

# 원전 디지털 I&C 계통 고장예측을 위한 신뢰도 함수 추정 인공지능 모델 비교연구<sup>+</sup>

(Comparative Study of AI Models for Reliability Function  
Estimation in NPP Digital I&C System Failure Prediction)

이 대 영<sup>1)\*</sup>, 이 정 훈<sup>2)</sup>, 양 승 혁<sup>3)</sup>

(DaeYoung Lee, JeongHun Lee, and SeungHyeok Yang)

**요 약** 원전 계측제어계통은 정상운전 시 자가 진단기능의 유지보수를 위해 일정 주기로 건전성을 확인하고 있으며, 계획예방정비 기간 동안 기능 및 성능점검을 실시하여 필요한 경우 유지보수를 하고 있다. 하지만 원전의 정보를 계측하고 제어하는 계측제어계통에서도 선제적으로 고장을 진단하고 대처하여 사고전과를 방지할 수 있는 기술개발이 필요하다. 이에 본 논문에서는 계측제어 장비의 환경조건과 자가 진단 데이터를 활용한 신뢰도 함수 추정 방안을 연구하였으며, 고장데이터의 획득을 위해 계측제어 장비의 부품에 대한 Feature 별 확률분포를 가정하여 가상 고장데이터를 생산하였다. 이러한 고장데이터를 바탕으로 생존분석에서 활용되는 대표적인 인공지능 모델(DeepSurve, DeepHit)을 이용하여 신뢰도 함수를 추정하였고, 그와 동시에 전통적인 준모수적 방법론인 Cox 회귀모델을 통해 신뢰도 함수를 추정하여 환경조건과 진단 데이터를 바탕으로 한 잔여 수명 계산을 통해 적용 가능성을 확인하였다.

**핵심주제어:** 원자력 발전소, 디지털 계측제어계통, 고장예측, 딥러닝, 신뢰도 함수

**Abstract** The nuclear power plant(NPP)'s Instrumentation and Control(I&C) system periodically conducts integrity checks for the maintenance of self-diagnostic function during normal operation. Additionally, it performs functionality and performance checks during planned preventive maintenance periods. However, there is a need for technological development to diagnose failures and prevent accidents in advance. In this paper, we studied methods for estimating the reliability function by utilizing environmental data and self-diagnostic data of the I&C equipment. To obtain failure data, we assumed probability distributions for component features of the I&C equipment and generated virtual failure data. Using this failure data, we estimated the reliability function using representative artificial intelligence(AI) models used in survival analysis(DeepSurve, DeepHit). And we also estimated the reliability function through the Cox regression model of the traditional semi-parametric method. We confirmed the feasibility through the residual lifetime calculations based on environmental and diagnostic data.

**Keywords:** Nuclear Power Plant, Digital I&C System, Failure Prediction, Deep Learning, Reliability Function

\* Corresponding Author: ldy242@fnctech.com

+ 본 연구는 산업통상자원부와 한국에너지기술연구원의 지원을 받아 수행한 연구임.(No.20224B10100120)

Manuscript received October 30, 2023 / revised November

17, 2023 / accepted December 02, 2023

1) ㈜미래와도전 디지털기획부, 제1저자 및 교신저자

2) ㈜미래와도전 사업개발그룹, 제2저자

3) ㈜미래와도전 디지털기획부, 제3저자

## 1. 서론

2000년대 이후 건설원전에는 디지털 기술이 계측제어계통에 접목되어 온라인 자가 진단, 자동시험기능 등과 같이 기기의 자가 진단기능이 발전되어 왔다. 이렇게 원전에도 디지털기기 사용이 늘어나면서 공통원인고장, 복잡도에 따른 신뢰성 현안, SW 및 통신 신뢰성에 대한 현안이 대두되고 있다. 원전 계측제어계통은 정상운전 시 자가 진단기능의 유지보수를 위해 일정 주기로 건전성을 확인하고 있으며, 계획예방정비 기간 동안 기능 및 성능점검을 실시하여 필요한 경우 유지보수를 하고 있으나 보다 선제적으로 고장을 진단하고 대처하여 사고전파를 방지할 수 있는 기술개발이 필요한 실정이다.

기존 가동원전에서 고장진단의 문제점을 개선하기 위해 빅데이터와 인공지능과 같은 4차 산업혁명 기술을 활용하여 계측제어계통에 대한 상태진단 및 고장예측 기술을 개발할 필요가 있다. 이러한 기술은 고장 및 손상 발생 전에 그 가능성을 예측하여 선제적으로 대응함으로써 원전 불시 정지 및 사고를 사전에 예방할 수 있어 원전의 안전성을 획기적으로 향상시킬 수 있다.

보통 계측제어계통의 사고·고장의 빈도는 계측결함 및 인적 실수보다 크지 않지만, 디지털 계측제어계통의 경우 성능저하 없이 갑자기 고장이 나는 경우가 많고, 계측제어계통의 고장은 불시 정지사고로도 이어질 수 있기 때문에 계측제어계통의 손상진단 및 고장예측이 필요한 상황이다.

본 연구에서는 이러한 손상진단 방법의 하나로 신뢰도 함수를 이용한 계측제어계통의 수명을 예측함으로써 적절한 PCB(Printed Circuit Board) 교체를 통해 불시에 발생할 수 있는 기기고장을 사전에 방지하고자 한다. 따라서 본 논문에서는 신뢰도 함수를 통한 수명 예측 방법을 제시하고 이를 생존분석 분야에서 사용되는 인공지능 모델을 통해 추정함으로써 모델 간의 차이점을 분석하고 보다 나은 모델을 제안하고자 한다.

## 2. 신뢰도 함수 추정 방법

### 2.1 신뢰성 척도와 잔여 수명

계측제어계통은 전자부품이 조합된 다량의 PCB로 구성되어 있다. 이러한 기기의 수명을 신뢰도 함수를 통해서 보다 체계적이고 과학적으로 접근하기 위해서는 시스템의 고장을 수학적으로 모델링 할 필요가 있다. 시스템은 여러 개의 부품으로 구성되므로 시스템의 고장은 부품의 고장과 밀접하게 관련되어 있다. 따라서 시스템의 고장을 모델링하기 위해서는 먼저 부품 고장을 모델링해야 한다. 부품에는 수리 가능한 것과 수리가 불가능한 것이 있다. 수리 불가능 부품의 경우에는 최초 고장만을 고려하면 되지만 수리 가능 부품에 있어서는 수리 활동이 후속 고장에 영향을 미치므로 최초 고장을 후속 고장과 구별하여야 한다. 이와 같이 부품의 유형에 따라 고장의 수학적 모델이 다를 수 있지만, 본 논문에서는 최초 고장의 모델링에 대해 중점적으로 다루고자 한다.

부품의 상태는 작동 혹은 고장의 둘 중 하나로 구분될 수 있다. 또한 부품의 고장은 제조당시에 발생한 결함으로 인해 이미 고장상태에 있는 경우와 작동상태에서 가동되는 어느 시점 이후에 고장이 난 경우로 나누어 볼 수 있다. 전자는 정적 고장으로 작동 즉시 고장상태를 검출할 수 있게 된다. 후자는 동적 고장으로 수명이 0이면 정적 고장과 일치하게 된다. 따라서 정적 고장은 동적 고장의 특수한 형태로 취급할 수 있다.

본 절에서는 수리 불가능한 부품의 신뢰성을 평가하기 위한 척도를 소개하고 신뢰성 척도를 활용한 고장예측 방법에 대해 설명한다(Kapur et al., 2014). 일반적으로 수명  $T$ 는 고장 밀도함수  $f(t)$ 와 고장 분포함수  $F(t)$ 를 갖는 연속변수로 가정한다. 이때, 신뢰도 함수  $R(t)$ 는 시스템 혹은 부품이 작동을 시작하여 특정 시점까지 고장 나지 않고 여전히 작동되고 있을 확률로 다음 식(1)과 같이 정의된다.

$$R(t) = \Pr(T > t) = 1 - \int_0^t f(u) du \quad (1)$$

$$= \int_t^\infty f(u) du = 1 - F(t)$$

고장률 함수  $h(t)$ 는 측정 시점까지 고장 나지 않고 작동하던 부품이 다음 순간에 고장 나게 될 가능성이 어느 정도인가를 나타내는 척도로써 다음 식(2)와 같이 정의된다.

$$h(t) = \frac{f(t)}{R(t)} = \frac{-R'(t)}{R(t)} = -\frac{d}{dt} \ln R(t) \quad (2)$$

평균수명  $MTTF$ (Mean Time To Failure)는 수리 불가능한 부품일 경우 당해 부품의 평균수명이라 할 수 있으며 다음 식(3)과 같이 정의된다.

$$MTTF = \int_0^\infty t f(t) dt = \int_0^\infty R(t) dt \quad (3)$$

상기 식들을 통해 신뢰도 함수와 고장률, 평균수명과의 관계를 알 수 있다. 따라서 본 논문에서는 이러한 신뢰성 척도 간의 관계를 바탕으로 고장예측을 위한 신뢰도 함수를 도출하고 이에 따른 평균수명을 제시함으로써 계측제어시스템의 환경변수에 따른 잔여 수명의 관계를 인공지능 모델을 통해 도출하는 다양한 방법을 비교하였다.

## 2.2 고장데이터

특정 부품(대상 제품의 수준이 시스템 등 다양하나 주 대상이 부품이므로 이로 통칭함)의 수명분포에 대한 정보를 얻기 위해서는 그 부품에 대한 고장데이터가 필요하다. 고장데이터는 주로 여러 개의 동일한 부품을 작동시키는 고장시험을 통해 얻을 수 있다. 만약 모든 부품이 고장 날 때까지 시험을 수행했다면 여기서 얻은 자료를 완전 자료(Complete data)라고 부른다. 그러나 시간적 혹은 경제적인 이유로 어느 시점

에서 시험을 중단했다면 이때 얻어진 자료는 관측중단 자료(Censored data)라고 한다. 불완전자료는 관측중단 자료를 포함하여 시험 중이던 부품이 어떤 이유로 유실되는 등 우리의 통제범위를 벗어난 상황에서도 얻어질 수 있다. 또, 통제된 고장시험 대신 실제 가동상황을 관측하여 부품의 고장데이터를 얻을 수도 있는데 이런 자료를 사용 현장 자료(Field data)라고 부른다.

본 연구는 고장데이터의 획득을 위해 미 국방부의 전자부품 신뢰도 예측 방법인 MIL-HDBK-217F를 바탕으로 계측제어 장비 부품의 고장 밀도함수를 지수분포로 단순 가정하여 고장률을 계산하고 이를 빅데이터로 구축하여 인공지능 모델을 개발하는 것이 주요 목표이다. 이때, 부품의 설계 특성요소(예, 메모리 사이즈, 비트 수, 게이트 수, 트랜지스터 수)는 상수로 고정하고 부품의 운영 환경요소(예, Ambient Temperature, Electrical Stress)에 따른 부품 입력 상수를 조절하여 고장률을 계산하게 된다. 다만, 본 논문은 고장데이터를 바탕으로 신뢰도 함수를 도출함에 있어 인공지능 모델을 활용할 경우 적용되는 모델에 따른 비교연구가 목적이다. 따라서 데이터 생산에 사용되는 시간을 최소화하면서 가장 이상적인 데이터 상태를 통해 선행적으로 연구를 진행하기 위해 Table 1과 같이 확률분포

Table 1 Virtual Failure Data Generation Rules

Feature	Distribution	Shape (k)	Scale (θ)	Weight
Voltage(10 <sup>-3</sup> )	Gamma	5	30	5%
Temp(°C)		15	1.6	35%
Frequency(Hz)		3	10	5%
Power(W)		5	30	5%
No of Pins	Uni-form	5	30	20%
VSR*		On = 0 Off = 1		10%
JTCM**				10%
ESCM***			5%	
Etc.				5%

\*VSR : Voltage Stress Ratio

\*\*JTCM : Junction Temp. Calc. Mode

\*\*\*ESCM : Elec. Stress Calc. Mode

를 가정하고 난수 생산을 통해 가상 데이터를 추출하였다.

이때, Feature 별 가중치 및 확률분포는 제작사의 고장원인 분석 결과에 따라 정의하였다. 부품에 가해지는 물리적 조건은 감마분포를 통해 데이터를 생산하였고, 부품의 계산 모드는 On/Off로 구분하여 균등분포에 따라 데이터를 생산하였다. 각 Feature가 수명에 미치는 영향은 가중치로 가정하였고 각각의 고장률 계산을 통해 평균수명을 계산하여 Table 2와 같이 2,000개의 결과를 생산하였다.

Table 2 Virtual Failure Data

No	Vol ( $10^{-3}$ )	Temp ( $^{\circ}\text{C}$ )	...	Event	Time ( $10^3\text{hr}$ )
1	95.729	36.476	...	1	20
2	166.419	23.071		0	5000
3	143.180	28.351		1	204
4	144.393	23.183		1	268
5	121.079	28.206		1	232
:	:	:		:	:

**2.3 신뢰도 함수 추정 방법**

고장데이터를 분석하여 여러 가지 신뢰성 척도를 추정하는 통계적인 추론 방법에는 수명분포에 대해 특정 모델을 가정하지 않는 비모수적(Nonparametric) 방법과 특정 수명분포 모델을 가정하는 모수적(Parametric) 방법이 있다.

주로 사용되는 비모수적 신뢰도 함수 추정방법에는 Kaplan-Meier 곡선(Kaplan-Meier curve)을 이용하는 방법과 로그 순위법(Log-Rank Test)이 있다. 이들은 데이터의 특성을 전혀 반영하지 못하고 시간(Time)과 사건(Event)만을 고려하여 생존율을 추정하는 가장 단순한 방법이다. 모수적 신뢰도 함수 추정 방법은 결과 변수가 정규분포, 이항 분포, 또는 푸아송 분포와 같이 기존에 알고 있는 분포를 따른다는 가정하에 회귀분석을 통하여 신뢰도 함수를 추정하는 방법이다. 흔히 사용되는 모수적 방법에는 Weibull, Exponential, Log-logistic, Log-normal,

Generalized gamma model 등이 있다.

준모수적(Semi-parametric) 추정 방법은 분포에 대한 특정한 가정이 필요 없다는 점에서 비모수적인 특징을 가지고 있으나, 공변량이 주어졌을 때 특정한 식으로 데이터의 특징을 표현할 수 있기에 모수적인 특징도 가지고 있는 방법으로 Cox 비례위험회귀모델(Cox proportional hazard regression model), Cox 회귀모델로 불린다. Cox 회귀모델은 신뢰도 함수가 지수함수(Exponential Function)를 따른다는 것과 두 군의 위험비가 연구 기간 동안 일정하게 유지된다는 비례위험 가정을 포함한다.

Faraggi and Simon (1995)은 Cox 회귀모델의 선형 예측자를 다층 퍼셉트론(Multi-Layer Perceptron, MLP)으로 대체하는 인공지능 기법을 처음으로 제안하였다. 그러나 Xiang et al. (2000)과 Sargent (2001)에 의해 이 모델이 일반적인 Cox 회귀모델보다 우수하지 못한 것으로 판명되었다. Katzman et al. (2018)은 DeepSurv를 통해 딥러닝 프레임워크에서 이러한 모델들을 다시 연구하고 이러한 인공신경망이 C-index (Harrell Jr et al., 1982) 측면에서 고전적인 Cox 회귀모델을 능가할 수 있다는 것을 보였다.

Cox 회귀모델을 기반으로 한 유사한 모델에는 SurvivalNet(Yousefi et al., 2017)이 있다. 이는 신경망을 사용하여 비례적인 Cox 모델을 맞추기 위한 프레임워크로 하이퍼파라미터의 베이시안 최적화를 포함한다. 그리고 Zhu et al. (2016)과 Zhu et al. (2017)은 Cox 방법론을 이미지로 확장했다. 이들은 DeepSurv의 MLP를 CNN(Convolutional Neural Network)으로 대체하고 폐암의 병변 이미지와 전체 슬라이드 조직 병리학 이미지에 이러한 방법을 적용했다.

고장예측을 위한 대안 추정 방법은 시간을 이산화하고 미리 정해진 시간 간격에 대한 신뢰도 함수를 계산하는 것이다. Luck et al.(2017)은 DeepSurv와 유사한 방법을 제안했지만 고장예측을 위한 추가적인 이산 출력 세트를 사용하고 이 시간 간격에서 등회귀 손실(Isotonic Regression loss)를 계산하였다. Fotso(2018)는 신경망을 사용하여 고장확률을 직접 계산하는 Multi-task 로지스틱 회귀를 매개변수화하였고, Lee et al.

(2018)은 확률 질량 함수를 신경망으로 추정하고 Log-likelihood를 Ranking loss와 결합하는 DeepHit이라는 방법을 제안하였다.

언급된 논문들 대부분은 Ishwaran et al. (2008)의 Random Survival Forests(RSF)의 성능을 벤치마킹하였고, RSF는 분할 기준으로 Log-rank 검정을 사용하여 Random Forest를 계산한다. 이는 잎 노드의 누적 위험을 계산하고 이를 앙상블 전체에서 평균한다. 따라서 RSF는 비례성 가정에 제한받지 않는 매우 유연한 연속 시간 방법이다.

본 논문에서는 앞서 생성된 고장데이터를 활용하여 생존함수 추정을 위한 대표적인 인공지능 모델이라 할 수 있는 DeepSurv 모델과 DeepHit 모델을 통해 신뢰도 함수를 추정해 보고 이를 기존 전통적 방식의 신뢰도 함수 추정 방법과 비교해 보고자 한다.

### 3. 인공지능 모델

#### 3.1 모델 구조

DeepSurv(Katzman et al., 2018)는 Faraggi and Simon(1995)에서 제안한 신경망과 유사한 MLP 구조로 Cox 회귀모델의 비례 선형 구조를 딥러닝을 통해 비선형적 모델로 일반화하였다. DeepSurv는 종속변수의 선택이 필요하지 않지만, 적응형 학습을 한다는 측면에서 기존 Cox 회귀모델에 비해 유리한 측면이 있다. 또한, Cox 회귀모델의 Proportional Hazard 특성을 유지하면서 선형 조합을 통해 간단한 Cox 회귀모델에서 간과하게 다룰 수 있는 입력 데이터의 복잡성과 상호작용에 대한 모델링이 가능한 장점이 있다.

DeepSurv는 하나 이상의 은닉층을 통하여 가중치 감쇠 효과, ReLU(Rectified Linear Units) 활성화 함수, Batch 정규화, Dropout, 경사 하강법 등을 통해 비선형 효과를 구현한다. 심층신경망의 최종 은닉층 Output 변수가 Cox 회귀모델의 입력으로 사용되도록 모델 구조에 은닉층을 추가하여 모델의 비선형성을 개선하였다. 출

력은 단일노드이며 네트워크에 의해 추정된 고장률 함수를  $\hat{h}_\theta(x)$ 라고 할 때 Faraggi and Simon(1995)과 유사하게 Loss Function은 다음식(4)를 통해 결정할 수 있다.

$$L(\theta) = - \sum_i \left( \hat{h}_\theta(x_i) - \log \sum_j e^{\hat{h}_\theta(x_j)} \right) \quad (4)$$

DeepSurv는 MLP의 출력 노드를 조절하여 비선형적 모델 분포의 간격을 조절할 수 있으며, 단일데이터 입력에 대한 개별 비선형 분포를 예측할 수 있다. DeepSurv는 다양한 신뢰성 분석에 활용할 수 있고 특히 의료계에서 생존분석의 애플리케이션으로 활용하고 있다(Choi et al., 2020).




Fig. 1 DeepSurv Model Architecture

DeepHit(Lee et al., 2018)는 딥러닝 기법을 신뢰도 분석에 적용하여 신경망을 통해 비모수적 방법으로 Output 변수가 발생하기까지의 시간을 학습하는 모델로써, 시간에 따른 예측인자의 위험도가 변화하는 것을 허용한다.

DeepHit에서 사용하는 데이터는 세 가지 요소로 구성되는데, 기간, 고장 발생 여부, 데이터 특성(Feature)이 그 요소들이다. 목표하고 있는

확률을 학습하기 위해 DeepHit는 아래와 같은 구조를 갖는다.

- Shared Sub-network :  $x$ 로 표현되는 한 데이터의 Feature가 전결합층(Fully-Connected Layer)으로 구성된 레이어를 통과하면 그 결과에 Feature 원본  $x$ 를 더하여  $z = (f_s(x), x)$ 에 해당하는 output 벡터를 출력함. (벡터의 길이는 Feature의 개수)
- Cause-Specific Sub-networks : Shared Sub-network를 통과하고 나온 벡터  $z$ 를 입력으로 하여 대상이 되는 Event의 개수만큼 Cause-Specific Sub-network를 구성하여 기존의 분석 방법들과는 달리 여러 이벤트에 대해서 분석할 수 있음. 각 Cause-Specific Sub-network를 통과하면 Event 별 Output Layer 벡터를 가져오게 됨.
- Output(Softmax) Layer : Event 별 Output Layer 벡터들을 모두 이어붙이고, Softmax 함수를 통과하여 Event  $i$ 가  $j$  시점에 발생할 확률의 추정함.

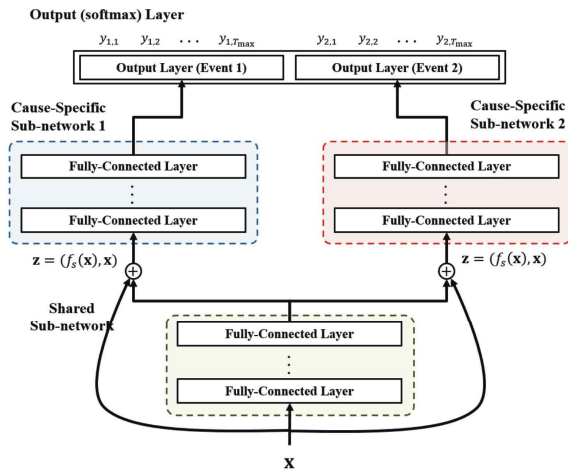


Fig. 2 DeepHit Model Architecture

### 3.2 성능 평가 기준

Cox 회귀분석에서 모델의 적합도를 평가하는 방법에는 Harrell's C-index와 Time-dependent ROC(Receiver Operating Characteristic) 곡선, 그리고 iAUC(integrated Area Under the Curve)

가 있다(D'Agostino and Nam, 2003). Concordance Index라고도 불리는 Harrell's C-index는 가장 고전적인 방법으로 모델에 대한 직관적인 해석이 가능하다. C-index를 계산하기 위해서는 먼저 데이터들을 고장시간의 오름차순으로 나열하고, 고장이 발생한 데이터들보다 오래 생존한 데이터들의 개수를 모두 더한다. 그리고 데이터들을 예측된 고장시간의 오름차순으로 나열하고, 고장이 발생한 각 데이터보다 오래 생존할 것으로 바르게 예측된 데이터의 수를 모두 더한다. 이 두 합을 식(5)와 같이 비율로 나타내면 C-index가 계산된다. C-index는 보통 0과 1 사이의 수로 나타내며, 일반적으로 1에 근접할수록 정확성이 높다고 판단할 수 있으며, 0.5에 근접할수록 정확성이 낮다고 판단한다(Raykar et al., 2007; Yang et al., 2022).

$$C = \frac{\sum_{i \in U} \left( \sum_{T_j > T_i} 1_{f_j > f_i} \right)}{\sum_{i \in U} \left( \sum_{T_j > T_i} 1 \right)} \quad (5)$$

여기서,  $U$ 는 고장이 관찰된 데이터셋이며  $T_i$ 는 실제 관측된 고장시간,  $T_j$ 는 모델이 예측한 고장시간을 나타내고,  $f_i$ 와  $f_j$ 는 각 관측  $i$ 와 예측  $j$ 의 고장 발생 여부를 나타낸다.

Time-dependent ROC 곡선은 Kaplan-Meier 신뢰도 함수 추정량과 Bayes 이론을 이용하여 모든 시점에서 민감도와 특이성을 구하여 확인할 수 있다(Kamarudin et al., 2017). 기본적인 개념은 Logistic Regression의 ROC 곡선과 비슷하지만, 시간에 따른 ROC 곡선의 형태가 다른 것이 특징이다. iAUC는 시점  $t$ 에서의 ROC curve의 적분값인 AUC 값을 이용한 수치를 의미한다(Heagerty and Zheng, 2005).

### 3.3 신뢰도 함수 추정

먼저 전통적인 방식의 준모수적 방법으로 Cox 회귀모델을 통해 신뢰도 함수를 추정하였다. 파이썬에서 생존분석을 수행하기 위해 주로

사용되는 lifeline 패키지를 활용하였으며 이벤트의 발생 및 누락에 대한 데이터를 기반으로 신뢰도 함수 및 신뢰 구간을 계산하였다. 고장데이터는 총 1,280개를 사용하였으며 이 중 985개가 고장이 확인되었고 나머지 295개는 고장을 관찰하지 못한 우측 중도절단(Right Censoring)된 데이터이다. 이 데이터는 절대적 비교를 위해 인공지능 모델에도 훈련데이터로 동일하게 적용하였다. 이를 통해 추정된 Cox 회귀모델은 식(6)과 같이 고장률을 계산하게 되는데 그에 따른 계수는 Table 3과 같이 추정되었다. 여기서,  $h_0(t)$ 는 기준 고장률로, 시간에 따른 고장률을 나타낸다.

$$h(t) = h_0(t) \exp\left(\sum_i^n B_i \times Ftr_i\right) \quad (6)$$

Table 3 Coefficient and Error of Cox regression

Feature(Ftr)	B	exp(B)	Error
Voltage	0.00	1.00	0.00
Temp	0.15	1.16	0.01
Frequency	-0.04	0.96	0.00
Power	-0.01	0.99	0.00
No of Pins	0.60	1.82	0.07
VSR	0.52	1.68	0.07
JTCM	0.23	1.26	0.06
ESCM	0.37	1.45	0.06
Etc	-0.03	0.97	0.00

Table 3에 따르면 Voltage의 회귀계수(B)가 0을 나타내면서 신뢰도 함수 영향이 없다는 결과가 나오고 있으나 실제 가상 데이터 생산 시 5%의 기여도를 가지고 있었던 것을 고려하면 Cox 회귀모델의 C-index가 0.83임에도 정확한 신뢰도 함수를 추정했다고 판단하기 어렵다.

다음으로 인공지능 모델을 통해 신뢰도 함수를 추정해 보았다. pycox 패키지는 생존분석을 위한 Python 패키지로써 시간에 따른 이벤트 발생 확률을 예측하고 생존 곡선을 시각화할 수

있어 신뢰도 함수 추정에 활용할 수 있다. 또한 다양한 통계적 측정 지표를 계산하여 모델의 성능을 평가하기도 한다. 본 연구에서는 DeepSurv 모델에 해당하는 CoxPH 모듈과 DeepHit 모델에 해당하는 DeepHitSingle 모듈을 활용하여 Table 4와 같은 동일한 조건에서 신뢰도 함수를 추정하였다.

Table 4 Hyper-Parameters of Deep-Learning

Hyper-Parameters	Value
No. of Feature	9
No of Nodes	32 x 32
Normalization	batch_norm
Dropout	10%
Activation Func	ReLU

Input 변수의 수는 9개로 동일하며 32개의 Output 노드를 가진 레이어 2개를 사용하여 MLP 구조를 완성하였다. Batch\_size 256개의 데이터마다 정규화를 진행하고 10%의 Dropout을 하였으며 활성화 함수는 ReLU를 사용하였다. 학습률(Learning Rate)은 pycox 패키지에서 제공하는 lr-finder를 사용하여 적용하였고, epoch 수는 512로 지정하였으나 대부분 Early Stopping 되었다. 이렇게 도출된 2개의 모델은 1초라는 비교적 짧은 학습시간으로 신뢰도 함수를 추정할 수 있었으며 테스트 데이터에 대한 Inference 결과를 Cox 회귀모델(CoxRgs)과 함께 비교해 보면 Fig. 3과 같다.

각 모델의 C-index를 확인해 보면 Table 5와 같으며 기존 Cox 회귀모델보다 두 개의 인공지능 모델이 높은 적합도를 보여주었다. 그리고 본 연구에서는 DeepSurv 모델이 후에 발표된

Table 5 C-index of Models

Model	C-index
CoxRgs	0.83
DeepSurv	0.91
DeepHit	0.85

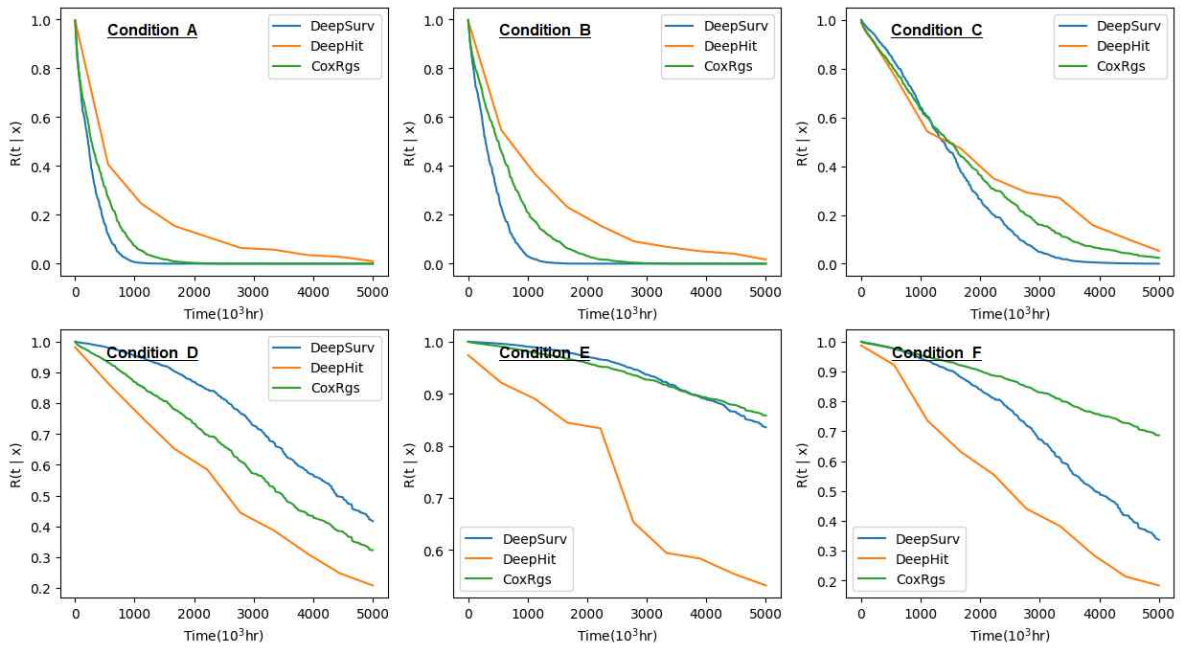


Fig. 3 Test Result of Model Inference

DeepHit 모델보다 더 높은 적합도를 보이고 있으나 이는 임의로 산출된 가상 데이터를 기반으로 한 연구인 점과 좀 더 세부적인 Fine Tuning 과정을 거치지 않은 이유인 것으로 판단된다.

### 3.4 잔여 수명 계산

이렇게 도출된 신뢰도 함수를 통해 본 연구에서는 궁극적으로 계측제어 장비의 잔여 수명을 예측하였다. 현장에서 측정되는 계측제어 장비의 환경조건과 장비의 PCB 상태(Condition) Feature 값들은 인공지능 모델을 통해 상태별 신뢰도 함수를 도출하고 이를 바탕으로 평균수명을 도출하였다. 이를 Fig. 3의 테스트 데이터의 신뢰도 함수를 통해 계산해 보면 Table 6과 같다. 각 Condition 별로 잔여 수명은 늘어나고 줄어들 수 있으며 여기서 주목해야 하는 부분은 3가지 모델의 경향성은 일치한다는 점에서 주어진 실제 수명 예측의 효용성을 가진다고 할 수 있겠다.

본 연구에서는 원전 디지털 계측제어 계통에서 사용되는 보드의 수명 예측을 위하여 신뢰도 함수를 추정하고 환경변수와 기기 상태정보에 따른 잔여 수명 예측을 가상 데이터를 바탕으로 실시하였다. 대상 모델은 준모수적 방법인 Cox 회귀모델과 이를 인공지능망을 통해 비선형 함수로 구현한 DeepSurv 모델과 DeepHit 모델을 Basic한 형태로 적용하여 신뢰도 함수를 추정하였다. C-index를 통해 DeepSurv 모델의 적합도가 더 우수하다는 것을 비교연구를 바탕으로 도출할 수 있었고, 이를 발전소에 적용할 경우 다양한 환경에서 즉각적인 수명 예측이 가능하다는 것을 세 모델의 비교를 통해 증명하였다.

Table 6 Remaining Life time of Models

Cond	CoxRgs	DeepSurv	DeepHit
A	390	265	893
B	634	360	1147
C	1708	1454	1935
D	3273	3840	2691
E	4692	4711	3684
F	4291	3631	2641

Unit :  $10^3$  hr

## 4. 결론



다만, 본 연구에 적용된 가상 데이터들은 여러 가정 사항을 바탕으로 산출되어 이상적인 데이터에 가깝다고 할 수 있으며, 이에 따라 실제 데이터가 적용될 경우 다양한 한계성이 발견되어 추가적인 인공지능 모델 검토와 Fine Tuning 과정이 필요할 것으로 보인다.

## References

- Choi, C. W., Kim, H. J., Shim, E. E., Im, A. Y., Lee, Y. J., Jeong, S. J. and Kim, K. B. (2020). Review of Lung Cancer Survival Analysis with Multimodal Data. *Annual Conference of KIPS* Vol.27 No.2.
- D'Agostino, R. B. and Nam, B. H. (2003). Evaluation of the performance of survival analysis models: discrimination and calibration measures. *Handbook of Statistics 2003*, 23:1-25. DOI: 10.1016/S0169-7161(03)23001-7
- Faraggi, D. and Simon, R. (1995). A neural network model for survival data. *Statistics in Medicine*, 14(1):73-82.
- Fotso, S. (2018). Deep neural networks for survival analysis based on a multi-task framework. arXiv preprints arXiv:1801.05512.
- Harrell, F. E., Califf, R. M., Pryor, D. B., Lee, K. L. and Rosati, R. A. (1982). Evaluating the yield of medical tests. *Journal of the American Medical Association*, 247 (18): 2543-2546.
- Heagerty, P. J. and Zheng, Y. (2005). Survival model predictive accuracy and ROC curves. *Biometrics*; 61(1):92-105.
- Ishwaran, H., Kogalur, U. B., Blackstone, E. H. and Lauer, M. S. (2008) Random survival forests. *The Annals of Applied Statistics*, 2(3) 841-860.
- Kamarudin, A. N., Cox, T., Kolamunnage-Dona, R. (2017). Time-dependent ROC curve analysis in medical research: current methods and applications. *MC Medical Research Methodology*, 17(1):53.
- Kapur, K. C. and Pecht, M. (2014). *Reliability Engineering*, New Jersey, John Wiley & Sons
- Katzman, J. L., Shaham, U., Cloninger, A., Bates, J., Jiang, T., and Kluger, Y. (2018). DeepSurv: personalized treatment recommender system using a Cox proportional hazards deep neural network. *BMC Medical Research Methodology*, 18(1).
- Lee, C., Zame, Z., Yoon, J., and Schaar, M. (2018). Deephit: A deep learning approach to survival analysis with competing risks. *In Thirty-Second AAAI Conference on Artificial Intelligence*, Vol.32 No.1.
- Luck, M., Sylvain, T., Cardinal, H., Lodi, A., and Bengio, Y. (2017). Deep learning for patient-specific kidney graft survival analysis. *arXiv preprint*, arXiv:1705.10245.
- Raykar, V. C., Steck, H., Krishnapuram, B., Dehing-Oberije, C. and Lambin, P. (2007). On ranking in survival analysis: bounds on the concordance index. *In Proceedings of the 20th International Conference on Neural Information Processing Systems*, pages 1209-1216.
- Sargent, D. J. (2001). Comparison of artificial neural networks with other statistical approaches. *Cancer*, 91(8):1636-42.
- Xiang, A., Lapuerta, P., Ryutov, A., Buckley, J., and Azen, S. (2000). Comparison of the performance of neural network methods and Cox regression for censored survival data. *Computational Statistics & Data Analysis*, 34:243-257.
- Yang, J., Jeon, S., Lee, H. S. (2022) Predictive models and visualizations according to outcome variables using R - focusing on regression analyses. *Journal of Health Informatics and Statistics*, Vol.47 : 21-30.
- Yousefi, S., Amrollahi, F., Amgad, M., Dong, C., Lewis, J. E., Song, C., Gutman, D. A., Halani, S. H., Vega, J. E. V., Brat, D. J.

and Lee, A. D. (2017). Predicting clinical outcomes from large scale cancer genomic profiles with deep survival models. *Scientific Reports*, 7(1): 11707.

Zhu, X., Yao, J. and Huang, J. (2016). Deep convolutional neural network for survival analysis with pathological images. *In 2016 IEEE International Conference on Bioinformatics and Biomedicine*, pages 544-547.

Zhu, X., Yao, J., Zhu, F., and Huang, J. (2017). WSISA: Making survival prediction from whole slide histopathological images. *In 2017 IEEE Conference on Computer Vision and Pattern Recognition*, pages 6855-6863.



**이 대 영 (DaeYoung Lee)**

- 한양대학교 토목공학과 학사
- 서울대학교 응용공학과 석사
- (현재) (주)미래와도전 디지털 기획부 부장
- 관심분야: 시계열 예측, 자연어처리, 디지털전환



**이 정 훈 (JeongHun Lee)**

- 서울대학교 원자핵공학과 학사
- 서울대학교 원자핵공학과 석사
- (현재) (주)미래와도전 사업개발그룹 기술이사
- 관심분야 : Big Data 품질, XAI, AI based Numerical Methods



**양 승 혁 (SeungHyeok Yang)**

- 중앙대학교 전자전기공학부 학사
- 중앙대학교 전자전기공학과 석사
- (현재) (주)미래와도전 디지털 기획부 대리
- 관심분야: Data Analysis, Computer Vision, Time Series Prediction & Classification