



공학석사 학위논문

ARMA & GARCH와 회색 이론을 이용한 기계 상태 예지



2013년 2월

부경대학교대학원

메카트로닉스공학과

권 도 운

공학석사 학위논문

ARMA & GARCH와 회색 이론을 이용한 기계 상태 예지





부경대학교대학원

메카트로닉스공학과

권 도 운

박진희의 공학석사 학위논문을 인준함



목 차	
I. 서론 ·····	· 1
1.1 연구 배경	· 1
1.2 연구의 필요성	· 7
1.3 연구 목적	• 8
1.4 논문의 구성	• 8
Ⅱ. ARMA & GARCH와 회색이론 ······	• 9
2.1 사용된 알고리즘	• 9
2.2 회색 이론	• 9
2.3 잔존확률 함수	13
2.4 자기상관계수과 편자기상관계수	14
2.5 ARMA & GARCH ·····	16
2.6 최대 확률 추정	24
Ⅲ. ARMA & GARCH 모델과 회색이론을 이용한 예지 기법	26
3.1 진동 데이터의 개요	26
3.2 기계 실제 진동 심각도의 평가와 예측	26
3.3 기계 결함의 검출과 예측	27
Ⅳ. 감속기 및 압축기에 대한 실험 및 예측 결과	37
4.1 실험	37
4.2 압축기 예측 결과	42
4.3 감속기 예측 결과	47
V. 결론 ·····	57
부록	59
참고 문헌	66

Prognosis of Machine Health Condition using ARMA & GARCH Model and Grey Model

Do-Woon Kwon

Department of Mechanical Engineering, The Graduate School, Pukyong National University

Abstract

GNAT

LUNI

Appropriate strategy of machinery maintenance is one of significant factors to enable companies' owners to improve their product quality and to reduce manufacturing cost. Vibration is considered to be the best operating parameter to judge dynamic conditions such as imbalance (overall vibration), bearing defects and stress applied to components. However, a real severity of vibration may not be correctly recognized due to mechanical and electrical noises from the measuring equipments.

This research presents two prognostic methods for methane compressor and speed reducer. The first is a new method based on Grey model and survival probability for machine degradation prediction, and the second is a novel application of autoregressive moving average (ARMA) and generalized autoregressive conditional heteroscedasticity (GARCH) to evaluate and predict the actual severity of vibration collecting from machines to aid in making more accurate conclusions about their health condition. In this work, ARMA and GARCH models are respectively utilized to specify conditional mean and conditional variance of vibration data. The mutual combination of ARMA and GARCH models will be able to give and accurate or real severity of machinery vibration. The forecasts of combined model, So-called ARMA/ GARCH model, play and important role in making decisions on machine repair or possible improvements in order to reach its maximum run-ability, before any unplanned breakdown.

In the Grey model prediction result, a modification of GM(1,1) has been made to improve the accuracy of prediction, since the model is built by using only four input data. It is able to track closely the sudden change in machine degradation condition. Real trending data of low methane compressor and speed reducer acquired from condition monitoring routine are employed for evaluating the proposed method.

In the ARMA/GARCH prediction model result, it shows more than 90% accuracy. This provides a systematic study of using the ARMA/GARCH prediction model to identify the occurrence and growth of machine fault based on the signal of acceleration peak recorded from a real system of low methane machine in a petrochemical plant and speed reducer in the wind turbine. The quite accurate results indicate the adequacy of the proposed model used in the machine condition monitoring system as well as its application in the CBM system.

제 I 장 서론

1.1 연구 배경

1.1.1 예지의 정의와 유래

기계 건강 상태 진단(Prognosis of Machine Health Condition)분야는 현재 많은 관심을 받고 있다. 진단은 비정상 상태와 결함 주기를 예상하는 정보를 이용한다. 예로부터 예지의 역사와 진단의 역사는 많은 관련성을 가지고 있다.

1) 진단과 예지의 역사 🦯

• 값비싼 컴퓨터 연산이 출현하기 전에 진단은 매뉴얼이나 사람의 경험에 의 존하였다.

디지털 컴퓨터의 출현과 함께, 초기 전문가 시스템은 오일 분석에 기초하
 여 디젤 기관차 엔진 진단을 시도하였다. 사람들은 여전히 진단을 필요로 한
 다.

• 1970년대는 핵 발전소와 같은 고부가 가치 시스템을 위한 장비 상태 모니 터링과 미니컴퓨터를 사용한 온라인 진단을 선보이기 시작했다. 사람의 해석 은 여전히 필요로 하였다.

• 1980년대는 장비 상태 모니터링을 할 수 있는 개인용 컴퓨터 및 디지털 분 석기를 사용을 선보였다. 극단적인 예외로 일부 자동 종료가 포함되기는 하지 만 사람의 개입은 여전히 필요로 했다.

• 1990년대는 군사 전자 제품과 고부가가치 민간 시스템에 추가된 실시간 진 단을 선보였다.

현재는 진단은 자동차, 전자/전기 기계 장치, 항공 등 여러 분야에 널리 퍼져있다. 예지는 구성요소 단계에서 시작되었다. 시스템 전체 예지는 아직 없다. 대체로 예지는 기계가 멈추기 전에 이들이 얼마나 더 사용할 수 있는지를 작업자에 의해 결정된다.

예지에 관한 문헌은 진단하는 사람들에 비해 매우 적은 숫자이다. 하지만, 예지는 현대 산업의 긴급 요구 사항이기 때문에 연구자들에게 더욱 매력적인 주제가 된다.

1.1.2 예지의 기본적인 이해

우리는 종종 실제 생산 설비의 어떤 한 부분의 수명은 두 단계로 나눌 수 있다. 첫 번째 단계는 정상 작동 상태로부터 큰 편차가 없는 정상 작동 단계 라고 한다. 두 번째 단계는 결함 지연 기간이라고 한다. 왜냐하면 결함이 시작 될 수 있고, 점차적으로 실제 고장으로 발전할 수 있기 때문이다. 다시 말해, 이 단계 동안에 기계는 작동하고 있지만 결함 단계에 있는 것이다. 상태 감시 의 활용으로, 장비에 이미 나타난 숨겨진 결함은 발견 될 것이지만 유지 보수 계획을 위해 두 번째 단계의 시작 지점의 예측을 발견할 것이다. 이후에 잔존 수명은 더욱 중요하다. 이것은 Fig. 1.1와 같이 최초에 Christer가 개발한 지연 시간의 개념과 관련 있다.⁽¹⁾



Fig. 1.1 The delay time concept

우리는 초기 지점 u와 지연 시간 h의 길이를 어떻게 찾아내는지에 관심이 있다. 상태 감시를 함으로써, 결함의 심각도 및 잔여 수명에 미치는 영향을 평 가하기가 어렵지만 u를 감지하기는 더 쉬울 수 있다. 즉, 우리는 이용 가능한 상태 정보를 제공하여 잔여 수명을 평가하는데 더 관심이 있다. 예지의 목적 을 달성하기 위해, 세 가지 중요한 단계가 필요하다. 첫째, 결함 또는 이상이 초기 단계에서 감지 할 수 있어야 한다. 둘째, 기계나 시스템 성능이 견고하게 평가되어야하며 지속으로 추적해야 한다. 마지막으로, 남아있는 수명(또는 잔 존 수명)과 기계 또는 시스템의 가능한 고장 모드를 효과적으로 예측해야 한 다. 남아있는 수명을 평가하는 것은 이러한 세 가지 단계에서 가장 중요하다. 왜냐하면 남아있는 수명은 직접적으로 진단의 결정 변수를 제공하기 때문이 다. 하지만 효과적으로 기계요소의 남은 수명을 예측하는 방법들이 존재한다. 수명 예측의 도전들 중 하나는 어떻게 상태 감시 신호에 따라 적절하게 감소 표시를 어떻게 설정하는지 알아보는 것이다. 진동신호는 요소들에 적용되는 응력, 베어링 결함, 언 밸런스와 같은 동적 조건을 판단하는 최고의 작동 요소 로 간주된다. 보통, 시간 특징은 진동 신호의 크레스트 팩터, 평균, 실효치, 첨 도 등이 있고 주파수 특징은 결함 주파수 크기의 평균, 전체 시간에 대한 결 함 주파수 조화 성분 등이 있다. 하지만, 이러한 수치들은 높은 가속도 시험에 서 적합하지 않거나 초기 결함에 낮은 감도를 가진다. 실제로, 비록 매우 다양 한 특징들이 진동신호의 특성을 다른 측면에서 설명하도록 추출할 수 있어도. 이전 연구 작업은 각 특징이 오직 특정 단계에서 특정 결함만 유효하다는 것 을 보여준다. 좋은 성능 평가 방법은 시스템 열화 평가를 위한 여러 가지 특 징들로부터 상호 정보를 활용해야 한다. 또한, 좋은 열화 신호는 기계의 수명 의 다른 단계 동안 기계가 겪는 물리적 변화를 잡아내야 할뿐만 아니라 실제 상황에서 판단하기 쉬워야 한다.

1.1.3 예측 시스템의 목적

신뢰할 수 있는 예측 시스템은 기계의 결함 전파 경향을 예측 할 수 있고 고장이 위험 수준에 도달하기 전에 경보를 제공하는데 매우 유용하다. 온라인 예지 시스템은 적합하게 진단 결과를 증명하고 기술 자료를 수정함으로써 기 계 고장 진단의 신뢰성을 증명하는데 사용될 수 있다.^(2,3)

비용을 절감하고 수리 시간을 단축하기 위해 상태기반 예측 보존은 진단을 하는데 있어 고급 기술을 필요로 하는 현대 산업에 효율적인 전략이 되어왔 다. 예측은 결함이 발생하기 전에 문제를 발견하고 분석하고, 해결하기 위한 목적으로 잘 알려진 공학기술 한계에 대한 기계 성능의 경향을 분석하기 위한 도구이며 예측 보수 수단의 사용이다. 더 향상된 예측은 성능 열화 감시와 평 가에 중점을 두어 결함들을 예측하고 방지할 수 있을 것이다.

1.1.4 예지의 접근법과 연구

예측을 위한 접근법들은 크게 3가지로 분류한다: 통계학적 접근법, 모델 기 반 접근법, 데이터 기반 접근법. 통계적 접근법은 예측 기법의 가장 간단한 형 태로 고장이 발생하기 전에 잔존 기간의 요소들을 나타내는 수많은 구성요소 표본들로부터 통계적 정보를 모집하고 개별적인 요소들의 수명을 예측하는 이 러한 통계값을 사용한다. Yan은 주어진 조건 변수와 고장 예측을 위한 조건 변수와 결함 예측을 위한 조건 변수를 경향으로 하는 자기회귀 이동 평균 시 계열 모델을 통해 결함의 확률을 계산하기 위해 로지스틱 회귀 모델을 사용했 다. 그때 결함 확률의 정해진 레벨은 잔존수명을 예측하는데 사용된다.⁽⁴⁾

모델 기반 접근법은 정확한 수학적 모델들이 물리적인 시스템에서 구축할 수 있는 곳에서 적용된다. 이러한 방법은 시스템의 감지된 측정과 수학적 모 델의 출력 사이의 일관성 검사의 과정의 특징으로 오차를 사용한다. 모델 기 반 접근법은 부품 고장 모드 진행을 이해하기 위해 전통적으로 사용되고 기술 적으로 종합적인 접근 방식을 제공한다. Ray와 Tangirala는 기계 구조물의 시 간에 의존 손상 속도와 축적의 실시간 계산을 위한 피로 균열 역학 비선형 확 률적 모델을 사용하였다.⁽⁵⁾ Li는 베어링 잔존 수명 추정에 대한 기계적 모델링 을 통해 두 가지 결함 감지 모델을 도입하였다.⁽⁶⁷⁾

데이터 기반 접근법은 데이터 마이닝 기법 혹은 기계 학습 기술이라고 알려 져 있다. 이들은 시스템 동작을 학습하는 예지 모델을 구축하기 위해 대량의 과거 고장 데이터를 활용하고 요구한다. 이러한 기술 중에서, 인공지능은 적합 한 모델을 생성하기에 유연성이 있어 주기적으로 사용된다. 많이 존재하는 접 근법들은 시스템을 설계하고 잔존 수명을 평가하기 위해 ANNs을 사용했다. 대부분의 ANN 기법들은 한 단계만 고려하는 시계열 예측 모델들이었다. Wang 과 Vachtsevanos는 산업용 냉각기에 적용할 예측에 대한 구조를 제안 했다⁽⁸⁾. 이런 예지 모델은 다이나믹 웨이블릿 신경망, 강화 학습, 그리고 유전 자 알고리즘을 포함시켰다. 이 모델은 진동 신호를 기반으로 베어링 결함의 성장을 예측하는데 사용되었다. Table 2.1 List of prognosis methods, their advantages and disadvantages.

Approaches	Advantages	Disadvantages
Statistical approaches	 Do not require condition monitoring Population characteristic in- formation enable Can be trained to recognize the types of faults 	• Only provide general, overall estimates for the entire pop- ulation of identical units
Model-based approaches	 Can be highly accurate Require less data than da- ta-driven approaches 	 Real-life system physics is often too stochastic and complex to model. Simplifying assumptions need to be examined. Various physics parameters need to be determined.
Data-driven approaches	 Do not require assumption or empirical estimation of physics parameters Do not require a priori knowledge 	• Generally required a large amount of data to be accu- rate

1.1.5 문제점과 해결책

데이터 기반 기술은 데이터를 다른 기술들에 비해 효율성이 우수한 것으로 고려된다. 예를 들어, 복잡한 기계 시스템에서, 모델 기반 접근법은 데이터 기 반 접근법이 기계 작동 조건의 과거와 현재 데이터만을 사용하는 동안에 수학 적 모델을 결정하기 어렵다는 것을 보여 준다. 또한, 이번 연구는 진동 데이터 를 사용하여 데이터 기반 방법을 사용하는데 초점을 맞추고 있다. 진동 기반 결함 예측은 많은 문헌들에서 충분하게 참조하였다. 예를 들어, Vachtsevanos 와 Wang은 베어링의 시간에 따른 결함을 예상하기 위해 동적 웨이블릿 신경 망 회로를 사용하였다; Huang 등은 SOM과 백 프로퍼게이션 신경망 방법등 을 적용하여 볼 베어링의 잔존 수명을 예측하는데 적용하였다⁽⁹⁾; Wang은 리 커런트 신경망과 ANFI 시스템을 결과를 비교하고 활용하여 회전 기계의 손상 열화를 예측하였다⁽¹⁰⁾; Satish와 Sarma은 퍼지로직과 신경망을 결합하여 소용 및 중형 유도전동기의 베어링의 잔존 수명을 예측하였다⁽¹¹⁾; Tran은 기계의 작동 상태를 예측하기 위한 예측 모델로서 회귀나무를 사용한 데이터 기반 예 측 방법과 one-step ahead 예측 방법론을 제안하였다⁽¹²⁾. 이러한 접근법들은 주로 다음 값을 예측하는데 사용할 수 있는 진동 관측에 맞는 전문가 시스템 이나 모델을 알아내는데 집중한다. 하지만, 아직 처리되지 않은 몇 가지 문제 가 있다.

• 예측 결과의 신뢰성이 낮다: 진동은 가장 변하기 쉬운 신호의 한 종류이다. 진동 변동은 측정 방법 중 기계의 소음이나 작동 주기로 이루어져 있는 취득 장비뿐만 아니라 측정 방법에 따라 달라진다. 진동은 증가하는 마모 심각도 및 결함의 발생으로 기계 수명 이후 기간에 훨씬 더 변동하기 쉽게 된다. 예 지는 유지보수가 가능한 일정에 조기에 결정이 되어야 유용하다. 따라서, 심하 게 변화하는 진동의 경향을 정확하게 예상할 수 있는 전문가 방법의 예지를 알아내는 것은 여전히 이론적인 것이다.

•실제 진동 심각도는 제대로 계산될 수 없다. 진동 심각도는 같은 작동 조건 하에 각은 지점에서 비슷한 기계로부터 가능한 수치나 일정 기간 동안 동일한 지점에 대한 기준 값과 ISO 표준에 제정된 기준을 현재 전체 진동 수치와 비 교하여 평가된다. 그러나 원래 진동의 매우 변하기 쉬운 성질은 진동 심각성 의 잘못된 평가를 내리게 된다. 또한, 위에서 언급한 다양한 고장 메커니즘의 정의에 따라, 단순히 기존의 접근 방식은 다양한 사용자의 목적에 만족하는 충분한 유연성을 가지고 있지 않다.

이번 연구에서, ARMA & GARCH 모델은 이러한 단점을 극복하기 위해 사용된다. ARMA 모델은 조건부 분산 GARCH 모델에서 조건부 평균은 지속적

으로 발달하는 마모와 결함의 변화하는 추이에 대한 기계 동작을 설명하는데 사용할 수 있다. 실제 진동 심각도는 ARMA & GARCH 예측 모드로부터 조 건부 평균과 조건부 분산 사이를 결합한 유용한 데이터를 사용함으로써 평가 하고 전망할 수 있다. 또한, 이 연구는 결함 진단으로서 어떤 종류의 결함인지 명시하지는 않지만, 제안된 모델은 가속도 포락처리를 사용하여 고주파수 결 함의 발생과 성장하는 것을 확인하는데 사용할 수 있다.

1.2. 연구의 필요성

예측은 상태기반 유지보수(CBM) 시스템의 매우 중요한 부분이다. 예측을 연구하는 필요성은 산업 업계에서 CBM 시스템의 필요성으로서 간주된다. 유 지 보수 전량 중: 교정 유지보수, 예정된 유지보수, 상태지반 유지보수(CBM), CBM은 기계 상태를 결정할 수 있는 다른 방법들 보다 더 우수하다고 여겨진 다. CBM 시스템은 현대 산업에서 점점 더 중요한 역할을 담당해 왔다. 미국 의 공업 회사의 유지 보수 비용은 1979년부터 10~15%씩 매년 증가하고 있다. 특정 산업에 따라, 유지 보수 비용은 생산 제품의 비용의 10~40%가 넘는 값 사이에서 나타낸다⁽¹³⁾. 예를 들어, 총 부가가치 비용의 비율로서 유지 보수 비 용은 광업에서 20~50%, 기본 금속에서 15~25%이며 가공 및 제조 산업에서 3~15%이다⁽¹⁴⁾. Knights와 Oyanader의 연구에 따르면 세계의 주요 구리 생산 에서 유지 보수 비용은 총관산 생산 비용의 44%로 평가된다. 마찬가지로, 이 러한 유지 보수 비용의 20~40%는 주요 구성 부품의 수리와 관련이 있다. 따 라서 주요 시스템 복구 피용은 전체 운영 비용의 9~18%로 간주한다. 우리는 훌륭한 CBM 시스템으로부터 얻을 수 있는 이점들이 있다.⁽¹⁵⁾

- 유지 보수 비용을 줄일 수 있다.
- 장비 신뢰성 및 가용성을 향상시킬 수 있다.
- 장비 중단 시간을 줄일 수 있습니다.
- 관찰 시스템의 서비스 수명을 연장한다.
- 시스템 상태의 지속적인 평가를 제공한다.
- 운영 안전성을 향상시킬 수 있다.

- 결함 심각도를 줄일 수 있다.
- 가장 치명적인 오류를 제거하려고 한다.
- 유지 보수 주기를 연장한다.
- 기술자 교육 요건을 줄여준다.

위의 이점을 달성하기 위해, CBM 시스템의 정밀도나 신뢰성을 향상시키는 예지의 지능적인 방법을 알아내는 것이 반드시 필요하다.

1.3 연구 목적

이번 연구는 기계 건강 상태의 미래 상태를 평가하고 예고하는 지능형 방식 으로서 ARMA & GARCH 모델과 회색 이론을 활용하는 것을 목표로 한다.

- 목표는 다음과 같다.
- 진동의 RMS와 1X 성분을 사용하여 실제 진동 심각도를 평가하고 예측한다.
- 신호처리를 통한 기계의 결함을 감지한다.
- 기계 건강 상태를 예측하고 예고하는 ARMA & GARCH 모델과 회색 모 델의 새로운 지능형 응용법을 알아본다.
- ARMA & GARCH 모델과 회색 모델의 장기간 예측의 정확한 결과는 잔 존수명을 계산하는데 매우 유용하다.
- 본 연구의 성공적인 결과들은 기계 건강 상태의 신뢰할 수 있는 평가와 CBM 시스템이 실제 응용하는데 더 유용할 수 있도록 제공한다.

23

제Ⅱ장 ARMA & GARCH와 회색이론

2.1 사용된 알고리즘

본 논문에서는 회색이론, ARMA & GARCH에 관하여 배경 이론들을 소개 한다.

2.2 회색 이론

회색 모델은 시계열의 예측값을 계산한다. 회색 시스템 이론의 목적은 이용 가능한 데이터를 사용한 시스템의 현실적인 관리 방법을 추출할 수 있다는 것 이다. 이 과정은 회색 순서의 발생이라고 알려져 있다.

회색이론이란 중국의 등취룡 교수가 제창한 기법이다. 명백히 되어 있는 것 을 '백색', 완전히 불분명한 것을 '흑색'이라고 부르고, 애매한 상태를 '회색'이 라고 부른다. 예를 들면, 인체에 대한 외관의 정보, 신장, 체중 등은 기지의 사 실로 '백색'이지만, 인체의 정보 네트워크, 인체의 효능 구성 등은 부분적으로 미지이므로 '회색'이 라고 할 수 있다. 정보를 완전히 알고 있는 '백색'과 정보 를 완전히 모르는 '흑색'을 함께 갖고 있는 회색이론에서의 예측은 '회색' 상태 라고 본다.

그래서 회색이론에 의한 예측에는 다음의 다섯 가지가 있다.

(1) 수열예측

일련의 값(시계열 데이터)에 대한 대소의 크기 변화를 예측하는 것을 말한다.

(2) 재해예측

재해를 일으킬 것 같은 한계값을 초월하는 이상값이 언제 또 나타날지를 예 측하는 것을 말한다.

(3) 계절재해예측

일반적으로 1년의 어떤 특징 시기밖에 발생하지 않는 재해변화의 출혂을 예 측하는 것을 말한다.

(4) 위상예측

어떤 일정기간의 시계열 데이터의 파형이 다음에 어떻게 변화해 갈 것인지 를 예측하는 것을 말한다.

(5) 시스템 종합예측

요인이 되는 각 요소의 동태관계를 찾아내어 시스템 전체의 변화를 이해하 고 예측하는 것을 말한다.

시계열 데이터의 예측은 회색예측 중의 수열예측을 가리킨다. 또한 회색이 론에서의 예측의 특징으로서 적은 데이터라도 예측이 가능하기 때문에, 결손 값 또는 결측값이 많은 경우나 과거의 축적 데이터가 적은 경우, 데이터가 적 어 규칙을 발견하기 어려운 경우 등에 유용하다.

실제로, GM(n,m)은 회색 모델의 기본적인 표시방법이다. 여기서 n은 차분 방정식의 순서이고, m은 변수의 개수이다. 비록 대부분의 연구자들이 GM(1,1) 모델에 집중하고 있지만 다양한 형태의 회색 모델들이 고려될 수 있 다. 그 이유는 계산 효율 때문이다. CH 21 मी

2.2.1 GM(1,1)

Grev 모델 GM(1.1)은 아래의 세 가지 기본 연산을 가지는 시계열 예측 모 델이다.

- Accumulated generation opeation
- Inverse accumulated generation
- Grev model

Grev 예측 모델은 미분 방정식을 만드는 accumulated generation의 연산을 사용한다. 본질적으로 더 적은 데이터를 요구하는 특징을 가지고 있다. (16,17)

Step.1 : 초기 시간 순서

Step.2 : 초기 순서 $X^{(0)}$ 에 기초하여, 새로운 순서 $X^{(1)}$ 은 모델을 만드는 중 간 메시지를 입증하고 변화 추이를 약하게 하기 위한 accumulated generating 연산을 통해 설정된다.

식 (2.8)로부터 이것을 구하게 되면

$$\begin{bmatrix} x^{(0)}(2) \\ x^{(0)}(3) \\ \vdots \\ x^{(0)}(n) \end{bmatrix} = \begin{bmatrix} -Z^{(1)}(2) & 1 \\ -Z^{(1)}(3) & 1 \\ \vdots & \vdots \\ -Z^{(1)}(n) & 1 \end{bmatrix} \begin{bmatrix} a \\ b \end{bmatrix},$$
(2.6)
a \varphi b \varphi d \vec{U} S \vec{L} = \vec{A} \vec{U} S \vec{L} = \vec{A} \vec{L} = \vec{L} = \vec{A} \vec{L} = \vec{L}

$$Y_n = [x^{(0)}(2), x^{(0)}(3), \dots, x^{(0)}(n)]$$
(2.7)

$$B = \begin{bmatrix} -Z^{(1)}(2) & 1 \\ -Z^{(1)}(3) & 1 \\ \vdots & \vdots \\ -Z^{(1)}(n) & 1 \end{bmatrix}$$
(2.8)

여기서 Y_n과 B는 각각 정벡터와 accumulated 행렬이다. 또한 아래 식을 얻는다

식(2.10)~(2.13)에 근거하여 식(2.9)를 일반적인 최소 자승법에 적용하면 계수 A는 아래와 같이 나타낼 수 있다.

$$A = (B^T B)^{-1} B^T Y_n (2.11)$$

Step 4. 식 (2.11)과 식(2.5)에 A를 대체하면, 근사 방정식은 다음과 같다.

$$\hat{x}^{(1)}(k+1) = (x^{(0)}(1) - \frac{b}{a})e^{-ak} + \frac{b}{a}$$
(2.12)

여기서 $\hat{x}^{(1)}(k+1)$ 은 시간 (k+1)의 $x^{(1)}(k+1)$ 의 예측 값이다.

식(2.12)에 역 accumulated generating 연산 완료 후에 시간 (k+1)에 $x^{(0)}(k+1)$ 의 예측값 $\hat{x}^{(1)}(k+1)$ 은 아래와 같다.

$$\hat{x}^{(0)}(k+1) = \hat{x}^{(1)}(k+1) - \hat{x}^{(1)}(k)$$
(2.13)

2.2.2 GM(1,1)의 수정

CA

여기서 제시될 방법은 예측의 정확성을 향상시키기 위해 계산과정을 수정하였다. 다음 절차에 따라 할 수 있다.⁽¹⁸⁾

1. *m*값을 적용한 식(2.13)에 순서대로 값을 추가한다. *m*은 수정된 예측 값 의 개수이고, 임의의 값이다. *k*=*n*일 때, 식(2.13)은 다음과 같다

$$\hat{x}^{(1)}(n+i) = (x^{(0)}(1) - b/a)e^{-a(n+i-1)} + b/a \quad i = 1, 2, ..., m$$
(2.14)

2. 따라서, 식(2.14)는 식(2.15.a)에서 m의 개수에 따라 예측값을 증가 시킬 수 있다. 이 방정식은 식(2.14)로부터 유도되었다. 결국, 예측 값의 최종 결과 는 식(2.15.b)에 도시 된 대로 예측값 m의 평균값을 취함으로서 결정될 수 있 다.

$$\hat{x}^{(1)}(n+i) = \hat{x}^{(1)}(n+i) - \hat{x}^{(1)}(n+i-1)$$
(2.15.a)

 $\hat{x}^{(0)}(n+i)=$ 의 예측 값은

$$\left(\frac{1}{m}\right)x\left[\hat{x}^{(0)}(n+1)+\hat{x}^{(0)}(n+2)+\ldots+\hat{x}^{(0)}(n+m)\right]$$
(2.15.b)

2.3 잔존확률 함수

S(t)로 표시되는 잔존 함수는 시간 t까지 각각의 요소나 구성 요소들이 살 아남는 확률로서 정의된다. 우선 간단한 경우를 살펴보면, 모든 요소들이 고장 이 발생하는 시간이 정확하게 알려진 경우다. $t_1, t_2, ..., t_n$ 이 n요소들의 잔존시 간으로 하면, 잔존 함수는 다음과 같이 계산된다.⁽¹⁹⁾

$$S(t) = \frac{N - D_t}{N} \tag{2.16}$$

여기서 N은 요소들의 총 개수이고, D_t 는 시간 t까지 고장이 발생한 요소들의 수이다.

반면에, 구성요소나 시스템이 아직 고장이 발생하지 않았다면 잔존시간은 아직 알지 못한다. 이 경우에, 잔존함수는 다음과 같은 방정식을 사용하여 평 가할 수 있다.

$$S(t) = \exp[-(c \ e(t))]$$
(2.17)

여기서 c는 상수값이고, e(t)는 error indicator라고 불리며 다음과 같이 정의 된다.

$$e(t) = \sqrt{\frac{\sum_{i=1}^{n} (d_i)}{n}}$$

(2.18)

여기서 n은 데이터의 총 개수를 표현하고 d는 정상 상태의 극한값과 상태감 시 데이터의 분산 값이다.

2.4 자기상관계수과 편자기상관계수

2.4.1 자기상관계수

시계열 데이터 $\{x(t)\}$ 에 있어서 다음의 상관계수를 1기 떨어진 자기상관계수 또는 1차의 자기상관계수(autocorrelation coefficient) ρ_1 이라고 한다.

•••	x(t-1)	x(t)	x(t+1)	x(t+2)	•••
•••	x(t-2)	x(t-1)	x(t)	x(t+1)	•••

시계열 데이터 {x(t)}에 있어서 다음의 상관계수를 2기 떨어진 자기상관계수 또는 2차의 자기상관계수 ρ_2 라고 한다.

	x(t-1)	x(t)	x(t+1)	x(t+2)	
•••	x(t-3)	x(t-1)	x(t-1)	x(t)	•••

시계열 데이터 {*x*(*t*)}에 있어서 다음의 상관계수를 *k*기 떨어진 자기상관계수 또는 *k*차의 자기상관계수 *p*_k라고 한다.



일반적으로 m차의 표본자기상관계수를 ρ_m, m 차의 모자기상관계수를 $\rho(m)$ 이 라고 표기한다.

자기상관계수를 그래프로 표현한 것을 자기상관 플롯 또는 코레로그램 (correlogram)이라고 한다. 시계열분석에서는 없어서는 안 될 도구의 하나이 다.

2.4.2 편자기상관계수

편자기상관계수(partial autocorrelation coefficient)의 정의는 그렇게 간단하 지는 않다. *ρ*₁,*ρ*₂,*ρ*₃를 각각 1차, 2차, 3차의 자기상관계수라고 하면,

1차의 편자기상관계수
$$\Phi_{11} = \frac{|\rho_1|}{|1|} = \rho_1$$
 (2.20)

2차의 편자기상관계수
$$\Phi_{22} = \frac{\begin{vmatrix} 1 & \rho_1 \\ \rho_1 & \rho_2 \end{vmatrix}}{\begin{vmatrix} 1 & \rho_1 \\ \rho_1 & 1 \end{vmatrix}}$$
 (2.21)

3차의 편자기상관계수
$$\Phi_{33} = \frac{\begin{vmatrix} 1 & \rho_1 & \rho_1 \\ \rho_1 & 1 & \rho_2 \\ \rho_2 & \rho_1 & \rho_3 \end{vmatrix}}{\begin{vmatrix} 1 & \rho_1 & \rho_2 \\ \rho_1 & 1 & \rho_1 \\ \rho_2 & \rho_1 & 1 \end{vmatrix}}$$
 (2.22)

여기에서 | |은 행렬식을 의미한다.

요컨대, *k*차의 편자기상관계수는 1기부터 *k*-1기까지의 영향을 제거한 다음 의 상관계수를 의미한다.

ANDIA

편자기상관계수의 그래프 표현을 편자기상관 플롯이라고 한다. 자기상관 플 롯과 마찬가지로 시계열분석의 필수 도구이다.

일반적으로 편자기상관 플롯은 자기상관 플롯과 쌍으로 이용한다.

2.5 ARMA & GARCH

2.5.1 자기회귀-이동평균과정 (autoregressive-moving average; ARMA) 1) ARMA(p,q) 모형

정상시계열 데이터

에 있어서

시점 t의 값
$$x(t)$$
가 백색잡음(white noise) $u(t)$ 를 이용해서

$$x(t) = a_1 x(t-1) + a_2 x(t-2) + \cdots + a_p x(t-p) + u(t) - b_1 u(t-2) - \cdots - b_q u(t-q) + u(t-2) - \cdots - b_q u(t-q) + u(t-2) - \cdots - b_q u(t-q) + u(t) - b_1 u(t-2) - \cdots - b_q u(t-q) + u(t-2) +$$

로 표현될 때, 이 식을 자기회귀이동평균 ARMA(p,q) 모형이라고 한다.

실제로는

ARMA(1,1) 모형 ARMA(2,1) 모형 ARMA(1,2) 모형

등과 같이

 $p=0,\,1,\,2\qquad q=0,\,1,\,2$

의 경우를 취급하는 경우가 많다.



성질 2.1기 앞의 예측값 $\hat{x}(t,1)$

$$\hat{x}(t,1) = a_1 x(t) - b_1 \{ x(t) - \hat{x}(t-1,1) \}$$
(2.46)

성질 3. 1차의 자기상관계수 ρ₁

$$\rho_1 = \frac{(1 - a_1 b_1)(a_1 - b_1)}{1 - 2a_1 b_1 + b_1^2} \tag{2.47}$$

성질 4. m차의 자기상관계수 ρ_m

$$\rho_m = a_1^{m-1} \rho(1) \tag{2.48}$$



이것들은 상수항을 포함하고 있지 않은 모형이다.

Table 2.1 The theoretical characters of ACF and PACF of ARMA(p,q) process

확률과정	ACF	PACF
AR(p)	지수적으로 감소하거나 소멸하 는 싸인함수 형태	시차 p이후에는 0으로의 절단 형태
MA(q)	시차 q이후에는 0으로의 절단 형태	지수적으로 감소하거나 소멸하 는 싸인함수 형태
ARMA(p,q)	시차(p-q) 이후에는 지수적으로 감소하거나 소멸하는 싸인함수 형태	시차(p-q) 이후에는 지수적으로 감소하거나 소멸하는 싸인함수 형태

2.5.2 GARCH (generalized autoregressive conditional heteroskedasticity) 1) ARCH(q) 모형

조건부분산을 모형화하는 방법 중 하나는 ϵ_t^2 를 다음과 같이 AR(p)모형의 형태로 나타내는 것이다.

$$\epsilon_t^2 = \zeta + \alpha_1 \epsilon_{t-1}^2 + \alpha_1 \epsilon_{t-2}^2 + \dots + \alpha_p \epsilon_{t-p}^2 + \omega_t \tag{2.49}$$

즉, $\epsilon_t^2 \sim AR(p)$ 과 같이 표현하고, ω_t 는 백색잡음으로서

$$\begin{split} E(\omega_t) &= 0\\ E(\omega_t) &= \begin{cases} \lambda^2, t = s\\ 0, \ t \neq s \end{cases} \end{split}$$

을 만족한다. ϵ_t 가 (2.49)을 만족하는 경우 차수가 p인 자기회귀이분산모형을 따른다고 하며 조건부 분산

$$E(\epsilon_t^2 | \epsilon_{t-1}^2, \epsilon_{t-2}^2, \dots) = \zeta + \alpha_1 \epsilon_{t-1}^2 + \alpha_1 \epsilon_{t-2}^2 + \dots + \alpha_p \epsilon_{t-p}^2 + \omega_t$$
(2.51)

은 시간에 따라 변함을 알 수 있다.

(2.49)에 의하면 ϵ_t는 시간에 따른 상관관계가 없으나 ϵ²_t은 상관관계가 있으므로 ϵ_t는 독립은 아니라는 것을 알 수 있다. 또한 ϵ_t가 확률변수이므로
 ϵ²_t ≥ 0을 만족하고, (2.49)과 (2.51)로부터 다음과 같은 조건이 만족되어야 한다.

$$\omega_t \ge -\zeta(\zeta > 0), \ \alpha_j \ge 0, \ j = 1, \cdots, p \tag{2.52}$$

또한 ϵ_t^2 이 공분산정상성을 만족하려면

$$1 - \alpha_1 z - \alpha_1 z^2 - \dots - \alpha_1 z^p = 0 \tag{2.53}$$

의 해가 단위원 바껭 존재하여야 하며 $\alpha_j \ge 0$ 이라는 조건 하에서 (2.53)는 (13-6)과 동일함을 보일 수 있다.

$$\alpha_1 + \alpha_2 + \cdots + \alpha_p < 1 \tag{2.54}$$

즉, 계수들의 합이 1보다 작으면 ϵ_t^2 는 약정상성의 조건을 만족하고 비조건부 분산

(2.55)

$$\sigma^2 = E(\epsilon_t^2) = \zeta/(1 - \alpha_1 - \alpha_2 - \dots - \alpha_p)$$

은 시간과 무과한 상수가 된다. 조건부 분산을 모형화하는 또 하나의 방법은 ϵ_t 를 다음과 같이 표현하는 것 이다. $\epsilon_t = \sigma_t \cdot v_t$ (2.56)

단, {v_t}는 서로 독립이고 동일한 분포를 따르며(*i.i.d*) $E(v_t) = 0, E(v_t^2) = 1$ 이다. 만약 σ²_t가

$$\sigma_t^2 = \zeta + \alpha_1 \epsilon_{t-1}^2 + \alpha_2 \epsilon_{t-2}^2 + \dots + \alpha_p \epsilon_{t-p}^2$$
(2.57)

을 만족하면

$$E(\epsilon_t^2 | \epsilon_{t-1}, \epsilon_{t-2}, \cdots) = \zeta + \alpha_1 \epsilon_{t-1}^2 + \alpha_1 \epsilon_{t-2}^2 + \cdots + \alpha_p \epsilon_{t-p}^2$$
(2.58)

가 되어 (2.51)와 동일하게 된다. 즉, (2.56)과 (2.57)을 만족하는 ϵ_t 는 ARCH(p) 모형을 따른다.

2) ARCH모형의 추정

오차항 ϵ_t 가 ARCH모형을 따르는 회귀모형을 생각해 보자

$$y_t = \dot{x_t}\beta + \epsilon_t \tag{2.59}$$

즉, ϵ_t 는 (2.56)과 (2.57)을 만족하며 (2.56)에서 v_t 는 설명변수 x_t 와 Y_{t-1} 과는 독립이며 *i.i.d.* N(0,1)을 따른다고 하자. 단,

$$\begin{split} Y_{t} &= (y_{t}, y_{t-1}, \cdots, y_{1}, y_{0}, \dot{x}_{t}, \dot{x}_{t-1}, \cdots, \dot{x}_{1}, \dot{x}_{0}, \cdots, \dot{x}_{-p+1}) \end{split} \tag{2.60}$$

$$& \vdash \text{ Ad } t \mathcal{P} \text{All } \mathcal{P} \text{ All } \mathcal{P} \text{ A$$

이제 (2.59)에서 미지의 모수들을 θ≡[β,δ]라고 놓으면 p개의 초기값에 기초 한 조건부 가능도함수는 다음과 같으며

$$L(\theta) = \sum_{i=1}^{T} \log f(y_t | x_t, Y_{t-1}; \theta)$$

= $-\frac{T}{2} \log(2\pi) - \frac{1}{2} \sum_{i=1}^{T} \log(\sigma_t^2) - \frac{1}{2} \sum_{i=1}^{T} (y_t - \dot{x_t}\beta)^2 / \sigma_t^2$ (2.63)

초기값 θ_0 를 이용하여 (2.62)의 조건부 분산 σ_t^2 을 구한 후 수치최적화 방법을 이용하여 로그가능도함수 (2.63)를 최대로 하는 θ 를 구하면 된다. 그러나 정상 성조건 $\sum_{j=1}^{p} \alpha_j < 1$ 과 음이 아닌 값을 갖는 조건 $\alpha_j \ge 0$ 를 추정 시에는 반영하 기는 쉽지 않다.

주가수익률 등의 시계열자료들을 히스토그램으로 나타내면 정규분포보다 꼬리가 두텁거나, 뾰족한 정도를 나타내는 첨도가 큰 경향을 나타내므로 t-분 포를 따른다고 가정하기도 한다. 따라서 Bollerslev는 오차항의 분포로 $\epsilon_t \sim t_v$, 즉 자유도가 v인 t분포를 제안하고 있다. t-분포 이외에도 많은 분포들이 오 차항의 분포로 제안되고 있으나 여기서는 더 이상 다루지 않기로 한다. ϵ_t 가 정규분포를 따르지 않는 경우에도 v_t 가 다음 조건을 만족하면

$$\begin{split} E(v_t \,|\, x_t, Y_{t-1}) \,{=}\, 0 \\ E(v_t \,|\, x_t, Y_{t-1}) \,{=}\, 1 \end{split}$$

(2.64)

(2.63)를 이용하여 얻은 MLE $\hat{\theta} \equiv (\hat{\beta}, \hat{\zeta}, \hat{\alpha}_1, \dots, \hat{\alpha}_p)$ 는 일치추정량이라는 것이 알려져 있다. 또한 적당한 조건이 만족되면 $\hat{\theta}$ 이 점근적으로 정규분포를 따름 을 보일 수 있어, 이를 이용한 추정 방법을 준 가능도 추정법이라고 한다.

3) GARCH 모형

ARCH 모형의 경우 다음과 같이 σ_t^2 는 p개의 ϵ_t^2 들을 이용하여 설명이 가능 하다.

$$\sigma_t^2 = \zeta + \alpha_1 \epsilon_{t-1}^2 + \alpha_1 \epsilon_{t-2}^2 + \dots + \alpha_p \epsilon_{t-p}^2$$
(2.65)

그러나 σ_t^2 가 다음과 같은 모형을 따른다고 하면

$$\sigma_t^2 = \zeta + \pi(B)\epsilon_t^2, \ \pi(B) = \sum_{j=1}^{\infty} \pi_j B^j$$
(2.66)

추정해야 할 모수가 너무 많아지게 된다. 만약 π(B)를 다음과 같이 쓸 수 있 다면

$$\pi(B) = \frac{\alpha(B)}{1 - \delta(B)} = \frac{\alpha_1 B^1 + \alpha_2 B^2 + \dots + \alpha_p B^p}{1 - \delta_1 B^1 - \delta_2 B^2 - \dots - \delta_r B^r}$$
(2.67)

ARMA 모형의 경우처럼

$$\sigma_t^2 = \kappa + \delta_1 \sigma_{t-1}^2 + \delta_2 \sigma_{t-2}^2 + \dots + \delta_p \sigma_{t-p}^2 + \alpha_1 \epsilon_{t-1}^2 + \alpha_2 \epsilon_{t-2}^2 + \dots + \alpha_p \epsilon_{t-p}^2 \qquad (2.68)$$

$$\kappa \equiv [1 - \delta_1 - \delta_2 - \dots - \delta_r] \zeta$$

와 같이 적은 개수의 모수를 이용하여 설명이 가능하다. 이러한 모형을 GARCH (r,p)모형이라고 한다. 이 모형은 13-3과 같이 ϵ_t^2 를 설명하는 형태를 갖도록 다시 쓸 수 있다.

$$\epsilon = \kappa + (\delta_1 + \alpha_1)\epsilon_{t-1}^2 + (\delta_2 + \alpha_2)\epsilon_{t-2}^2 + \dots + (\delta_m + \alpha_m)\epsilon_{t-m}^2 + \omega_t$$

- $\delta_1\omega_{t-1} - \delta_2\omega_{t-2} - \dots - \delta_r\omega_{t-r}$ (2.69)

단, $m = \max\{p, r\}, \omega_t = \epsilon_t^2 - \sigma_t^2$ 이며, j > r이면 $\delta_j \equiv 0$ 이고 j > p이면 $\alpha_j \equiv 0$ 가 된다. ω_t 는 예측오차이므로, ω_t 가 GARCH(r,p)모형을 따른다면 ϵ_t^2 는 ARMA(m,r)형 태의 모형을 따른다고 볼 수 있다.

GARCH모형을 분석 시 유의해야 할 점들을 살펴보면 다음과 같다.

첫째, 모스들이 음이 아니어야 한다

$$\kappa > 0, \ \alpha_j \ge 0, \ \delta_j \ge 0, \ j = 1, 2, \ \cdots, m$$
(2.70)

둘째, 공분산정상성을 만족하여야 한다.

$$1 - (\delta_1 + \alpha_1)z - (\delta_2 + \alpha_2)z^2 - \dots - (\delta_m + \alpha_m)z^m = 0$$
 (2.71)

의 근의 절대값이 1보다 커야 한다는 점이다.

셋째, 결과해석에 유의해야 한다. 13-15를 보면, j번째 AR계수는 $\alpha_j + \delta_j$ 이며 MA계수는 $-\delta_j$ 이다. 즉, j번째 lag 이전의 ϵ_{t-j}^2 이 현재의 ϵ_t^2 에 미치는 영향은 α_j 가 아니라 $\alpha_j + \delta_j$ 이다. 예를 들어, GARCH(1,1) 모형을 살펴보면,

$$\epsilon_t^3 = \kappa + (\delta_1 + \alpha_1)\epsilon_{t-1}^2 + (\epsilon_t^2 - \sigma_t^2) - \delta_1(\epsilon_{t-1}^2 - \sigma_{t-1}^2)$$
(2.72)

이고, $\alpha_1 + \delta_1$ 의 값이 1에 가까울 때, 과거의 변동성이 오랫동안 지속되는 것을 볼 수 있다. 만약 $\sum_{j=1}^r \delta_j + \sum_{j=1}^m \alpha_j = 1$ 이 되면 단위근이 존재하며 ϵ_t^2 은 IGARCH모 형을 따른다고 한다.

2.6 최대 확률 추정

GARCH 모델은 식(2.73)와 같이 표현된다.

$$\sigma_t^2 = k + G_1 \sigma_{t-1}^2 + A_1 \epsilon_{t-1}^2 \tag{2.73}$$

여기서 ϵ_t 는 ARMA(1,1)에서 추론되는 값이고 조건부 분산 σ_t^2 를 가진다고

가정한다. 4가 가우시안을 따른다고 할 때, 추정 함수는 식(2.74)과 같다.

$$L(k, G_1, A_1) = \prod_{t=2}^{T} \frac{1}{\sqrt{2\pi\sigma_t}} exp\left\{-\frac{\epsilon_t^2}{2\sigma_t^2}\right\}$$
(2.74)

그리고 상수항을 무시하는 로그 추정 함수는 식(2.75)와 같다.

$$l(k, G_1, A_1) = -\frac{1}{2} \sum_{t=2}^{T} \left\{ \log \sigma_t^2 + \frac{\epsilon_t^2}{\sigma_t^2} \right\}$$
(2.75)

여기서, 식(2.73)은 반복적으로 구할 수 있다. 예측값 $E(\sigma_t^2) = 1/(1 - G_1 - A_1)$ 에서 σ_1^2 으로 대신한다. 그리하여 로그 추정함수 $\partial l/\partial k = 0$, $\partial l/\partial G = 0$ 와 $\partial l/\partial A_1 = 0$ 의 도함수를 풀어 예측값 k, G_1 와 A_1 을 찾기 위해 최대 확률을 사용할 수 있다.⁽²⁰⁾

11 10

제Ⅲ장 ARMA & GARCH 모델과 회색이론을 이용한 예지 기법

3.1 진동 데이터의 개요

각각의 기계적 문제나 결함은 고유의 방식으로 진동을 생성한다. 진동의 종류에 따라서 원인을 파악하고 적절한 정비를 하는데 사용된다. 기계 상태 감시에 사용되는 주요 두 가지 진동 유형이 있다: 전체 진동과 가속도 포락처 리. 전체 진동 감시는 정상, 저주파 기계 진동을 감지하고 불평형, 정렬불량과 기계적 느슨함과 같은 회전과 구조적 문제들을 발견한다. 포락처리는 고 주파 수를 증폭한다 ; 반복적인 베어링과 기어 메시 진동 신호들은 정상 전체 진동 신호 상태에서 보여주지 않은 금속간의 접속으로 인해 고 주파의 초기 결함을 나타낸다.

이런 종류의 진동 데이터의 유용한 특성은 이전 연구에서 아직 완전히 이용 되지 않고 있다. Tran, Niu. 진동 데이터는 이러한 연구를 통해 예측 모델의 성능을 입증하는데 사용되었다. 반면에, 전체 진동과 가속도 포락처리로 표현 된 실제 심각도와 고 주파수 결함을 알 수 없을 것이다. 즉, 이러한 연구 결과 들은 CBM 시스템에 충분치 못할 수 있다.

3.2 기계 실제 진동 심각도의 평가와 예측

전체 진동(가속도나 속도의 실효값)은 기계의 건강 상태를 판단하기 위해 진동 심각도를 평가하는 표준으로써 사용된다. 실제로 전체 진동은 매우 휘성 이 높은 신호이기 때문에, 어떤 처리 없이 진동 심각도를 평가하는 것은 유용 하지 않을 수 있다. ARMA & GRACH 모델과 회색 모델은 이러한 문제점을 처리하는데 유용성을 보여준다. ARMA 모델로 부터의 조건부 평균과 GARCH 모델로 부터의 조건부 분산은 명확하게 각각의 마모의 꾸준한 성장 이나 기계 결함의 진행과정에 대해 설명함으로서 기계의 기계적인 상태를 나 타낸다. 조건부 평균과 조건부 표준 분산의 합은 보다 효율적으로 실제 기계 심각도를 평가하는데 사용된다. 유용한 전체 진동의 장래 심각성은 ARMA & GARCH 모델에서 조건부 평균과 조건부 분산의 예측을 사용하여 예상하고 있다.

3.3 기계 결함의 검출과 예측

기계의 정상 상태 주기에는, 포락처리된 가속도값과 운전 주파수(1X) 성분 이 시간에 따라 증가하는 경향이 있다. 이것은 결함의 성장이나 기계의 기계 적 열화 때문이다. 포락처리의 개발은 더 이상 고려할 가치가 없고 ARMA 모 델에 의해 충분하게 수집된 선형 프로세스로서 고려되지 않는다. 이번 경우에 는, ARMA 모델에서 생성된 ϵ_t 는 백색잡음 과정으로 간주된다. 따라서, 이러 한 잡음을 대표하는 GARCH 모델에서 조건부 분산 σ_t^2 의 결과들은 거의 일정 하다. 결함이 분명하게 심각한 단계에 도달하면, 가속도 포락처리가 비정상적 으로 성장하고 복잡하게 만들 것이다. 즉, 가속도 포락처리는 여전히 선형 프 로세스가 아니고 따라서, ARMA 모델에서 혁신 ϵ_t 들은 백색잡음이 아니다. 따 라서 조건부 분산 σ_t^2 은 시간에 따라 달라질 수 있다. 따라서, 시간에 따른 조 건부 분산의 변화가 기계 문제의 발생과 발전을 설명해준다.

미래에 결함의 성장은 지속적으로 ARMA & GARCH 모델을 업데이트한 예측된 결과를 사용함으로서 설명된다. 실제 기계 진동 심각도를 평가하고 예 측하며, 기계적 문제를 검출하기 위한 설명은 그림 3.1에 분명하게 보여준다.

3.3.1 차수비 분석

본 기법은 기존의 차수비 분석(order ratio analysis)에서 착안된 방법으로 차수비 분석은 가로축에 회전주파수를 기준으로 진동 발생 주파수와의 비를 표시하고, 세로축에 진폭을 나타내는 분석 기법이다. 회전기기에 있어 회전 주 파수는 주파수 분석 시에 가장 중요한 요소로 회전속도의 특정 배수 성분이 결함 주파수로 검출되는 사례가 빈번하다. 이는 물리적으로도 회전 기계 부품 에서 발생되는 결함은 회전주파수의 주기로 반복적인 외력 즉, 가진력을 받게 되므로 회전주파수의 조화성분으로 주파수 선도 상에 표현되어진다. 그러므로 회전 주파수의 차수 즉, 배수 성분들은 보다 많은 결함 정보를 내포하고 있으 며, 이에 대한 정확한 분석만으로도 일부 특정 결함들에 대한 진단이 가능해 진다. 본 논문에서 제안하고자 하는 차수비 기법은 차수비 분석과 RMS 성분 을 함께 분석하는 것을 말한다. 우선 RMS는 실효치라고 하며 이를 이용하여 전체 진동신호 크기의 경향을 파악하는 기준데이터로 사용된다. RMS는 식 (3.1)로 정의된다.



RMS를 통해 신호의 상태 변화에 따른 전체적인 경향을 확인하여 높은 변동 량이 발견되면, 회전주파수의 차수 성분에 따른 주파수 변화를 관찰한다. 기본 적으로 회전주파수인 1X성분이 다른 차수에 비해 탁월하게 크게 평가된다면 이는 질량불평형에서 기인한 결함으로 간주 되며, Fig. 3.1과 같이 주파수 영 역에서 회전주파수 1X 성분이 과대하게 관측되는 것을 알 수 있다. 또한 일반 적으로 기계결함은 회전주파수의 배수 성분을 많이 발생시키는데 이는 앞서 언급했듯이 회전주파수가 가진력으로 작용하는 이유에 기인한다고 할 수 있 다. 그러므로 회전주파수의 배수 성분을 분석하는 것은 결함을 규명하는데 중 요한 정보가 되며, Fig. 3.2과 같이 다양한 결함에서 실제 회전주파수의 배수 성분으로 나타나는 것을 알 수 있다⁽²¹⁾.



3.3.2 정렬불량

정렬불량(misalignment)은 불평형과 같이 진동원인의 대부분을 차지한다. 대부분의 기계는 단품으로 작동되기 보다는 모터 또는 엔진과 같이 동력을 발 생시키는 기계요소와 송풍기, 펌프 등과 같이 특별한 용도로 이용되는 기계 요소와의 결합으로 이루어져 있다. 때문에 두 기계요소의 결합이 요구되는데 이 때 커플링에 의한 결합이 일반적이다. 정렬불량이라는 것은 구동축과 피동 축이 같은 중심선 산에 있지 않기 때문에 높은 진동이 발생하는 현상을 말한 다. 정렬불량이 있으면 회전체 축이 강제적으로 굽혀지기 때문에, 외관상의 초 기 굽힘이 생기고, 그것에 의해 진동을 발생한다.

정렬불량에는 평심 정렬불량(parallel misalignment), 평각 정렬불량(angular misalignment) 그리고 편심 및 편각 정렬불량이 혼합된 복합 정렬 불량의 3가 지로 나눌 수 있다. 주요 진동 특성을 살펴보면 아래와 같다.
- 1) 진동 신호의 시간 파형은 조화 파형이다.
- 2) 반경방향의 진동 주파수 스페트럼에서 1X 성품과 2X 성분을 주요 성분
 으로 나타내며 대부분의 경우 1X 성분보다 2X성분이 크게 나타난다.
- 3) 축 방향의 진동주파수 스펙트럼에서 1X 성분이 크게 나타난다.
- 4) 전형적인 축의 휘돌림은 전향(forward)이며 궤적(orbit)은 바나나 형상이 다.
- 5) 진동은 하중에 민감하고, 진폭은 하중의 증가에 따라 증가한다.

3.3.3 베어링 결함 검출

구름 요소 베어링에 대한 결함은 그 종류와 원인 및 결함 진행 단계에서 부 터 대책까지 많은 부분이 이미 충분한 문헌을 통해 연구되어져 왔다⁽²²⁾. 구름 요소 베어링에서는 베어링 형상과 운전 속도에 따라 결정되는 특이한 베어링 특징 주파수 5가지가 검출되며, 이는 다음 수식으로 명확히 표현되어 진다.



Fig. 3.3 The configuration of bearing

• 기본 열 주파수(fundamental train frequency, FTF), 케이지 주파수:

$$FTF = f_c = \frac{f_r}{2} \left[1 - \frac{Bd}{Pd} \cos \emptyset \right]$$
(3.3)

• 볼 자전 주파수(ball spin frequency, BSF):

$$BSF = f_s = \frac{Pd}{2Bd} f_r \left[1 - \left(\frac{Bd}{Pd}\right)^2 \cos \varnothing \right]$$
(3.4)

• 외륜 통과 주파수(ball pass frequency of outer race, BPFO) :

$$BPFO = f_o = N(FTF) = \frac{f_r}{2} N[1 - \frac{Bd}{Pd} \cos \emptyset]$$
(3.5)

• 내륜 통과 주과수(ball pass frequency of inner race, BPFI) :

$$BPFI = f_i = N(f_r - FTF) = \frac{f_r}{2} N[1 + \frac{Bd}{Pd} \cos \emptyset]$$
(3.6)

3.3.4 기어 결함 탐지

기어 박스(gear box)는 원동거의 속력이나 회전력을 증감하기위해 기어를 이용해 회전수를 가변시키는 동력전달 장치이다. 기어 박스는 운전 중에는 구 동기어와 피동기어가 연속적으로 맞물려 회전하게 되는데 이때 기어 시스템에 서는 가장 기본적으로 측대역파(side band)를 가진 GMF가 발생한다^(23,24). 기 어 맞물림 주파수는 기어 이(teeth)의 수 Z와 회전 속도 N의 곱으로서 다음 식과 같이 표현할 수 있다.

$$f_m = \frac{N}{60} \times Z \tag{3.7}$$



Fig. 3.5 Difference between normal and fault condition

측대역파는 기어 맞물림 주파수를 중심으로 회전주파수 합차만큼의 폭으로 발생되는 특징을 가지고 있다. 구동기어와 피동기어는 연속적으로 맞물려 회 전하므로, 정상상태인 두 기어의 기어 맞물림 주파수는 같아야한다. 하지만, 기어 표면에 결함이 발생게 되면 기어 맞물림 주파수와 더불어 기어 맞물림 주파수의 2차, 3차인 조화 성분들이 함께 발생하게 되는데 이때 특히 2차 조 화 성분이 1차, 3차 조화 성분보다 상대적으로 큰 진폭을 가진다면, 이는 기어 에 과대한 백래쉬(backlash)가 존재하거나 기어 이중에 하나가 진동을 하는 것을 의미한다.

백래쉬란 서로 물린 한 쌍의 기어에서 각 잇 면 사이의 간격, 혹은 기어를 반대방향으로 돌릴 때 기어이 사이의 공간에 의해 기어가 약간 헛도는 현상을 말한다. 이상적인 기어에서는 백래쉬가 없지만 실제 기어에서는 가공상의 오 차, 조립상의 오차에 의해 백래쉬가 발생한다. 과대한 백래쉬가 발생하면 GMF사이의 배수 성분에서 높은 진폭이 발견되며, Fig. 3.11와 같이 기어의 공진 주파수로 의심되는 주파수 성분이 나타나기도 한다.



특히 기어에 정렬불량이 생기면, 정렬 불량이 존재하는 기어 이 부위에서 서 로 부딪히게 되어 기어의 자연스러운 회전을 힘들게 만든다. 이러한 현상은 주파수 분석에서 GMF의 2차 조화성분의 피크로 나타나는데 이로 인해 2X GMF는 통상 기어 정렬 문제로 인해 야기되는 결함 주파수로 간주된다.⁽²⁵⁾

Fig. 3.7은 3단 감속기의 구조를 나타내고 있으며 식(3.8)~(3.13)은 각 기어의 속도와 주파수, 측대파를 계산하는 식을 나타내고 있다.



$$N_p = N_s \times \frac{T_r}{T_p}$$

(3.8)

$$F_m = T_s \times (N_s - N_o) = T_r \times N_o \tag{3.9}$$

Ot y

Prominent Gear Mesh Component
$$= F_p \times F_m$$
 (3.10)

$$F_{s} = \pm N_{p} \times (N_{s} - N_{o}) \tag{3.11}$$

$$F_p = \pm (2 \times N_p) \tag{3.12}$$

$$F_r = \pm (N_p \times N_o) \tag{3.13}$$

3.3.5 포락처리

포락 처리는 베어링의 결함이 나타내는 주파수를 찾는데 이용되는 대표적인 분석 방법이다. 베어링결함이 발생한 경우, 볼이 결함 부위를 통과할 때마다 충격력이 가진 되어 베어링의 고유 진동수에 대응하는 진동이 발생하고 이 경우 결함 주파수와 베어링의 고유진동수는 크게 다르게 된다. 얻어진 진동 파형은 베어링의 고유 진동에 의한 파형을 결함에 의한 반복 주파수로 진폭 변조된 것이 된다. 설비 진단에 필요한 정보는 베어링의 고유 진동이 아니고 결함에 의해 발생한 진동 성분이다. 이와 같이 변조 주파수와 피 변조 주파수 사이의 비가 큰 신호로부터 변조 주파수 성분의 정보를 얻는데 효과적이다. 포락처리 과정은 일반적으로 대역 통과 필터(band-pass filter), 저역 통과 필터(low-pass filter)의 순서로 진행된다. 대역 통과 필터는 기계적 진동 요소에 의해 발생되는 저주파·고진폭의 신호를 제거할 수 있으며, 대역 통과 밖의 랜덤 노이즈(random noise)를 제거하는 역할을 하기 때문에 그 범위의 설정은 매우 중요하다고 할 수 있다.

아래의 Fig.3.8~3.11은 포락검출하는 순서를 나타내고 있다.



Fig.3.8



Fig.3.9



Fig.3.10



제 Ⅳ장 감속기 및 압축기에 대한 실험 및 예측 결과

4.1 실험

본 장에서는 회색이론과 ARMA & GARCH, 두 가지 알고리즘의 성능을 검 증하고자 2가지의 데이터가 사용되었다.

1) 오차계산

예측 모델의 정확도를 알아보기 위해 예측 오차를 사용한다. 본문에서 사용 된 오차측도는 다음과 같다. 예측 오차 : $\hat{e_t}(1) = Z_{t+1} - \hat{Z_t}(1)$

① 제곱근평균제곱예측오차 : RMSE(root mean square prediction error)

$$MSE = \frac{\sqrt{\sum_{t=1}^{m} \hat{e}_{n-1+t}(1)^2}}{m}$$
(4.1)

② 평균절대백분위예측오차 : MAPE(mean absolute percentage prediction error)

$$MAPE = \frac{100}{m} \sum_{t=1}^{m} \left| \frac{\hat{e}_{n-1+t}(1)}{Z_{n+t}} \right|$$
(4.2)

③ 평균절대예측오차 : MAE(mean absolute prediction error)

$$MAE = \frac{\sum_{t=1}^{m} \left| \hat{e}_{n-1+t}(1) \right|}{m}$$
(4.3)

④ 결정계수 : R-squared

$$\begin{split} SS_{tot} &= \sum_i (y_i - \bar{y})^2,\\ SS_{err} &= \sum_i (y_t - \bar{y_t})^2 \end{split}$$

$$R^2 = 1 - \frac{SS_{err}}{SS_{tot}}$$

결정계수를 제외한 오차 값들은 그 값이 작을수록 추정치가 정확하다는 것을 표현하고 결정계수는 1에 가까울수록 더 정확하다는 것을 나타낸다.

(4.4)

4.1.1 감속기

첫 번째 대상은 풍력 터빈이다. 풍력 터빈의 시험 작동에 사용되는 감속기 의 가속도 신호를 측정하였다. 측정기간은 2011년 6월부터 2011년 9월까지 측 정하였다. 측정에 관한 내용은 Table 4.1에 기록하였다. 사용된 센서는 3축 센 서로 감속기의 각 단에 설치하였고, 총 3포인트로 구성되어있다. 모든 포인트 에 베어링이 설치되어 있고, 센서에 대한 상세 정보는 Table 4.2에 나타내었 다. Fig.4.1는 센서 설치 위치와 감속기의 개략도를 함께 나타내었다. Table 4.3은 감속기의 각 단의 속도와 베어링 결함 주파수를 계산하여 나타내었다. 계측된 데이터를 이용하는 것은 실제 사례에서 얻어진 신호를 알고리즘에 적 용하기 위함이다. 계측 당시 감소기의 상태는 정상으로 양호한 상태였다. 유성 기어 맞물림 주파수 계산한 결과 시간이 경과 할수록 1X GMF성분의 크기가 증가하였고 모든 기어 단에서 1단 기어 기어 맞물림 주파수 조화성분이 발생 1단의 기어 맞물림 주파수가 유성기어의 전체의 진동을 지배하였다. 1X GMF 를 시간순으로 나열하여 데이터를 구성하였다.



Fig. 4.1 Speed reducer

Table 4.1 Measure information of the speed reducer

기간	2011년 06월 28일 ~ 2011년 09월 27일
스머기소 ㅈ거	1200 rpm/무부하
十岁 7号 至在	1200 rpm/80Nm
시험주기	1회/일, 가동 2hr 이후
Sampling rate	20 kHz
측정 시간	3.3초 7 6 6 6
센서	3축 가속도 센서

Table 4.2 Information of the sensors

위치		P1	P2	Р3
S,	/N	58608	58607	58609
	Х	10.12 mV/g	10.62 mV/g	9.928 mV/g
감도	Y	10.05 mV/g	10.17 mV/g	9.937 mV/g
	Z	10.26 mV/g	9.996 mV/g	10.50 mV/g

Gear Type	1 st Stage	2 nd Stage	3 rd Stage	
Ring Gear Teeth	62	78	68	
Planet Gear Teeth	24	29	25	
Sun Gear Teeth	13	18	16	
Pinion Gear Teeth	14			
No. of balls of Pitch Bearing	135			

Table 4.3 Information of Planetary gear

Table 4.4 The result of bearing fault frequency and the stage speeds

	1 Stage	1200 [rpm]		214.93
Operating	2 Stage	650 [rpm]	GMF [Hz]	130.98
	3 Stage	403 [rpm]		58.50
Position	Model	1X of fault type	Fault frequency [Hz]	
		BPFO	121.50	
1 Stage	Ball Bearing #6012	BPFI	158.50	
	* 3	BSF	74.36	
		FTF	8.68	
	Roller	BPFO	65.	.81
2 Stage	Bearing	BPFI	85.85	
	#22217	BSF	40.28	
		FTF	4.70	
	Roller	ler BPFO 39.02		.02
3 Stage	Bearing	BPFI	53.29	
	#23122	BSF 2.92		92
		FTF	2.9	92

4.1.2 압축기

두 번째 대상은 저탄소 압축기이다. 측정된 압축기의 모습은 Fig. 4.2와 같다. 데이터 측정 기간은 2005년 8월부터 2005년 11월까지 6시간 마다 측정하였다. 대략 470개 정도의 데이터가 기록되었고 Fig. 4.4은 압축기의 가속도 피크 데이터의 그래프를 나타내고 있다. 이 데이터는 압축기가 시간 순서로 정상 상태부터 고장이 발생한 단계까지 기계의 이력의 정보를 포함하고 있다. 따라서 이 데이터도 시계열 데이터로 분류할 수 있다.



Fig. 4.2 Methane Compressor

	-		NS.Y	
-	0	/ ГН 3	2	1/
Table	4.4	Description	of	system

Electric motor		Compressor		
Voltage	6600 V	Type	Wet screw	
Power	440kW	Loho	Male rotor(4 lobes) Female rotor (6 lobes)	
Pole	2 Pole	Lobe		
Bearing	NDE: #6216 DE: #6216	Dooring	Thrust: 7321 BDB Radial: Sleeve type	
RPM	3565rpm	Dearing		

4.2 압축기 예측 결과

Fig. 4.3는 압축기의 피크값을 나타낸 것이다. 그래프의 300 포인트에서 급 격하게 값이 변하였고 308 포인트에서 최종 결함이 발생하였다. 기계를 분해 하여 확인한 결과, 베어링(7321 BDB)의 윤활 불량으로 인한 과열로 인해 생 긴 결함이었다. 그 후 베어링의 교체 작업이 이루어졌다.



열화 곡선을 얻기 위해서, Fig. 4.4와 같이 전동 진폭의 0.4±0.03의 값을 기 계의 정상 상태의 경계로 결정하였다. 이는 각 시간의 진동 진폭이 경계를 벗 어났는지 아닌지를 분석된다. 그 값이 경계의 안에 있는 경우에는 이전 값과 같고 그렇지 않은 경우에 그 편차 값을 얻는다. 식 (2.16)에 따르면, D_t 는 시 간 t까지의 전체 편차 값을 나타내고 N은 전체 데이터의 편차 값을 나타낸다. 경계 값과 관측 값의 차이가 많이 날수록 열화 곡선의 기울기는 커지고 이는 결함이 점점 진행하고 있다는 것을 나타낸다. 결과는 Fig. 4.5과 같다. 1에서 0.9까지는 결함이 시작된 시점을 나타내고 0.1의 지점은 고장이 발생한 시점을 나타낸다.



Fig. 4.5 Degradation curve based on real data

4.2.2 회색 이론

Fig. 4.5과 같은 열화 곡선은 기계의 상태를 나타내는 중요한 자료이다. Fig. 4.6은 회색 이론 GM(1,1)의 수정된 모델을 적용하여 열화곡선의 예측 모델을 실제 데이터와 함께 나타내었다. 그림에서 알 수 있듯이 실제 그래프와 예측 데이터의 오차는 앞서 4.1절에서 언급한 오차계산을 사용하였고 Table 4.5에 나타내었다.



Fig. 4.6 The prediction result of the grey model

4.2.3 ARMA & GARCH

Fig. 4.7(a)와 Fig. 4.7(b)는 각각 자기상관 그래프와, 편자기상관 그래프를 나타낸 것이다. 모형을 기반으로 모델을 선정하여 ARMA & GARCH에 적용 한 결과는 Fig. 4.8과 같다. 압축기 데이터를 이용한 예측값들의 오차를 Table 4.5에 정리하였다.



- 45 -



Table 4.5 Error value of the predictions

	1	R	RMSE	MAE	MAPE
Grey model	Prediction	0.9364	0.03778	2.1579	4.0614%
ARMA & GARCH	Totally conditional value	0.9761	0.02007	1.1607	1.6603%
	Conditional mean	0.9813	0.02144	0.7068	1.255%

4.3 감속기 예측 결과

감속기의 상태 변화를 보기 위해 주파수 분석을 하였다. 감속기의 가속 시 험의 두 가지 조건의 주파수 데이터를 Fig. 에 나타내었다. 베어링 결함 주파 수가 나타나는 것을 확인할 수 없었고, 기어 맞물림 주파수(GMF)의 배수 성 분이 나타나는 것을 확인 할 수 있었다. 그 중 1X GMF의 값이 시간이 경과 할수록 증가하는 경향을 가진다는 것을 확인하였다. 두 조건의 가속시험이었 지만 부하 조건의 데이터에서 뚜렷한 데이터를 확인할 수 있었고 Fig.4 와 같 이 포락선 검출에 의해 측대파가 발생하는 것을 쉽게 확인할 수 있었다. 이를 시계열 데이터로 Fig 4.11에 나타내었다.















Fig. 4.9 The actual signal of vibration acquired from real field



Fig. 4.10 Enveloping spectrum

4.3.3 회색이론 예측 결과

감속기 데이터의 결과에도 동일하게 GM(1,1)의 수정된 모델을 사용하여 예 측 데이터를 구하여 Fig. 4.11와 같은 결과를 얻었다. 실제 데이터와 예측 데 이터의 오차 값은 Table 4.6에 나타내었다. 1~5 데이터는 예측을 위한 트레이 닝 구간으로 사용되어 6번째 데이터부터 예측이 이루어졌다.



Fig. 4.11 The prediction result of the grey model

4.3.4 ARMA & GARCH 예측 결과

Fig. 4.12(a)와 Fig. 4.12(b)는 각각 자기상관 그래프와, 편자기상관 그래프를 나타낸 것이다. 모형을 기반으로 모델을 선정하여 ARMA & GARCH에 적용 한 결과는 Fig. 4.13과 같다. 압축기 데이터를 이용한 예측값들의 오차를 Table 4.6에 정리하였다.



- 55 -



Table 4.6 Error value of the predictions

	NO	R	RMSE	MAE	MAPE
Grey model	Prediction	0.94189	0.016708	1.3897	4.1698%
ARMA & GARCH	Totally conditional value	0.83699	0.053295	4.9677	18.276%
	Conditional mean	0.94785	0.018901	1.4867	5.33%

제 V장 결론

오늘날 많은 산업 개발과 함께 기계 유지보수는 작동 비용뿐만 아니라 정확 성이나 신뢰성에 관해서 더욱 엄격해져야한다. 부적합한 유진보수 전략은 생 산성뿐만 아니라 고객에 대한 서비스의 저하로 결과로 나타나고 심지어 안전 및 환경 문제로도 이어진다. 이 연구는 상태감시정비의 정확성이나 신뢰성을 향상시키는 예측의 새로운 체계적인 연구를 제공하며, 이것은 기계 유지보수 의 가장 효과적인 방법이다.

진동 기반의 예측은 널리 연구되었다. 하지만 진동은 가장 휘발성 있는 신 호이다. 기계의 수명이 다 되면 마모가 심해지고 고장이 발생하기 때문에 더 욱더 많은 진동의 변화가 생긴다. 예지는 유지보수 성능의 일정이 조기에 결 정되는 기간에만 유용하다. 따라서, 심하게 변화하는 진동의 경향을 정확하게 예상하는 전문가 진단 방법을 알아내는 것은 여전히 이론적인 이야기다. 또 다른 문제는 정확하게 실제 진동 심각도를 어떻게 평가하는 가이다. 진동 심 각도는 현재의 전체 진동값을 비교하여 평가한다. 하지만 원래 진동이 너무 쉽게 변화는 성질을 가졌다면 진동 심각도의 잘못된 평가를 내릴 것이다.

ARMA & GARCH 모델이라고 부르는, 선형 ARMA 모델과 비선형 GARCH 모델을 결합한 새로운 진동 기반의 예측 방식은 기계 건강 상태를 추정하고 예측하지 조사하였다. ARMA 모델에서 조건부 평균과 GARCH 모 델로부터 조건부 분산을 구하여 꾸준히 성장하는 결함과 변동 진행 형태에 관 한 기계의 동작을 설명 하는데 사용할 수 있다. 실제 진동 심각도는 ARMA & GARCH 예측 모델에서 얻은 조건부 평균과 분산 사이에서 결합된 데이터 를 사용함으로서 평가하고 예상할 수 있다. 압축기의 고장은 윤활 불량으로 인해 진동의 피크 값이 지속적으로 커졌으며 감속기의 경우는 축의 정렬불량 으로 인한 회전 주파수의 지속적인 증가가 나타난 것이다. 석유 화학 공장의 메탄 압축기와 풍력 발전기의 감속기에서 얻은 데이터로 제안된 예측 모델들 의 성능을 확인할 수 있었다. 이 모델들의 성능의 비교 기준으로 4가지 오차 계산 방법을 사용하여 비교해 본 결과 압축기에서는 회색이론이 ARMA & GARCH 모델의 결과 보다 오차 값이 크게 나타났으며, 감속기 데이터 예측 모델의 결과는 ARMA & GARCH의 Totally conditional value값의 오차가 가 장 크게 나타났다. ARMA & GARCH 모델과 회색 모델의 정확한 예측 결과 는 기계 상태 건강 예측의 활용하는데 적합함을 보여준다.

하지만, 이 모델들은 실제 발생한 기계의 갑작스런 고장을 알 수 없다. 실제 현장에서 기계 상태 감시 시스템 또는 CBM의 활용성을 확인하기 위해, 기계 잔존수명 예측에 보다 심층적인 연구가 필요로 한다. 기계 잔존 수명을 계산 하기 위한 ARMA & GARCH 모델이나 회색모델 및 다른 효과적인 방법들의 우수성을 갖추는 것은 향후 연구에 반드시 필요하다.



A.1 자기회귀과정(autoregressive process; AR)

정상시계열 데이터 ..., x(t-p), ..., x(t-2), x(t-1), x(t), x̂(t, 1), x̂(t, 2) 비 비 비 비 비 ρ기전 2기전 1기전 현재 예측값 예측값 에 있어서 "시점 t에 있어서의 변동은 시점 t-1로부터 t-p까지의 영향을 받고 있는 것은 아닌가?" 라고 생각할 수 있다. 그래서 u(t)를 백색잡음(white noise)이라고 했을 때, 시점 t-1로부터 t-p까 지의 영향을 x(t) = a_1x(t-1) + a_2x(t-2) + ... + a_px(t-p) + u(t) (1.1) 와 같이 표현한 식을 자기회귀 AR(ρ) 모형이라고 한다. 실제로는 p=1 또는 p=2까지이므로, AR(1) 모형, AR(2) 모형

을 취급하는 경우가 많다. 특히, a₁ = 1의 AR(1) 모형

$$x(t) = x(t-1) + u(t)$$
(1.2)

를 난보(random walk)라고 한다.

A.2 AR(1) 모형의 성질



$$x(t) = a_1 x(t-1) + u(t)$$
(1.3)

성질 2.1기 앞의 예측값 $\hat{x}(t,1)$

$$\hat{x}(t,1) = a_1 x(t) \tag{1.4}$$

성질 3. m차의 자기상관계수 ρ_m



Fig. 1.1 ACF & PACF of AR(1) model

A.3 AR(2) 모형의 성질

$$x(t) = a_1 x(t-1) + a_2 x(t-2) + u(t)$$
(1.6)

성질 2.1기 앞의 예측값 $\hat{x}(t,1)$

$$\hat{x}(t,1) = a_1 x(t) + a_2 x(t-1)$$
 (1.7)

 성질 3. 27] 앞의 예측값 $\hat{x}(t,2)$
 (1.8)

 $\hat{x}(t,2) = a_1 \hat{x}(t,1) + a_2 x(t)$
 (1.8)

 성질 4. 1차의 자기상관계수 ρ_1
 (1.9)

 성질 5. 1차의 자기상관계수 ρ_2
 (1.9)

 (1.9)
 (1.10)

이것들은 상수항을 포함하고 있지 않은 모형이다.





PACF

Fig. 1.2 ACF & PACF of AR(2) model

 백색잡음(white noise)의 검정 시계열 데이터 {x(1),x(2),...,x(t-1),x(t)}
 에 대해서 다음의 가설 H₀가 성립하는지 어떤지를 조사하는 검정방법을 Ljung-Box 검정이라고 한다.

가설
$$H_0: \rho(1) = \rho(2) = \rho(3) = \cdots = \rho(m) = 0$$
 (1.12)

여기에서 $\rho(1), \rho(2), \rho(3), ..., \rho(m)$ 은 모자기상관계수이다. 표본자기상관계수 $\rho(1), \rho(2), \rho(3), ..., \rho(m)$ 과 구별할 필요가 있따. 이 표본자

기상관계수 ρ(1), ρ(2), ρ(3), ..., ρ(m)을 사용하면, Ljung-Box의 검정통계량 Q*는

$$Q^* = t(t+2) \left\{ \frac{\rho_1^2}{t-1} + \frac{\rho_2^2}{t-2} + \dots + \frac{\rho_m^2}{t-m} \right\}$$
(1.13)

이 된다.

이 검정통계량은 자유도 m의 카이제곱 분포에 따르기 때문에 유의수준을 α=0.05로 하면, 기각역은

임계치
$$\chi^2(m; 0.05) <$$
검정통계량 Q^*

이 된다.

B.1 이동평균과정(moving average process; MA)

정상시계열 데이터

을 취급하는 경우가 많다.

B.2 MA(1) 모형의 성질

성질 1. MA(1) 모형의 식

 $x\left(t\right) = u\left(t\right) - b_{1}u\left(t-1\right)$

(2.2)

성질 2. 1기 앞의 예측값 $\hat{x}(t)$

$$\hat{x}(t) = -b_1 \{ x(t) - \hat{x}(t-1,1) \}$$
(2.3)

성질 3. 1차의 자기상관계수 ρ1

$$\rho_1 = \frac{-b_1}{1+{b_1}^2} \tag{2.4}$$





B.3 MA(2) 모형의 성질

성질 1. MA(2) 모형의 식

$$x(t) = u(t) - b_1 u(t-1) - b_2 u(t-2)$$
(2.5)

성질 2.1기 앞의 예측값 $\hat{x}(t,1)$

$$\hat{x}(t,1) = -b_1 \{x(t) - \hat{x}(t-1,1)\} - b_2 \{x(t-1) - \hat{x}(t-2,1)\}$$
(2.6)






참고문헌

- Christer, A.H., Innovative decision making, In: Brown, K.C., White, D.J. (Eds.), Proceedings of the NATO Conference on Role and Effectiveness of Theory of Decision Practice, Hodder and Stoughton, UK, (1976), pp. 368–377.
- (2) Pourahmadi, M., Foundations of Time-series Analysis and Prediction Theory, Wiley, New York,(2001)
- (3) Wand, W.,Ismail, F., Golnaraghi, F., Assessment of gear damage monitoring techniques using vibration measurements, Mechanical Systems and Signal Processing, 15, (2001), 905–922
- (4) Yan, J., Koc, M., and Lee, J., 2004, "A prognostic algorithm for machine performance assessment and its application," Production Planning and Control, Vol. 15, pp. 796–801
- (5) Ray, A. and Tangirala, S., 1996, "Stochastic modeling of fatigue crack dynamics for on-line failure prognostics," IEEE Trans. Control Systems Technology, Vol. 4, pp. 443–451.
- (6) Li, Y., Billington, S., Zhang, C., Kurfess, T., Danyluk, S., and Liang, S., 1999, "Adaptive prognostics for rolling element bearing condition," Mechanical Systems and Signal Processing, Vol. 13, pp. 104–113.
- (7) Li, Y., Kurfess, T.R., and Liang, S.Y., 2000, "Stochastic prognostics for rolling element bearings," Mechanical Systems and Signal Processing, Vol. 14, pp. 747–762.
- (8) Wang, P. and Vachtsevanos, G., 2001, "Fault prognostics using dynamic wavelet neural networks," AI EDAM-Artificial Intelligence for Engineering Design Analysis and Manufacturing, Vol. 15, pp. 349–365.
- (9) Haung, R., Xi, L., Li, X., Liu, C.R., Qiu, H., and Lee, J., 2007, "Residual life prediction for ball bearings bsed on self-organizing map and back propagation neural network methods," Mechanical Systems and Signal Processing, Vol.21,pp.193–207

- (10) Wang, W.Q., Golnaraghi, M.F., and Ismail, F., 2004, "Prognosis of machine health condition using neuro network methods," Mechanical Systems and Signal Processing, Vol.21,pp. 813–831
- (11) B. Satish, N.D.R. Sarma, A fuzzy BP approach for diagnosis and prognosis of bearing faults in induction motors, In IEEE Power Engineering Society General Meeting (2005)2291–2294
- (12) V.T.Tran, B.S. Yang, M.S. Oh, A.C.C Tan, Machine condition prognosis based on regression trees and one-step-ahead prediction, Mechanical Systems and Signal Processing 22(5)(2008)1179-1193
- (13) T. Wireman, World class maintenance management, Industrial Press, New York, 1990.
- (14) J.D. Campbell, Uptime: Strategies for excellence in maintenance management, Productivity Press, USA, 1995.
- (15) P.F. Knights, P. Oyanader, Best-in-class maintenance benchmarks in Chilean open-pit mines, Proceedings of The first International Conference on Mining Innovation, Santiago, 2004.
- (16) J.L.Deng, Introduction to grey system theory, Journal of Grey system, Vol.1(1)(1989) pp.1-24
- (17) M.Mao and E.C.Chirwa, Application of grey model GM(1,1) to vehicle fatality risk estimation, Technological Forecasting and Social Change, Vol, 73(2006) pp.558-605
- (18) S. Tangkuman, B.S. Yang., Application of grey model for machine degradation prognostics., Journal of Mechanical Science and Technology 25 (12)(2011) 2979–2985
- (19) E.T. Lee and J. W. Wang, Statistical Methods for survival Data Analysis, 3rd Ed., John Wiley&Sons, Inc, New Jersey, USA, 2003.
- (20] H.T. Pham. Prognosis of Machine Health Condition Using ARMA-GARCH Model. University of Pukyung. 2010
- (21) Vibration school homepage, http://vibrationschool.com/mans/Plots/SPlots1.thm
- (22) T.Momono and B. Noda, Sound and vibration in rolling bearings, Motion &

Control NSK, (1999), N0.6

- (23) Vibanalysis homepage, http://www.vibanalysis.co.uk/vibanalysis/gears/gears.html
- (24) 양보석 편저, 기계설비의 진동 상태 감시 및 진단, 인터비젼, pp.356~359.
- (25) 오준석, 무선센서를 이용한 기계 건강 진단 및 예지를 위한 통합 소프트
 - 웨어, University of Pukyung (2011).



감사의 글

본 논문이 완성되기까지 정성어린 지도와 끊임없는 관심으로 지도해 주신 이 연원 교수님께 진심으로 감사드립니다. 지금은 고인이 되셔서 하늘나라에 계 시는 (故)양보석 교수님께 직접 이 논문을 드릴 수 없지만 저의 석사생활을 시작하게 해준 교수님께 무한의 감사의 말을 올리고 싶습니다. 논문이 완성되 기 까지 많은 지도로 완성도를 더하게 해주신 이일영 교수님과 손정현 교수님 게 감사의 말을 전합니다.

학부 4학년 때 실험실에 들어와서 아무것도 모르지만 과제에도 참여하여 공 부도 하고 때로는 운동으로 함께 땀도 흘려가면서 희노애락을 같이 하였던 선 후배님들 잊지 못할 것입니다. 언제나 많은 공부하기를 원하셔서 이런저런 일 들 시켜주시던 민찬이형, 말수는 적었지만 저희들과 함께 일하기 원했던 정민 이형, 바쁜 회사 일 때문에 얼굴 보기 어려웠지만 만날때 마다 반가웠던 선용 이형, 저와 함께 실험실을 꾸준히 시켜온 진희, 저의 논문에 지대한 영향을 주 고 고국으로 떠난 stenly 등 모두에게 고맙다는 말 전하고 싶습니다. 그리고 저의 대학원 생활 시작과 함께 고향으로 돌아가셔서 자주 찾아뵙진 못했지만 언제나 믿고 응원해 주신 부모님께도 감사의 마음을 전합니다.

학부생활과 대학원 생활동안 담당 목사님으로 지도해주신 박균진 목사님, 저 의 말벗이 되어준 의진, 승훈, 진화, 은혜, 현호, 주은누나, 의택이형, 재원이, 현수형, 같은 교회는 아니지만 저의 상담자가 되어준 성민이, 하임이 아빠 광 진이에게도 늘 감사한 마음입니다.

(故)양보석 교수님의 별세로 인해 지도교수님이 바뀌는 약간은 특별한 상황 을 겪어가면서 대학원 생활을 하였습니다. 하지만 (故)양보석 교수님께서 남기 신 많은 업적들 때문에 끝까지 포기하지 않고 공부할 수 있었다 생각이 듭니 다. 아직 사회에 나가 삶의 무거움을 직접 경험하진 못했지만 이 후에 있을 많은 경험이 대학원 기간 동안 겪은 모든 일들에서 밑바탕이 되었으면 하는 바램입니다.