

A Study on Estimating the Next Failure Time of a Compressor in LNG FPSO

Sang-Je Cho* · Hong-Bae Jun*[†] · Jong-Ho Shin** · Ho-Jin Hwang***

*Dept. of Industrial Engineering, Hongik University

**Dept. of Design and Human Engineering, UNIST

***Korea Research Institute of Ships and Ocean Engineering

LNG FPSO 압축기 고장시간 예측 방안에 관한 연구

조상제* · 전홍배*[†] · 신종호** · 황호진***

*홍익대학교 산업공학과, **울산과기대 디자인 및 인간공학과

***선박해양플랜트연구소 해양플랜트산업기술센터

The O&M (Operation and Maintenance) phase of offshore plants with a long life cycle requires heavy charges and more efforts than the construction phase, and the occurrence of an accident of an offshore plant causes catastrophic damage. So previous studies have focused on the development of advanced maintenance system to avoid unexpected failures. Nowadays due to the emerging ICTs (Information Communication Technologies) and sensor technologies, it is possible to gather the status data of equipment and send health monitoring data to administrator of an offshore plant in a real time way, which leads to having much concern on the condition based maintenance policy. In this study, we have reviewed previous studies associated with CBM (Condition-Based Maintenance) of offshore plants, and introduced an algorithm predicting the next failure time of the compressor which is one of essential mechanical devices in LNG FPSO (Liquefied Natural Gas Floating Production Storage and Offloading vessel). To develop the algorithm, continuous time Markov model is applied based on gathered vibration data.

Keywords : Condition-Based Maintenance, Offshore Plant, LNG FPSO, Compressor, Continuous Time Markov Model

1. 서론

오늘날 시스템의 운용에 있어서 유지보수의 중요도는 점점 더 증가되고 있다. 이는 개발되는 시스템이 더욱더 복잡해짐에 따라 서버 시스템들 간의 영향도 다양해지면서 보증해야 될 사용시간이 점점 더 증가하기 때문이다. 특히 육상 및 해양 플랜트 시설 및 장비들의 경우에는 고가의 도입비용이 들어가며, 비교적 긴 기간 동안 사용

되고, 단위 시스템의 일부 사소한 문제라도 플랜트 전체의 운용에 막대한 손실을 입힐 수 있는 특성을 가지고 있다. 이러한 특성들로 인해 유지보수 관리의 중요도가 점점 더 커지고 있다. Mobley[26]의 연구에 따르면 시스템의 종류에 따라 다르긴 하겠지만 일반적으로 유지보수 비용은 시스템 가격의 15~60%를 차지한다고 한다. 미국 산업계의 경우 플랜트 장비 및 기자재의 유지보수를 위해서 쏟아 붓는 연간 비용이 2천억 달러를 넘는다고 하며 이 중에서 부적절한 유지보수로 인한 손실비용이 연간 6백억 달러에 이를 것이라고 추정하고 있다[26].

유지 보수방법은 크게 사후 보전과 예방 보전으로 나뉘어진다. 사후 보전은 시스템의 고장을 발견한 이후 보

전 행위를 수행하는 것을 지칭한다. 이에 반해 예방 보전은 제품의 고장이 발생하기 이전에 보전 행위를 수행하는 것을 의미한다. 예방보전은 보전 시기를 결정하는 방식에 따라 시간기반보전(Time-Based Maintenance : TBM)과 상태기반보전(Condition-Based Maintenance : CBM)으로 나누어진다. 시간기반보전은 제품 열화에 가장 비례하는 파라미터(생산성, 작동회수 등)를 바탕으로 수리주기를 미리 결정하고 수리 주기가 도래하면 무조건 수리하는 것으로 기존에 가장 많이 사용하고 있는 보전방식이다. 시간기반보전의 경우 유지 보수의 정책을 결정하는 방법이 비교적 간단하여, 많은 제품에서 이러한 방식을 선호하고 있다. 하지만 시간기반보전은 보전주기와 기능열화주기가 완전히 일치하지 않기 때문에 잔존수명에 대한 손실비용이 발생, 과잉 보전활동이 될 수 있다. 즉, 보전 주기를 길게 설정할 경우 제품의 신뢰도에 대한 문제가 발생하고, 신뢰도를 높이기 위해 보전 주기를 짧게 설정할 경우 과잉 보전으로 인한 비용이 발생한다는 문제가 있다. 또한 보전주기 동안 고장이 발생할 수 있기 때문에 사후보전비용 및 생산손실비용이 발생할 가능성이 항상 존재한다. 일반적으로 시스템 개발 및 생산/판매 회사에서 권고하는 적정 유지보수 주기가 있으나, 이는 실효성이 떨어지고, 또한 시스템 고장시의 손실비용이 큰 경우, 비용 문제에 있어서도 비효율적이다. 이에 반해 상태기반보전은 시스템의 상태 모니터링 데이터를 바탕으로 시스템의 진단을 실시하여 그 결과에 근거하여 보전의 필요와 시기를 결정하는 방안이다. 영국 표준(British Standard)에 따르면 상태기반보전은 “기계의 상태를 나타내는 파라미터(parameter)를 통하여 나타나는 주요한 열화 현상에 대응하는 보수 방안(Maintenance carried out in response to a significant deterioration in a machine as indicated by a change in a monitored parameter of the machine condition).”이라 정의하고 있다[16]. 상태기반보전과 타 보전 방식의 가장 큰 차이점은 제품의 열화 과정에 대한 고려인데, 상태기반보전에서는 제품의 고장은 우발적으로 발생하는 것이 아니라 정상 상태에서 고장 상태에 이르기 전 열화 과정에 따라 증상을 보인다는 가정에서 출발한다[8]. 상태기반보전은 시스템의 현재 상태에 근거하여 보전 시점을 결정하므로, 시스템에 손상이 발생하기 전에 보전을 수행할 수 있고, 또한 시간기반보전의 과잉 보전 문제를 해결 할 수 있다. 따라서 상태기반보전은 리스크 관리에 있어 시간기반보전보다 더 좋은 성능을 보이며, 선호되는 보전방식이다[2]. Durdjanovic et al.[7]에 따르면 상태기반보전의 적용으로 인해 기업들은 약 20%의 생산손실을 막을 수 있다고 한다.

과거에는 시스템의 사용 기간 동안 가시화된 정보를 수집하기 어려웠다. 이러한 이유로 불확실한 시스템 상

태를 근거로 유지보수가 이루어져왔다. 하지만 최근에는 RFID(Radio Frequency Identification), 다양한 센서, 무선 통신 및 PEID(Product Embedded Information Devices), DCS (Distribute Control System), SCADA(Supervisory Control and Data Acquisition) 기술들이 발달함에 따라 시스템의 현재 상태 정보를 모니터링하기가 용이해졌다. 특히 플랜트 산업에 있어서는 마이크로프로세서와 컴퓨터 기반 계장/계측 기술의 발달로 인해 플랜트 장비들의 운용 상태를 모니터링하고 이를 바탕으로 유지보수의 최적화를 도모하는 일이 가능해지고 있다[26]. 따라서 이러한 기술들을 바탕으로 시스템의 상태를 진단하고, 진단 정보를 근거로 향후 상태를 예지하고, 보전 시점을 결정하는 것이 가능해졌다. 이를 바탕으로 상태기반 상태기반보전에 관한 연구가 새로이 조명을 받고 있는 실정이다.

일본 후쿠시마 원전 사고 이후, 화석 연료(원유 및 가스)에 대한 관심과 더불어 육지 석유 자원의 고갈로 인하여 척박한 환경에서 해양 플랜트의 설치가 늘어나고 있다. 해양 플랜트는 척박한 환경 및 협소한 작업 공간, 기후변화 등으로 인한 다양한 위험 요소를 가지고 있으며 사고로 이어지는 경우가 많다[3]. 뿐만 아니라 해양 플랜트는 20~30년에 이르는 긴 수명주기로 인해 건조비용보다 유지보수에 더 큰 노력을 필요로 한다. Lee와 Lee [20]의 연구에 따르면, 해양 플랜트의 경우는 조선소 생산 단계에서의 설계 및 건조 비용보다 인도 이후 해운사의 운영단계에서 필요한 비용이 대부분을 차지하고 있으며, 실제로 LNG(Liquefied Natural Gas) FPSO(Floating Production and Storage Offloading vessel) 시스템의 경우 운용 유지보수 및 검사 비용이 전체 비용의 약 90%로 알려져 있다고 한다. 따라서, 운용단계에서의 효율적인 운용은 해양 플랜트의 사용 가능 시간을 높일 수 있을 뿐만 아니라 운항 및 유지 보수비용을 절감 시킬 수 있다.

최근에 건설중이거나 운전 중인 국내외 해양 플랜트에서는 주요 기기 및 설비의 수명 및 가동률 향상을 위해 효율적인 상태기반 예지 정비 및 관리기법이 도입되고 있다. 즉, 실시간 가동 상태와 정밀 진단을 수행함으로써 운전원에게 최적의 운전 상태를 제시할 수 있으며, 운전 중인 설비에 대한 결함분석과 수명예측을 통해 미리 결함을 제거하고 최적의 유지보수 조건을 결정함으로써 신뢰성 있는 운전과 함께 설비수명의 연장 및 가동률 향상을 위해 체계적이고 효율적인 관리를 수행하고자 하는 것이다. 이러한 이유로 해양 플랜트에서는 기존에 이루어지고 있는 정기 보전보다 보전활동의 신뢰성과 경제성을 크게 개선시킬 수 있는 상태기반 보전 방안의 적용이 필요하다.

본 연구에서는 해양 플랜트 LNG FPSO의 주요 장비 중 하나인 원심식 압축기(Centrifugal compressor)를 대상

으로 상태기반 보전 방안을 제시하고자 한다. 이를 위해 본 연구는 압축기의 진동상태 정보를 기반으로 연속시간 마코프 모델(Continuous Time Markov Model) 이론을 활용하여 현재시점부터 다음 고장까지의 시간을 추정하는 방안을 제시하고, 원심식 압축기에 적용한 사례를 소개할 것이다.

본 연구의 구성은 다음과 같다. 제 2장에서는 상태기반보전과 관련한 기존 연구들에 대해서 살펴본다. 제 3장에서는 본 연구에서 대상으로 하고 있는 원심식 압축기 장비의 특성과 진동데이터에 대해서 살펴보고, 고장이력 및 이상 진동데이터를 기반으로 연속시간 마코프 모델 이론을 이용하여 원심식 압축기의 고장시간을 추정하는 방안을 제시한다. 그리고 제 4장에서는 제시된 방안에 대해 사례 연구를 통해 검증해본다.

2. 기존 연구

유지보수와 관련한 연구들로 그동안 시간기반 예방보전활동에 대한 연구들은 많이 이루어져왔다. 이에 반해 상태기반 보전과 관련한 연구들은 그 중요성에도 불구하고, 시스템의 운용기간 동안의 상태정보를 파악할 기술 체계의 구축이 미흡했던 이유로 연구가 상대적으로 많이 진행되지 못했었다. 본 장에서는 일반적인 상태기반 보전에 대한 기존 연구들과 그리고 본 연구에서 대상으로 하고 있는 해양 플랜트의 유지보수와 관련한 기존 연구들로 나누어 연구동향을 살펴본다.

2.1 상태기반보전 기존 연구

시간기반보전 활동의 단점을 보완하기 위하여 최근에 주목받고 있는 상태기반 보전방법은 온라인 혹은 정기적으로 제품 상태를 점검하여, 그 결과를 미리 예측해 수리여부를 결정하는 방식으로 최근에 발전된 센서기술 또는 휴대형 상태진단장비 등을 활용하여 열화 데이터를 수집, 열화특성 값의 전개 여부를 예측하여 수리여부를 결정하는 방식을 취하고 있다. 상태기반 보전방법은 실질적인 제품의 운용 및 열화 상태에 따라 고장발생 시점을 사전에 예측, 선행보전활동을 수행함으로써 사후보전비용을 최소화할 수 있도록 하는 최신 보전 방식이다. 상태기반 보전방법은 시간기반 보전방법이 가지고 있던 과잉보전, 부정확한 고장 분석, 지체되는 설비 개량 등의 문제를 개선하고, 보전 활동의 신뢰성을 높이며, 경제성을 크게 개선시킬 수 있다.

상태기반 보전기술과 관련해서는 지금까지 몇몇 연구들이 수행되었다. 예를 들어, Goncharenko와 Kimura[9]는

스틸 밴드(steel band)의 금(crack)문제로 인해 고장이 발생하는 현상을 fuzzy logic neural network으로 모델링을 하여 고장이 언제 발생하는지를 예측하였다. Saranga와 Knezevic [29]은 시스템의 신뢰성 예측을 위하여 상태기반 보전 하에 RCP(Relevant Condition Predictor)를 기반으로 하는 방법론을 제시하였고, Lu et al.[24]은 시계열 데이터 분석을 바탕으로 시스템 환경이 동적으로 변화하는 상황에서 실시간으로 신뢰도를 예측할 수 있는 방안에 대해 연구하였다. 또한, Lee[21]은 최신 정보기술과 통계이론을 바탕으로 한 상태기반보전 기술을 제시하고 이를 공작기계 제품에 적용해 보았으며, Grall et al.[10]은 점진적으로 열화되는 단순 구조 기계류 제품에 대한 상태기반보전 체계를 제시하였다. Djurdjanovic et al.[7]은 여러 종류의 센서들과 무선 인터넷 기술을 바탕으로 기계류 제품에 대해 상태기반보전을 수행할 수 있는 와치독(watchdog) 에이전트 개념을 제시하였고, Seo와 Seo [30]은 유전 알고리즘을 이용하여 공장설비의 보전을 위한 최적 검사 간격의 의사결정을 지원하는 새로운 방법론을 제안하였다. Antoine et al.[1]은 고장과 불확실성으로 인한 비용을 최적화하기 위해 최적의 검사와 교체를 결정하는 방안을 제시하였다. 이를 위하여 보전을 수행하여야 한계치와 시스템 상태에 따른 검사 스케줄을 고려하였다. Lin et al. [23]은 진동시그널로부터 유용한 조건 지표(condition indicator)를 추출하고, 추출된 정보를 기반으로 기어박스(gear-box)의 최적보전정책을 개발하기 위하여 비례위험(proportional-hazard) 모형을 활용하였다. 한편, Yang et al.[34]은 로지스틱 회귀분석을 통해 엘리베이터 문 동작 시스템의 성능 모델을 수립한 후, ARMA(Autoregressive Moving Average Model) 모델을 기반으로 잔여수명을 예측하였다. Choe et al.[5]은 가스배관의 결함에 대한 통계처리와 분포 자료를 바탕으로 결함 깊이를 가지고 잔존수명과 사용 신뢰성을 계산하였다. 최대 결함 깊이 분포를 기반으로 배관의 고장실패확률을 예측하였다. 그밖에 Fu와 6인 [8]은 수력 전기 발전 장치의 상태기반 보전에 관한 큰 틀을 제시하였다. 그 큰 틀에서 연구자들은 상태기반 보전에 필요한 필수 3 요소로서 1) 모니터링과 예측, 2) 진단 및 예측, 그리고 3) 의사 결정 체계를 제시하였다. Jun et al.[15]은 자동차의 엔진오일 교환을 위한 상태기준보전 알고리즘을 제시하였다. 그들의 연구에서는 운행중 차량의 엔진오일 상태를 차량 운행 환경에 대한 미션 프로파일(mission profile)정보와 엔진오일 상태를 간접적으로 파악할 수 있는 대표 성능지표들을 가지고 파악하여 이를 바탕으로 엔진오일의 상태를 예측하는 방법을 제시하였다.

본 연구에서 제안하는 마코프 체인을 통한 상태기반보전 연구도 활발하게 이루어져 왔다. Carey와 Dan[4]은

HMMs(Hidden Markov Models)을 이용한 상태기반보전 방안을 제시하였다. 시간에 대한 변화량이 매우 적은 준정적인(quasi-static) 신호를 이용하여 기계의 진단과 예지를 수행하였다. 또한 Suprasad et al.[31]은 마코프 과정을 이용하여 상태기반보전 방안을 제시하였다. 검사 시 상태를 통하여 비용 최적화된 보전 의사 결정을 하고, 검사 스케줄을 최적화하는 방안을 제시하였다.

2.2 해양 플랜트 유지보수 기존 연구

해양 플랜트 유지보수와 관련하여 지금까지 몇몇의 연구들이 수행되어 왔다. Wang과 Majid[33]은 해양 플랜트에서 예방 정비의 효과를 분석한 다음 주요한 하위 구성품(sub-unit)과 주요 예방 정비 활동을 분석한 이후 적절한 유지보수 주기를 결정하는 신뢰성 데이터 분석 및 모델링을 소개하였고, Rouhan과 Schoefs[28]은 해양 구조물의 비파괴 검사에 있어서 고장을 확인할 확률과 고장이 이상 없이 알릴 확률을 의사 결정 계획단계에 반영하기 위해 확률 모형을 제시하였다. 또한, Dey et al.[6]은 태국의 해양에 존재하는 석유 및 가스 파이프라인을 대상으로 다중 기준 의사 결정(multiple-criteria decision-making) 및 가중치 방법(weight method)을 이용하여 리스크 기반의 유지보수 모델을 제시하였다. Moan[25]은 해양 구조물의 설계, 검사, 유지보수, 수리단계의 상호 단계가 강건 설계(design for robustness), 검사 방법의 결정, 스케줄 및 수리 전략에 어떻게 영향을 미치는지 살펴보기 위해 IMMR(Inspection, Monitoring, Maintenance, Repair)에 관한 신뢰성 기반의 관리(reliability-based management)방안에 대하여 연구하였다. 그 밖에 Jang et al.[13]은 선상(On-Board)에서 설비보전, 도면관리 및 유지보수에 필요한 자재 구매 등 관련된 모든 업무를 통합하여 효율적으로 관리할 수 있는 선박, 해양 플랜트용 온보드 설비관리시스템을 소개하였고, Jeon et al.[14]은 MOL(Middle-Of-Life) 단계의 선박제품의 상태기반보전 기법 및 PLM(Product Lifecycle Management) 시스템의 구성 요소로서, 센서와 무선 통신 그리고 마이크로 컨트롤러로 구성된 PEID(Product Embedded Information Device)을 연구하였다. 한편 Park과 Lee[27]은 부식과 도장을 고려한 선체잔여수명 예측시스템을 설계하였다. 연구자들은 수명예측을 위한 시간 의존 부식모델(Time-dependent corrosion wastage model)에 초점을 맞추었다. 설계된 잔여수명 예측시스템에서는 선종별 선체 구조부위별 부식 두께에 대한 기존의 검사치를 통계 확률적으로 처리하여 선체 부식수명을 예측하였다.

지금까지 상태기반보전 관련 기존 연구들과 해양 플랜트 유지보수 기존 연구들에 대해 살펴보았다. 비록 적

지 않은 연구들이 수행되어져 왔지만 아직 미흡한 부분들이 존재하는 것도 사실이다. 그 동안 수행되어 왔던 일반적인 상태기반보전에 대한 연구들은 그 성숙도 수준에 있어서 초보단계에 머물러 있으며[17], 그나마 수행된 연구들 대부분이 특정 센서 데이터에 대한 가공, 처리, 제품 상태 데이터 해석, 현 상황에 대한 통계적 규칙이나 패턴을 찾는 성능진단 및 평가에만 초점이 맞추어져 있고, 과거의 데이터나 사건으로부터 미래에 발생 가능한 상황이나 사건을 예측하여 선제적인 의사결정을 지원하는 예지에 관한 연구는 많이 미흡했다. 해양 플랜트의 유지보수와 관련한 기존 연구들은 그동안 주로 해양 플랜트의 예방 보전에 있어 정기 보전에 치중되어 왔고, 진단에 관한 연구는 많이 있었으나 다음 고장시간을 예지하는 보전에 관한 연구는 미흡하였다. 따라서, 본 연구에서는 이러한 기존 연구들의 문제점들을 해소하기 위해 해양 플랜트 LNG FPSO 주요 장비중에 하나인 원심식 압축기 장비의 진동데이터 해석을 바탕으로 현재 시점에서 다음 고장시점까지를 예측하는 방안을 제시하고자 한다.

3. 문제 정의

본 연구에서는 해양 플랜트 LNG FPSO에 사용되는 원심식 압축기의 진동상태 데이터를 바탕으로 현시점에서 앞으로 critical한 고장이 발생할 때까지의 시간을 예측하는 문제를 다루고자 한다.

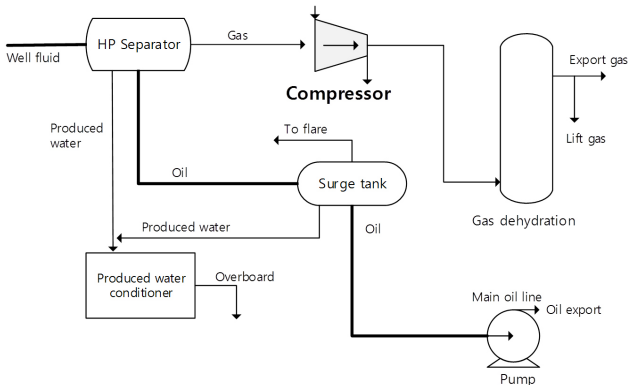
3.1 대상시스템 및 장비 소개

LNG는 천연가스를 가스전에서부터 사용자에게 액화하여 전달하는 방식을 말한다. 가스전에서 채취된 천연가스는 산성가스 및 수분, 그리고 수은을 제거하는 전처리공정을 통과한 후에 중질분을 분리하고, 액화공정에서 LNG로 액화하여 수송선을 이용하여 수요처로 이동된다. 이러한 가스전처리 공정과 액화 및 저장 공정을 육상이 아닌 부유식 해상 플랜트에서 하는 시스템이 LNG FPSO이다[22].

본 연구에서는 해양 플랜트 LNG FPSO의 액화(Liquefaction) 공정의 주요 장비 중 하나인 원심식 압축기를 대상으로 한다. 압축기관 생산공정이나 장비 구동을 목적으로 공기 또는 가스를 압축하는 기기로 LNG FPSO에 사용되는 압축기는 전체 플랜트 내에서 에너지 소비가 가장 큰 부분이다.

본 연구에서 다루고자 하는 LNG FPSO의 주요장비 중의 하나인 원심 압축기는 팬, 프로펠러, 터빈으로 구성되어 있는 터보 기계류에 속한다. 원심 압축기는 고속회전

하는 임펠러의 원심력에 의해 속도에너지를 압력에너지로 변환시켜 압축하는 기능을 수행하며, 원심 송풍기의 구조와 대체적으로 동일하지만 고압력을 내기 위해서는 고속회전으로 운동되어야 하기 때문에 이를 견딜 수 있는 구조로 만들어진다. <Figure 1>은 LNG FPSO에서 압축기가 하는 역할을 PFD(Process Flow Diagram)로 표현한 것이다.



<Figure 1> Process Flow Diagram of Water, Oil, Gas Separation in LNG FPSO

아래의 <Table 1>은 대상 장비인 원심 압축기의 주요 고장원인들을 나타낸 표이다. 주요 원인들 중 회전체/축의 고장원인 비율이 상당히 높으며, 이에 따른 운전 정지 시간도 다른 고장 원인에 비해 상대적으로 긴 것을 알 수 있다. Hussin et al.[11]에 따르면 해양 플랜트에서 사용되어지는 원심식 압축기의 고장 건수가 6년 동안 약 27건에 이르렀다고 한다.

<Table 1> Failures of Centrifugal Compressor[18]

Failure causes	Frequency
Rotation/shaft	22%
Instrumentation	21%
Radial bearing	13%
Blade/impellar	8%
Thrust bearing	6%
Compressor seal	6%
Motor winding	3%
Diaphragm	1%
Etc.	20%
Total	100%

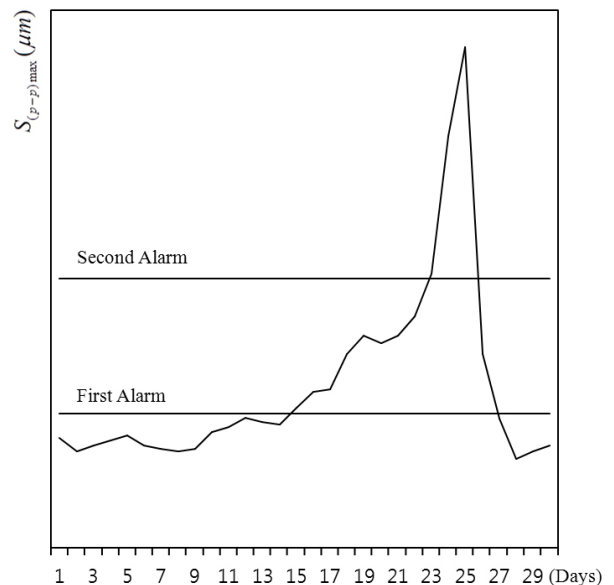
3.2 진동 데이터 특성

압축기와 같은 회전기계의 상태를 예측하려면 상태 변

화에 대해 예민하게 반응하는 파라미터가 필요하다. 상태 예측용 징후 파라미터는 일반적으로 기계가 정상 상태에 있을 때 어느 값의 주변을 랜덤으로 변동하지만 한 번 고장이 발생하면 고장의 진행과 함께 변동하면서 증가해간다[32].

회전체/축의 상태를 모니터링하기 위해서 여러 상태진단 기법들 중 진동 데이터 모니터링 방법이 많이 사용된다. 기계 부품 등의 결함이나 열화 등으로 이상이 발생하면 대부분의 경우, 진동의 크기나 성질이 변화하기 때문이다. 따라서 기계에서 발생하는 진동을 측정하여 크기나 성질의 변화를 분석함으로써 기계를 정지하거나 분해하는 일이 없이 기계상태의 이상 유무를 감시하거나 이상의 내용을 전달할 수 있다[34]. 즉, 진동 시계열 데이터는 고장 시간 예측에 있어 주요 입력 데이터로 활용될 수 있다.

기계 상태의 미소한 변화를 검지(detection)하기 위한 진동 감시의 효과적인 방법 중의 하나는 장시간 또는 단 시간에 걸쳐 시간의 함수로 기계 진동의 변화를 감시하는 것이다. 경향 관리는 수치 값으로 인식할 수 없는 매우 미소한 변화를 사람의 눈으로 시각적으로 파악할 수 있다[34]. 본 연구에서는 진동 신호를 진폭 대 시간으로 취하는 경향 선도(trend plot)를 이용하여 진동 현상을 모니터링하고, 이를 바탕으로 고장 시점을 예측하고자 한다. 경향 선도는 진동 분석에서 주파수 대신 시간을 중심으로 분석하는 방법이다.



<Figure 2> Example of Trend Plot

축진동(Shaft Vibration) 측정에 선호되는 측정량은 진동변위(ISO 7919[12])이다. 보통 회전부의 상대위치와 운

동을 상태 감시하는 경우 진동변위를 많이 사용한다. 축진동의 진동 변위를 평가하는 방안 중 본 연구에서 사용하는 평가 방안은 회전축에 대한 측정 센서들의 두 직교 방향의 양진폭 변위값 중 큰 값으로, ISO 7919[12]는 $S_{(p-p)max} = [S_{A(p-p)}, S_{B(p-p)}]_{max}$ 를 양진폭의 평가 척도로 제시하였다. 여기서 SP-P란 측정방향에서 양진폭(Peak to Peak) 변위를 나타낸다.

ISO 7919[12]에 따르면 산업용 기계, 가스 터빈 세트의 회전 운전 상태를 4가지(A, B, C, D)로 구분하였다 : A : 시운전시, B : 통상 운전시, C : 경보치, D : 정지치. 각 상태의 양진폭(Peak to Peak) 변위의 허용치는 다음과 같다 : A/B : $4800/\sqrt{n}$, B/C : $9000/\sqrt{n}$, C/D : $13200/\sqrt{n}$. 여기서 n 은 최대연속 회전속도(RPM)이다. 본 연구에서는 이 허용치를 참조하여 진동데이터 분석시 고장 및 알람 허용치를 설정하였다.

3.3 문제 해법

본 연구에서는 대상 장비인 LNG FPSO내 원심식 압축기의 고장 시점을 예측하는 방안을 신뢰성 이론과 연속 시간 마코프 모델 이론을 바탕으로 제시하고자 한다. 구체적인 해법 설명에 앞서 주요 notation과 function을 설명하면 다음과 같다.

Notation 설명

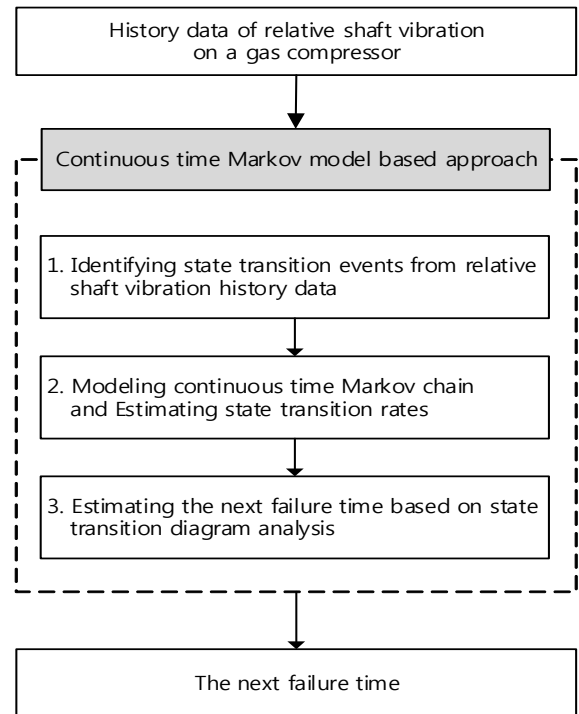
- s 압축기의 상태를 나타내는 index
- $\tau_{ss'}$ s 상태에서 s' 상태로 변화한 횟수
- $t_{ss'}^{(n)}$ 진동데이터가 s 상태에서 s' 상태로 변화한 n 번째 상태 전이에서 s 상태에서 머무른 시간($n = 1, 2, \dots, \tau_{ss'}$)
- $T_{ss'}$ s 상태에서 s' 상태로 변화한 상태 전이의 전이율

Function 설명

$L_S(t|s=S)$ 현재 상태가 S 일 때 최초로 S' 상태로 도달하는 데까지 걸리는 시간의 기대값

LNG FPSO의 가스압축기의 고장 예측 방안은 <Figure 3>과 같이 신뢰성 이론과 대기행렬 이론을 기반으로 하고 있다. 본 연구에서 제안하는 고장 예측 방안은 다음 순서를 따른다.

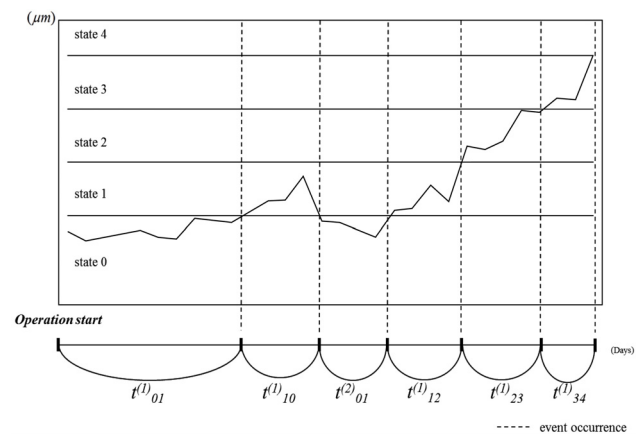
Step 1 : 연속 마코프 프로세스를 활용하기 위하여 진동 데이터를 앞서 언급한 ISO 7919를 기반으로 하여 상태를 구분하였다. 다만 본 연구는 통상 운전시의 원심식 압축기의 진동 데이터를 가정하고 있으므로 시운전시의 허용치는 무시하고자 한다. 또한, 경보단계에서는 다음 고



<Figure 3> Continuous Time Markov Model Based Approach

장 시점의 예측이 통상 운전시 보다 더욱 중요하기 때문에 경보단계에 해당하는 진동 규격을 3등분하여 Low, Middle, High로 나타내었다. 각각의 상태를 나타내는 인덱스는 s 로 나타내고, 본 연구에서는 다음과 같은 5가지의 상태를 대상으로 한다.

- $s = 0$: 통상 운전 상태
- $s = 1$: 경보 상태(Low)
- $s = 2$: 경보 상태(Middle)
- $s = 3$: 경보 상태(High)
- $s = 4$: 정지 상태



<Figure 4> Collecting History Data Classified by State Transition

<Figure 4>는 각각의 상태전이를 어떻게 기록하는지 나타낸다. $t_{ss'}^{(n)}$ 은 진동데이터가 s 상태에서 s' 상태로 변화할 때 s 상태에서 머무른 시간을 의미하고, 이 때 n 은 s 에서 s' 로 변화한 몇 번째 기록인지를 의미한다.

Step 2 : 본 연구에서는 기본적으로 마코비안 특성을 가지는 지수분포에 따라 각 상태전이가 발생함을 가정하고 있다. 이는 진동 데이터가 실제 패턴을 통하여 향후 증가할지 감소할지 파악하기 어렵다는 인터뷰를 바탕으로 가정하였다. $\tau_{ss'}$ 를 s 상태에서 s' 상태로 변화한 횟수라 할 때, 전이율 $T_{ss'}$ 는 아래와 같다.

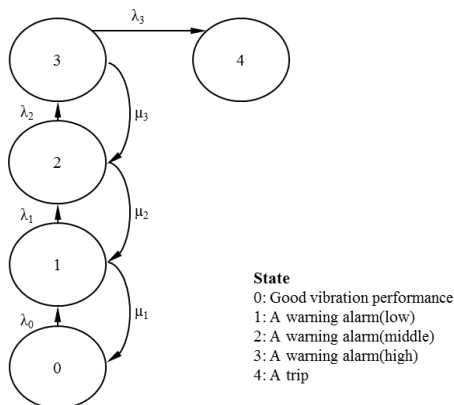
$$T_{ss'} = \frac{\tau_{ss'}}{\sum_{k=1}^{\tau_{ss'}} t_{ss'}^{(k)}} \quad (1)$$

단 $\tau_{ss'}$ 의 수가 충분히 클 경우, 와이블 과정에서 얻어지는 고장 시간에서 마지막 고장 이후 다음 고장의 추정값을 적용할 수 있다[19]. 이 값은 상수값으로 Homogeneous하여 연속 마코프 모델에 사용하는데 있어 무리가 없다.

$$T_{ss'} \equiv \hat{\beta}_{ss'} \cdot \frac{\tau_{ss'}}{\sum_{k=1}^{\tau_{ss'}} t_{ss'}^{(k)}} \quad (2)$$

$$\text{where } \hat{\beta}_{ss'} \approx \frac{\tau_{ss'}}{\sum_{m=1}^{\tau_{ss'}-1} \ln\left(\frac{\tau_{ss'}}{\sum_{k=1}^m t_{ss'}^{(k)}}\right)} \quad (2)$$

본 연구에서는 연속시간 마코프 체인에서 많이 사용하는 파라미터를 이용하기 위하여 $s = s'-1$ 인 경우 $T_{ss'}$ 를 λ_s 라 두고, $s = s'+1$ 인 경우를 $T_{ss'}$ 를 μ_s 이라 둔다.



<Figure 5> State Transition Diagram of Relative Shaft Vibration

Step 3 : <Figure 5>는 본 연구에서 다루는 상태 전이도를 나타낸다. 식 (1)이나 식 (2)를 통하여 도출한 전이율을 통하여 고장 시점의 추정이 가능하다. $L_{S'}(t|s=S)$ 를 현재 상태가 S 일 때 최초로 S' 상태로 도달하는 시간의 기대값이라 하자. $L_{S'}(t|s=0)$ 은 아래와 같다.

$$\begin{aligned} L_{S'}(t|s=0) &= \sum_{x=0}^{\infty} \left[\left(\frac{\mu_{S'-1}}{\lambda_{S'-1} + \mu_{S'-1}} \right)^x \cdot \left(\frac{\lambda_{S'-1}}{\lambda_{S'-1} + \mu_{S'-1}} \right) \cdot x \cdot \right. \\ &\quad \left. \left\{ L_{S'-1}(t|s=S'-2) + \frac{1}{\mu_{S'-1}} \right\} \right. \\ &\quad \left. + \sum_{x=0}^{\infty} \left[\left(\frac{\mu_{S'-1}}{\lambda_{S'-1} + \mu_{S'-1}} \right)^x \cdot \left(\frac{\lambda_{S'-1}}{\lambda_{S'-1} + \mu_{S'-1}} \right) \cdot \frac{1}{\lambda_{S'-1}} \right] \right. \\ &\quad \left. + L_{S'-1}(t|s=0) \right] \quad (3) \\ &= \left[\frac{\lambda_{S'-1} \cdot \mu_{S'-1}}{\left\{ 1 - \left(\frac{\mu_{S'-1}}{\lambda_{S'-1} + \mu_{S'-1}} \right) \right\}^2} \cdot \left\{ L_{S'-1}(t|s=S'-2) + \frac{1}{\mu_{S'-1}} \right\} \right. \\ &\quad \left. + \frac{1}{\lambda_{S'-1}} + L_{S'-1}(t|s=0) \right] \quad (4) \end{aligned}$$

(단 $L_0(t|s=0) = 0$ and $L_1(t|s=0) = \frac{1}{\lambda_0}$, $S' = 2, 3, 4$)

$$L_{S'}(t|s=S'-1) = L_{S'}(t|s=0) - L_{S'-1}(t|s=0) \quad (5)$$

현재 상태가 $S'-1$ 일 때, 다음 상태가 S' 이 되지 못하고, $S'-2$ 가 된 횟수가 x 번일 때, 식 (3)의 첫 번째 항은 $S'-1$ 상태에서 $S'-2$ 상태로 변화하는데 걸린 시간과, $S'-2$ 상태에서 $S'-1$ 상태로 변화하는데 걸린 시간의 기대시간을 의미한다. $L_{S'-1}(t|s=S'-2)$ 는 $S'-2$ 상태에서 $S'-1$ 상태로 변화하는데 걸리는 시간으로 $S'-2$ 상태에서 $S'-3$ 상태로 변화하였다가 이후 $S'-1$ 로 변화하는 시간 또한 계산에 포함되어야 하기 때문에 단순히 $1/\lambda_{S'-2}$ 로 표현하지 못한다. 또한 식 (3)의 두 번째 항은 $S'-1$ 상태에서 S' 상태로 도달하는데 걸린 시간을 의미한다. 마지막으로 식 (3)의 마지막 항은 현재 상태가 0일 때 최초로 $S'-1$ 상태로 도달할 시간을 의미한다.

현재 state가 0, 통상운영 상태일 때, 다음 고장은 $L_4(t|s=0)$ 로 나타낼 수 있고, 다음 식 (6)에 의해 고장 시점의 추정이 가능하다.

$$\begin{aligned} L_4(t|s=0) &= \left[\frac{\lambda_3 \cdot \mu_3}{\left\{ 1 - \left(\frac{\mu_3}{\lambda_3 + \mu_3} \right) \right\}^2} \cdot \left\{ L_3(t|s=2) + \frac{1}{\mu_3} \right\} \right. \\ &\quad \left. + \frac{1}{\lambda_3} + L_3(t|s=0) \right] \quad (6) \end{aligned}$$

식 (6)을 통하여 현재 state가 0일 때 다음 고장을 추정하기 위해서는 $L_3(t|s=2)$ 와 $L_2(t|s=0)$ 을 도출하여야 하는데, 이는 식 (4)와 식 (5)을 통하여 도출이 가능하다.

또한 현재 state가 S일 때, 다음 고장은 아래의 식으로 표현할 수 있다.

$$L_4(t|s=S) = L_4(t|s=0) - L_S(t|s=0) \quad (7)$$

4. Case Study

본 연구에서는 축진동의 $S_{(p-p)max}$ 데이터를 기반으로 제 3장에서 제시한 고장까지 걸리는 시간에 대한 예측 방안의 사례 연구를 보이하고자 한다.

Step 1 : 샘플 데이터는 다음과 같다.

$$\tau_{01} = 28, \tau_{12} = 25, \tau_{23} = 12, \tau_{34} = 5, \\ \tau_{10} = 23, \tau_{21} = 20, \tau_{32} = 7$$

여기서 $\tau_{34} = 5$ 의 의미는 state 3에서 state 4로 넘어가는 이벤트 숫자와 같고, 이것은 즉 고장의 횟수가 총 5번이라는 것을 의미한다.

Step 2 : <Table 3>은 총 28개의 State 0에서 State 1으로 변하는 상태 전이 데이터를 나타낸 것이다. 식 (2)를 통하여 위의 데이터의 척도 모수 $\hat{\beta}_0$ 와 고장률 함수 λ_0 를 추정하면 아래와 같다.

$$\hat{\beta}_{01} \approx \frac{28}{\sum_{m=1}^{27} \ln(620.7828 / \sum_{k=1}^m t_{01}^{(k)})} = \frac{28}{25.3469} = 1.1047 \quad (8)$$

$$\lambda_0 = T_{01} \equiv 28 \cdot \hat{\beta}_0 \cdot \frac{1}{\sum_{k=1}^{28} t_{01}^{(k)}} = 28 \cdot 1.1047 \cdot \frac{1}{620.7828} = 0.0498 \quad (9)$$

위와 같이 기록된 데이터의 수가 충분한 경우 식 (2)을 이용하여 식 (9)과 같이 λ_0 값을 추정할 수 있으며, 같은 방식으로 <Table 3>의 데이터를 통하여 λ_1 값을 추정하면 0.1096이 나온다.

<Table 4>는 5개의 State 3에서 State 4로 상태 변이의 데이터를 나타낸 것이다. 이와 같이 기록된 데이터의 수가 충분하지 않은 경우 $\lambda_2, \lambda_3, \mu_1, \mu_2, \mu_3$ 의 추정은 식 (1)을 이용하여 추정할 수 있다. 다음 식 (10)은 λ_3 값을 추정하는 예를 보인 것이다.

<Table 2> State Transition Data logged from State 0 to State 1

n	$t_{01}^n (days)$	n	$t_{01}^n (days)$
1	27.1491	15	17.21889
2	27.34791	16	31.15123
3	17.95437	17	32.44528
4	25.21705	18	20.52289
5	13.91148	19	18.74831
6	33.20359	20	21.01193
7	9.151745	21	9.606962
8	19.56944	22	22.73098
9	9.906956	23	34.30795
10	7.688598	24	30.91905
11	33.47534	25	30.8892
12	27.22364	26	19.17847
13	30.03122	27	17.50494
14	14.81035	28	17.90596

<Table 3> State Transition Data logged from State 1 to State 2

n	$t_{12}^n (days)$	n	$t_{12}^n (days)$
1	8.067937	14	7.595435
2	12.20144	15	10.65996
3	10.35079	16	12.53101
4	13.47584	17	6.604811
5	10.52834	18	7.568627
6	10.52549	19	11.39907
7	10.80039	20	12.22548
8	11.91516	21	12.61955
9	8.676589	22	10.02284
10	7.986128	23	7.700108
11	13.1235	24	9.362867
12	9.8466	25	12.1726
13	8.1512		

<Table 4> State Transition Data logged from State 3 to State 4

n	$t_{34}^n (days)$
1	4.35639
2	2.76207
3	2.483207
4	2.139931
5	3.797224

$$\lambda_3 = T_{34} \equiv \frac{5}{\sum_{k=1}^5 t_{34}^{(k)}} = \frac{5}{15.5388} = 0.3028 \quad (10)$$

아래의 <Table 5>, <Table 6>, <Table 7>, <Table 8>은 기록된 수가 충분하지 않은 상태 전이 데이터를 나타낸 표이다.

<Table 5> State Transition Data logged from State 2 to State 3

n	$t_{23}^n(days)$	n	$t_{23}^n(days)$
1	4.556848	7	5.292337
2	3.356801	8	4.141467
3	3.341551	9	5.669448
4	4.344885	10	3.596734
5	6.531252	11	5.468217
6	4.750618	12	3.694979

<Table 6> State Transition Data logged from State 1 to State 0

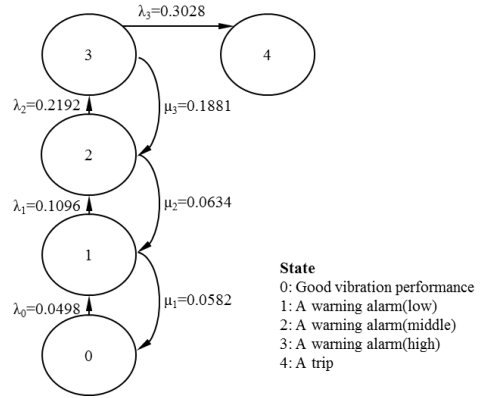
n	$t_{10}^n(days)$	n	$t_{10}^n(days)$
1	23.96633	13	15.09506
2	8.446151	14	16.80681
3	14.45887	15	14.23533
4	21.05506	16	25.16945
5	22.98696	17	12.84559
6	11.9394	18	10.35061
7	16.59663	19	8.336276
8	8.979538	20	25.9142
9	18.73128	21	26.8688
10	27.40702	22	11.79822
11	10.74102	23	14.46904
12	27.86022		

<Table 7> State Transition Data logged from State 2 to State 1

n	$t_{21}^n(days)$	n	$t_{21}^n(days)$
1	21.66717	11	21.71048
2	23.48268	12	10.26189
3	13.28045	13	19.69799
4	6.363142	14	9.717575
5	22.57028	15	24.05417
6	19.67795	16	8.485054
7	17.58114	17	6.44593
8	8.929758	18	20.13992
9	20.61978	19	10.15864
10	6.541435	20	24.06584

<Table 8> State Transition Data logged from State 3 to State 2

n	$t_{32}^n(days)$
1	6.704814
2	8.702715
3	4.046467
4	5.436323
5	6.75059
6	1.258886
7	4.315152



<Figure 6> State Transition Diagram of Sample Data

Step 3 : 이러한 방식을 통하여 나타낸 상태 전이도는 위의 <Figure 6>와 같다.

현재 state가 0, 통상운영 상태일 때, 다음 고장까지 걸리는 시간은 아래와 같이 도출이 가능하다.

$$L_4(t|s=0) = \left[\frac{0.3028 \cdot 0.1881}{\left(1 - \left(\frac{0.1881}{0.3028 + 0.1881}\right)\right)^2} \cdot \left\{ L_3(t|s=2) + \frac{1}{0.1881} \right\} \right] + \frac{1}{0.3028} + L_3(t|s=0) \quad (11)$$

식 (11)을 통하여 현재 state가 0일 때 다음 고장을 추정하기 위해서는 필요한 $L_3(t|s=2)$, $L_3(t|s=0)$ 값은 아래의 과정에 따라 도출할 수 있다.

$$L_3(t|s=2) = L_3(t|s=0) - L_2(t|s=0) \quad (12)$$

$$L_3(t|s=0) = \left[\frac{0.2192 \cdot 0.0634}{\left(1 - \left(\frac{0.0634}{0.2192 + 0.0634}\right)\right)^2} \cdot \left\{ L_2(t|s=1) + \frac{1}{0.0634} \right\} \right] + \frac{1}{0.2192} + L_2(t|s=0) \quad (13)$$

$$L_2(t|s=1) = L_2(t|s=0) - L_1(t|s=0) \quad (14)$$

$$L_2(t|s=0) = \left[\frac{0.1096 \cdot 0.0582}{\left(1 - \left(\frac{0.0582}{0.1096 + 0.0582}\right)\right)^2} \cdot \left\{ L_1(t|s=0) + \frac{1}{0.0582} \right\} \right] + \frac{1}{0.1096} + L_1(t|s=0) \quad (15)$$

$$L_1(t|s=0) = \frac{1}{0.044} = 20.0803(days) \quad (16)$$

식 (16)의 값을 식 (15)에 대입하면 아래와 같다.

$$\begin{aligned} L_2(t|s=0) &= \left[\frac{0.1096 \cdot 0.0582}{\left\{1 - \left(\frac{0.0582}{0.1096 + 0.0582}\right)\right\}^2} \cdot \left\{20.0803 + \frac{1}{0.0582}\right\} \right] \\ &+ \frac{1}{0.1096} + 20.0803 = 29.7616 \end{aligned} \quad (17)$$

식 (16), 식 (17)의 값을 식 (14)에 대입하면, 식 (18)과 같다.

$$L_2(t|s=1) = 29.7616 - 20.0803 = 9.6812(days) \quad (18)$$

또한 식 (17), 식 (18)의 값을 식 (13)에 대입하면, 식 (19)와 같으며,

$$\begin{aligned} L_3(t|s=0) &= \left[\frac{0.2192 \cdot 0.0634}{\left\{1 - \left(\frac{0.0634}{0.2192 + 0.0634}\right)\right\}^2} \cdot \left\{9.6812 + \frac{1}{0.0634}\right\} \right] \\ &+ \frac{1}{0.2192} + 29.7616 = 34.9116 \end{aligned} \quad (19)$$

식 (17), 식 (19)의 값을 식 (12)에 대입하면, 식 (20)과 같다.

$$L_3(t|s=2) = 34.9116 - 29.7616 = 5.1500(days) \quad (20)$$

마지막으로 식 (19), 식 (20)의 값을 식 (11)에 대입하면 다음 고장까지 걸리는 시간은 아래와 같이 추정 가능하다.

$$\begin{aligned} L_4(t|s=0) &= \left[\frac{0.3028 \cdot 0.1881}{\left\{1 - \left(\frac{0.1881}{0.3028 + 0.1881}\right)\right\}^2} \cdot \left\{5.1500 + \frac{1}{0.1881}\right\} \right] \\ &+ \frac{1}{0.3028} + 34.9116 = 39.7809 \end{aligned} \quad (21)$$

만약 현재 state가 1, low 경보 상태라면, 다음 고장까지 걸리는 시간은 식 (16)과 식 (21)에 의하여 아래와 같이

계산되어진다.

$$\begin{aligned} L_4(t|s=1) &= L_4(t|s=0) - L_1(t|s=0) \\ &= 39.7809 - 20.0803 = 19.7005(days) \end{aligned} \quad (22)$$

만약 현재 state가 2, middle 경보 상태라면, 다음 고장까지 걸리는 시간은 식 (17)과 식 (21)에 의하여 아래와 같이 계산되어진다.

$$\begin{aligned} L_4(t|s=2) &= L_4(t|s=0) - L_2(t|s=0) \\ &= 39.7809 - 29.7616 = 10.0193(days) \end{aligned} \quad (23)$$

또한 현재 state가 3, high 경보 상태라면, 다음 고장까지 걸리는 시간은 식 (19)와 식(21)에 의하여 아래와 같이 계산되어진다.

$$\begin{aligned} L_4(t|s=3) &= L_4(t|s=0) - L_3(t|s=0) \\ &= 39.7809 - 34.9116 = 4.8693(days) \end{aligned} \quad (24)$$

지금까지 신뢰성이론과 대기행렬이론을 기반으로 고장시간을 예측하는 방안에 대한 사례연구를 살펴보았다. 제조설비의 P-F(Potential Failure) 곡선을 생각할 때, 시간의 흐름에 따라 상태가 악화되어(즉, s값이 커질수록) 상태 전이율 값이 커지는 현상을 생각해 볼 수 있다. 본 사례연구에서도 <Figure 6>의 λ_s , μ_s 의 수치값의 변화를 보면 s값의 증가에 따라 상태가 점점 더 빨리 악화되는 방향으로 진행됨을 알 수 있다. 식 (3)을 자세히 들여다 보면, 고장까지 걸리는 시간은 λ_s 보다 μ_s 에 더 크게 영향을 받음을 알 수 있다. 즉, μ_s 값의 증가는 고장상태에 최초로 도달하게 되는 평균 시간이 증가하는데 어느 정도 영향을 미침을 알 수 있다. 반면, λ_s 값의 증가의 경우는 상태가 악화되는 확률이 커지게 됨으로 인해서 고장상태에 도달하게 되는 평균 시간을 크게 하는데 영향을 많이 미친다고 말할 수 없다.

5. 결 론

본 연구에서는 LNG FPSO의 Liquefaction 공정의 주요 장비 중 하나인 원심식 압축기를 대상으로 고장시점을 예측 하는 방안을 제안하였다. 제안된 예측 방안은 원심식 압축기의 축진동 데이터를 기반으로 연속시간 마코프 모델 이론을 이용하여 다음 고장시점까지 걸리는 시간을 예측하였다. 본 연구에서 제안한 예측 방안을 잘 활용하게 되면 원심식 압축기 장비의 유지보수 비용의 감소, 장비의 수명 연장, 부품의 교체시기 연장, 작업 환경의 안

정성 증가등과 같은 기대효과들을 얻을 수 있다.

본 연구에서 사용된 연속시간 마코프 모델의 경우 현재의 진동 데이터가 향후 증가할지 감소할지 모른다는 가정하에 이를 확률 모델을 통하여 다음 고장을 예측하였다. 만약 진동 데이터가 향후 감소할지 증가 할지를 판단할 수 있는 요인이 주어진다면 이에 대한 분석을 통하여 보다 정확한 고장 시간을 예측 할 수 있을 것이다. 또한 본 연구에서는 해양 플랜트의 주요 장비중에 하나인 원심식 압축기를 대상으로 고장이력 및 진동 데이터를 바탕으로 고장 시간을 예측하는 방안을 제시하였지만, 플랜트 장비에 영향을 미칠 수 있는 여러 다른 시스템 및 프로세스 파라미터들 (부하, 유량, 온도 속도 등)을 고려한 시스템 차원의 예측 알고리즘을 제시하지는 못했다. 이는 추후 과제로 연구해볼 가치가 있다고 하겠다.

Acknowledgement

이 논문은 2013년도 정부(교육과학기술부)의 재원으로 한국연구재단의 기초연구사업 지원을 받아 수행된 것임 (NRF-2013R1A1A2007505). 또한, 2013학년도 홍익대학교 학술연구진흥비에 의하여 지원되었음.

References

- [1] Antoine, G., Laurence, D., Christophe, B., and Michel, R., Continuous-time predictive-maintenance scheduling for a deteriorating system. *IEEE Transactions on Reliability*, 2002, Vol. 51, No. 2, p 141-150.
- [2] Arunraj, N.S. and Maiti, J., Risk-based maintenance policy selection using AHP and goal programming. *Safety Science*, 2010, Vol. 48, No. 2, p 238-247.
- [3] Bae, J.H. et al., A study on risk quantifying method for the worker accidents of offshore plant considering uncertainty. *Proceedings of the society of naval architects of Korea*, 2012, p 113-118.
- [4] Carey, B. and Dan, M., Condition-based maintenance of machines using hidden markov models. *Mechanical Systems and Signal Processing*, 2000, Vol. 14, No. 4, p 597-612.
- [5] Choe, B.H., Lee, S.H., Kim, Y.P., Kim, W.S., and Ko, Y.T., Probabilistic Assessment of life Time for Gas Pipe Lines. *Proceedings of Trans. Korean Soc. Mech. Eng.*, 2004, p 234-239.
- [6] Dey, P.K., Ogunlana, S.O., and Naksuksakul, S., Risk-based maintenance model for offshore oil and gas pipelines : a case study. *Journal of Quality in Maintenance Engineering*, 2004, Vol. 10, No. 3, p 169-183.
- [7] Durdjanovic, D., Lee, J., and Ni, J., Watchdog agent-an infotronics-based prognostics approach for product performance degradation assessment and prediction. *Advanced Engineering Informatics*, 2003, Vol. 17, No. 3-4, p 109-125.
- [8] Fu, C., Ye, L., Liu, Y., Yu, R., Jung, B., Cheng, Y., and Zeng, Y., Predictive maintenance in intelligent-control-maintenance-management system for hydroelectric generating unit. *IEEE Transactions on Energy Conversion*, 2004, Vol. 19, No. 1, p 179-186.
- [9] Goncharenko, I. and Kimura, F., Remote maintenance for IM. *Proceedings of the first international symposium on environmentally conscious design and inverse manufacturing (EcoDesign'99)*, 1999, p 862-867.
- [10] Grall, A., Dieulle, L., Berenguer, C., and Roussignol, M., Continuous-time predictive-maintenance scheduling for a deteriorating system. *IEEE Transactions on Reliability*, 2002, Vol. 51, No. 2, p141-150.
- [11] Hussin, H., Hashim, F.M., Muhammad, M., and Ibrahim, S.N., A systematic and practical approach of analyzing offshore system maintenance data. *Proceedings of the International Multiconference of Engineers and Computer Scientists*, 2010, Vol. 3.
- [12] ISO 7919, *ISO Standard : Mechanical Vibration of Non-Reciprocating Machine-Measurements on Rotating Shafts and Evaluation*, Technical report, 1996.
- [13] Jang, D.H. et al., Developing the maintenance system for offshore plant and ship. *Proceedings of the society of naval architects of Korea*, 2011, p 1262-1271.
- [14] Jeon, J., Lee, J.H., and Son G.J., Development of PEID for acquiring maintenance information during product lifecycle of marine vessels. *Journal of the Korean society of ocean engineers*, 2012, Vol. 26. No. 5, p 63-72.
- [15] Jun, H.B., Conte, F.L., Kiritsis, D., and Xirouchakis, P., A predictive algorithm for estimating the quality of vehicle engine oil. *International Journal of Industrial Engineering : Theory, Applications and Practice*, 2009, Vol. 15, No. 4, p 386-396.
- [16] Kim, Y.S., *CBM approach for facility equipment*, Technical report. Procon co., No. 2, 2012, p 96-103.
- [17] Koc, M. and Lee, J., A system framework for next-generation E-maintenance systems. *Transaction of Chinese Mechanical Engineer*, 2001, Vol. 12, No. 5.
- [18] Lee, B.J, *Vibration and maintenance handbook for field*

- engineers, Technical report, 1999, p 18-94.
- [19] Lee, H.W., Kim, J.J., Park, S.H., MTBF estimator in reliability growth model with application to Weibull process. *Journal of the Korean Society for Quality Management*, 1998, Vol. 26, No.3, pp 71-81.
- [20] Lee, K.H. and Lee, J.M., A study on augmented reality technologies in the operation and maintenance phase of offshore plants. *Proceedings of the society of naval architects of Korea*, 2011, p 106-111.
- [21] Lee, J., E-intelligence strategies for product and manufacturing innovation. *Transaction of Chinese Mechanical Engineer*, 2001, Vol. 12, No. 5, p 526-531.
- [22] Lee, S.K., State-of-the-art for LNG-FPSO technology. *Journal of the Korean Society of Marine Engineering*, 2012, Vol. 36, No. 1, p 62-78.
- [23] Lin, D., Wiseman, M., Banjevic, D., and Jardine, A.K., An approach to signal processing and condition-based maintenance for gearboxes subject to tooth failure. *Mechanical Systems and Signal Processing*, 2004, Vol. 18, No. 5, p 993-1007.
- [24] Lu, H., Kolarik, W.J., and Lu, S.S., Real-Time Performance Reliability Prediction. *IEEE Transaction on Reliability*, 2001, Vol. 50, No. 4, p 353-357.
- [25] Moan, T., Reliability-based management of inspection, maintenance and repair of offshore structures. *Structure and Infrastructure Engineering*, 2005, Vol. 1, No. 1, p 33-62.
- [26] Mobley, R.K., *An Introduction to Predictive Maintenance*. Elsevier science publisher, 2002.
- [27] Park, S.W. and Lee, H.M., Design of Hull Residual Life Prediction System Considering Corrosion and Coating. *Journal of the society of naval architects of Korea*, 2013, Vol. 50, No. 2, p 104-110.
- [28] Rouhan, A. and Schoefs, F., Probabilistic modeling of inspection results for offshore structures. *Structural safety*, 2003, Vol. 25, No. 4, p 379-399.
- [29] Saranga, H. and Knezevic, J., Reliability prediction for condition-based maintained systems. *Reliability Engineering and System Safety*, 2001, Vol. 71, No. 2, p 219-224.
- [30] Seo, K.K. and Seo, J.H., Decision-making Method of Optimum Inspection Interval for Plant Maintenance by Genetic Algorithms. *Journal of the Society of Korea Industrial and Systems Engineering*, 2003, Vol. 26, No. 2, p 1-8.
- [31] Suprasad, V., Leland, M., and Hoang, P., Cost effective condition based maintenance using markov decision processes. *Proceedings of IEEE Annual Maintainability Symposium on RAMS*, 2006, p 464-469.
- [32] Toshio, T., *Survey on predictive maintenance technologies for production plant*, Technical report. New-tech co., 2010, p 100-108.
- [33] Wang, W. and Majid, H.B.A., Reliability data analysis and modelling of offshore oil platform plant. *Journal of Quality in Maintenance Engineering*, 2000, Vol. 6, No. 4, p 287-295.
- [34] Yang, B.S., *Condition monitoring and diagnostics*, Intervention publisher, 2006.