

〈 논문 〉

## 효율적 유지보수를 위한 도시철도 전동차 브레이크의 시스템 신뢰도 최적화

배철호\* · 김현준\* · 이정환\* · 김세훈\* · 이호용\*\* · 서명원†  
(2006년 5월 2일 접수, 2006년 11월 23일 심사완료)

### Reliability Optimization of Urban Transit Brake System For Efficient Maintenance

Chul-Ho Bae, Hyun-Jun Kim, Jung-Hwan Lee, Se-Hoon Kim,  
Ho-Yong Lee and Myung-Won Suh

Key Words: System Reliability Optimizaition(시스템 신뢰도 최적화), Urban Transit(도시철도), Maintenance(유지보수), Neural Network(인공신경망), Genetic Algorithm(유전자 기법)

#### Abstract

The vehicle of urban transit is a complex system that consists of various electric, electronic, and mechanical equipments, and the maintenance cost of this complex and large-scale system generally occupies sixty percent of the LCC (Life Cycle Cost). For reasonable establishing of maintenance strategies, safety security and cost limitation must be considered at the same time. The concept of system reliability has been introduced and optimized as the key of reasonable maintenance strategies. For optimization, three preceding studies were accomplished; standardizing a maintenance classification, constructing RBD (Reliability Block Diagram) of VVVF (Variable Voltage Variable Frequency) urban transit, and developing a web based reliability evaluation system. Historical maintenance data in terms of reliability index can be derived from the web based reliability evaluation system. In this paper, we propose applying inverse problem analysis method and hybrid neuro-genetic algorithm to system reliability optimization for using historical maintenance data in database of web based system. Feed-forward multi-layer neural networks trained by back propagation are used to find out the relationship between several component reliability (input) and system reliability (output) of structural system. The inverse problem can be formulated by using neural network. One of the neural network training algorithms, the back propagation algorithm, can attain stable and quick convergence during training process. Genetic algorithm is used to find the minimum square error.

#### 1. 서 론

도시철도 전동차는 전기, 기계적으로 결합된 매우 복잡한 구조를 가진 대형시스템으로 고속주

행에 따른 안전성의 확보가 필수적이다. 이러한 안전성 확보를 위해 전동차 유지보수 측면에서 필요한 비용은 전체 운영비의 60% 정도를 차지할 정도로 그 영향력이 크다.<sup>(1)</sup> 따라서 도시철도 전동차의 안전성 확보와 경제적 제약에 대응하는 합리적인 유지보수의 기준 마련이 절실한 실정이다. 본 연구에서는 도시철도 전동차의 합리적 유지보수를 위한 기준지표로써 신뢰도의 개념을 도입하고자 한다.

일반적으로 신뢰도는 ‘시스템이나 기기, 부품

† 책임저자, 회원, 성균관대학교 기계공학부

E-mail : suhmw7447@skku.edu

TEL : (031)290-7447 FAX : (031)290-7447

\* 회원, 성균관대학교 대학원 기계공학부

\*\* 회원, 한국철도기술연구원

등이 주어진 조건하에서, 의도하는 기간 동안, 규정된 기능을 고장 없이 발휘할 확률'로 정의된다.<sup>(2)</sup> 신뢰도의 개념을 전동차의 유지보수에 적용하면 전동차의 각 물리적 시스템들의 기능을 유지할 수 있도록 현재 운용조건에 적합한 정비계획을 세우는 것이다.

최근 Paint 등<sup>(2)</sup>이 최적화 알고리즘 중, 유전자 알고리즘(GA, Genetic Algorithm)을 이용하여 신뢰도 관점에서 신뢰도 최적화를 구현하였고, Mettas 등<sup>(3)</sup>은 목표 신뢰도를 만족하는 동시에 비용함수를 최소화하는 최적화 기법을 제시하였다. 또한, Robert H. Sues 등<sup>(4)</sup>은 MPPSS(Most Probable Point System Simulation)을 이용하여 신뢰도 최적화에 접근하여 시스템 민감도를 고려하는 기법을 소개하는 등 신뢰도에 관련한 많은 연구가 진행되어 왔다.

하지만 유지보수의 관점에서 운영 중인 데이터와 신뢰도를 접목한 분야의 최적화를 수행하는 연구는 미흡한 실정이다. 이유는 크게 두 가지로 볼 수 있다. 첫째는 실제 산업 구조물에 적용한 신뢰도 평가 시스템(RES, Reliability Evaluation System)의 적용 사례가 미비하여 운용되고 있는 유지보수 이력 데이터 확보가 어렵기 때문이다. 둘째는 특정 구조물에 통용 될 수 있는 비용함수(cost function)를 도출하기 어렵기 때문에 이를 이용하여 최적화를 수행할 경우, 그 결과에 오차가 있을 수 있기 때문이다.

본 연구에서는 선행연구<sup>(5-7)</sup>에서 얻어진 유지보수 이력데이터를 인공신경망(NN, Neural Network)을 이용한 학습을 통해 최적화 문제정의를 하였고, 전체시스템의 목표신뢰도를 만족시키는 주요 부품의 신뢰도를 도출하기 위한 역 해석의 해를 구하기 위해 유전자 알고리즘을 이용함으로써 효과적인 주요부품의 신뢰도를 얻을 수 있었다. 구체적 대상으로 VVVF(Variable Voltage Variable Frequency) 전동차의 14개 장치시스템 중, 브레이크 시스템을 최적화하여 유지보수 과정에서 유지해야 할 각 서브컴포넌트(subcomponent)의 최적 신뢰도를 산출하고, 이를 이용한 합리적 정비 주기의 기준을 제시하고자 한다.

## 2. 시스템 신뢰도 최적화

시스템 신뢰도 최적화는 대상 시스템이 안전상

유지해야 할 목표 신뢰도를 충족시키기 위해 해당 시스템을 구성하는 각 장치들의 요구 신뢰도를 계산하는 것이다. 최적화된 각 장치의 신뢰도를 시간의 단위로 변환하면 해당 장치의 고장간격을 유추할 수 있으므로, 유지보수 이력데이터를 이용한 합리적인 정비주기 기준을 마련할 수 있다.

본 연구에서는 최적의 신뢰도를 도출하기 위해 Fig. 1과 같은 역 해석 방법을 적용하였다. 관련 연구<sup>(6,7)</sup>를 통해 개발된 웹 기반의 신뢰도 평가 시스템 데이터베이스로부터 각 장치의 신뢰도와 시스템의 신뢰도와의 관계를 추출하고, 이를 신경망 이론으로 학습하여 역 해석 방법에서 정의한 목적함수를 구성하였다. 구성된 목적함수는 유전자 알고리즘을 이용하여 최소화하였다.

### 2.1 역 해석

일반적으로 매개변수의 결정방법은 기지의 변수를 이용하여 미지의 변수를 결정하는 역 해석 이론이 많이 적용된다. 해석에 관련된 미지의 매개변수를  $x^* \in X$  라 하고 기지의 측정변수를  $y^* \in Y$  라 할 때,  $\Psi: X \rightarrow Y$ 의 함수 관계가 성립된다고 하면, 실제 입력변수와 출력변수와의 관계는 다음과 같이 나타낼 수 있다.

$$y = \Psi(x) + \epsilon \tag{1}$$

이 때,  $\epsilon$ 은 미지의 매개변수  $X$ 에 대한 해석 값  $\Psi(x)$ 과 실험 값  $y$ 사이의 오차이다.

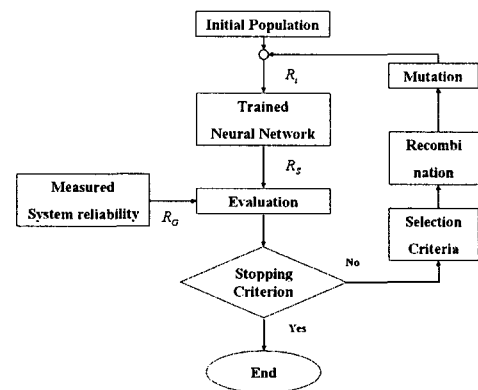


Fig. 1 Flow chart of the hybrid neuro-genetic technique

역 해석 문제의 해를 구하는 방법은 실제로 많은 어려움이 있을 수 있다. 가령 함수의 관계가 일대일대응이 아니라면 역 함수를 구하는 것은 불가능한 일이고, 구한다하더라도 잘못된 값을 구하게 된다. 이를 해결하기 위해 역 문제 해석은 새로 함수를 구성하고 이 함수의 최소 및 최대값을 구하여 역 함수의 해를 얻는 것이다. 일반적으로 목적함수를 최소화하여 미지의 매개변수를 구하는 방법이 널리 사용되고 있다. 이러한 개념을 시스템 신뢰도 최적화에 적용을 시키면, 대상 시스템의 목표 신뢰도(기지변수)와 신뢰도 평가를 통해 계산되는 신뢰도(미지변수) 간의 오차를 최소화하는 각 구성장치의 신뢰도(매개변수)를 구하는 문제로 귀결된다. 이는 식 (2)와 같이 문제정의를 할 수 있다.

$$\text{Min } \Psi = (R_S(X) - R_G)^2 \quad (2)$$

$$X = (R_i)^T,$$

$$\text{s.t. } R_{i,\min} \leq R_i \leq R_{i,\max}, i = 1, 2, \dots, n$$

여기서,  $R_S(X)$ 는 미지변수로서 신뢰도 평가를 통해 계산되는 대상 시스템의 신뢰도,  $R_G$ 는 기지변수로서 안전성 보장을 위해 요구되는 시스템 목표 신뢰도,  $\Psi$ 는  $R_S(X)$ 와  $R_G$ 사이의 오차함수,  $R_i$ 는 매개변수로서 대상 시스템을 구성하는 각 장치의 신뢰도이다.  $R_{i,\min}$ 는 각 장치의 하한 신뢰도로서 기준시간에 대한 각 장치의 현재 신뢰도를 적용하고,  $R_{i,\max}$ 는 상한 신뢰도로서 99.9%의 신뢰도를 적용한다.

### 2.2 인공 신경망

인공신경망<sup>(8)</sup>은 인간이나 동물들이 가지고 있는 생물학적인 뇌의 신경 세포(neuron)를 모델화하여 인공적인 지능을 만드는 것이다. 이러한 신경망에서 중요한 구성 요소는 처리기(processing element)와 이들 상호간의 연결(interconnection)이다. 신경세포의 인공적인 모델을 처리기 또는 유닛(unit)이라 하는데 이는 한 처리기에 연결된 다른 처리기들로부터의 입력에 연결선의 가중치를 고려하여 더한 후 그 결과를 적당한 활성화 함수로 처리하여 연결된 다른 처리기로 출력한다. 이를 수식적으로 표현하기 위해 하나의 처리기와

연결된 다른 처리기들의 출력  $x_i$ 를 해당하는 두 처리기 사이의 연결강도  $w_i$ 로 곱한 값들의 합, 즉 net를 다음과 같이 계산할 수 있다.

$$\text{net} = \sum_{i=1}^n w_i x_i \quad (3)$$

이 합을 다음과 같은 활성화 함수에 적용시켜서 얻은 결과를 그 처리기의 출력으로 하여 이와 연결되어 있는 다른 처리기로 보낸다.

$$y = f(\text{net}) \quad (4)$$

여기서, 활성화 함수  $f(\text{net})$ 는 신경세포의 반응 여부를 결정하는 역할을 한다. 현재 제안된 다양한 신경망 모델은 계층 수, 출력 형태, 데이터 유형, 학습 방법 그리고 활성화 함수와 같은 기준에 따라 분류할 수 있는데, 본 연구에서는 신경망 모델 중 다층 및 순환 신경망인 역전파 인공신경망을 사용하였다. 역전파 학습 알고리즘은 두 단계의 순서에 의해 이루어진다고 볼 수 있다. 첫 번째 단계에서는 입력을 네트워크에 제시하면 이것이 네트워크의 전 방향으로 전파되어 출력을 내고, 이 출력과 목표 출력과의 차이에 미분계수를 곱하여 출력 뉴런에 대한 오차를 계산한다. 두 번째 단계에서는 오차신호가 네트워크의 역방향으로 전파되어 가면서 각 뉴런의 오차 신호가 계산되고, 이것을 바탕으로 연결강도를 수정한다. 이러한 네트워크를 시스템 신뢰도 학습에 적용을 시키면 Fig. 2와 같이 도식적으로 나타낼 수 있다.

Fig. 2에서 알 수 있듯이 모든 유닛은 연속적인 층들 사이에 단지 순방향 연결로만 이루어진 입력층, 은닉층, 출력층을 형성한다. 역전파 인공신경




Fig. 2 Three-layer neural network

망의 학습, 즉 지도학습을 위한 기본 개념은 식 (5)의 정의에서 시작된다.

$$E = \sum_{p=1}^m E_p = \sum_{p=1}^m (R_{T,p} - R_{S,p})^2 \quad (5)$$

여기서,  $E_p$ 는  $p$ 번째 학습패턴에 대한 오차의 제곱항을 의미하며  $m$ 은 패턴 수,  $R_{T,p}$ 는  $p$ 번째 학습패턴에 대한 시스템 신뢰도의 목표 값,  $R_{S,p}$ 는  $p$ 번째 학습패턴에 대한 출력 값을 나타낸다. 학습과정 동안 연결강도는 **Steepest gradient descent method**에 의해 수정되고 출력 값이 목표 값에 근사하게 되었을 때 학습이 종료된다. 본 연구에서는 활성화 함수로 시그모이드(sigmoid) 함수를 사용하였고, 입-출력을 0.1~0.9로 스케일링하였으며, 은닉층의 개수는 7개를 사용하였다. 또한 역전파 학습 알고리즘의 향상을 위해 적응 학습률을 이용하였다.

### 2.3 유전자 알고리즘

유전자 알고리즘<sup>(9-11)</sup>은 진화 알고리즘 중 하나로 자연 진화의 모델에 기초를 둔 확률 최적화 알고리즘이다. 유전자 알고리즘은 **Holland**<sup>(9)</sup>에 의해 개발되었으며, 전통적으로 고정된 길이의 비트형식  $u_i^k \in I \in \{0,1\}^l$ 과 같은 문자열을 사용한다. 목적함수의 값으로부터 가장 좋지 못한 개체를 이탈시키는 방법을 통해 각 개체의 적합성을 일률적으로 판단한다.

Fig. 3은 유전자 알고리즘의 기본 구조를 나타내고 있다. 여기서 알 수 있듯이 유전자 알고리즘은 3가지 연산자(operator), 즉 교배(crossover), 돌연변이(mutation), 선택(selection)을 이용하여 진화과정을 인위적으로 수행하는 것으로 각 연산자의 역할과 최적화 과정에 대한 기본 개념을 다음 네 가지로 분류할 수 있다.

- 1)  $n$ 개의 염색체(chromosome)로 구성된 최초 유전자 집단을 무작위로 구성한다.
- 2) 다음 세대를 구성하는 염색체 후보들을 선별하는 과정으로서 식 (6)을 이용한 적합도가 높은 개체를 확률적인 방법으로 선택한다.

$$\Phi(R_i^k) = \max \{ \psi(R_i^k) \mid R_i^k \in p^k \} - \psi(R_i^k), \forall i \in \{1, \dots, \lambda\} \quad (6)$$

확률적 선택을 위해서 개체  $u_i$ 의 번식률  $P_c$ 는 식 (7)과 같은 상대적 적합방정식에 의해 얻는다.

$$P_c(R_i^k) = \frac{\Phi(R_i^k)}{\sum_{i=1}^{\lambda} \Phi(R_i^k)} \geq 0 \quad (7)$$

3) 선택된 유전자들 중에서 확률적으로 선택된 한 쌍씩을 상호 교배시켜 새로운 염색체 구성한다.  $P_c$ 는 개체마다 재결합의 확률을 의미하고, 일반적으로 [0.6, 1.0] 사이의 값이다. 무작위로 선정된 두 개체들은 다음 세대의 새로운 두 개체로 번식된다.

$$\begin{cases} u_{\alpha}^{k+1} = \{u_{\alpha 1}^k, \dots, u_{\alpha m}^k, u_{\beta(m+1)}^k, \dots, u_{\beta l}^k\} \\ u_{\beta}^{k+1} = \{u_{\beta 1}^k, \dots, u_{\beta m}^k, u_{\alpha(m+1)}^k, \dots, u_{\alpha l}^k\} \end{cases} \quad (8)$$

4) 어떤 유전자가 미치 검증 받지 못하고 도태되는 것을 방지하기 위해 미리 주어진 확률에 의해 돌연변이 시키는 것으로 최적의 값을 구하기 위한 수단으로 이용한다. 유전자 알고리즘에서 돌연변이는 비트 문자 레벨에서 이루어지며, 전형적인 유전자 작용자이다. 돌연변이 확률  $P_m$ 은 매우 작은 값을 가지며, 하나의 비트를 식 (9)와 같이 변화시킴으로써 작용한다.

$$u_{ij}^{k+1} = \begin{cases} u_{ij}^{k+1} & \vartheta_{ij} > p_m \\ 1 - u_{ij}^{k+1} & \vartheta_{ij} \leq p_m \end{cases} \quad (9)$$

여기서,  $\vartheta_{ij}$ 는 각 비트를 새로이 만드는 [0, 1] 사이의 무작위 변수이다.

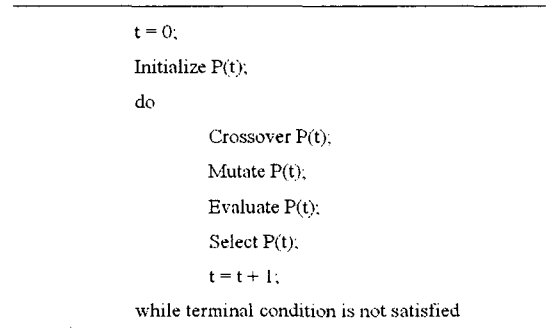


Fig. 3 Fundamental structure of genetic algorithm

이와 같이 유전자 알고리즘은 각 세대에서 적합도가 낮은 열성 유전자는 도태시키고 우수개체들끼리 상호교차 시켜서 우수한 새로운 세대를 만드는 과정을 반복적으로 수행함으로써 최적해를 구하게 된다.

### 3. 브레이크 시스템의 신뢰도 평가

#### 3.1 마찰제동 및 공압제어 시스템

일반적으로 도시철도 전동차에 적용되는 제동의 종류는 상용제동, 비상제동, 보안제동, 정차제동, 주차제동 등이 있으며 제동방식에는 견인전동기와 인버터를 통해 이루어지는 전기적인 회생제동 방식과 차륜이나 디스크와 마찰체의 접촉 마찰 저항을 통해 이루어지는 마찰제동 방식으로 나누어진다. 정상적인 경우, 감속의 대부분은 회생제동 방식이 적용되고, 일정속도 이하가 되거나 회생제동력이 부족하게 되면 마찰제동 방식이 작용한다. 이러한 마찰제동 방식의 경우 마찰제동 및 공압제어(FBPC, Friction Brake & Pneumatic Control) 시스템이 작동하게 되는데 본 연구에서는 이를 대상으로 한다.

마찰제동 및 공압제어 시스템은 공기를 이용하여 도시철도 전동차를 정지시키거나 정지된 상태를 유지하는 시스템이다. 이 시스템은 제동 제어부(brake control), 공기압축기(air compressor), 마찰

제동부(friction brake), 공기통(reservoirs), 밸브류(valves), 기적 보완기(horn) 등으로 구성되어 있다. 제동 제어부는 제동 작용장치(BOU, Brake Operation Unit)를 비롯하여 전동차의 제동력 확보를 위한 모든 제어용 부품을 말한다. 여기서 제동 작용장치는 전기적 신호에 의해 제어되며 전동차의 제동 시, 공기통으로 공기의 충기 또는 배기를 제어한다. 마찰 제동부는 제동 제어부로부터 신호를 받아 전동차의 속도 감소나 정지를 위해 운동에너지를 열에너지로 변환하여 발생된 열에너지를 발산하는 장치이다. 밸브는 공기통으로 공기의 충기 또는 배기를 조절하는 장치로 제동 제어부에 의해 제어된다. 일반적으로 밸브는 Poppet type과 Sliding action type으로 나뉘며 Poppet type 밸브는 유체흐름제어, 압력 및 방향 제어에 사용되고, Sliding action type 밸브는 균일한 압력을 필요로 하는 곳에 사용된다.

일반적으로 대상 시스템의 신뢰도를 평가하기 위해서는 장치체계(BOM, Bill of Material), 기능블록도(FBD, Function Block Diagram), 신뢰도블록도(RBD, Reliability Block Diagram)가 필요하다. 따라서 본 연구에서는 위와 같은 마찰제동 및 공압제어 시스템의 각 장치 상호간 기능적 관계 및 흐

Table 1 Part list of brake system

Subsystem	Units & Parts
Friction Brake & Pneumatic Control	<ul style="list-style-type: none"> <li>• Brake Control</li> <li>• Valves</li> <li>• Brake</li> <li>- Brake disc</li> <li>- Brake pad</li> <li>• Compressed Air Supply</li> <li>• Reservoir</li> <li>• Pneumatic Horn</li> </ul>

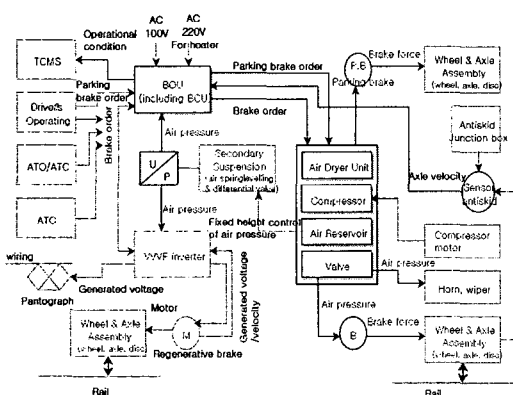


Fig. 4 Functional block diagram




Fig. 5 Reliability block diagram

Table 2 The result of reliability evaluation for FBPC

Subsystem	Developed system	
	Failure rate (x 10 <sup>-6</sup> hour)	MTBF (hour-Unit)
Brake Control	202.2	4,946
Valves	106.9	9,355
Friction Brake	122.6	8,157
Air Compressor	8.0	125,000
Reservoir	20.6	48,544
Pneumatic Horn	25.6	39,063
<b>Total(unit)</b>	<b>485.9</b>	<b>2,058</b>

를 통해 Table 1, Fig. 4, Fig. 5에 이들을 나타내었다. 여기서 Table 1은 대상 시스템의 장치체계, Fig. 4는 기능블록도, Fig. 5는 신뢰도블록도이다. 마찰제동 및 공압제어 시스템의 신뢰도블록도는 Fig. 5와 같이 시스템을 구성하는 각 장치의 직렬구조로 표현할 수 있는데, 이는 시스템을 구성하는 각 장치 중 하나라도 고장이 발생하면 제동성능 및 전동차 운행에 직접적인 영향을 미치기 때문이다.

3.2 신뢰도 평가 및 결과

도시철도 전동차와 같은 복잡시스템의 유지보수이력 데이터를 이용한 신뢰도 평가를 위해서 본 연구에서는 다음과 같이 가정한다.

- 1) 전동차를 구성하는 각 장치(subcomponent)의 고장은 독립적으로 발생한다.
- 2) 전동차의 각 장치의 상태는 고장 또는 가용으로 구분된다.
- 3) 전동차를 구성하는 각 장치의 교환 및 수리이력 데이터를 고장으로 간주한다.
- 4) 전동차의 고장은 우발고장이므로 고장은 지수분포를 따른다.

일반적으로 고장이 지수분포를 따르는 시스템의 신뢰도 평가 척도는 고장률(failure rate), 평균 고장간격(MTBF, Mean Time Between Failures), 평균 고장거리(MDBF, Mean Distance Between Failures) 등을 사용한다. 전동차 편성 차량에 대한 목표 신뢰도 지표는 현재 운행 중인 검수 기준에 근거하면 MTBF가 115hrs, 이에 대한 마찰제동 및 공압제어 시스템의 목표 신뢰도 지표는 MTBF가 898hrs로 나타났다. 이에 대하여 본 연구자들은 선행 연구로써 도시철도 전동차의 5년간 유지보수 이력 데이터<sup>(1)</sup>를 BOM코드(장치구분), 고장코드(고장현상, 원인, 결과), 누적고장수, 가동시간 등으로 구분하고, 이를 이용하여 웹기반의 VVVF 전동차의 신뢰도 평가 프로그램<sup>7)</sup>을 개발한 바 있다. 개발된 신뢰도 평가 프로그램을 이용하면 현재 전동차의 서브시스템(subsystem)인 마찰제동 및 공압제어 시스템은 2량 1unit단위로 구성되어 있으며 10량 1편성이기 때문에 편성에 대한 시스템의 신뢰도 지표는 고장률 485.9×10<sup>-6</sup>, MTBF는 2,058hrs 이다. 이는 Table 2에 나타내었다.

4. 브레이크 시스템의 신뢰도 최적화

4.1 주요부품 선별

마찰제동 및 공압제어 시스템의 신뢰도를 최적화함에 앞서 주요부품 선별을 선행하였다. 이는 도시철도와 같은 복잡 시스템의 경우, 시스템을 구성하는 많은 부품의 수는 수식의 근사화 및 최적화 계산량에 큰 부담을 주기 때문이다. 따라서 본 연구에서는 브레이크 시스템의 신뢰도에 영향을 주는 영향도에 따라 주요부품을 선별함으로써 근사화 과정에서 필요한 입, 출력 데이터의 양 및 최적화 계산 비용을 절감하였다. 주요부품은 식 (10)과 같은 민감도 함수의 개념을 이용한 신뢰도 관점에서의 영향력<sup>3)</sup>을 구하여 선별할 수 있다.

$$G = \left[ \frac{\partial y}{\partial x_1}, \frac{\partial y}{\partial x_2}, \dots, \frac{\partial y}{\partial x_n} \right]^T \tag{10}$$

식 (10)을 주요부품 선별을 위해 전동차 브레이크 시스템에 적용하면, 식 (11)에서와 같이 각 구성장치의 신뢰도 변화량에 대한 마찰제동 및 공압제어 시스템의 신뢰도 변화량으로 영향력을 정의하고 그 지표를 구할 수 있다.

$$I_R(i) = \frac{\partial R_{FBPS}}{\partial R_i} \tag{11}$$

$$0 < I_R(i) < 1, i = 1, 2, \dots, 6$$

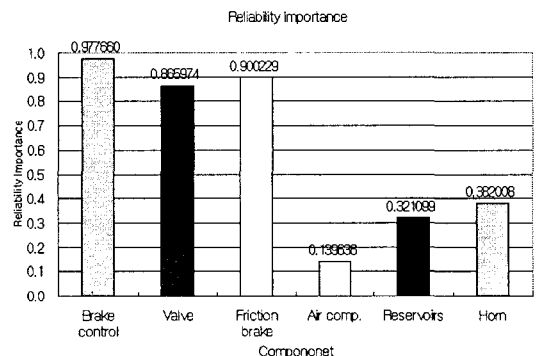


Fig. 6 Reliability importance

마찰제동 및 공압제어 시스템의 신뢰도를 개선하기 위한 영향도는 Fig. 6과 같이 제동 제어부 ( $I_{R,BC}=0.978$ ), 밸브류( $I_{R,V}=0.866$ ), 마찰 제동부 ( $I_{R,FB}=0.900$ ), 기적 보완기( $I_{R,H}=0.382$ ), 공기통 ( $I_{R,R}=0.321$ ), 공기압축기( $I_{R,AC}=0.134$ ) 순으로 나타났다. Fig. 6에서도 알 수 있듯이 기적 보완기, 공기통, 공기압축기 장치는 영향도가 제동 제어부, 밸브류, 마찰 제동부에 비해 현저하게 미비하다. 따라서 본 연구에서는 마찰제동 및 공압제어 시스템의 신뢰도 개선을 위해 주요부품 및 설계변수로서 제동 제어부, 밸브류, 마찰 제동부의 신뢰도를 선정하였다.

4.2 문제정의

마찰제동 및 공압제어 시스템의 신뢰도를 최적화하기 위해 역해석 방법을 이용하면 그 문제는 식 (12)와 같이 정의된다.

$$\text{Min } \Psi = (R_{FBPS}(X) - R_G)^2 \quad (12)$$

$$X = (R_{BC}, R_V, R_{FB})^T,$$

s.t.  $0.834 \leq R_{BC} \leq 0.999$

$0.909 \leq R_V \leq 0.999$

$0.896 \leq R_{FB} \leq 0.999$

여기서,  $R_{FBPS}(X)$ 는 신뢰도 평가 시스템을 통해 계산되는 마찰제동 및 공압제어 시스템의 신뢰도를 말하고,  $R_G$ 는 현재 운행 중인 전동차 편성 차량에 대한 검수 기준에 근거한 목표 신뢰도를

의미한다.  $X$ 는 마찰제동 및 공압제어 시스템을 구성하고 있는 장치, 즉 제동 제어부, 밸브류, 마찰 제동부의 3×1 신뢰도 행렬이다.

최적화는 매개변수인  $X$ 벡터에 대하여 평가되는 시스템 신뢰도  $R_{FBPS}$ 와 검수 기준에 의거한 목표 신뢰도  $R_G$ 의 오차의 제곱항으로 정의되는 오차함수  $\Psi$ 의 최소화가 목적이다. 이때, 매개변수인 각 장치는 검수 기준에 근거한 기준 시간 898hrs에서 신뢰도 평가 시스템을 통해 예측되는 신뢰도를 하한 신뢰도로, 상한 신뢰도로써 99.9%의 신뢰도를 설정하여 자유롭게 움직일 수 있도록 하였다.

또한, 시스템의 신뢰도와 장치간의 신뢰도 관계를 나타내는  $R_{FBPS}(X)$  함수를 도출하기 위하여 설계변수의 일정 증분에 따른 목적함수인 대상 시스템의 신뢰도를 추출하여 이를 인공 신경망 이론에 따라 학습하였다. 이는 최적화를 수행하는 동안 각 단계(step)마다 신뢰도 평가를 필요로 하기 때문에 함수 값의 반복 계산량을 줄이는 효과도 있지만, 무엇보다 웹기반으로 구성된 신뢰도 평가 시스템의 유지보수 이력 데이터를 데이터베이스로부터 추출하여 최적화에 이용하기 위함이다.

본 연구에서는 영향력 분석을 통해 선별된 주요부품의 신뢰도 구간을 0.865, 0.89, 0.915, 0.94, 0.965, 0.99까지 6등분하고, 인공 신경망 학습을 위해 입력층은 3개 주요부품의 신뢰도 조합인 3개의 유닛, 출력층은 대상 시스템의 신뢰도인 1개 유닛, 패턴 수는 1,331개를 사용하였으며, 은닉층은 7개 유닛을 사용하였고, 적응 학습률을 위한 에러율 0.001, 학습 증가율은 1.05, 학습 감소

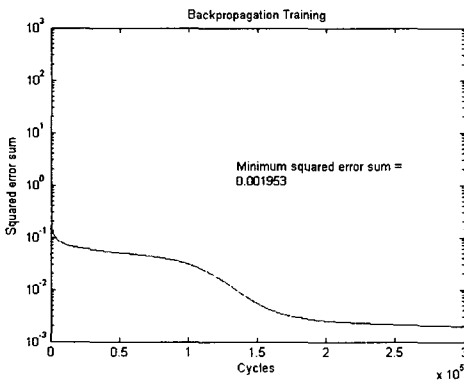


Fig. 7 Neural network training result




Fig. 8 Target value with network output value

율을 위한 에러율 0.7로 하였다. Fig. 7은 학습 결과를 나타낸 것이고, Fig. 8은 학습을 통해 출력값을 비교한 것이다. Fig. 7에서 알 수 있듯이 최종 SSE(Sum Square Error)은 0.001953으로 안정적인 값을 알 수 있다.

4.3 신뢰도 최적화 및 결과

인공 신경망을 이용해 정식화된 최적화 문제를 설계변수  $R_{BC}$ ,  $R_V$ ,  $R_{FB}$ , 즉 마찰제동 및 공압 제어 시스템을 구성하는 주요부품의 최적 신뢰도를 도출하기 위해 유전자 알고리즘을 적용하였고, 최대값을 구하는 문제로 변형하기 위해 적합도 함수를 식 (13)과 같이 설정하였다.

$$fitness = \frac{1}{[R_{FBPC}(X) - R_G]^2} \quad (13)$$

이 때 모집단수(population size)는 150, 염색체의 길이는 44, 교배율은 0.25, 돌연변이 확률은 0.01, 선택방식은 Roulette Wheel Selection방식을 선택하였다. 최적화는 검수 기준을 만족하기 위한 신뢰도 0.90, 0.95의 2가지 경우에 대하여 수행되었고, Fig. 9~10은 적합도 함수의 수렴 결과를 나타낸다. Fig. 9~10은 CASE 1( $R_G=0.90$ )의 경우 79번째 세대, CASE 2( $R_G=0.95$ )의 경우 97번째 세대에서 최적해가 수렴함을 나타낸다. 이 때 주요부품의 최적 신뢰도는 Table 3에 나타내었다. Table 3에서 알 수 있듯이 CASE 1에서 오차율 0.0222%, CASE 2에서 오차율 0.021%로서 두 경우 모두 좋은 결과를 나타내었으며 이로부터 신뢰도를 역해석 이론과 Neuro-genetic algorithm을 적

용하여 최적 신뢰도를 구하는 것이 효과적임을 알 수 있었다.

4.4 정비주기 기준 도출

도시철도 전동차에서 고장은 우발고장으로 신뢰도 지표는 지수분포를 따르므로 일반적인 관계를 이용하면 식 (14)와 같이 신뢰도 함수를 나타낼 수 있다.

$$R(t) = exp\left[-\int_0^t \lambda(t)dt\right] = exp[-\lambda t] \quad (14)$$

여기서,  $t$ 는 각 장치의 가동시간이고,  $\lambda(t)$ 는 고장률 함수를 말한다. 식 (14)는 고장이 지수분포 함수를 따르는 장치의 신뢰도 지표인 MTBF를 이용하면 식 (15)와 같이 표현된다.

$$R(t) = exp\left[-\frac{t}{m}\right] \quad (15)$$

여기서,  $m$ 은 장치의 평균고장간격 MTBF를 의미한다. 이러한 식 (14), (15) 함수식을 이용하여 역함수로 풀어 시간영역으로 변환하면 식 (16)과 같다.

$$t = -\frac{1}{\lambda} \log_e R = -m \log_e R \quad (16)$$

앞서 수행한 마찰제동 및 공압제어 시스템을 구성하는 각 장치의 최적 신뢰도 결과수준을 만족하는 정비주기를 계산하기 위해 최적 신뢰도, 현




Fig. 9 Generation history of CASE 1( $R_G=0.90$ )




Fig. 10 Generation history of CASE 2( $R_G=0.95$ )



Table 3 Final analysis result

	CASE 1(R <sub>G</sub> =0.90)		CASE 2(R <sub>G</sub> =0.95)	
	Optimum Result	Maintenance Cycle(hrs)	Optimum Result	Maintenance Cycle(hrs)
R <sub>BC</sub> <sup>*</sup>	0.9572	216.33	0.9783	108.50
R <sub>V</sub> <sup>*</sup>	0.9783	205.23	0.9883	110.09
R <sub>FB</sub> <sup>*</sup>	0.9623	312.69	0.9829	140.34
	Result Value	Reference Value	Result Value	Reference Value
R <sub>S</sub>	0.9009	0.9011	0.9505	0.9503
ER(%)	0.0222		0.0210	

고장률 및 평균수명주기, 정비시간 등을 이용하여 식 (16)을 재구성하면 다음과 같다.

$$T_i = -\frac{1}{\lambda_i} \log_e R_i^* = -m_i \log_e R_i^* \quad (17)$$

$i = 1, 2, \dots, n$

여기서,  $T_i$ 는  $i$ 번째 장치의 정비주기,  $\lambda_i$ 는  $i$ 번째 장치의 현 고장률,  $m_i$ 는  $i$ 번째 장치의 현 평균고장간격,  $R_i^*$ 는  $i$ 번째 장치의 최적 신뢰도이다. 식 (17)을 이용하여 두 가지 경우의 목표 신뢰도 0.90, 0.95를 유지하기 위해 주요부품의 정주기기는 Table 3에 나타내었다. 현재 전동차의 유지보수과정에서 운영하고 있는 검수/정비주기에서 브레이크 시스템의 경우는 일상검사에 해당하고, 일상검사는 3일 간격으로 이루어지고 있다. 전동차의 1일간 10시간의 가동시간을 고려하면 30시간마다 검수/정비가 이루어진다고 볼 수 있다. 이를 Table 3의 결과와 비교하면 안전성의 확보와 동시에 유지보수 비용을 절감할 수 있음을 알 수 있다.

### 5. 결론

본 연구에서는 유지보수 이력 데이터를 시스템 관점에서 접근하여 유지보수 검수 기준을 만족하는 장치의 요구 신뢰도를 도출하는 방법을 제시하였다. 시스템 신뢰도 최적화 기법을 도시철도

전동차의 브레이크 시스템에 적용하여 최적의 신뢰도를 산출하고, 주요부품의 정비주기 기준을 제시하기 위하여 적용함으로써 다음과 같은 결론을 얻었다.

(1) 브레이크 시스템의 근간이 되는 마찰제동 및 공압제어 시스템은 6개 하위장치로 구성되었으며, 이들 하위장치 중 하나라도 고장이 발생하면 제동성능 및 전동차 운행에 영향을 미치기 때문에 직렬구조의 신뢰도 관계를 보였다.

(2) 최근 5년간 유지보수 이력 데이터를 이용하여 현재 VVVV 전동차 브레이크 시스템의 신뢰도를 분석함으로써 시간 변화에 따른 주요 신뢰도 조합을 추출할 수 있었다.

(3) 브레이크 시스템을 구성하는 각 장치의 신뢰도 영향력을 분석함으로써 최적화 과정에서 필요한 입, 출력 데이터의 양 및 계산 비용을 절감할 수 있었고, 정비주기 기준 마련의 대상을 정의할 수 있었다.

(4) 브레이크 시스템의 목표 값을 만족하는 주요부품의 신뢰도를 얻기 위해 본 연구에서는 역해석 이론과 Neuro-genetic algorithm을 혼용한 최적화 기법을 제시하였다. 최적화를 통해 얻은 주요 부품의 최적 신뢰도를 역함수를 이용하여 시간의 단위로 변환, 정비주기 기준을 제시할 수 있었다.

### 후 기

본 논문은 한국과학재단 목적기초연구(R01-2004-000-10938-0)와 교육인적자원부, 산업자원부, 노동부의 출연금으로 수행한 최우수연구실 및 해외공동연구(KRF-2005-213-D00020) 지원사업의 연구결과입니다.

### 참고문헌

- (1) Lee, H. Y., Park, K. j., Ahn, T. K., Kim, G. D., Yoon, S. K. and Lee, S. I., 2003, "A Study on the RAMS for Maintenance CALS System for Urban Transit," *Korean Society for Railway*, Vol. 6 No. 2, pp. 108~113.
- (2) Laura Painton and James Campbell, 1995, "Genetic Algorithms in Optimization of System Reliability," *IEEE TRANSACTIONS ON*

- RELIABILITY*, Vol. 44, No. 2, pp. 172~178.
- (3) Adamantios Mettas, 2000, "Reliability Allocation and Optimization For Complex Systems," *PROCEEDINGS Annual RELIABILITY and MAINTAINABILITY Symposium*, pp. 216~221.
- (4) Robert H. Sues and Mark A. Cesare, 2005, "System Reliability and Sensitivity Factors via the MPPSS Method," *Probabilistic Engineering Mechanics*, Vol. 20, No. 2, pp. 148~157.
- (5) Kim, K. H., Bae, C. H., Lee, H. Y. and Suh, M. W., 2004, "A Study on the Standardization of Failure Classification Method for IT Maintenance System of Urban Transit," *The Korea Society of Automotive Engineers Fall Conference*, Vol. 3, pp. 1361~1365.
- (6) Lee, H. Y., Bae, C. H., Kim, K. H. and Suh, M. W., 2005, "A Study on Implementation of a BOM Management System Using Component Technique for Maintenance System of Urban Transit," *The Korean Society of Mechanical Engineers A*, Vol.29, No.1, pp.124~131.
- (7) Bae, C. H., Kim, S. B., Lee, H. Y., Chang, S. H. and Suh, M. W., 2005, "A Study on Development of the Reliability Evaluation System for VVVF Urban Transit," *Transactions of KSAE*, Vol. 13, No. 5, pp. 7~18.
- (8) Rumelhart, D. E., Hinton, G. E. and Williams, R. J., 1986, "Learning Internal Representations by Error Propagation," *In Parallel distributed processing: exploration in the micro-structure of cognition*, Vol. 1, pp. 318~362.
- (9) Holland, J. H., 1975, *Adaptation in Natural and Artificial Systems*, Ann Arbor, Michigan: The University of Michigan Press.
- (10) Furukawa, T. and Yagawa, G., 1995, "Parameter Identification Using an Evolutionary Algorithm and Its Performance Under Measurement Errors," *Computational Mechanics '95*, Springer, pp. 122~127.
- (11) Mitsuo Gen, Runwei Cheng, 1997, *Genetic Algorithms and Engineering Design.*, A Wiley-Interscience Publication.