해 계획정비 주기의 최소단위를 0.5년으로 규정하고 있다. 그 외에도 해군은 누적 엔진 사용시간이 24,000시간(약 9년)에 도달하면 충분해정비(OVHL)을 수행한다. 해군은 1척의 함정을 운용하는 30여년동안 충분해정비는 3회, 0.5년 주기(연 2회)의 계획정비는 약 60회 수행하며, 이를 규정에 명시하여 연간

함정 운용계획에 반영한다(해군 정비관리 규정, 2018). 본 연구에서는 일정기간 운용과 정비를 반복적으로 수행하는 정비를 기간 고정형 정비(Period Fixed Maintenance)라고 명명하였다. 주기적인 계획정비를 수행함에도 불구하고 작전 임무 수행 중 치명적인 고장이 발생하여 모항으로 복귀해야 하는 상황도 발생한다. 이는 건조가 막 끝난 신형 함정에도 해당된다. 모든 장비와 부속을 새 제품으로 탑재하였음에도 불구하고 첫 출항부터 고장이 발생하여 인수 시기가 지연되는 일도 발생한다. 임무중 발생하는 함정의 고장은 작전 수행에 치명적인 영향을 미친다. 규정에 명시된 바와 같이 0.5년의 주기에 도달하면 반드시 계획정비를 수행한다. 계획정비는 꼼꼼하게 수행되기 때문에 계획정비가 끝난 함정의 고장량은 0으로 보아도 무방하다. 그럼에도 불구하고 계획정비와 계획정비 사이의 기간에 고장이 발생하는 것은 함정의 노후화와 관련된다고 할 수 있다.

과거의 연구에서는 장비나 설비의 고장은 총수명주기 동안 욕조모양(Bathtub)을 따른다고 알려져 있다. 도입 초반인 장비들은 부품들과의 호환성 문제 등으로 많은 고장이 발생한다. 초기의 고장이 수정되면 고장이 적은 안정기 기간을 거친 후 장비 노후화에 따라 수명 말기에는 고장이 다시 많아진다. 이는 총수명주기 동안 고장 발생량이 변하므로 계획정비의 간격을 상수로 고정하면 안된다는 의미가 된다. 그러나, 해군 함정은 기간 고정형 정비를 수행중이다. 수명 초기와 말기에는 고장이 많아도 정비주기가 도래하지 않아 계획정비를 수행하지 못하고, 안정기에는 고장량이 적는데도 주기가 도래하여 정비를 실시하게 된다. 다시 말하면, 해군은 장비의 수명에 따라 정비 빈도를 늘리고 줄일 수 있어야한다.

한편, 총수명주기에 따라 고장량인 변화는 정비부대의 처리 업무량에 편차 발생을 초래한다. 정비인력은 고정되어 있으나 노후된 함정이 들어오면 고장량이 많아 정비인력이 부족할 수도 있다. 반대로, 안정화된 함정이 들어오면 고장량이 적어 정비인력이 낭비될 수도 있다.

이와 같이, 해군은 기간 고정형 정비를 수행함으로써 총수명주기에 따른 고장 발생확률의 변화를 반영하지 못하여 불안정적으로 함정을 운용중이다. 운용중 누적된 고장량의 편차에 의해 정비부대의 업무 수행에도 지장을 미친다. 정비량이 많은 경우 이는 불완전 정비로 이어질 수 있으며 함정 운용에 또 다른 지장을 초래할 수 있다.

1.2 연구목적

본 연구의 목적은 해군의 기간 고정형 정비의 문제점을 파악하고 이를 개선한 확률 기반형 정비 모델을 구축하고 효과를 비교하는 것이다. 이를 위해 해군의 고장 데이터를 수집하여 계층형 베이지안 추정 방법으로 회귀모델을 구축하였다. 본 연구에서는 이 모델을 고장함수로 명명하였다. 도출한 고장함수를 기존에 입증된 ARIMA와 Prophet과 성능을 비교하여 본 연구에 사용하기 적합함을 보였다. 고장함수를 시스템 다이내믹스 시뮬레이션에 적용하였다. 현재 해군의 정비 정책에 따라 기간 고정형 정비 모델과 확률 기반형 정비 모델을 구현하고 비교하였다. 정비 모델의 비교를 통해 고장함수에 따라 계획정비간 간격이 유연한 계획정비를 수행하였을 때의 효과를 입증하고자 한다.

이를 위해 본 연구는 다음과 같이 구성되었다. 2장에서는 고장 예측과 관련된 과거의 연구들을 살펴보고, 해군의 고장 데이터와 함정 운용에 대해 서술한다. 3장에서는 고장함수의 추정과정과 시스템 다이내믹스 구축에 대해 설명하였다. 4장에서 고장함수 추정결과와 시뮬레이션 결과를 분석하고 5장에서 향후 연구방향을 제시하였다.

2. Literature Review

2.1 고장 예측 모델

고장을 예측한다는 것은 수명 구간별 고장확률 분포를 도출한다는 것과 같다. 본 연구에서는 수명 구간별 고장확률의 분포를 고장함수라고 명명하였다. 과거의 연구에서는 자기회귀 이동평균(ARIMA), 지수평활(exponential smoothing), 주기 및 추세 분할(seasonal trend decomposition) 등의 여러 방법으로 고장함수를 도출하기 위한 노력들이 있었다(Hyndman and Athanasopoulos, 2018). 최근에는 시계열을 중심으로 추세(trend), 주기(seasonal)와 다른 회귀 요소들을 일반화 가법 모형(General Additive Model) 방법으로 결합하는 프로phet(Prophet) 알고리즘을 이용한 예측 방법이 개발되기도 하였다(Taylor, S.J., and Letham, B., 2018).

장비의 고장 분포는 일반적으로 욕조모양(Bathtub shape)을 보인다고 알려져 있다. 정량화된 욕조모양 확률분포 모델을 구축하기 위해 와이블(Weibull), 포아송(Poisson) 분포의 파라미터를 적합하는 연구가 있었다. Wang and Yin(2019)는 욕조모양의 구간을 3구간(확률 감소, 유지, 증가)으로 분할하였다. 와이블 분포를 활용하여 각 구간의 파라미터를 적합하여 추세 요소로 적용하고 각 구간의 확률적 요소를 자기회귀 이동평균법으로 적합하였다. Sherbrooke(2006)은 포아송 분포를 기반으로한 파레토 최적화 알고리즘(Constructive algorithm)을 개발하였는데 파라미터 적합의 문제로 일반화된 알고리즘으로 활용하기에는 한계가 있었다. Zammori et al.(2020)은 시계열 와이블 분포를 이용하여 파라미터 적합의 문제 해결에 관한 연구를 하였다. 확률 분포의 파라미터를 적합하는 연구 외에도 베이지안 네트워크를 이용한 시계열 예측법(Dikis, K. and Lazakis, I. , 2019), 계층화 분석법(Analytic Hierarchy Process)(Yoo, J-M. et al., 2019) 등의 방법이 연구되었다. 과거의 연구들에서는 특정 분포를 가정하고 적절한 파라미터를 적합하는 방법이 많이 연구되었다.

데이터의 정보량이 비균일하면서 구조가 유사한 경우 계층형 베이지안(Hierarchical bayesian) 모델을 적용하면 계층간 정보 공유(Information pooling)의 특성을 이용할 수 있다(Gelman, 2006). 계층형 모델에서 정보는 하위층의 모수를 상위층의 모수로 표현함으로써 정보가 공유된다. 예를 들어, 하위층의 확률 분포가 $N(\mu, \sigma)$ 일 때, 평균(μ)를 $\mu \sim N(\mu_1, \sigma_1)$ 으로 표현할 수 있고, 이때, μ_1 은 상위층의 모수가 된다. 모수를 통해 정보가 공유되면 정확도 높은 모델을 구축할 수 있다(Gelman et al., 2013; Taieb et al., 2017). 또한, 계층형 모델에서는 데이터의 일부가 변경되거나 추가되는 경우에도 전체 모델의 모수(Hyper

parameter)는 수정되지 않고, 해당층의 모수만 업데이트하는 방식으로 모델을 유지할 수 있다는 장점이 있다(Gelman, 2006).

2.1 해군 함정 고장 데이터와 함정 운용

해군 함정의 고장의 종류는 2가지로 나눌 수 있다. 작전 운용중 즉시 모항으로 복귀해야 하는 중고장과 작전 임무 수행에 문제가 없는 경고장이 그것이다. 중고장은 실제로 발생하는 일은 거의 없지만 경고장은 빈번하게 발생한다. 수집된 해군 함정의 엔진 고장 데이터는 중고장과 경고장을 모두 포함하나, 대부분 경고장에 해당한다. 중고장은 발생 즉시 정비한다. 경고장은 계획정비 입고시 모두 정비되므로 계획정비 종료 시점의 고장량은 0으로 본다. Yoo, J-M. et al.(2019)는 SNA(Social Network Analysis), 코사인 유사도와 K-mean 클러스터링 방법을 이용하여 함정 장비의 정비 경향을 분석하였다. 정비 경향 분석 결과 함정용 추진엔진은 엔진의 작동시간과의 관계는 적었으나, 비슷한 시기에 획득된 장비들의 정비경향이 비슷하다는 결과가 도출되었다. 즉, 획득 시기에 따라 고장확률은 비슷한 경향으로 나타난다.

통계 모델에 적절한 파라미터를 적합시키기 위해서는 많은 양의 데이터가 필요하다. Wang and Yin(2019)는 발전소의 약 30년 분량의 운용 데이터를 동원하기도 하였다. 한국군은 보안의 문제로 데이터를 충분히 기록하지 않는다. 또한 정보체계 도입시기가 늦고 새로운 정보체계로의 업그레이드 과정에서 과거의 데이터가 적절히 보존되지 않았다. 본 연구에서는 해군 전투용 함정 98척의 추진용 엔진의 고장 횟수 데이터를 활용하였다. 데이터의 확보 기간은 최근 10년치의 데이터였지만 정보 체계의 특성상 누락, 오기 입력 등의 데이터가 많아 활용 가능한 데이터의 양은 많지 않았다. 최근 10년의 데이터에는 1900년대에 도입된 노후함정부터 2010년 이후 도입된 신형 함정도 포함되어 있다. 즉, 본 연구에서 확보한 2010~2019년의 데이터 구간에서 98척 함정의 수명은 대부분 다르다. 예를 들어, 2005년에 인수한 함정이라면 수명으로 5~15년에 해당하는 데이터들이 확보되었다. 1985년에 인수한 함정은 25~30년 수명에 해당하는 데이터들이 확보되었다. 노후함정의 데이터 기록 종료 시점들을 분석하여 해군 함정의 평균적인 총수명주기는 약 31년임을 확인하였다. 고장함수는 수명에 따른 고장확률 변화를 나타내는 것이며, 유정민 등(2019)의 연구에서 고장은 함정 도입년도의 영향을 많이 받는다. 본 연구에서 확보한 98척의 데이터를 도입년도 기준으로 수명에 따라 재배열하였다.

Figure 1은 수명에 따라 데이터를 재배열하고, 총수명주기(y축) 31년중 데이터가 존재하는 구간을 색으로 표현한 것이다. 여기서 x축은 확보한 데이터 중 함정의 번호를 의미한다. 고장이 많은 부분은 밝은 색으로 표현하였다. 다시 말하면, 색으로 표시된 부분은 함정(x축)의 수명(y축)별 고장량(색의 밝기)을 나타낸 것이다. 군 데이터의 보안문제로 본 연구에서는 데이터를 수치로 표기하지 않거나, 필요한 경우 비율 조정된 데이터(scaled data)를 사용하였다. Figure 1과 같이 함정별 데이터는 도입년도(수명)에 따라 데이터 존재구간이 다르다. 10년치의 데이터를 수집하였지만 10년간의 데이터가 모두 존재하는 경우가 드물다. 수명별

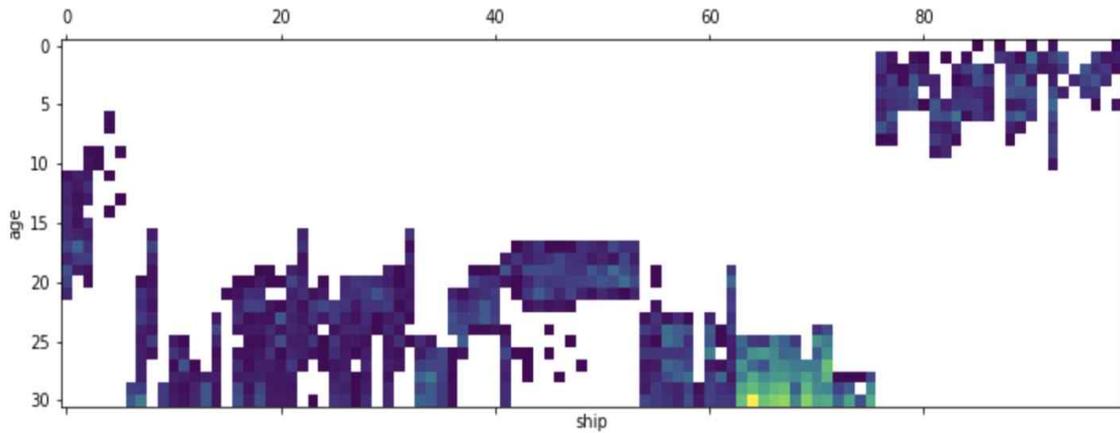


Figure 1. Data location by age and ship

데이터의 양도 다르다. 단, 함정 엔진 고장 데이터는 모두 엔진이라는 특성에 의해 동일한 구조로 표현 가능하다. 해군 PCC 함정에서 사용하는 S1이라는 엔진을 예를 들면, S1은 PCC 타입의 엔진 그룹에 속하고 동시에 해군 함정용 엔진이라는 전체 그룹에 속한다. 다시 말하면, S1은 총 3개 계층(해군용 엔진, PCC 타입용 엔진, S1 자체)의 특성을 모두 가진다. 98척의 함정 엔진을 모두 Figure 2와 같이 3층 구조로 표현 가능하며, 정보가 비균일하다는 특징이 있다. 따라서 본 연구에서는 데이터의 특성을 반영하여 계층형 베이지안 모델 구축시 정확도 높은 모델을 추정할 수 있을 것으로 판단하였다.

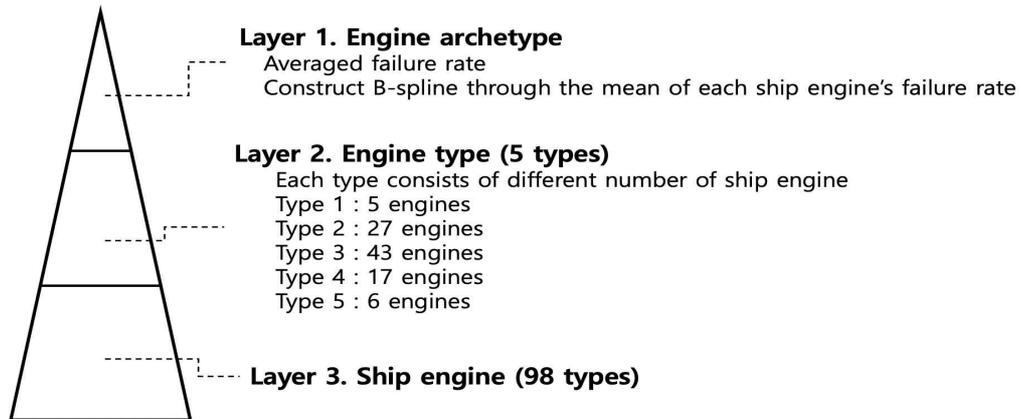


Figure 2. Hierarchical structure of ship's engine failure

3. 모델링

3.1 고장함수 추정2)

2) 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.

Figure 2의 최상위층은 해군 엔진 전체의 특성을 나타낸다. 총수명 31년간의 고장발생 형태를 확인하기 위해 데이터들의 수명별 평균을 산출하여 Figure 3과 같이 도식화하였다. x축은 1~31년의 수명을 나타내고, y축은 비율 조정된 수명별 고장량이다. 즉, Figure 3는 수명별 평균 고장 횟수를 뜻한다. 산출한 수명별 평균 고장량을 바탕으로 선형회귀와 B-spline을 이용하여 적합하였다. B-spline 곡선 추정은 총수명주기를 노트(knot)로 분할하여 각 구간에 차수가 낮은 다항식을 적합할 수 있으므로 구간별 모수의 수가 적다. 기저함수와 가중치(weight)의 조합을 이용하여 각 구간의 비선형 고장 함수를 추정하므로 다항 회귀에 비해 과대 적합이나 과소 적합의 부담이 적다(McElreath, 2020).

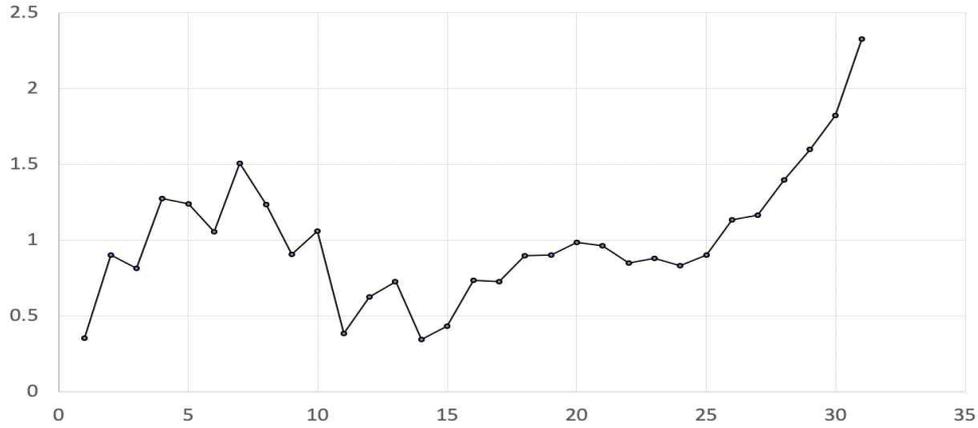


Figure 3. Distribution of the average failures during the total life cycle

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

총수명주기의 기간을 6년 주기로 나누면 6년 주기의 고장 패턴은 상대적으로 고장 횟수가 늘어나는 구간, 줄어드는 구간, 유지되는 구간으로 나누어진다. 따라서 본 연구에서는 knot를 5개로 지정하였다. B-spline으로 수명별 기저함수와 가중치를 도출하였다. 이 값은 최상위층의 특성정보가 되며, 하위층에 초모수로써 공유된다. 데이터가 적고 비균일한 최하층의 개별 함정은 초모수의 공유에 따라 총수명주기의 고장확률을 도출할 수 있게 된다. B-spline을 반영한 계층형 베이지안 모델을 (1)과 같이 구축하였고 MCMC 샘플링을 이용하

여 모수들을 추정하였다(Hyndman et al., 2011; Tabandeh and Gardoni, 2015). 추정한 고장함수를 시스템 다이내믹스 시뮬레이션에 반영하였다.

3.2 시스템 다이내믹스 모델

3.1에서 산출한 고장함수를 시스템 다이내믹스에 적용하여 고장과 정비의 프로세스를 Figure 4과 같이 모델링하였다. 누적확률 > 문턱값 시 정비 문턱값은 총고장량 누적함수의 $q_c(1/62)$

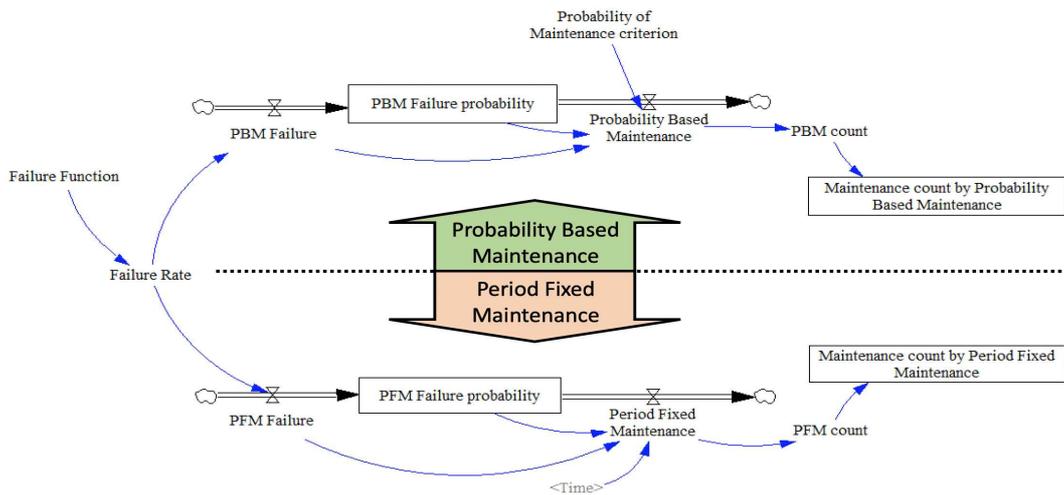


Figure 4. System dynamics model

모델은 크게 2부분으로 나누어진다. Figure 4에서 중앙의 점선을 기준으로 상단은 확률 기반형 정비(Probability Based Maintenance, 이하 PBM)이고, 하단은 기간 고정형 정비(Period Fixed Maintenance, 이하 PFM)이다. 'Failure Rate'는 고장함수('Failure Function')로부터 산출되는 고장량이다. 하단의 기간 고정형 정비는 현재 해군에서 실시 중인 정비 정책이다. 현실의 정책을 반영하여 5개월 운용, 1개월 계획정비를 실시하는 상황을 묘사하였다. 기간 고정형 정비에서는 5개월간 'Failure Rate'에서 들어온 고장량('PFM Failure')이 저장변수인 'PFM Failure probability'에 쌓인다. 6개월 차가 되면 계획정비를 실시하여 쌓여있던 고장량이 모두 해소된다. 기간 고정형 정비는 이와 같이 6개월 단위의 운용과 정비 프로세스를 반복한다. 상단의 확률 기반형 정비는 기간 고정형 정비와 동일하게 고장량('PBM Failure')이 저장변수인 'PBM Failure probability'에 쌓인다. 그러나, 확률 기반형 정비 모델에서는 'Probability of Maintenance criterion' 변수가 계획정비 실시 여부를 판단한다. 'Probability of Maintenance criterion'에서 설정된 수준 이상의 고장이 쌓이면 계획정비를 실시한다. 계획정비를 실시하면 쌓여있던 고장량은 모두 해소된다. 확률 기반형 정비에서 정비 수행 기준은 'Probability of Maintenance criterion'에서 상수로 지정된다. 이 값은 기간 고정형 계획정비 프로세스를 수행하였을 때 실시하는 정비량('Period Fixed Maintenance')들의 평균으로 설정하였다. 이는 총수명주기간 수행하는 정비 총량을 균등하게 배열한다는 의미가 된다.

고장량과 정비량은 서로 인과관계를 가지게 된다. 시스템 다이내믹스에서 인과관계는 사이클을 도는 형태를 가지는데 이를 루프라고 하며(Azar, 2012) 루프들과 변수들이 모여 시스템을 이룬다(Karnopp, 2012). 시스템 다이내믹스 모델의 핵심은 정비 프로세스 루프의 변화이다. 현행 시스템인 기간 고정형 정비 모델은 시간 변수(time)와 쌓여있는 고장량('PFM Failure probability')에 따라 정비량('Period Fixed Maintenance')이 결정되는 인과관계 루프를 가진다. 연구모델인 확률 고정형 정비 모델의 루프는 시간을 변수로 받지 않는다. 확률 고정형 정비 모델은 고장량('PBM Failure probability')과 계획정비 수행의 기준이 되는 'Probability of Maintenance criterion'의 영향을 받는 인과관계 루프를 가진다. 즉, 시뮬레이션 모델을 통해 output 변수의 차이에서 기인하는 인과관계 루프의 변화가 발생시키는 정비효율을 측정할 수 있다. 두 정비모델의 계획정비 횟수를 각각 'Maintenance count by Probability Based Maintenance'와 'Maintenance count by Period Fixed Maintenance'에 저장한다. 이는 총수명주기 동안 계획정비를 수행한 시점과 총 횟수에 대한 정보가 되어 성능 척도로 활용된다.

4. 결과 및 분석

4.1 고장함수 추정 결과 분석

계층형 베이지안으로 추정한 고장함수는 Figure 5와 같다. 그래프에서 가로축은 수명이며 세로축은 비율 조정(scaled)된 수명별 고장확률이다. 그래프의 파랑색 선은 계층형 구조의 최상위층에 해당하는 해군 엔진 전체를 대표하는 고장함수에 해당한다. 보라색 5개 선은 중간층에 해당하는 함정 타입별 고장함수이며, 98개의 초록색 선은 하위층에 해당하는 각 개별 함정 엔진의 고장함수가 된다. 그래프의 전체적인 형태는 과거의 연구에서 논의된 바와 같이 욱조 커브와 비슷한 형태를 보인다.

5년 이하의 수명주기 부분은 욱조 커브와 다른 형태를 보이는데 이는 데이터의 특성에서 기인한다. 본 연구에 사용된 데이터는 군 직접 정비에 해당하는 데이터이다. 건조된 함정은 인수 후에 일정기간동안 조선소의 하자 정비(warranty) 기간을 가진다. 대부분의 초반 고장은 하자 정비로 분류되어 조선소에서 직접 수리를 실시하며 그 외의 고장에 한하여 군이 직접 정비한다. 인수에서 5년까지의 데이터에는 하자 정비에 해당하는 고장이 누락되어 있으므로 실제로는 Figure 5의 초반 부분보다 큰 값을 가질 가능성이 크다. 5년이 지난 함정은 고장확률이 줄었다가 수명이 늘어감에 따라 점차 증가한다. 대략 27년이 지난 후 고장확률은 급격하게 증가한다.

본 연구의 정비 정책 비교 대상 고장함수는 최상위층인 파랑색에 해당하는 해군 엔진 전체를 대표하는 고장함수이다. 타입별 고장함수와 개별 함정에 해당하는 고장함수에 대한 분석은 본 연구에서는 제외하였다. 고장함수 추정에 사용된 계층형 베이지안 통계는 과거의 연구를 통해 입증된 방법론이나, B-spline과 함께 사용하는 경우에는 효과가 입증되었다고 할

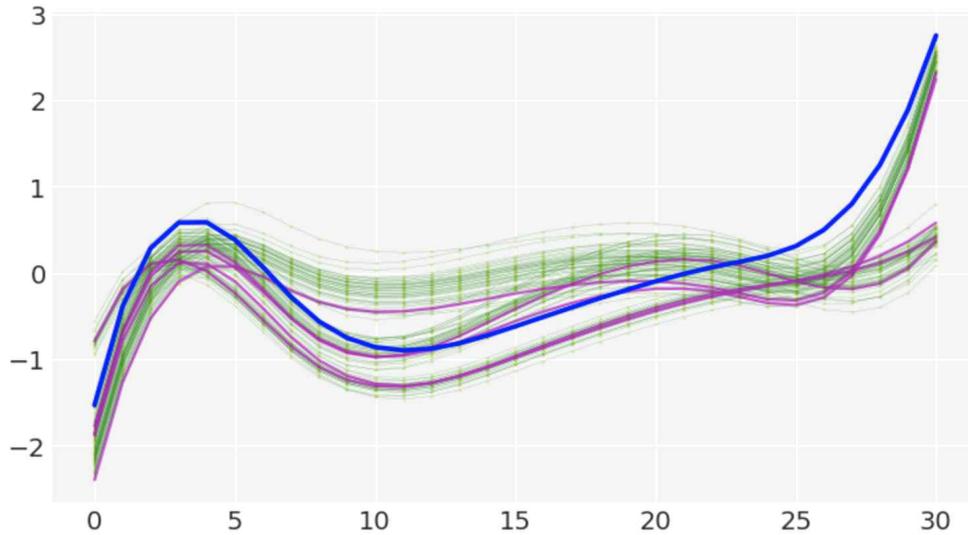


Figure 5. Failure function by hierarchical bayesian model

Table 1. RMSE comparison

Hierarchical model	ARIMA	Prophet
1.0349	1.2587	1.0875

수 없다. 따라서 고장함수를 과거에 성능이 확인된 예측 알고리즘과 비교하였다. 비교모델은 ARIMA(Auto Regression Integrated Moving Average)와 Prophet으로 지정하였다. ARIMA는 과거로부터 성능이 입증되어 널리 연구되었으며, 고장함수 추정에 활용된 연구도 존재한다(Wang and Yin, 2019). Prophet은 세계적인 sns 기업 Facebook에서 개발한 최신 예측 알고리즘으로 푸리에 분할(Fourier decomposition)을 기반으로 시계열 예측에서 우수한 성능을 보인다(Taylor and Letham, 2018). 본 연구의 고장함수와 두 비교모델의 성능을 RMSE(Root Mean Square Error)로 측정하였다(Hyndman and Koehler, 2006). 비교결과는 Table 1과 같다.

RMSE값은 계층형 모델이 비교모델보다 작았다. 계층형 모델은 B-spline의 기저함수, 가중치와 초모수의 정보공유를 통해 예측한다. 즉, 예측에 사용되는 정보량이 비교모델들보다 많기 때문에 정확도가 상대적으로 높았다. 비교모델들은 정보공유가 없으므로 상대적으로 정확도가 낮았다. 해군 엔진의 고장 데이터로 적합한 고장함수의 성능은 과거의 연구에서 입증된 비교모델들에 비해 좋아 본 연구에 활용 가능하다고 판단하였다.

4.2 시스템 다이내믹스 시뮬레이션 결과 분석

함정의 총수명주기 31년을 월 단위로 총 372개월의 정비모델을 시뮬레이션 하였다. 두 정비모델의 수명에 따른 계획정비시의 고장량은 Figure 6와 같고, 통계치는 Table 2와 같다.

기간 고정형 계획정비는 5개월간 쌓인 고장량을 계획정비에서 모두 해소하는 패턴을 반복

하므로 고장함수와 같은 패턴을 따른다. 즉, 매 계획정비 수행 시 수행하는 정비량이 합정

Table 3. Simulation result statistics

Maintenance	Max	Min	Mean	Std.	Period between maintenance		
					Max	Min	Std.
Probability Based	24.02	15.73	18.26	1.56	1.25	0.1667	0.2579
Period Fixed	32.46	1.08	14.32	5.59	0.5	0.5	0

고정량 vs 고정기간 정책의 고장량 비교

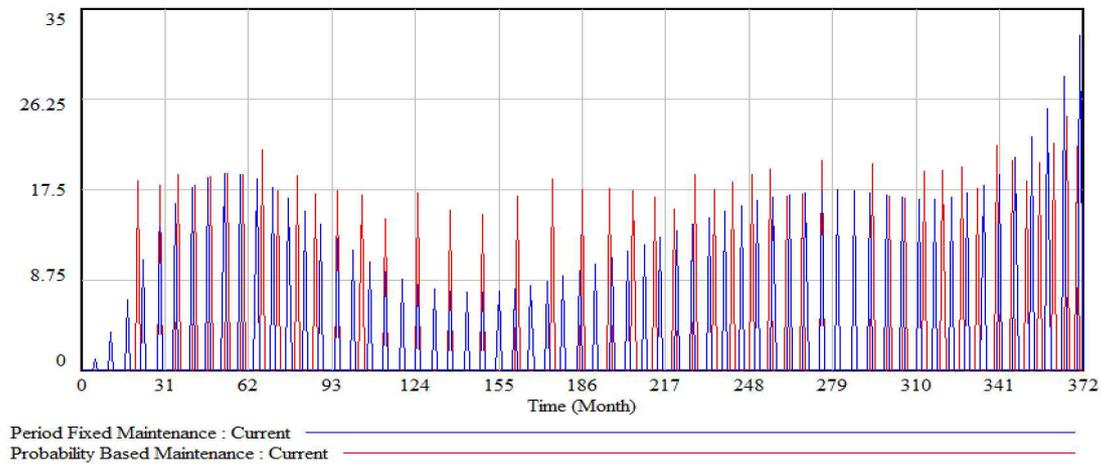


Figure 6. Comparison of planned maintenance between two maintenance processes의 수명에 따라 다르다. 이는 정비를 수행하는 정비부대의 업무부하와 직결된다. 업무부하가 합정의 수명에 따라 늘거나 줄어든다. 고장량이 많은 수명 후반부의 합정이 동시에 정비부대에 입고되면 업무부하가 커져 완전한 정비가 이루어지지 않을 위험이 따른다. 반대로 정비 업무량이 적은 구간에서는 정비부대의 정비능력이 낭비되는 상황이 발생한다.

Figure 6에서 확률 기반형 정비 모델은 정비 실시 간격이 매번 다르다. 고장량이 비교적 많은 초반과 후반구간에서는 계획정비 빈도가 높고, 중반구간에서는 계획정비 빈도가 낮다. Table 2과 같이 확률 기반형 정비의 간격은 최소 0.1667년에서 최대 1.25년까지 변경된다. 확률 기반형 정비 모델은 고장 발생 확률이 큰 구간에서 정비를 자주 실시한다. 한편, 정비량이 총수명주기간 비교적 일정하여 정비부대의 업무부하를 일정하게 유지할 수 있다. Table 2는 계획정비 1회 수행시 평균 정비량을 나타내며 각각 18.26, 14.32로 확률 기반형 계획정비가 기간 고정형 계획정비보다 평균 정비량이 크다. 이는 총수명주기간동안 총 정비량은 같으나, 계획정비 수행횟수에 차이가 발생하였기 때문이다. 이에 대한 분석은 본 내용 뒤에 기술하였다.

표준편차는 차이가 크다. 기간 고정형 정비의 표준편차는 확률 기반형 정비 표준편차의 약 3.6배이다. 이는 정비부대의 업무부하 편차가 크다는 의미이다. 즉, 기간 고정형 계획정비는 정비부대 운용 측면에서 확률 기반형 계획정비보다 비효율적이다. Table 2에서 기간 고정형 계획 정비량과 확률 기반형 계획 정비량의 최대값은 32.46과 24.02이다. 계획정비가 끝

난 시점에 함정의 고장량은 0으로 가정하였으므로 정비량의 최대값은 작전 운용중 함정에 노출된 최대 고장량이 된다. 이는 작전 임무 성공 가능성과 연관된다. 해군 함정은 작전 임무중 고장이 발생하면 임무를 중단하고 모항으로 복귀해야한다. 즉, 기간 고정형 계획정비보다 확률 기반형 계획정비의 작전 임무 성공 가능성이 더 높다.

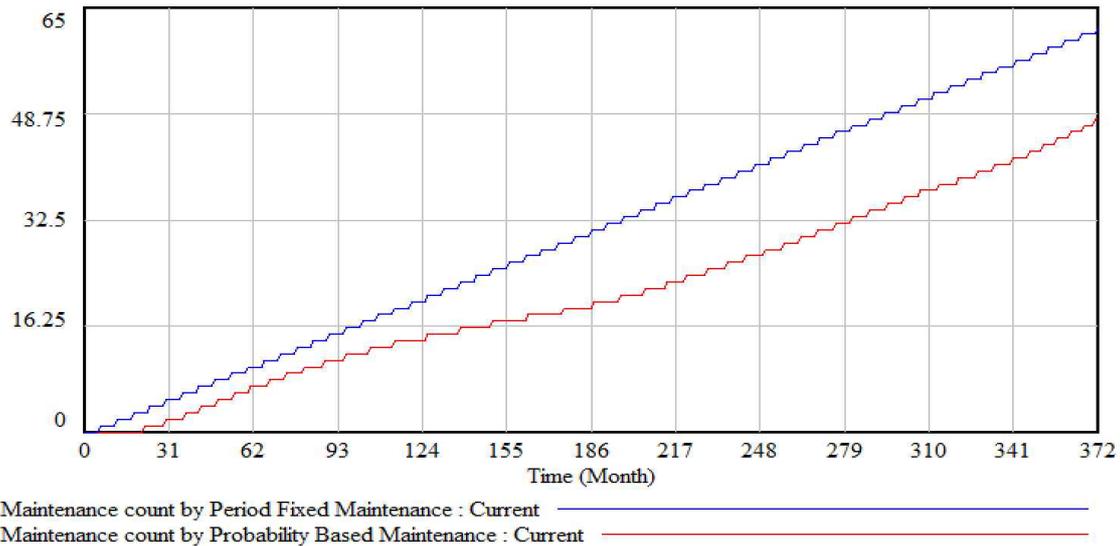


Figure 7. Maintenance count comparison

Figure 7은 총수명주기간 두 정비모델의 계획정비 수행 횟수를 비교한 것이다. 계획정비를 1회 실시할 때마다 y축이 1씩 증가하는 그래프이다. 기간 고정형 계획정비는 5개월마다 계획정비를 주기적으로 수행하므로 그래프도 일정한 계단 형태를 보인다. 확률 기반형 계획정비는 고장함수에서 고장이 잦은 초반과 후반기간에 계획정비를 자주 실시하여 기울기가 상대적으로 크고, 고장이 적은 중반기간에는 적게 실시하여 기울기가 상대적으로 완만하다. 총수명주기간 실시하는 계획정비의 총 횟수는 확률 기반형 정비가 48회, 기간 고정형 정비가 62회이다. 확률 기반형 계획정비를 수행하였을 때 계획정비 수행횟수는 14회(22.6%) 감소하였다. 해군에서는 함정의 상태나 작전 운용 계획에 따라 계획정비 시작 시기를 조금씩 조정하는 경우가 있다. 해군의 계획정비 수행 기록에 따르면 계획정비 입고 시기는 특별한 경우를 제외하면 규정상 기준에서 최대 한 달을 초과하지 않았다. 또 연 2회라는 규정에 따라 입고시기가 늦어지면 다음 입고는 그만큼 일찍 들어가는 경우가 많았다. 즉, 5개월 간격으로 설정된 계획정비 간격을 4~6개월로 유동적으로 변화시키면 보다 현실적인 시뮬레이션이라고 할 수 있다. 그러나, 확률 기반형 정비는 현재까지 수행한 바가 없으므로 이와 같은 현실성을 부여하는데 한계가 있다. 5개월로 설정된 기간 고정형 정비 정책을 시행하는 상황에서 6개월 차에 계획정비를 시작한다면 이는 최대 25% 지연된 것이라고 할 수 있다. 따라서 본 연구에서는 이 비율(25%)을 확률 기반형 정비에 적용하였다. 상수로 고정된 확률 고정형 정비의 계획정비 수행 기준 변수('Probability of Maintenance criterion')에 25%의 동적인 변화를 주고, 1,000회 반복 시뮬레이션하여 총수명주기간 계획정비 수행 횟수에 변화가 있는지 확인하였다. 시뮬레이션 결과 확률 기반형 정비 모델의 계획정비 횟수는 47 ~

50회까지 변화였고($E = 48.2, \sigma = 0.499$), 기간 고정형 정비 모델은 62회로 일정하였다. 기간 고정형 정비 모델의 62회와 비교하여 확률 기반형 정비 모델의 계획정비 횟수는 약 13.8회(22.3%) 감소하였다. 즉, 시뮬레이션에 현실성을 부여하여도 확률 기반형 계획정비를 수행하면 총수명주기간 계획정비 횟수가 줄어든다. 계획정비 수행횟수의 감소는 2가지 의미를 가진다. 첫 번째는 함정의 운용가용도 측면이다. 모델에서 계획정비 1회는 1달을 가정하였다. 총수명주기 중 계획정비 수행 횟수(일수)는 함정의 불가동일수에 해당한다. 예를 들어 총수명주기간 계획정비를 10회 수행하였다면 함정의 불가동일수는 10개월이 된다. 총 372개월의 총수명주기를 고려하였을 때 확률 기반형 정비 모델의 운용 가용도(가동개월수/총수명개월수)는 87.1%이고, 기간 고정형 계획정비의 운용 가용도는 83.3%가 된다. 즉, 확률 기반형 정비 수행시 함정의 운용 가용도는 약 3.8% 향상될 수 있다. 두 번째는 정비예산 절감 측면이다. 본 연구에서는 보안상의 문제로 함정의 1회 정비예산은 공개하지 않는다. 단, 계획정비에 소모되는 예산은 매년 일정한 수준으로 할당된다. 다시 말하면, 횟수 자체를 정비예산과 같다고 이해하는 것에 대한 이견이 발생할 여지가 적다. 현실성을 부여한 시뮬레이션 결과에서 확률 기반형 정비를 수행하면 기간 고정형 정비를 수행하였을 때보다 총수명주기간 계획정비 횟수가 22.3%(13.8회) 적었다. 즉, 확률 기반형 정비를 실시하면 총수명주기간 정비예산을 약 22.3% 절약할 수 있다고 할 수 있다.

5. 결론

해군에서는 일정기간의 작전 운용과 계획정비를 주기적으로 반복하는 개념으로 함정을 운용한다. 본 연구에서는 해군의 고장 데이터를 계층형 베이지안 모델에 적합하여 고장함수를 추정하였다. 고장함수에서는 함정운용초기 조선소 하자수리로 인한 초반의 군 정비 데이터 누락 부분을 제외하면, 과거의 연구를 통해 알려진 바와 같이 욱조모양의 곡선 형태를 보였다. 계층형 베이지안으로 추정한 고장함수는 과거의 연구에서 예측 성능이 입증된 ARIMA, Prophet과 비교하여 RMSE 값이 낮았으므로 본 연구에 활용할 수 있다고 판단하였다. 추정한 고장함수를 시스템 다이내믹스에 적용하였다. 해군에서 시행중인 기간 고정형 정비 모델과 본 연구의 제안모델인 확률 기반형 정비 모델을 비교하여 효과를 검증하였다. 해군은 본 연구결과를 정비정책 결정의 참고자료로 활용할 수 있다.

기간 고정형 계획정비를 확률 기반형 계획정비로 변경하였을 때의 장점은 다음과 같다. 첫째, 계획 정비량이 상대적으로 일정해지므로 정비부대의 업무부하 균일화가 가능하며, 정비인력의 낭비나 과부하를 줄일 수 있다. 둘째, 작전 임무 수행 중 누적되는 최대 고장량을 줄일 수 있으므로 함정 운용중 발생하는 고장으로 인한 작전 임무 실패 가능성을 줄일 수 있다. 셋째, 총수명주기간 계획정비 수행 횟수를 줄일 수 있다. 시뮬레이션에서는 계획정비 횟수가 약 22.3% 감소하였다. 계획정비 예산은 일정한 수준으로 편성되므로 계획정비 횟수의 감소는 계획정비 예산의 절감(22.3%)으로 해석 가능하다. 넷째, 계획정비 수행 횟수의 감소는 함정의 운용 가용도와 직결된다. 시뮬레이션에서 확률 기반형 계획정비로 변경시 약

3.8% 운용 가용도의 상승이 가능함을 확인하였다.

한편, 연구모델은 다음의 한계가 있어 보완시 더욱 실증적인 연구가 가능할 것으로 판단된다. 첫째, 고장함수의 노이즈를 줄이기 위해 B-spline을 적용하여 곡선 추정하였으나 데이터에는 여전히 다량의 노이즈가 포함되어 있을 것으로 판단된다. 관련 군 전문가의 데이터 분석으로 더 정확한 데이터 확보시 더욱 실증적인 고장함수 추정이 가능하다. 둘째, 조선소 하자수리 기간의 고장 데이터 확보가 불가능했다. 때문에 고장함수의 초반구간(0 ~ 5년)에 대한 신뢰도가 다른 구간에 비해 떨어진다. 셋째, 연구모델에서 가정한 5개월 운용과 1개월 계획정비는 연구 모델에서 가정한 수치이며 실제와는 미세한 차이가 있다. 본 연구에서는 이를 보완하기 위해 현실성을 적용하여 계획정비 입고 기준을 25% 유동적으로 적용하였으나 현실을 그대로 반영하였다고는 할 수 없다. 따라서 실제 계획정비 입고 데이터에서 입고 지연에 대한 분포를 도출하여 적용하면 보다 실증적인 시뮬레이션이 가능하다. 넷째, 확률 기반형 계획정비를 수행하면 정비부대의 업무 부하를 평준화 할 수 있으나, 입장 간격이 균일하지 못하다는 이슈가 발생할 수 있다. 시뮬레이션 결과에서 확률 기반형 정비를 수행하면 계획정비간 간격이 최소 0.1667에서 최대 1.25년까지 유동적이었다. 이는 계획정비 시기를 결정함에 있어 큰 유연성을 필요로 하므로 함정 운용 계획을 세우는데 있어 다소 현실성이 떨어지는 결과라고 할 수 있다. 따라서 향후 연구를 통해 기간 고정형 정비와 확률 기반형 정비의 장점을 적절히 반영하는 최적화 모델을 도출한다면, 해군에게 보다 현실성 있는 제안이 될 것이다.

6. 참고문헌

Azar, Ahmad Taher. (2012), *System dynamics as a useful technique for complex systems*, International Journal of Industrial and Systems Engineering 10.4 : 377-410.

Gelman, A. (2006), Multilevel(hierarchical) modeling: what it can and cannot do, *Technometrics*48(3), 432-435.

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*.

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.

Karnopp, Dean C., Donald L. Margolis, and Ronald C. Rosenberg.(2012), System dynamics: modeling, simulation, and control of mechatronic systems, *John Wiley &*

Sans

McElreath, R. (2020), *Statistical rethinking: A Bayesian course with examples in R and Stan*, CRC press. Richardson, George P. Feedback thought in social science and systems theory. University of Pennsylvania

Moon, H-J., Choi, J-W., Lee, H-S. (2020), Failure prediction in hierarchical equipment system: spline fitting naval ship failure, *Stancon 2020(mc-stan.org)*

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.

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*

Taylor, S. J., & Letham, B. (2018), Forecasting at scale. *The American Statistician*, 72(1), 37-45. Thibodeau, Robert, and E. N. Dodson, Life cycle phase interrelationships, *Journal of Systems and Software* 1 (1979): 203-211.

Wang, J., and 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.