

지능형 Active Network를 이용한 전력구간 및 교통사고구간 자동판단

홍유식* 이상윤**

◆ 목 차 ◆

- | | |
|-----------------|--------------|
| 1. 서론 | 3. 교통사고구간 진단 |
| 2. 전력 사고구간 자동판단 | 4. 결론 |

1. 서론

액티브 네트워크는 통신망에서 새로운 서비스를 보다 신속하고 경제적으로 도입하고 망자원을 보다 적절하게 활용할 수 있도록 해주는 망이다. 그러므로, 요즘, 액티브 네트워크를 이용하여 보안에 활용할 경우 사이버 공격자의 실제 위치를 역추적 할수 있고, 네트워크에 대한 접근을 원천적으로 차단 및 고립화 시킬수 도있다. 최근 데이터 및 방송과 전화 분야에서 다양한 기술들이 개발돼 많은 종류의 서비스가 제공되고 있다. 방송·통신의 통합서비스에 대한 가입자의 욕구도 커지면서 상호 다른 매체간의 통합·융합화도 일반화되고 있는 상황이다. 이러한 배경에서 정보통신 부에서는 유·무선 통합망을 이용해 다양한 차세대 멀티미디어 서비스를 제공할 수 있도록 IT839 전략의 3대 인프라중 하나로 광대역통합망(BcN) 구축을 추진하고 있다.

BcN사업은 오는 2010년까지 현재 1.5~2Mbps급 수준의 초고속인터넷 서비스 속도를 대폭 향상시킨 50~100Mbps급 광대역통합망을 구축, 2000만 유·무선 가입자에 통신·방송·인터넷을 융합한 멀티미디어 서비스를 제공한다는 내용이다. 정통부는 KT·SK텔레콤·데이콤이 주도하는 3개 컨소시엄을 BcN 사업자로 선정, 1차 사업을 진행하는 등 사업에 탄력을 불어

고 있다. BCN 구축을 위한 가입자망 접속 기술로서 여러가지 방식이 거론되고 있다. 음성·데이터, 통신·방송이 융합된 품질보장형 서비스 제공을 위해서는 광가입자망(FTTH : Fiber-To-The-Home) 기술이 필수적이다. FTTH 구현기술은 방식별로 크게 AON(Active Optical Network)방식과 PON(Passive Optical Network)방식으로 구분된다. 뿐만 아니라, AON 방식은 기존 스위치 장비를 이용하여 각 가정까지 광케이블 공급하는 구조이며 PON 방식은 가입자 근처에 수동 광소자를 설치한 후 각 가정까지 광케이블을 공급하는 구조이다. PON 방식에도 CWDM(Coarse Wavelength Division Multiplexing), DWDM-PON(Dense WDM-PON), E-PON (Ethernet-PON) 등 다양한 기술이 개발중이거나 개발 완료되어 있어 각 통신망 사업자들은 망구성 방식 및 기술별 특성에 따른 장단점 분석을 통해 전략적 선택을 한 후 FTTH를 구현할 것으로 보인다. 이러한 방식으로 각 가정까지 광케이블이 공급되면 현재 고객간의 단순통화 및 저속도의 인터넷서비스는 50Mbps~100Mbps 속도로 대역폭의 부족 없이 전화·방송·데이터 서비스를 통합한 멀티미디어 융합 서비스로 제공될 수 있다. 이는 기존의 PC 기반의 서비스에서 TV 기반 서비스로의 패러다임 변화를 의미하며, 지능화된 TV와 영상단말 등이 사용자의 편의성과 다양한 요구를 만족시키는 고객 중심의 네트워크 환경이 조성된다.

주요 예상서비스를 살펴보면, 거실에서 HD급 양방향 지능형 방송서비스 시청과 동시에 고품질 화상전

* 상지대학교 전산학과 부교수

** 국립 원주대학 여성교양과 전임강사

화 서비스를 이용할 수 있으며 자녀들은 각 방에서 기존 초고속인터넷 이외에, 양질의 교육서비스와 각종 게임과 같은 콘텐츠(Contents) 역시 HD급 대화면으로 주문형(On Demand)으로 받을 수 있게 된다. 개인의 다양한 욕구를 충족시켜줄 수 있는 개인 맞춤형 방송으로 발전할 것이며, TV를 시청하면서 상품을 구매할 수 있는 T-커머스가 이뤄진다. 또한 의료분야에서 원격지에 있는 환자의 상태를 정확하게 파악하기 위해 고품질 화상전송이 필요한 원격진료 서비스가 가능해져 높은 삶의 질을 누릴 수 있을 것으로 전망된다.

2. 전력 사고구간 자동판단

본 논문에서는 신경망 및 퍼지 전문가시스템을 이용하여 기존 전력 구간의 정전구간, 변압기 고장, 고압선송전소 단선 구간, 교통사고 구간, 등을 판단하는 알고리즘 및 시뮬레이션 결과를 제시한다.

시스템의 가장 중요한 부분을 차지하고 있으며, 소프트웨어 시스템의 고장은 인간의 생활, 환경 또는 경제적인 손실에 치명적인 영향을 유발시킬 수 있다. 따라서, 소프트웨어 시스템 개발은 사용자가 의도하는 목적에 적합한 충분한 품질 수준에 일치해야 하며, 요구되는 품질 수준에 일치하는 지 여부를 평가할 수 있는 측도가 필요하다. 일반적으로 소프트웨어의 품질을 정량적으로 표현하는 속성 중의 하나가 소프트웨어 신뢰성이다[12,17]. 소프트웨어 신뢰성은 주어진 환경 하에서 주어진 시간동안 소프트웨어가 고장 없이 작동할 확률로 정의된다[4,12].

소프트웨어 신뢰성을 평가하기 위해 고정된 시간 간격(Fixed time interval)에서의 고장 발생 현상이 주어진 분포를 따른다는 가정하에 유도된 수학적 모델에 관찰된 고장 데이터를 이용해 추정된 모수를 적용한 통계적 신뢰성 성장 모델(Software reliability growth models : SRGMs)이 일반적으로 사용되고 있다. 최근들어 모델의 모수 추정과 모델 자체 학습으로 미래의 결과를 예측하는데 신경망(Neural networks : NNs)이 적용되고 있다[1,7]. NNs은 사전에 고장 발생 현상이 주어진 분포를 따른다는 가정이 필요 없이 단지 입력된 고장 데이터에 적합하도록 학습을 통해 자

율적으로 망의 내부 모델을 개발하고 미래의 고장 발생 과정에 대한 예측을 할 수 있는 장점을 갖고 있다. 즉, 고장 발생 이력의 복잡성에 적합하도록 모델의 복잡성을 자율적으로 조절하기 때문에 널리 사용되고 있는 통계적 모델보다 정확한 결과를 얻을 수 있다[5,10,17]. 소프트웨어 신뢰성 예측 관련 대표적인 신경망 연구로는 Karunanithi et al. [8,9]과 Park et al. [16]이 있다.

소프트웨어 시험이나 운영중에 수집되는 고장 데이터는 소프트웨어 신뢰성을 추정하거나 예측하는데 사용된다. 일반적으로 수집되는 고장 데이터 형태는 고장 수(일정한 시간 간격동안 발생한 고장 수 기록)나 고장 시간(각 고장이 발생한 시점을 기록하는 고장 시간 데이터)이며, 고장시간 데이터 형태가 아닌 고장시간 데이터를 그룹화한 형태인 그룹 데이터(Grouped data) 형태만 활용할 수 있는 경우도 있다. 이 데이터 형태는 고장 수 데이터와 동일하나 다른 점은 가변적인 시험 간격(Variable time interval of Testing) 형태를 취한다.

고정된 시간 간격에서 수집된 고장 수를 이용할 경우, 현재 시점의 신뢰성을 추정하거나 고정된 미래 시점의 신뢰성을 예측하는데는 문제가 되지 않는다. 그러나 그룹 데이터의 경우, 가변적인 시간 간격을 가지므로 고정된 시간 간격에 적합한 모델로 가변적인 미래 시점에서의 신뢰성을 예측하는데는 문제가 발생할 수 있다. 기존의 통계적 SRGMs 들은 가변 시간 간격을 가진 그룹 데이터에 대한 많은 연구가 이루어지지 못하였으며, 특히 신경망 모델에 대한 연구는 없는 실정이다.

따라서, 본 논문에서는 가변적인 시간 간격을 가진 그룹 데이터에 적합한 신경망 모델을 개발하는 연구를 수행하고자 한다. 2장에서는 관련 연구 및 문제점을, 3장에서는 가변 시간간격 데이터에 적합한 신경망을 제안하며, 4장에서는 제안된 모델 13가지에 대해 전향 신경망(FeedForward Network : FFN)을 이용해 모델의 예측 결과를 실험한 후 최적의 모델을 선정하고 널리 알려진 신경망과 통계적 SRGM들과 상호 비교함으로써 제안된 모델의 적합성을 살펴보고자 한다.

2.1 고장 구간 문제점

데이터 쌍들 $(t_i, C_i), i=1, 2, \dots, n$ 이 소프트웨어 시험 결과 관찰되었다고 가정하자. 여기서 C_i 는 i 번째 시험 시간인 t_i 까지 발견된 누적 고장 수를 의미하며, 등 간격을 유지하는 단위 시험시간 $\Delta t_i = t_i - t_{i-1}$ 로, i 번째 단위 시험시간에서 발견된 고장 수 $\Delta C_i = m_i = C_i - C_{i-1}$ 로 정의된다. 이들 데이터 쌍들을 고장 수 데이터라 칭한다.

소프트웨어 신뢰성 분야에서, 미래에 발생하는 고장 수를 예측하는데 가장 널리 알려진 망으로는 FFNs와 PRNs (Partial Recurrent Networks)인 Jordan과 Elman 망이 있다. Karunanithi et al. [8,9]는 신경망을 활용하여 소프트웨어 신뢰성 예측을 모델링하였으며, 소프트웨어 신뢰성 예측에 캐스케이드-상환 학습 알고리즘 [2] (Cascade-correlation learning algorithm : CC)을 이용하여 FFNs과 PRNs이 적용될 수 있음을 보였다. 신경망의 예측력을 평가하기 위해 2가지 훈련 제도 (Training regimes)를 고려하였다.

- 일반 훈련제도(Generalization training regime) : 입력 (Input) t_i 는 목표 (Target) C_i 에 관련
- 예측 훈련제도(Prediction training regime) : 입력 t_{i-1} 는 목표 C_i 에 관련

또한, 고장 수 데이터에 대해 잘 알려진 통계적 SRGMs들과 비교하였다. 실험에 사용된 14개의 데이터를 살펴보면, 10개 (Data1, Data3-10 와 Data14)는 고장 수 데이터이며, 나머지 4개 (Data2와 Data11-13)는 고장시간 데이터이다. 고장 시간 데이터에 대해 고장 수 데이터 신경망 모델을 잘못 적용한 점을 보완하기 위해 Park et al. [16]은 고장 시간 데이터에 대해 유사한 연구를 수행하였다. 10개의 고장 수 데이터 중 Data4와 Data5는 데이터 수집 시간 간격이 일정하지 않은 그룹 데이터의 경우이고 나머지들은 데이터 수집 시간 간격이 일정한 경우이다.

신경망을 함수 근사, 회귀분석 또는 시계열 분야에 이용하는 경우, 주어지는 시간 간격은 일정한 데이터를 활용하는 것이 일반적이며, 또한 소프트웨어를 시

<표 1> 그룹 데이터 특성 및 고장 데이터

데이터	참고 문헌	LOC	고장 수	Data Size	Application (Time interval)
Data 4	[15]	1,317,000	328	17	PL/I database application software (CPU execution time in Hours)
Data 5	[15]	35,000	279	10	Hardware control program (Time of Observation in Months)
System T1	[14]	21,700	136	21	Real time command control (CPU execution time in Hours)
System T38	[14]	Not known	32	11	Not known (CPU execution time in Hours)

Data4				Data5			
t_i	Δt_i	ΔC_i	C_i	t_i	Δt_i	ΔC_i	C_i
2.45	2.45	15	15	1.0	1.0	10	10
4.9	2.45	29	44	1.5	0.5	64	74
6.86	1.96	22	66	2.0	0.5	18	92
7.84	0.98	37	103	3.0	1.0	43	135
9.52	1.68	2	105	4.5	1.5	44	179
12.89	3.37	5	110	6.0	1.5	13	192
17.1	4.21	36	146	8.0	2.0	34	226
20.47	3.37	29	175	11.0	3.0	28	254
21.43	0.96	4	179	12.0	1.0	15	269
23.35	1.92	27	206	13.0	1.0	10	279
26.23	2.88	17	223				
27.67	1.44	32	255				
30.93	3.26	21	276				
34.77	3.84	22	298				
38.61	3.84	6	304				
40.91	2.3	7	311				
42.67	1.76	17	328				

험하면서 수집되는 고장 수 데이터는 일반적으로 시간 간격이 일정한 형태를 취한다. 그러나 <표 1>과 같이 데이터 수집 시간 간격이 가변적인 그룹 데이터의 경우도 발생한다.

가변 시간간격을 가진 그룹 데이터를 기존의 고정된 시간간격에 적합한 신경망 모델을 이용하여 미래의 가변 시간 간격 시점에서의 고장 수를 예측할 경우 문제가 발생한다. 예를 들면, Karunanithi et al. [8,9]이 제안한 예측 훈련제도의 경우 입력은 t_{i-1} 인데 목

표는 고정된 시간간격인 t_i 시점에서의 누적 고장 수인 C_i 이다. 따라서, 그룹 데이터의 가변적 시간간격인 t_i 시점까지의 누적 발견 고장 수를 예측하려면 가변 시간간격 $\Delta t_i = t_i - t_{i-1}$ 정보를 알아야 한다. 그러나 기존 모델링에서는 Δt_i 정보가 전혀 들어있지 않음으로 문제가 발생하며, 이 모델은 Δt_i 가 일정할 때만 적용 가능하다. 이때는 t_i 들을 i 로 대체하여도 동일한 결과를 얻을 수 있다. 즉, Δt_i 가 가변 시간 간격일 경우, 기존 신경망 모델로는 Δt_i 시간 후에 발견되는 고장 수는 예측이 불가능하다. 이 문제를 해결하기 위해서는 현재 시점인 t_{i-1} 에서 얼마 동안의 시간에 발생하는 고장 수를 예측하는가 하는 가변 시간간격 (Δt_i)이 주어져야 한다. 이러한 그룹 데이터에 적합한 신경망 연구는 수행되지 않았다.

따라서, 3장에서는 가변적인 시간 간격 데이터에 적합한 신경망 모델을 얻기 위해 수집된 데이터를 이용하여 Karunanithi et al. [8,9]이 제안한 훈련 제도를 변경시켜 적절한 신경망 모델을 제시하고자 한다.

2.2 그룹 데이터에 적합한 신경망 모델

소프트웨어 시험 또는 운영 중에 l 시점까지 획득된 가변 시간간격 고장 수 데이터 (t_i, C_i), $i=1,2,\dots,l$ 를 활용하여 미래의 가변 시간 간격 시점 t_{i+r} 에서의 고장 수 C_{i+r} 를 신경망을 이용하여 예측하는 경우, 최적의 신경망을 어떻게 선택할 것인가가 문제로 제기된다. 본 장에서는 이러한 문제점을 해결하는 방법을 제시한다.

예측 고장 구간 가변 시간간격 시점 t_{i+r} 에서의 누적 고장 수 C_{i+r} 를 예측하기 위한 훈련제도로써, 신경망의 출력 목표 값으로 C_i 로 설정한다. 나머지 정보를 조합하여 신경망의 입력으로 설정함으로써 13개의 훈련제도를 <표 2>와 같이 고려할 수 있다.

<표 2>에서 R1과 R2는 각각 Karunanithi et al. [8,9]가 제시한 일반 훈련제도와 예측 훈련제도에 해당되며, R3-R13은 새로 제안된 훈련제도이다. 새로 제안된 훈련제도는 다음과 같이 표현된다.

- R3 : 입력 t_i 와 t_{i-1} 는 목표 C_i 에 관련

<표 2> 신경망 훈련 제도


훈련제도		입력 값					목표 값
		t_{i-1}	t_i	Δt_i	C_{i-1}	ΔC_i	C_i
Karunanithi et al.[8],[9]	R1		○				○
	R2	○					○
제안된 훈련제도	R3	○	○				○
	R4		○	○			○
	R5	○		○			○
	R6		○		○		○
	R7	○			○		○
	R8		○			○	○
	R9	○				○	○
	R10		○	○	○		○
	R11	○		○	○		○
	R12		○	○		○	○
	R13	○		○		○	○

- R4 : 입력 t_i 와 Δt_i 는 목표 C_i 에 관련

⋮

- R13 : 입력 t_{i-1} , Δt_i 와 ΔC_i 는 목표 C_i 에 관련

즉, Karunanithi et al.이 제안한 훈련제도 1 (R1)과 본 논문에서 제안하고 있는 훈련제도 4 (R4)에 대한 신경망의 구조는 (그림 1)과 같다.



(그림 1) 훈련제도 1 (R1)과 4 (R4)의 신경망 구조

훈련제도에 따라 현재의 t 시점까지 획득된 데이터로 신경망의 입력과 목표 값으로 설정하고 신경망을 훈련시킨다. 훈련이 완료된 신경망에 대해 미래의 가변 시점인 다음 단계 (Next-step)에 해당하는 입력 값을 신경망에 가하면 훈련된 신경망의 학습 능력에 의해 다음단계의 누적 고장수인 \hat{C}_{t+1} 이 출력되며, 이 값을 다음 단계의 누적 고장 수 목표값인 C_{t+1} 와 비교하여 훈련된 신경망의 예측 성능을 검증할 수 있다.

2.3 예측력 실험 및 결과 분석

다른 여러 가지 모델들을 비교하는데 있어, 어떤 의미 있는 척도로서 모델의 예측 정확도를 정량화하는 것이 필요하다. 소프트웨어 신뢰성 분야에서 일반적으로 사용되는 방법은 적합도 검증 (Goodness-of-fit), 다음 단계 예측력 (Next-step predictability)과 가변 미래시점 예측력 (Variable-term predictability)이다 [9,13]. 이들 접근법을 사용하여, Malaiya et al. [13]는 2가지 예측 척도로 평균 상대 예측 오차 (Average relative prediction error : AE)와 평균 편향(Average bias : AB)을 제안하였다. AE는 모델이 얼마나 잘 예측하는가의 척도이며, AB는 모델의 일반적 편향이다. 본 논문에서는 표 1의 4개 데이터에 대한 다음 단계 예측력을 평가하기 위해 AE 척도를 사용한다. 신경망의 구성 및 훈련은 MATLAB 5.2 Neural Network Toolbox Ver. 3.0의 FFNs을 구성하여 실험하였다.

2.4 예측 고장 구간 실험

본 연구에서는 은닉층이 1개인 FFN에 대해 역전파 알고리즘 (Backpropagation algorithm : BP)과 최적 시점에서 신경망의 훈련을 종료하는 기법을 사용하였다. 왜냐하면, Hornik et al. [6]은 은닉층이 1개인 FFN에 대해 시그모이드 작동함수를 가진 뉴런을 은닉층에 무한히 추가시키면 보편화된 함수근사기로서의 역할을 수행할 수 있음을 제시하였기 때문에 1개의 은닉층을 가진 FFN을 사용해도 되기 때문이다.

신경망의 은닉층 작동함수로는 시그모이드를, 출력층 뉴런의 작동함수로는 선형을 사용한다. 출력층 뉴

런의 작동함수로 선형을 사용하는 이유는 다음과 같다. 일반적인 신경망에 대해 관찰된 데이터를 정규화하지 않고 신경망에 직접 적용할 수 있는 방법은 출력층 뉴런의 작동함수로 선형을 사용하는 경우이다. 이에 대해 Cybeo [1]은 시그모이드 작동함수를 가진 1개의 은닉층으로 주어진 모든 문제를 표현할 수 있다는 보편적 근사 이론 (Universal Approximation Theorem)을 증명해 보였으므로 출력층 뉴런의 작동함수로 선형을 사용할 수 있고, 또한 이상은 [18]은 출력층 뉴런의 작동함수로 선형을 사용하여 정규화 시키지 않은 데이터를 이용하는 경우가 로지스틱 함수를 사용하여 정규화 시킨 데이터 보다 신뢰성 예측에 있어서 보다 좋은 결과를 얻었다. 그러나 출력층 뉴런에 로지스틱 함수를 사용하면 출력되는 값이 [0, 1] 범위로 한정되므로 수집된 데이터를 [0, 1] 범위로 정규화하여 신경망에 적용하고 출력된 결과를 다시 역정규화하는 불편이 따른다. Karunanithi et al. [8,9]는 출력층 뉴런의 활성화 함수로 로지스틱 함수를 사용하였다. 이 경우 입력-출력 변수 값의 변환 (정규화)이 필요함을 알 수 있다. 따라서, 본 논문의 접근방법은 어떠한 데이터 변환 과정도 필요없이 수집된 본래의 데이터를 바로 사용할 수 있는 장점이 있다.

신경망의 적절한 구조를 선택하기 위해 시행착오법 (Trial-and-Error)을 사용하고자 한다. 즉, 은닉 뉴런 수는 1개에서 30개까지 1개 단위로 변화시켜 가면서 FFN을 구성하고 최적시점 종료 기법 (Early Stopping 또는 Optimal Stopping)을 사용하여 오차가 최소가 되는 시점에서 신경망의 훈련을 멈추고 다음단계 예측 오차인 AE를 계산한다. 신경망의 다음단계 (Next-step) AE는 $e_{t+1} = ((\hat{C}_{t+1} - C_{t+1}) / C_{t+1}) \times 100$ 로 정의된다. 이 30개의 예측 오차 값 중 가장 최소의 예측 오차를 가진 뉴런이 해당 시점에서의 신경망의 최적의 뉴런수로 결정된다.

13개의 훈련제도에 대한 예측력을 평가하기 위해 다음단계 AE의 절대값의 평균인 $\bar{e}_{i,r} = \sum_{j=1}^n |e_{i,j}| / r$, $r=1$ 을 사용한다 [9]. 즉, $e_{i,1} = \bar{e}_{i,1}$. 그러나, 다른 r 의 값 (즉, 보다 먼 미래시점)이 고려될 수도 있다.

주어진 데이터로부터 신경망의 적절한 구조와 가치 값을 정확히 알 수 없기 때문에 대부분의 신경망

<표 3> 다음 단계의 전체 평균 오차 $\bar{e}_{t,1}$

훈련제도		AE			
		Data 4	Data 5	System T1	System T38
Karunanithi et al. [9]	R1	8.6566	10.5199	6.1444	19.6587
	R2	7.2819	4.6284	9.2793	21.3171
제안 훈련제도	R3	6.7723	12.4995	4.0958	22.4497
	R4	5.9137	7.7722	5.0835	21.7219
	R5	5.4105	11.9716	5.4402	22.3162
	R6	8.0187	13.4587	8.9349	23.0162
	R7	12.5464	14.3547	9.5820	21.2572
	R8	11.2911	16.8212	7.0710	21.2088
	R9	8.0208	12.8525	7.6602	20.4389
	R10	10.8478	18.7086	12.1971	23.7348
	R11	9.9429	13.8741	10.4018	13.6549
	R12	7.7233	15.2045	6.2945	20.1998
	R13	9.9101	17.1473	5.4160	23.7650

훈련방법은 신경망 가중치들의 초기 값을 랜덤하게 설정함으로 인해 신경망을 훈련시킬 때마다 예측력에 차이가 발생한다. 따라서 Karunanithi et al. [9]의 실험 방법과 동일하게 50회의 훈련을 통해 평균값을 취한 것으로 예측 오차를 구하고자 한다. 실험 결과 얻어진 다음단계의 전체 평균 예측 오차 $\bar{e}_{t,1}$ 는 <표 3>에 표기하였다.

2.5 예측력 결과 분석

AE는 단일 데이터에 대해 모델들의 예측 정확도를 비교하는데 사용될 수 있으며, 다른 여러 가지 다양한 데이터들에 대해 모델을 비교하기 위해서는 다른 측도가 필요하다. Karunanithi et al. [9]는 다양한 데이터들에 적합한 모델을 비교하는 측도로서 정규화된 AE (Normalized AE : NAE) 를 제시하였다. 데이터 s 에 대해 최대의 AE를 갖는 모델 (m)을 m_{max} 로, 이 모델의 AE를 $AE_s^{m_{max}}$ 라 하면 정규화된 상대오차 $NAE_s^m = AE_s^m / AE_s^{m_{max}}$ ($0.0 < NAE_s^m < 1.0$)가 되며, NAE 를 구한 후, 각 모델에 대한 순위 $R_m = \sum_1^{# of data set} NAE_s^m$ 을 구하여 모델의 예측력을 평가할 수 있다. <표 3>의 결과에 대한 NAE 및 순위에 따른 모델의 예측력 결과가 <표 4>에 제시되어 있다.

<표 4> 모델의 예측력

훈련 제도	NAE				R_m	순위
	Data 4	Data 5	System T1	System T38		
R1	0.6900	0.5623	0.5038	0.8272	2.5832	5
R2	0.5804	0.2474	0.7608	0.8970	2.4855	3
R3	0.5398	0.6681	0.3358	0.9446	2.4883	4
R4	0.4713	0.4154	0.4168	0.9140	2.2176	1
R5	0.4312	0.6399	0.4460	0.9390	2.4562	2
R6	0.6391	0.7194	0.7325	0.9685	3.0595	10
R7	1.0000	0.7673	0.7856	0.8944	3.4473	13
R8	0.8999	0.8991	0.5797	0.8924	3.2712	12
R9	0.6393	0.6870	0.6280	0.8600	2.8143	7
R10	0.8646	1.0000	1.0000	0.9987	3.8633	8
R11	0.7925	0.7416	0.8528	0.5746	2.9615	9
R12	0.6156	0.8127	0.5161	0.8500	2.7943	6
R13	0.7899	0.9165	0.4440	1.0000	3.1505	11

실험 결과 다음과 같은 결론을 얻을 수 있었다.

- (1) 가변 시간 데이터에 대해 미래의 얼마 동안의 기간에 발생하는 고장 수를 예측하는가 하는 기간 (Δt_i)이 주어진 신경망 모델 (R4와 R5)의 예측력이 Δt_i 가 주어지지 않은 Karunanithi et al. [9]가 제안한 훈련제도 (R1과 R2) 보다 좋은 결과를 나타내었다.
- (2) 제안된 훈련제도 11개 (R3-R13) 중 미래의 예측 가변 시간 간격인 Δt_i 정보가 없고 다른 정보 들로만 결합되어 입력되는 경우 (R3, R6-R9), 모델의 예측력이 나쁜 결과를 나타내었다.
- (3) 또한, Δt_i 정보가 들어 있지만 여러 가지 다른 정보가 결합되어 입력되는 경우 (R10-R13), 모델의 예측력이 좋은 결과를 나타내지 못하였다.

2.6 제안된 모델 평가

제안된 모델이 일반적으로 많이 사용되는 통계적 SRGMs 들과 신경망 모델보다 좋은 결과를 나타내는 지를 살펴보고자 한다. 본 비교에는 Data4와 Data5에 대한 Karunanithi et al. [9]의 신경망과 통계적 SRGMs 모델의 예측 결과와 제안 모델의 좋은 예측 결과를

(표 5) 선택된 데이터 특성 및 고장 데이터

데이터	참고 문헌	LOC	누적 고장 수	데이터 크기	적용분야
Data 2	[12]	21,700	136	25	실시간 전력사고구간 예측
Data 14	[15]	not known	266	46	실시간 교통사고구간 단선 예측

Data2			Data14					
시험 시간	발견 고장수	누적 고장수	시험 시간	발견 고장수	누적 고장수	시험 시간	발견 고장수	누적 고장수
1	27	27	1	2	2	26	7	184
2	16	43	2	0	2	27	0	184
3	11	54	3	30	32	28	22	206
4	10	64	4	13	45	29	2	208
5	11	75	5	13	58	30	5	213
6	7	82	6	3	61	31	12	225
7	2	84	7	17	78	32	14	239
8	5	89	8	2	80	33	5	244
9	3	92	9	2	82	34	2	246
10	1	93	10	20	102	35	0	246
11	4	97	11	13	115	36	7	253
12	7	104	12	3	118	37	3	256
13	2	106	13	3	121	38	0	256
14	5	111	14	4	125	39	0	256
15	5	116	15	4	129	40	0	256
16	6	122	16	0	129	41	0	256
17	0	122	17	0	129	42	5	261
18	5	127	18	0	129	43	2	263
19	1	128	19	0	129	44	3	266
20	1	129	20	0	129	45	0	266
21	2	131	21	0	129	46	0	266
22	1	132	22	30	159			
23	2	134	23	15	174			
24	1	135	24	2	176			
25	1	136	25	1	177			

모델	훈련제도	Data 4		Data 5		R_m	순위	
		AE	NAE	AE	NAE			
신경망 알고리즘 [9]	CC	FFN-R1	5.28	0.5617	10.00	0.4274	0.9891	5
		FFN-R2	4.64	0.4936	6.95	0.2970	0.7906	1
	Jordan-R1	8.84	0.9404	5.09	0.2175	1.1579	10	
	Jordan-R2	6.11	0.6500	8.67	0.3705	1.0205	6	
	제안 모델 (BP 알고리즘)	FFN-R4	5.91	0.6287	7.77	0.3321	0.9608	4
	FFN-R5	5.41	0.5755	11.97	0.5115	1.0871	7	
통계적 SRGMs [9]	Logarithmic	5.93	0.6309	6.42	0.2744	0.9052	3	
	Inverse Polynomial	7.95	0.8457	9.71	0.4150	1.2607	8	
	Exponential	6.01	0.6394	6.15	0.2628	0.9022	2	
	Power	9.40	1.0000	23.36	0.9983	1.9983	11	
	Delayed S-shape	6.25	0.6649	10.90	0.4658	1.1307	9	

나타내는 훈련제도 (R4-R5)에 대한 NAE를 사용하였으며, <표 5>에 기술되어 있다.

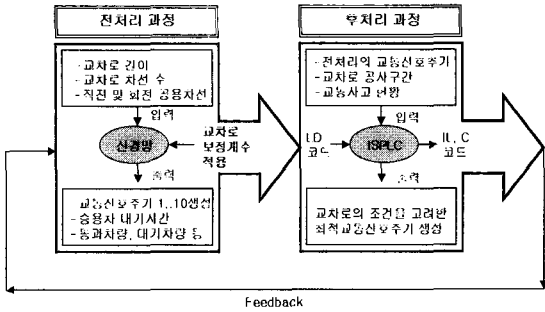
표 5에서 신경망 모델과 통계적 SRGMs들을 비교한 결과 FFN을 사용한 제안된 모델의 예측력이 중간 정도의 성능을 나타내었다. 그러나 신경망을 훈련시키는 과정에서 모델을 자동적으로 결정하는 알고리즘인 CC 알고리즘을 Δt_i 정보를 포함한 훈련제도 R4와 R5 입력자료를 사용하면 보다 좋은 모델을 찾을 수 도 있을 것이다.

3. 교통사고구간 진단

본 논문에서는 Loop detector에서 감지된 교통 정보에 근거하여 10개 교차로의 최적 신호주기를 산출하였다. 그러나 신경망을 이용한 10개 교차로의 최적 교통신호주기 모의실험은, 실제 교차로에서는 갑작스러운 교통량의 증가 및 앞 막힘 현상, 교통사고나 전화 공사, 수도관공사 등으로 일부차선을 사용하지 못하는 경우, 직진 및 회전을 공유하는 경우, 마라톤이나 각종 행사 등으로 인해서 횡단보도 및 보행자가 급격히 늘어난 경우 등을 고려하지 않았으므로 승용차 대기시간이 예상외로 길어진다. 또한 갑작스러운 교통사고나 교통량의 증가 시에는 교차로 조건을 정확하게 감지를 못할 경우에는 교차로 용량이 크게 달라지기 때문에 신경망을 이용한 교통 신호주기가 부정확하게 된다.

그러므로 승용차 대기 시간을 최소화하고 예상 외로 발생하는 교통의 문제점을 개선하기 위해서 전처리로 신경망을 이용한 교통신호주기를 생성하고, 후처리로 갑작스러운 교통량의 증가 및 앞 막힘 현상이나, 교통사고나 전화 공사, 수도관공사 등으로 일부차선을 사용하지 못하는 경우, 직진 및 회전을 공유하는 경우, 마라톤이나 각종 행사 등으로 인해서 횡단보도 및 보행자가 급격히 늘어난 경우 등을 고려한 교통신호주기를 생성하기 위해서, 지능적 PLC 시스템인 ISPLC (Intelligent Software Programmable Logic Controller) 시스템을 개발하여 실시간 교통 예측 시스템(Real Time Traffic Forecasting)에 적용하고자 한다.

개발하려는 시스템의 전처리와 후처리 과정은 그림 2에서 설명한다.



(그림 2) 지능형 교통신호등 흐름도

Fig. 2. The flowchart of Intelligent traffic light

본 논문에서는 LD (Ladder Diagram)라는 IEC1131-3의 표준 PLC언어를 사용하여 다른 IL(Instruction List)로 변형하여 프로그램의 활용성을 높이고 이것을 다시 고급언어인 C 언어로 변형하여 LD나 C언어에 익숙한 프로그래머들에게 모두 편리하게 설계되도록 시스템을 개발하고자 한다. 개발한 ISPLC의 전체적인 시스템 구조는 다음 그림 3과 같다.

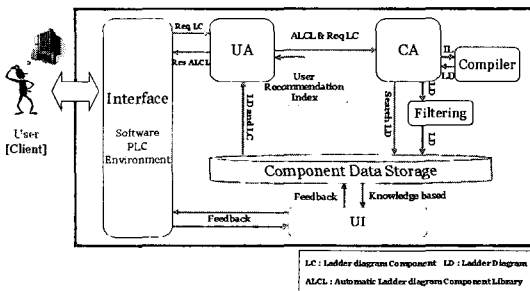
ISPLC는 다음과 같은 여덟개 세부 시스템 모듈을 갖는다: 사용자 인터페이스 (User Interface), 사용자 에이전트 (User Agent), 사용자 추천 인덱스 라이브러리(User Recommendation Index Library), 컨트롤 에이전트(Control Agent), 컴포넌트 데이터 스토리지(Component Data Storage), 사용자 인포메이션(User Information), 컴파일러 (Compiler), 필터링(Filtering).

사용자 추천 인덱스는 사용자의 프로그램 설계 과정을 패턴화하여 개인화 코드로 컴포넌트 또는 클래스 파일 형태로 저장한다. 또한 이 모듈은 사용자 인터페이스 상

에서 프로젝트나 시스템 개발시 이전의 프로그램 설계에 대한 컴포넌트 및 클래스 패턴 히스토리를 가지고서 사용자에게 제안해주는 모듈이다. 컴포넌트 데이터 스토리지는 코드매핑모듈과 코드생성모듈을 갖는다. 코드매핑모듈은 LD, IL, C or Visual C++, 세 언어 중 한 언어를 선택하여 프로그램을 하더라도 자동적으로 각각의 세 타입의 언어에 대한 상호 호환성을 위해 코드를 생성하며 매핑시킴, 코드생성모듈은 LD언어로 프로그래밍 시 사용자의 인터페이스내에 각각의 LD 모듈에 대한 프로그램이 가능할 수 있도록 소프트웨어 코드 즉, C 또는 Visual C++ 변환하여 생성해준다. 또한 사용자가 LD 언어를 사용하지 못하더라도, C 언어로 변환되므로 구현 및 프로그램이 가능하다. 사용자 인포메이션은 사용자의 히스토리 데이터, 즉 프로그램 가능한 컴포넌트나 클래스 데이터를 최적화하여 재사용성을 제공하기 위한 모듈이다. 컴파일러는 시스템의 툴 내에서 제공하는 인터프리터로서 파싱 처리가 가능하다. 필터링은 시스템내에서의 불필요한 코드를 최적화 시켜주는 기능을 제공한다.

사용자가 인터페이스를 통해 사용자 에이전트에게 LD 질의를 요청하면 사용자 에이전트와 컨트롤 에이전트는 질의를 갖고 통신을 한다. 이때, 컨트롤 에이전트는 요청 받은 질의를 컴포넌트 데이터 스토리지에서 검색하여 질의에 맞는 컴포넌트를 사용자 에이전트에게 전달한다. 질의에 따라 생성된 컴포넌트를 갖고 사용자 에이전트는 인터페이스를 통해 사용자에게 프로그래밍이 가능할 수 있도록 생성해 주며, 컴포넌트 히스토리를 사용자 추천 인덱스 라이브러리에 저장함으로써 재사용이 가능할 수 있도록 한다.

ISPLC에서 교통신호 운영자가 인터페이스를 통해 사용자 에이전트에게 최적신호주기를 질의를 요청하면 사용자 에이전트와 교통관제소 컨트롤 에이전트는 10개 교차로의 평균 주행속도와 대기시간 Loop Detector에서 감지된 데이터를 수집하게 된다. 이때, 컨트롤 에이전트는 요청받은 질의를 컴포넌트 데이터 스토리지에서 교통사고로 인한 직진 및 회전차선 공유 및 금지 차선 여부, 각종 야구경기나, 행사로 인한 횡단보도 보행자 수 증가여부, 교통사고 및 각종행사로 인한 평균 주행속도, 예상 통과 차량, 예상 대기차량 등을 고려하여 실제 교차로 상황에 적합한 최적의 교통 신호현시를 생성한다.



(그림 3) ISPLC 전체 시스템 구조

Fig. 3. The overview of ISPLC

일반적으로 예상 통과차량이 교차로의 용량이 30-70% 미만인 경우의 미포화나 근포화일 경우에는 4현시(남북 직진, 좌회전 우회전, 동서 직진)를 운영하여 최적 교통 신호주기를 생성할 수 있으나, 예상 통과차량이 교차로의 용량이 90% 이상인 과포화인 경우에는 교통신호주기를 감소해야 되고, 특히 교통사고 및 각종 공사나 행사로 인

해서 일부 차선이 폐쇄되면 2현시(남북 직진, 동서 직진)를 운영하여 승용차 대기시간을 단축해야 한다.

본 논문에서는 실제 교통조건을 고려하여 교통사고 및 각종 행사로 인한 일부 차선 폐쇄와 좌우 회전 금지, 4현시에서 2현시 변환등과 같은 실시간 교통정보를 교통관제소 컨트롤 에이전트 판단에 따라 10개 교차로의 최적 신호주기를 생성할 수 있도록 해준다. 새롭게 생성된 규칙은 교통정보 인덱스 라이브러리에 저장함으로써 미포화, 근포화, 과포화시에 퍼지규칙을 이용한 교차로 보정 조건, 보행자 수, 횡단보도 유무에 따라서, 어떠한 교차로에서도 재사용이 가능할 수 있도록 한다.

그림 4와 그림 5는 ISPLC 전체 구조에 포함된 교통 에이전트들의 관계를 나타낸 그림이다.

교통사고나 각종 행사시에 승용차 대기시간을 최소화 하는 최적교통 신호주기를 생성하기 위해서는, 10개 교차로의 평균 주행속도, 통과차량, 누적차량, 출발 지연시간을 고려하여 근포화와 과포화를 판단하게 된다, 그러면 퍼지 규칙을 고려한 10개 교차로에서 횡단보도, 좌회전 금지구간, 직진 및 회전 공용 구간 및 보행자를 새로운 입력으로 삼입시켜서 규칙베이스에 저장하고 새로 변환되거나 입력된 IL 코드를 이러한 규칙기반 시스템에서 찾아내어서 표준 C코드로 변환하여 사용자 에이전트가 사용자 추천 모듈에서 최적 교통신호주기를 생성하게 된다.

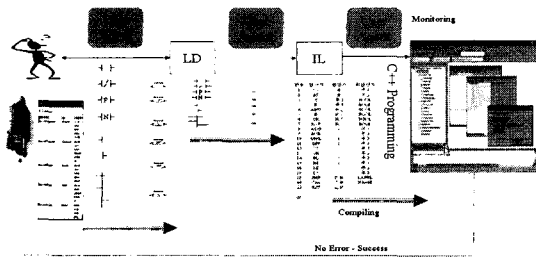
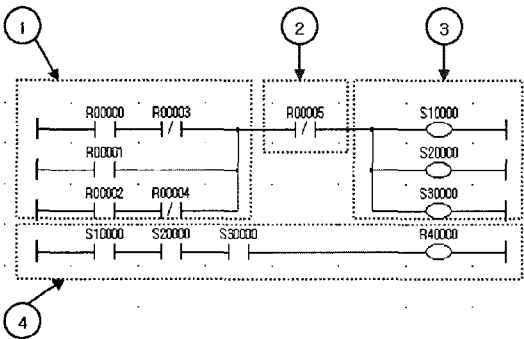
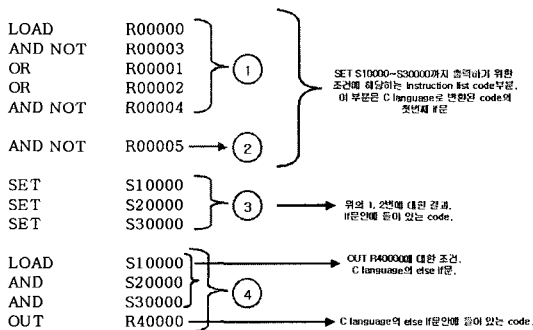


그림 4. ISPLC에서 에이전트들의 관계

Fig 4. The interrelationship among agents in ISPLC



(a) 초기상태




(b) IL로 변환된 코드

그림 5. LD->IL 코드변환 관계

Fig. 5. The relationship of LD->IL code conversion

3.1 실시간 교통제어 시스템 모델링

본 논문에서는 ISPLC를 본 논문에서 제안하는 실시간 교통예보 시스템(Real Time-Traffic Forecasting System: RT-TF System)에 적용하여 시뮬레이션 하고자 한다. 이 시뮬레이션 시스템은 실제교차로의 4현시에서 2현시 변환, 좌회전금지, 직진 및 회전차선 공유, 일부 차선 폐쇄, 각종 행사로 인한 보행자 급증 등의 실제세계의 도로상태를 소프트웨어 기반의 환경으로 옮겨 평균 주행속도를 향상시키고 평균 대기시간을 감소하기 위해서 최적교통신호 주기를 산출하기 위한 것으로 통과차량이 갑작스럽게 증가했을 경우나, 과포화 상태에 발생하는 앞 막힘 현상을 방지하기 위한 것이다. 본 논문에서는 RT-TF의 하드웨어와 소프트웨어 환경을 모두 컨트롤하기 위해 ISPLC를 적용하여 에이전트의 기능을 추가함으로써 어떠한 실제 교



(a) RT-TF시스템의 타이머설정 (b) RT-TF 신호등 체계
그림 6. RT-TF 시스템 모델링

(a) The timer setting of RT-TF system (b) RT-TF traffic states
Fig. 6. The system modeling of RT-TF system

차로에서도 최적의 교통신호주기를 생성할 수 있다. 교통 신호주기 운영자는 모든 교차로 조건을 고려한 로드맵 상에서의 교통 신호등 제어에 관한 LD로 프로그래밍시 사용자 에이전트는 LD상의 하나의 모듈을 IL로 매핑시켜 각각의 교통조건에 해당하는 모듈을 Visual C++로 자동 변환시킨다. 이러한 코드변환은 각 모듈을 단계별로 생성하여 자동으로 생성하도록 한다.

RT-TF 시스템의 모델링 구성도는 그림 3과 같다. 그림 6(a)의 제일 왼쪽이 빨간색(적), 다음이 주황색(황), 다음이 좌회전 화살표(좌), 다음이 초록색(청) 등을 나타내고 있다. 각 타이머의 설정시간은 교차로 조건을 고려한 최적 교통 신호주기 출력 값인 직진신호 30초, 좌회전 신호 20초, 경고신호 8초로 가정하였다. 그림 6(b)에서 각 방향별 출력 번호는 W(West)의 청, 좌, 황, 적 순으로 R3.0, R3.1, R3.2, R3.3이며, N(North)의 청, 좌, 황, 적 순으로 R3.4, R3.5, R3.6, R3.7이며, S(South)의 청, 좌, 황, 적 순으로 R3.8, R3.9, R3.10, R3.11이며, E(East)의 청, 좌, 황, 적 순으로 R3.12, R3.13, R3.14, R3.15를 나타낸다. 그림 6(b)는 RT-TF 신호등의 PLC 출력 접점을 표시한 것이다.

RT-TF 시스템의 신호등 체계의 동작은 다음 8가지로 나뉠 수 있다. ① 동쪽에서 남쪽으로, 서쪽에서 북쪽으로 각각 좌회전하도록 좌회전 신호등을 점등한다(남, 북 신호등은 적색등 점등). ② 동쪽과 서쪽 신호등은 모두 황색

등을 점등한다(남, 북 신호등은 적색등 점등). ③ 동쪽<->서쪽 직진 신호를 점등한다(남, 북 신호등은 적색등 점등). ④ 남쪽에서 서쪽으로, 북쪽에서 동쪽으로 각각 좌회전하도록 좌회전 신호등을 점등한다(동, 서 신호등은 적색등 점등). ⑤ 남쪽과 북쪽 신호등은 모두 황색등을 점등한다

(표 6) 교차로 로드 맵 시그널 서브루틴 기능

Table 6. The signal subroutine functions of cross road map

서브루틴 번호	출발지 기준 수행내용 (Processing)	출력 번호 (output number)	타이머 On (Timer On)	타이머 Off (Timer Off)
1	E — W 직진	R3.0, R3.12	TC3	TC4
2	E — W 좌회전	R3.1, R3.13	TC1	TC2
3	E — W 경고 (황색등)	R3.2, R3.14	TC2, TC4	TC3, TC5
4	E — W 정지 (적색등)	R3.3, R3.15	TC5, TC1	TC8, TC2
5	S — N 직진	R3.4, R3.8	TC7	TC8
6	S — N 좌회전	R3.5, R3.9	TC5	TC6
7	S — N 경고 (황색등)	R3.6, R3.10	TC6, TC8	TC7, TC1
8	S — N 정지 (적색등)	R3.7, R3.11	TC1, TC5	TC5, TC6

(E: East, W: West, S: South, N: North)

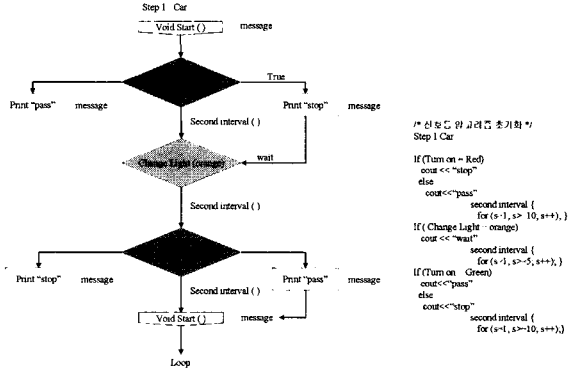



그림 7. RT-TF 시스템의 수행 알고리즘
Fig. 7. The execution algorithm of RT-TF system

(동, 서 신호등은 적색등 점등). ⑥ 남쪽<->북쪽 직진 신호를 점등한다(동, 서 신호등은 적색등 점등). ⑦ 남쪽과 북쪽 신호등은 모두 황색등을 점등한다(남, 북 신호등은 적색등 점등). ⑧ 수신호를 위한 황색등 점멸 회로를 작동시킨다.

PLC와 관련하여 에이전트 기반의 컴포넌트를 생성하여 교통사고 및 차선 폐쇄 및 각종 행사에 따른 교차로 변경조건을 8가지로 구현한다. 아래의 표 3은 위의 8가지 동작을 각각의 교차로 실제상황에서 앞 막힘 현상, 차선 폐쇄, 보행자수 급증 등에 따른 시그널 루틴을 나타낸 것이다.

그림 7은 RT-TF의 수행알고리즘이며, 그림 8은 각 신호등의 타임 밸런스에 따른 각각의 시그널 상태 변이도




그림 8. 신호등의 타임 밸런스에 따른 각각의 시그널 상태 변이도
Fig. 8. The signal state diagram according to time balance of signal lights




그림 9. 에이전트 기반 RT-TF 시스템의 시뮬레이션 과정
Fig. 9. The simulation of RT-TF system based on agents PLC

호등의 타임밸런스에 따른 시그널의 상태변화를 나타낸 그림이다.

실제교통 상황에 따라서, 갑작스럽게 교통량이 증가하거나 감소하는 경우, 4현시에서 2현시로 변경하는 경우, 각종 도로 공사나 행사 등으로 인해서 일부 차선이 폐쇄되는 경우에, 교차로 조건에 최적으로 평균주행시간을 변경하여 교통 신호 주기 값을 특정 어드레스 번지에 저장하는 과정을 설명하고 있다.

뿐만 아니라, 엑티브 네트워크와 지능형 센서가 결합이 되면 겨울철 교통사고를 예방할 수 있다. 눈길이나 빙판길은 한겨울에도, 날씨가 풀려도 햇볕이 닿지 않는 도로에는 빙판이 그대로 남아 대형 교통사고의 원인이 된다. 실제로 최근 폭설이 내린 영동고속도로 구간에는 하루평균 10여건 이상의 빙판길 추돌사고가

(표 7) 통과차량속도를 고려한 ISPLC와 기존신호등 TOD 대기시간비교

Table 7 Comparisons of vehicle waiting Time between ISPLC and conventional T.O.D traffic light

전처리 (퍼지 신경망)				후처리 (에이전트기법 및 ISPLC)			승용차 대기 시간 비교	
통과 차량	교차로 길이	교차로 차선 수	신호 주기	긴급	미포화	과포화	지능형 PLC	TOD 기존 방식
				차량	(하위)	(하위)		
BIG	상위>하위	상위>하위	단축	무	연장	단축	15초	20초
BIG	상위<하위	상위<하위	연장	무	연장	단축	13초	18초
BIG	상위<하위	상위>하위	정상	무	정상	단축	15초	14초
BIG	상위>하위	상위>하위	단축	유	단축	단축	07초	17초
BIG	하위>상위	하위>상위	연장	유	단축	단축	08초	15초
SMALL	상위<하위	상위<하위	단축	무	단축	단축	07초	09초
SMALL	상위<하위	상위>하위	정상	무	정상	단축	11초	14초
SMALL	상위<하위	상위<하위	단축	유	정상	단축	18초	29초
SMALL	상위<하위	상위>하위	정상	유	단축	단축	15초	27초

발생했다. 그러나 지난해까지만 해도 사고 다발지역으로 꼽히던 강원도 진부령터널과 대관령 2, 3터널구간에서는 올 겨울 들어 몇 차례 폭설에도 불구하고 단한건의 접촉사고도 발생하지 않았다. 도로에 쌓인 눈을 자동으로 녹이는 도로결빙방지시스템이 설치됐기 때문이다. 최근 지능형 도로(Smart Way)의 새로운 안전기능으로 관심을 끄는 도로결빙방지시스템은 도로 표면에 장착된 특수 센서가 쌓인 눈을 스스로 감지해 도로 위에 액상염화칼슘을 자동으로 뿌려준다. 도로 스스로가 쌓인 눈을 제거해 도로결빙을 막는 것이다. 더욱이 도로결빙방지시스템은 수작업으로 뿌리는 모래나 소금, 염화칼슘보다 제빙효율이 10배나 높아 사고예방 효과도 탁월하다.

실제로 일본, 북미, 북유럽 등 선진국에서는 도로 결빙방지기능을 갖춘 지능형 도로망 구축이 확대 일로에 있다. 특히 이 지역에서 도로결빙방지시스템을 설치한 후 해당 도로의 겨울철 방관길로 인한 사고 발생률은 평균 절반 이하로 감소했다. 도로에 깔린 질

은 안개나 폭우 등 예상치 못한 기상변화도 안전 운전을 위협하는 주요 원인이다. 잠시 뒤에 주행할 도로가 젖었는지 얇은 빙판길인지 짙은 안개에 쌓였는지를 미리 알 수 있다면 사고위험도 크게 줄일 수 있다. 그래서 변덕스런 날씨 변화를 운전자에게 예보하는 도로기상정보시스템(RWIS:Road Weather Information System)은 도로결빙방지시스템과 함께 ‘빠르고 안전한’ 운전환경을 위한 지능형 도로의 좋은 사례로 꼽힌다. RWIS는 도로변에 설치된 도로기상관측장비와 도로 표면에 박힌 습도·온도센서로부터 기상정보를 제공받아 차량 운전의 위험이 되는 기상상황을 1~2시간 전에 운전자에게 미리 통보해 준다. 일반 기상예보는 광범위한 지역의 날씨를 예측하지만 RWIS는 특정 도로구간만 다루기 때문에 기상예측의 정확도가 훨씬 뛰어나다. 일본에서는 이미 1000여곳의 사고다발 지역에 RWIS가 설치됐으며 국내에서도 서울 북악스카이웨이와 남부순환도로, 제주시 한라산 횡단도로 등 11개 구간에서 시험운영중이다.

이처럼 스마트웨이는 도로라는 물리공간에 센서와 같은 전자공간을 이식하고 사람과 도로가 접촉해 자유롭게 정보를 교환한다. 실제로 최근에 건설되는 고속도로는 첨단센서가 심어지고 유무선 통신망으로 촘촘히 연결돼 똑똑한 스마트웨이라 불려도 손색이 없다. 한낱 아스팔트 조각에 불과하던 포장도로가 어느새 유비쿼터스 기술을 구현하는 첨단 매체로 변신한 것이다. 명절 때마다 전국의 고속도로와 지방국도는 거대한 주차장으로 변하지만 운전자들은 별 다른 대안이 없다. 그저 마음을 비우고 끝없는 차량의 행렬이 움직이길 기다리는 것이 고작이다. 대도시의 주요 도로망도 심각한 동맥경화에 걸린 지 오래다. 억대를 호가하는 최고급 스포츠카도 꽉 막힌 도로 앞에선 무용지물이다. 도로 위에서 소비하는 시간은 해마다 늘어나 매년 수조원대의 사회적 비용을 유발한다.

하지만 유비쿼터스 기술을 적용한 스마트 웨이는 도로에 지능을 부여해 답답한 도로상황을 개선하는데도 위력을 발휘한다. 운전자가 상황에 따라 최적의 주행경로를 선택할 수 있도록 도로 스스로가 교통정보를 알려주는 실시간 교통정보망이 그 대표적인 사례다. 교통정보망은 수많은 노면 센서나 영상감지기로 도로위의 교통정보를 실시간으로 수집해 이를 다시

도로전광판과 유무선 통신망을 통해 사람들에게 알려 준다. 최근에는 휴대폰을 통해 전국 도로의 주행속도와 교통상황 동영상을 보여주는 교통정보서비스까지 등장했다. 이처럼 유비쿼터스 기술은 운전자가 ‘보다 빠르고 안전하게’ 목적지에 도착할 수 있도록 도와준다. 실제로 유비쿼터스 기술을 활용한 실시간 교통정보망은 한정된 도로자원으로 최대의 교통흐름을 수용할 수 있다. 사고시에도 구급차량의 현장 출동시간을 평균 3분의 1로 줄여 교통 사망률을 낮추는데도 큰 역할을 한다. 이제 도로는 단순히 아스팔트와 콘크리트로 만들어진 구조물이 아니다. 이미 서울과 부산, 대전시를 관통하는 주요 간선도로에는 교통흐름을 손바닥처럼 파악하는 특수센서와 영상감지망이 작동되기 시작했다. 오는 2005년경에는 노들길과 올림픽대로 41.8km 구간에 노면상태를 감지하는 RWIS망이 구축된다. 지능형 도로 건설이 전국으로 확산되고 있는 것이다. 빠르고 안전한 드라이빙을 바라는 운전자들이 오랫동안 꿈꿔온 길, 그것이 바로 유비쿼터스 세상으로 가는 길이다.

3.2 결빙 방지 시스템 작동원리

올 겨울 별 다른 사고없이 강원지역 스키장을 다녀온 사람들은 이미 푹푹한 지능형 도로의 혜택을 일부 경험한 것으로 생각해도 무방하다. 아스팔트 도로가 스스로 눈을 녹여 운전자의 안전을 보호하는 유비쿼터스 기술이 구현되고 있는 것이다. 도로가 스스로 쌓인 눈을 제거하는 도로결빙방지시스템은 두 종류의 노면센서와 기상관측장비, 융설액 분사펌프로 구성된다. 결빙감지센서와 온도, 습도센서가 도로에 쌓인 눈이 얼어붙을 조짐을 감지하면 도로 옆에서 눈을 녹이는 염화칼슘용액이 일제히 분사된다. 웬 만큼 내리는 눈은 하루 3~4회 융설액 분사로 해결되고 1m가 넘는 적설량이 쌓이면 20~30회 융설액을 뿌려 빙판길 사고를 막아준다. 이 시스템은 흔히 빙판길에 손으로 뿌리는 모래, 소금, 염화칼슘가루보다 제빙효율이 월등하며 자동차, 교량철반이 염화칼슘으로 부식되는 피해도 거의 없어 선진국형 제설 장비로 각광받고 있다. 실제로 눈이 많은 북유럽, 캐나다, 일본 등지에선 도

로결빙방지시스템 도입이 확대일로에 있다. 주로 설치되는 장소는 터널 입출구나 대형교량, 험준한 산악도로 등 대형사고 위험지역이 대부분을 차지한다. 국내에서는 폭설로 인한 빙판길 교통사고를 줄이기 위해 정선카지노 진입구간을 비롯해 강원도 진부령터널 상행선과 대관령 2, 3터널의 1.5km구간에 도로결빙방지시스템이 설치됐다. 또 수도권과 강원지역 산간도로 3곳에도 결빙방지시스템 설치가 진행 중이다. 결빙방지시스템이 설치된 강원지역 터널구간에서는 올 겨울 수차례 폭설에도 별다른 빙판길 접촉사고가 한건도 발생하지 않았다.

최근 사물에 전자태그(Radio Frequency Identification: RFID)를 부착하여 사물의 정보를 확인하고 주변 상황 정보를 감지하는 전자태그 및 센싱 기술이 등장하고 있다. 이러한 기술은 바코드를 대체하여 상품관리를 네트워크화, 지능화함으로써 유통 및 물품 관리뿐만 아니라 의료, 약품, 식품 등 분야에서 security, safety, 환경관리 등의 혁신을 선도할 것으로 전망된다. 미국, 일본 등 선진국에서는 수년 전부터 전자태그의 이러한 특징을 개발하기 위한 다양한 프로젝트를 통하여 전자태그 및 센서 기술 개발과 실용화에 적극적인 지원을 하고 있는 실정이다.

3.3 U-센서 네트워크의 개념

3.3.1 u-센서 네트워크의 기본 개념

USN(Ubiquitous Sensor Network)란 “필요한 모든 것(곳)에 전자태그를 부착하고 이를 통하여 사물의 인식 정보를 기본으로 주변의 환경정보(온도, 습도, 오염정보, 균열정보 등)까지 탐지하여 이를 실시간으로 네트워크에 연결하여 정보를 관리하는 것”을 말하는 것으로 궁극적으로 모든 사물에 컴퓨팅 및 커뮤니케이션 기능을 부여하여 Anytime, Anywhere, Anything 통신이 가능한 환경을 구현하기 위한 것이다. USN은 먼저 인식정보를 제공하는 전자태그를 중심으로 발전하고 이에 센싱 기능이 추가되고 이들간의 네트워크가 구축되는 형태로 발전할 것이다[4].

특히, 유통분야에서는 물품관리를 위해 바코드가 일반적으로 사용되어 왔으나 가격이 매우 싼 반면에

기본적으로 다량의 물품을 동시에 처리하는데 한계가 있고, 시간이 많이 걸리며, 실시간 정보 파악이 불가하며, 근접한 상태에서만 정보를 읽을 수 있는 단점이 있다. 이에 비해 전자태그 가격은 다소 비싼 편이나 동시에 많은 물품을 처리할 수 있고, 식별시간이 짧으며, 실시간 정보 파악이 가능하고 수십cm~수m 거리에서도 정보를 읽을 수 있으며 보안성도 뛰어나 세계적으로 바코드를 대체할 수 있을 것으로 전망되고 있다. 현재 전자태그는 저주파(125kHz) 및 고주파(13.56MHz)의 전자태그를 중심으로 60cm이내의 짧은 거리에서 출입 통제나 교통카드 등에 활용되고 있으나 앞으로는 극초단파(900MHz)와 마이크로파(2.4GHz)를 중심으로 인식거리가 늘어나고 가격이 저렴해지면서 유통, 물류, 환경 감지, 교통 등 다양한 분야에 적용될 것이 예상된다.

3.3.2 u-센서 네트워크의 구조 및 기술

u-센서 네트워크는 안테나가 부착한 태그(센서)와 안테나를 부착한 리더가 정보통신망과 연동됨으로써 구성되며 태그와 리더는 전파를 이용하여 연결되며 자체 에너지원 또는 수신 전파로부터 작동할 에너지 공급을 받아 동작한다.

리더기가 태그로 전파를 송신하면 태그는 수신 전파로부터 에너지를 얻어서 활성화되며 활성화된 태그는 자신의 정보를 실어서 리더기로 송신하게 된다. 이때 전자태그는 태그가 송신하는 전파의 에너지원을 얻는 방법에 따라 수동형(Passive)과 능동형(Active)으로 구분된다. 수동형은 리더기로부터 수신되는 전파에서 송신에너지를 얻고 능동형은 별도의 배터리에서 송신에너지를 얻으며 리더기는 수집된 정보 네트워크를 통하여 센터에 전달하게 된다. 구체적인 u-센서 네트워크 구현 관련 주요 기술로는 태그, RFID 리더기 및 인식방식을 들 수 있다.가. 태그 관련 기술

칩형 태그의 경우 현재 13.56MHz의 칩이 대량 생산되고 있으며, 향후 글로벌 유통과 물류 등 다양한 분야에서 이용될 900MHz 대역의 칩은 최근 ALIEN, PHILIPS, MATRICS 등에서, 2.45G의 칩은 히타치가 소량 생산하고 있다. 현재 칩의 가격이 태그 가격의 약 40%를 차지하고 있으나 소형화와 패키지 조립기

술을 통해 향후1센트 수준까지 가격을 낮출 수 있을 것으로 예상된다.

Chipless형 태그는 현재 인식거리, 정보용량 등의 한계로 제한적으로 이용되고 있으나 표면 탄성파를 이용한 태그 기술은 저가격, 센서기능 구현이 용이할 것으로 전망된다

센싱형 태그의 경우 태그의 기능을 확장하기 위한 센서 융합형 태그 기술을 통해 능동형 태그의 저가화를 추진중이며 피츠버그 대학은 센서와 통합 가능하고 안테나를 칩에 내장한 수동형 초소형(2.2mm × 2.2mm) 태그를 개발한 바 있다.

태그 안테나 및 패키지 기술의 경우 태그의 글로벌 사용을 위해 860-960MHz 대역에서 동작하는 소형의 광대역 안테나 기술을 개발중이며 안테나 제작비용을 줄이기 위해 칩과 결합이 용이한 프린팅 안테나 기술이 이용되고 있으나, 궁극적으로 안테나를 반도체 웨이퍼상에 직접 구현하기 위한 Antenna on chip 기술을 개발 중이다.

태그 신호 충돌 방지 알고리즘 채용으로 현재 초당 100개까지 인식이 가능하나 수백 개를 목표로 기술을 개발중이며, 여러 대역의 주파수 인식이 가능한 Multi-band, Multi-protocol 리더기 기술 또한 개발중이다. 현재 리더는 인식 성능을 높일 수 있도록 2~4개의 안테나를 배열하여 사용하고 있으나 향후 주변 환경에 적응하여 빔을 제어할 수 있는 빔성형(Beam forming) 안테나 기술이 적용될 전망이다.

전자태그를 이용하여 사물의 식별을 가능케 해야 하므로 용도에 따라서 단위 지역 또는 전 세계적으로 유일한 인식번호를 부여하기 위한 식별 코드 체계의 정의가 필요하다.

관련 표준으로는 국제유통표준화를 주도하는 EAN(European Article Number, 유럽)와 UCC(Uniform Code Council, 북미지역)에서 제안한 EPC(Electronic Product Code, 96bit)와 일본에서 제안된 u-ID(Ubiquitous-ID, 126bit) 체계가 있으며, 국제 표준화 작업을 진행중이다.

특히, 인터넷 주소 체계에서는 128bit의 IPv6를 추진하고 있어 EPC방식과 연계를 위해서는 국가차원의 코드체계 표준 대응방안의 수립이 필요한 실정이다.

또한 리더가 읽은 전자태그의 정보를 이용하여 다양한 상품정보를 비즈니스 애플리케이션에 연계시켜 주는 미들웨어의 개발 및 시험을 진행 중에 있으며 전자태그의 EPC 정보를 Savant 서버에 보내어 ONS에서 사물정보가 있는 PML의 위치를 확인하고 PML의 서버로부터 사물의 구체적인 정보를 얻는 연구가 진행 중이다.

4. 결론 및 향후 과제

본 논문에서는 신경망 및 퍼지 전문가시스템을 이용하여 기존 전력 구간의 정전구간, 변압기 고장, 고압선송전소 단선 구간, 교통사고 구간, 등을 판단하는 알고리즘을 제시하였다.

본 논문에서는 가변 시간간격을 가진 그룹 전력구간 고장 데이터에 대한 소프트웨어 신뢰성 예측을 하기 위한 신경망 모델을 연구하였다. 수집된 가변 시간간격 고장 데이터에 대해 필요한 모든 정보를 발췌하여 신경망의 입력으로 하는 훈련제도 11개를 제안하고 그 중에서 가장 좋은 훈련제도를 갖는 모델을 선정하였다. 본 연구에는 4개의 데이터가 사용되었으며, FFN 신경망에 한정하여 모델의 예측력을 평가하기 위해 다음 단계 고장 수에 대한 AE를 계산하고, NAE와 순위를 계산하여 다양한 모델의 결과와 비교함으로써 제안된 모델의 적합성을 평가하였다.

실험 결과 가변 시간 간격 데이터에 대해 미래의 특정 시점에서의 고장 수를 예측하기 위해서는 미래의 특정 시점에 대한 정보인 Δt_i 를 신경망의 입력으로 이용하는 모델 (R4-R5)의 예측력이 가장 좋음을 알 수 있었다. Δt_i 정보를 활용하지 않은 널리 사용되는 기존의 대표적인 통계적 SRGMs와 신경망 모델들과 비교 결과를 비교하였다.

뿐만 아니라, 액티브 네트워크는 유비쿼터스와 RDID 기법을 이용하여 결빙구간 예측 및 교통 사고 구간 판단, 전력사고 구간 판단을 자동으로 관리 할 수 있을 것이다.

본 연구 결과를 기반으로 하여, Δt_i 정보를 활용하여 다른 잘 알려진 신경망에 적용하거나 보다 많은 데이터를 이용한 전력사고구간 자동판단, 가로등 단선

구간 자동판단, 교통신호등 단선구간 판단 등의 연구가 활성화 될 것으로 사료된다.

참고 문헌

- [1] G. Cybenko, "Approximation by Super-positions of A Sigmoidal Function," *Mathematics of Control, Signals and Systems*, Vol. 2, pp. 303-314, 1989.
- [2] S. E. Fahlman and C. Lebiere, "The Cascade-Correlation Learning Architecture," *Advances in Neural Information Processing Systems II*, pp. 525-532, 1990.
- [3] J. Ghosh and K. Tumer, "Structural Adaptation and Generalization in Supervised Feedforward Networks," *Journal of Artificial Neural Networks*, Vol. 1, No. 4, pp. 431 - 458, 1994.
- [4] A. L. Goel, "Software Reliability Models Assumptions, Limitation, and Applicability," *IEEE Trans. on Software Eng.* Vol.SE-11, No.12, pp.1411-1423, 1985.
- [5] L. Holmström, P. Koistinen, J. Laaksonen, and E. Oja, "Neural and Statistical Classifiers-Taxonomy and Two Case Studies," *IEEE Trans. on Neural Networks*, Vol.8, No.1, pp.5-17, 1997.
- [6] K. Hornik, M. Stinchcombe, and H. White, "Multilayer Feedforward Networks are Universal Approximators." *Neural Networks*, Vol. 2, pp. 359-366, 1989.
- [7] R. H. Hou and S. Y. Kuo, "Applying Various Learning Curves to Hypergeometric Distribution Software Reliability Growth Model," *IEEE*. 1994.
- [8] N. Karunanithi, D. Whitley and Y. K. Malaiya, "Using Neural Networks in Reliability Prediction," *IEEE Software.*, pp. 53-59, 1992.
- [9] N. Karunanithi, D. Whitley, and Y. K. Malaiya, "Prediction of Software Reliability Using Connectionist Models," *IEEE Trans. on Software Eng.*, Vol.18, No.7, pp. 563-574, July. 1992.
- [10] T. M. Khoshgoftaar, E. B. Allen, J. P. Hudepohi,


- and S. J. Aud, "Application of Neural Networks to Software Quality Modeling of a very Large Telecommunications Systems," IEEE Trans. on Neural Networks, Vol.8, No.4, pp.902-909, 1997.
- [11] T. Y. Kwok and D. Y. Yeung, "Constructive Algorithms for Structure Learning in Feedforward Neural Networks for Regression Problems," IEEE Trans. on Neural Networks, Vol. 8, No. 3, pp. 630 - 645, 1997.
- [12] M. R. Lyu, "*Handbook of Software Reliability Engineering*," IEEE Computer Society Press, 1996.
- [13] Y. K. Malaiya, N. Karunanithi, and P. Verma, "Predictability Measures for Software Reliability Models," IEEE Trans. on Reliability, Vol. 41, No. 4, pp.539-546, 1992.
- [14] J. D. Musa, A. Iannino, and K. Okumoto, "*Software Reliability : Measurement, Prediction, Application*," McGraw-Hill, 1987.
- [15] M. Ohba, "Software Reliability Analysis Models," IBM Journal of Research and Development, Vol. 21, No. 4, pp. 428-443, 1984.
- [16] J. Y. Park, S. U. Lee, and J. H. Park, "Neural Network Modeling for Software Reliability Prediction from Failure Time Data," Journal of Electrical Eng. and Information Science, Vol. 4, No. 4, pp. 533-538, 1999.
- [17] F. Popentiu and D. N. Boros, "Software Reliability Growth Supermodels," Microelectron. Reliab. Vol. 36, No.4, pp.485-491, 1996.
- [18] 이상운, "비정규화 데이터를 이용한 신경망 소프트웨어 신뢰성 예측", 정보처리학회 논문지, 제7권, 제5호, pp.1419-1426, 2000. 5.
- [19] J. D. Musa, "Software Reliability Data," Technical Report, Data and Analysis Center for Software, Rome Air Development Center, Griffins AFB, New York, 1979.
- [20] Norme Internationale International Standard, CEI IEC 1131-3, Premiere edition, First edition, 1993
- [21] 이창현, "간선도로의 신호운영체제 개선에 관한 연구", 서울대 환경대학원, 1988
- [22] 김수철, "도시 간선도로의 교통신호체제 증진방안에 관한연구", 서울대 환경대학원, 1978
- [23] 도로교통안전협회, "대도시 신호등체제의 개선운영에 관한연구", 1984
- [24] "텔레매틱스 활성화 교통 개선율", 서울 경제, 2004. 01. 28
- [25] "車 막혀 年22조 낭비", 중앙일보, 2004,01,04
- [26] C.P.Pappis, E.H. Mandani, "A Fuzzy Logic Controller for a Traffic Junction" IEEE Trans.Syst., Man,Cyberm.,7(10),707-717, 1977.
- [27] M.Jamshidi, R.Kelsey, K. Bisset, "Traffic Fuzzy Control: Software and Hardware Imp-lementations", Proc. 5th IFSA, p.907-910,Se-oul,Korea, 1993.
- [28] R. Hoyer, U. Jumar, "Fuzzy Control of Traffic Lights", Proc.3rd IEEE International Conference Fuzzy Systems, pp.1526-1531, Orlando, U.S.A., 1994.
- [29] L.A. Zadeh, "Fuzzy Set," Information Control, Control, Vol.8, pp.338-353, 1965
- [30] 원태현의 6인, PLC 제어기술, 제2판, 복두 출판사, 2001.
- [31] 박양수의 2인, FA를 위한 PLC 실습, 복두 출판사, 1998.
- [32] 김종부의 3인, PLC 이론 및 실습, 복두 출판사, 2002.
- [33] PLC 이론과 실습, 삼성전자 사내교육 자료.

◎ 저자 소개 ◎



홍 유 식

1984년 : 경희대학교 전자공학과 (학사)
1989년 : 뉴욕공과대학교 전산학과 (석사)
1997년 : 경희대학교 전자공학과 (박사)
1985년~1987년 : 대한항공(N.Y.지점 근무)
1989년~1990년 : 삼성전자 종합기술원 연구원
1991년~현재 : 상지대학교 전산학과 부교수
2000년~현재 : 한국퍼지 및 지능시스템학회 이사
2004년~현재 : 대한 전자공학회 협동이사
2001년~2003년 : 한국 정보과학회 편집위원
2001년~2003년 : 한국 컴퓨터 교육산업학회 이사, 편집위원
관심분야 : 퍼지시스템, 전문가시스템, 신경망, 교통제어



이 상 운

1983년~1987년 : 한국항공대학교 항공전자 공학과(학사)
1995년~1997년 : 경상대학교 컴퓨터과학과 (석사)
1998년~2001년 : 경상대학교 컴퓨터과학과 (박사)
1992년~2003년 : 국방품질관리소 항공전자장비 및 소프트웨어 품질보증 담당
2003년 : 도립 강원전문대학 컴퓨터응용과 전임강사
2004년~현재 : 국립 원주대학 여성교양과 전임강사
관심분야 : 소프트웨어 공학(소프트웨어 시험 및 품질보증, 소프트웨어 신뢰성), 소프트웨어 프로젝트 관리, 신경망, 뉴로-퍼지, Use-Case, RUP, CBD
e-mail : sulee@sky.wonju.ac.kr