

신경회로망과 3차원 지형데이터를 이용한 마이크로셀 전파손실 예측

Microcellular Propagation Loss Prediction Using Neural Networks and 3-D Digital Terrain Maps

양서민 · 이혁준

Seomin Yang · Hyukjoon Lee

요약

전파의 유효 수신 신호 도달영역을 정확히 식별하는 것은 기지국 최적화를 이루는데 있어 가장 중요한 요소중 하나이다. 서울 도심 지역과 같이 고층건물이 밀집되어 있고, 넓은 도로와 좁은 도로가 불규칙적으로 배치되어 있으며, 고개와 강 등이 혼재된 지역에서도 높은 정확도를 갖는 전파손실 예측모델을 소개한다. 이 모델은 기 측정된 필드데이터로 훈련된 신경회로망을 기반으로 한다. 전파손실에 영향을 주는 가장 기본적인 변수들은 3차원 DEM 데이터와 벡터 데이터로부터 추출하여 신경회로망의 입력으로 사용한다. 학습이 완료된 신경회로망은 전파손실 모델의 근사함수이며, 학습에 사용된 필드 측정데이터에 포함되지 않은 타지역에서도 정확한 예측이 가능한 일반화 능력을 갖는다. 서울 도심 지역의 실제 서비스 환경에 대한 비교 실험결과를 통해 제안하는 모델의 우수성을 보인다.

Abstract

Identifying the boundary of the effective receiving power of waves is one of the most important factors for cell optimization. In this paper, we introduce a propagation loss prediction model which yields highly accurate prediction in very complex areas as Seoul where a mixture of many large buildings, small buildings, broad streets, narrow alleys, rivers and forests co-exist in an irregular arrangement. This prediction model is based on neural networks trained on field measurement data collected in the past. Using these data along with 3-D digital elevation maps and vector data for building structures, we extract the parameter values which mainly affect the amount of propagation loss. These parameter values are then used as the inputs to the neural network. Trained neural network becomes the approximated function of the propagation loss model which generalizes very well and can predict accurately in the regions not included in training the neural network. The experimental results show a superior performance over the other models in the cells operating in the city of Seoul.

「본 연구는 정보통신부의 1997년도 대학기초 연구지원사업으로 수행되었습니다.」
 광운대학교 컴퓨터공학과(Dept. of Computer Engineering, Kwangwoon University)
 · 논문 번호 : 981228-135
 · 수정완료일자 : 1999년 4월 1일

I. 서 론

무선통신망에서는 한정된 전파자원을 효율적으로 활용하여 경제적이고 효과적인 가입자 수용을 위한 셀 세팅이 대단히 중요시된다. 특히 유선통신망과는 달리 무선패널환경에 따른 음영지역의 형성은 호 손실의 직접적인 원인이 되기 때문에 기지국이 담당하는 서비스 영역과 음영지역의 정확한 분석 및 지속적인 망 최적화 작업이 필수적이다. 셀 최적화를 위해서는 각 셀의 유효 수신 전파의 도달 범위에 대한 정확한 사전 지식을 필요로 하며, 이는 주로 전파전파(wave propagation) 모델을 사용한 전파손실(propagation-loss) 예측을 통해 얻어진다. 전파는 기본적으로 주파수, 거리, 송수신기 안테나 높이, 대기 환경, 건물, 구릉, 산과 같은 지형 지물에 의해 반사, 회절, 산란 등의 영향을 받아 매우 복잡한 경로를 거치게 되고, 이에 따라 전파손실은 복잡한 비선형적인 특성을 갖는다^[1]. 전파손실을 모델링하기 위한 연구로서 초기에는 Okumura/Hata 모델로 대표되는 통계적인 방법을 사용하여 필드 측정 데이터에 기반한 분석을 통해 예측 모델을 얻었으나 임의의 지역조건에 대해 정확성을 보장할 수 없는 단점이 있다^{[2][3]}. 최근에는 회절 이론(GTD, Geometrical Theory of Diffraction)과 기하광학 이론을 이용한 결정론적인(deterministic) 방법들이 많이 연구되고 있다^{[4]~[6]}. 그러나, 이러한 이론적인 모델은 공통적으로 계산량이 많고, 복잡하여 실제 운영환경에서 사용하는데 있어 제약이 따른다. 경험적인 모델과 결정론적인 모델을 병합하여 만든 COST-231 Walfish/Ikegami 모델은 제한된 건물 정보만을 이용하여 간단히 구현이 되지만, 경험적인 모델에서와 같은 최적화 작업을 필요로 한다^{[7][8]}. 특히 통계적인 방법의 경우는 평균 지형고도와 같은 상대적으로 단순한 전파 환경을 가정으로 했기 때문에 실제 도심지에서와 같은 복합적 지형 조건하에서는 정확한 예측이 어렵다.

다. 이를 해결하기 위해 요즘들어 실제 지형을 그대로 표현한 3차원 지형정보를 사용하여 예측의 정확성을 높이는 방법들이 시도되고 있다^[9].

그밖에 신경회로망을 사용한 접근방식도 몇 가지 있다^{[10][11]}. 신경회로망은 인간의 뇌신경 조직을 모델로 하여 극히 단순한 기능을 갖는 다수의 인공 뉴런들과 이들간의 신호전달을 위한 연결강도를 갖는 연결로 이루어진 연결된 네트워크 형태의 계산 모델이다. 뉴런들 사이의 연결강도의 값은 학습에 의해 정해진다. 기존의 폰 노이만 컴퓨터의 순차적인 처리방식과는 다르게 다수의 인공 뉴런들에 의한 병렬/분산처리로 인하여 속도가 빠르고 오차에 강한 특성을 가지고 있기 때문에 패턴인식, 비선형 함수 근사화, 비선형 시스템 식별, 영상/음성 신호처리 등과 같이 수식적으로 표현이 불가능한 문제를 해결하는데 주로 쓰인다. 신경회로망에는 네트워크 구조나 학습규칙에 따라 여러 모델이 존재하는데, 특히 그림 1과 같이 입력층, 출력층, 다수의 은닉층을 포함한 계층적 구조를 가지고 오류 역전파(error-backpropagation) 알고리즘으로 학습하는 다층 퍼셉트론(Multi-Layer Perceptron, MLP)은 사용이 쉽고, 함수 근사화 성능이 우수하여 널리 사용되고 있다^{[12][13]}. 신경회로망을 이용한 함수 근사화 과정은 학습을 통하여 이루어지며, 오류 역전파 학습 알고리즘을 통해 신경회로망의 출력값과 목표 함수값의 평균제곱오차(Mean Squared Error)가 최소화가 되도록 뉴런간의 연결강도를 갱신하는 과정을 반복한다.

본 논문에서는 MLP를 이용한 전파손실 예측모델링 방법을 제안한다. 이 방법에서는 지형도를 이용하여 전파손실에 영향을 주는 요인들을 물리적으로 해석하여 정량적인 데이터를 추출하고 이를 신경회로망의 학습 데이터로 이용하여 도심의 실제 이동통신 환경에서도 정확한 전파 손실 예측이 가능하도록 하였다. 본 논문의 구성은 다음과 같다. Ⅱ절에서는 본 논문에서 제안하는 신경회로망 예측모델에 대해서 서술하고, Ⅲ절에서는 전파 환

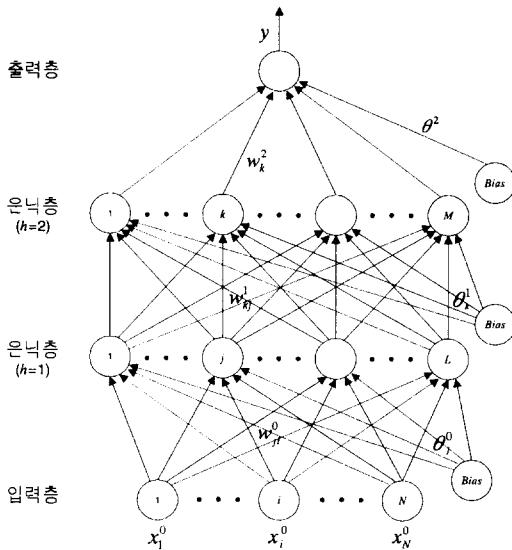


그림 1. 다층 퍼셉트론

Fig. 1. Multilayer perceptron.

경 및 전파 특성이 반영된 신경회로망 입력데이터를 얻기 위한 특징 추출에 대해서 고찰하고, IV절에서는 제안한 모델을 사용하여 실제 전파환경에 대한 예측결과와 타 모델과의 비교결과를 제시하고, V절에서는 본 연구결과를 간단히 정리하고 결론을 맺는다.

II. 신경회로망을 이용한 전파 손실 예측 모델

일반적으로 전파손실 모델은 다음 식과 같이 지형조건과 전파환경에 관련된 변수들의 함수로 표현된다.

$$L_p = f(h_b, f_c, h_m, d, \Delta h) \quad (1)$$

여기서 \$h_b\$는 기지국 안테나의 높이, \$f_c\$는 주파수, \$h_m\$는 수신측 이동 단말기의 높이, \$d\$는 기지국과 이동 단말기 간의 거리, \$\Delta h\$는 지형에서 고도의 변화량을 나타낸다. 예를 들면, 동경시의 측정 데이터를 기준으로 한 Hata의 도심지 전파손실 모델의 경우는 다음과 같다.

$$L_p = 69.55 + 2.16 \log f_c - 13.82 \log h_b - a(h_m) + (44.9 - 6.55 \log h_b) \log a \text{ dB} \quad (2)$$

여기서 \$a(h_m)\$은 수신안테나 높이에 대한 보정 인자이며, 지역의 특성에 따라 각각 다른 값이 적용된다. 이때 도심지에 대한 각 환경변수의 제한 조건은 \$150 \leq f_c \leq 1500 \text{ MHz}\$, \$30 \leq h_b \leq 200 \text{ m}\$, \$1 \leq d \leq 20 \text{ km}\$와 같다. 비선형적인 전파손실 함수 \$f\$를 유도하기 위해서는 주로 회절 이론과 전자기 이론을 응용하거나 통계적인 분석을 통한 근사화를 용 하지만, 복잡한 비선형적인 특성으로 인해 정확한 모델링에 어려움이 많다. 본 논문에서는 오류 역전파 학습 알고리즘으로 학습하는 MLP를 사용하여 전파손실을 모델링한다.

신경회로망을 이용한 함수 근사화 과정은 학습을 통하여 이루어지며, 학습과정은 다음과 같다^[13]. 그림 1에서 신경회로망의 최종 출력을 \$y\$, 입력 벡터를 \$\overline{\mathbf{X}}^0 = [x_1^0, x_2^0, \dots, x_N^0]'\$이라 하면, 최종 출력 \$y\$의 계산식은 다음과 같다.

$$y = f(\text{net}^H) \quad (3)$$

여기서 \$f(\text{net}^H) = \frac{1}{1 + e^{-\text{net}^H}}\$이고, \$\text{net}^H = \sum_k w_k^H x_k^H + \theta^H\$이다. \$f(\cdot)\$는 시그모이드(sigmoid) 함수로 뉴런의 활성화 함수이며, \$w_k^H\$는 \$H\$번째 은닉층의 \$k\$번째 뉴런과 출력 뉴런 사이의 연결가중치, \$H\$는 은닉층의 수, \$x_k^H\$는 \$H\$번째 은닉층의 \$k\$번째 뉴런의 출력값, \$\theta^H\$는 \$H\$번째 은닉층의 bias 또는 문턱치(threshold)이다. 출력 뉴런에서와 마찬가지로 모든 은닉층 \$h=1, \dots, H\$에 대하여 \$x_k^h\$는 하위 은닉층 뉴런의 출력값 \$x_j^{h-1}\$과 연결가중치 \$w_{kj}^{h-1}\$의 선형 조합에 의하여 다음과 같이 계산된다.

$$x_k^h = f(\sum_j w_{kj}^h x_j^{h-1} + \theta^h) \quad (4)$$

신경회로망의 학습은 입출력 쌍으로 이루어진 샘플데이터의 \$S = \{(a_p, b_p) | p=1, \dots, N\}\$ 집합

을 이용하여 입력 파라미터 \mathbf{a}_p 가 신경회로망의 입력값으로 주어졌을 때의 신경회로망 출력 y_p 와 b_p 간의 오차 $E_p = \frac{1}{2} \sum (y_p - b_p)^2$ 가 감소하도록 연결가중치 벡터 \mathbf{w}^h , $h=1, \dots, H$ 를 반복하여 갱신함으로써 이루어진다. \mathbf{w}^h 를 갱신하기 위한 식은 다음과 같다.

$$\begin{aligned} w_i^h(t+1) &= w_i^h(t) - \eta \frac{\partial E_p}{\partial w_i^h} \\ &+ \alpha(w_i^h(t) - w_i^h(t-1)) \end{aligned} \quad (5)$$

$$\begin{aligned} \theta_i^h(t+1) &= \theta_i^h(t) - \eta \frac{\partial E_p}{\partial \theta_i^h} + \alpha(\theta_i^h(t) \\ &- \theta_i^h(t-1)) \end{aligned} \quad (6)$$

여기서, η 는 학습속도, α 는 모멘텀 속도(momentum rate)이며, $h=H$ 일 때,

$$\frac{\partial E_p}{\partial w_k^H} = \frac{\partial}{\partial w_k^H} [\sum (y_p - b_p)^2], \quad (7)$$

$h=1, \dots, H-1$ 일 때,

$$\frac{\partial E_p}{\partial w_{ki}^h} = \frac{1}{2} \sum \frac{\partial}{\partial w_{ki}^h} (y_p - b_p)^2 \quad (8)$$

이다.

이러한 반복 학습과정을 통해 신경회로망은 입력벡터와 출력값과의 사상관계를 근사화하게 되며, 신경회로망의 입력벡터에는 송신 안테나와 각 예측 지점간의 전파 환경을 대표하는 정량적인 수치들이 사용될 수 있다. 신경회로망의 입력으로는 기본적으로 전파이론에서 사용되는 변수들과 다양한 전파환경을 고려하기 위하여 헤리스틱(heuristic)을 적용한 수치들이 포함되어 있고, 신경회로망 출력값은 입력이 생성된 지점에서의 전파손실 예측치가 된다. 다양한 전파환경에 대한 훈련을 통해 완성된 신경회로망은 단순한 보간법(interpolation)의 적용과는 달리 측정 데이터가 없는 다른 임의의 지역에 대한 예측이 가능한 일반화(generalization)

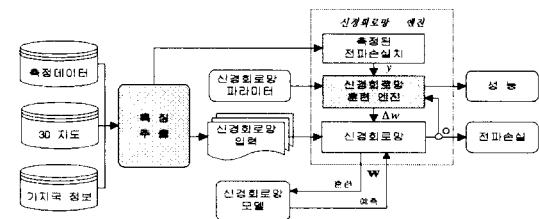


그림 2. 신경회로망 전파 손실 예측 모델링 시스템

Fig. 2. Wave propagation-loss prediction modeling system using neural network.

된 전파전파 모델로 완성된다. 신경회로망의 입력 벡터는 지형도와 같은 원천 데이터로부터 송신안테나와 수신지점간의 전파환경을 대표하는 정량적인 수치들을 추출함으로써 얻을 수 있고, 이 과정을 특징추출(feature extraction)이라 한다. 특징추출 단계에서 진행되는 자세한 내용은 다음 절에서 다루기로 한다. 전체 시스템의 진행과정은 그림 2와 같다. 먼저, 지형도, 기지국 데이터, 측정 데이터 등의 원천 데이터를 이용한 특징추출 과정을 통해 신경회로망 입력 데이터들을 얻고, 이들을 무작위로 훈련용 데이터와 검증용 데이터로 나눈 후에 먼저 훈련 데이터만을 사용하여 신경회로망을 훈련시킨다. 신경회로망 훈련이 완료되면 훈련시의 신경회로망 구조와 연결강도를 저장한 후 훈련에 사용되지 않은 검증 데이터를 사용하여 완성된 신경회로망의 성능을 평가하게 된다. 완성된 신경회로망 모델을 사용하여 임의의 지역에 대한 전파손실을 예측할 수 있다.

III. 신경회로망 모델의 입력 데이터

3-1 원천 데이터

1. 필드 측정 데이터

필드 측정 데이터는 기지국 주변 지역내 도로상에서 측정한 수신 전계 강도로 측정지점에 대한 GPS 좌표(위도, 경도), 수신 전계 강도 등이 포함되어 있다. 수신 전계 강도값은 전파손실값으로 변

환되어 사용된다.

2. 기지국 정보

주요 기지국 정보로는 기지국의 위치, 각 세터 안테나별 수평지향각, 다운틸트각, 주파수, 대역폭, 순송신전력(ERP) 등과 안테나 자체의 고유 특성 정보인 수평/수직 방사 패턴, 범폭, 최대 이득 등이 있다.

3. 3차원 지형/지도 정보

본 연구에서 사용하는 지형정보는 모두 직사각형 형태의 도엽으로 구성되어 있으며, $10\text{ m} \times 10\text{ m}$ 의 고해상도 3차원 디지털 고도 지도(Digital Elevation Map, DEM)와 도로, 강, 호수, 건물 등의 형태정보로 구성되어 있는 3차원 벡터 지도의 두 가지가 있다.

3-2 특징 추출

1. 송수신기 간의 거리

기지국 송신기와 수신기간의 거리는 전파손실의 가장 기본적인 요인으로 자유공간 상에서 거리와 주파수에 의한 송수신 전력의 비는 Friis 공식에 의해 정의되고, 이를 근거로 하여 송수신기간의 거리 d_{Tx-Rx} 를 신경회로망 특징의 하나로 사용한다.

2. 송신 안테나 특성

기지국에 설치된 송신안테나의 물리적인 특성은 셀의 전파 환경을 정하는 중요한 요인으로 작용한다. 안테나에 관련된 변수로는 안테나의 종류에 따른 안테나 최대 이득과 범폭, 수평/수직 방사특성, 송신탑의 설치 높이, 안테나의 수평/수직 지향방향 등이 있다. 송신안테나의 방향과 수신위치에 따른 전파 손실의 상대적인 영향을 포함시키기 위해 송신안테나의 지향방향을 기준으로 수신위치에서의 안테나 이득을 계산하여 각 위치에 대한 전체 안테나 이득 G_{total} 을 다음식과 같이 구한다.

$$G_{total} = G_{or} + G_{ot} + G_t(\theta_h) + G_v(\theta_v) \quad (9)$$

여기서 G_{ot} , G_{or} 는 송/수신 안테나의 최대 이득이고, $G_t(\theta_h)$, $G_v(\theta_v)$ 는 송신안테나의 지향방향과 수신지점간의 수평사이각 θ_h 과 수직사이각 θ_v 에 대한 이득의 감소치이다.

3. 장애물 투과

장애물 투과에 따른 손실 정도는 장애물의 종류, 투과 두께, 건물 외벽의 재질, 창문 비율, 주파수, 전파의 가시상태 등 여러 요인에 따라 정해진다. 이중에서 기지국과 수신기간의 가시상태와 투과 두께는 3차원 DEM과 벡터지도 데이터로부터 계산해낼 수 있다. 그럼 3과 같은 3차원 벡터지도에는 지형에 대한 정보를 포함하고 있지 않으므로 건물에 의한 투과 영향만을 계산하는데 사용되고, 산,

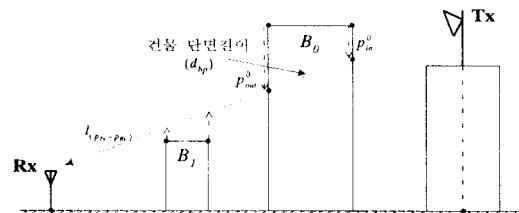


그림 3. 벡터 지도를 이용한 건물 투과 두께의 계산
Fig. 3. Calculation of obstacle profile using vector map.

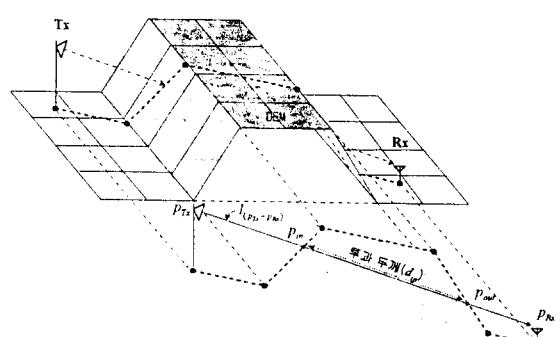


그림 4. DEM을 이용한 지형의 투과 두께 계산
Fig. 4. Calculation of obstacle profile using DEM.

고개와 같은 지형에 의한 전파의 투과 손실현상을 예측 모델에 포함시키기 위해서는 그림 4와 같은 DEM 데이터를 사용하여 투과 두께를 구해야만 한다. 송신기와 수신기간의 경로에 놓인 모든 장애물의 투과두께 d_{bf} 는 다음과 같이 지형에 의한 총 투과량과 건물에 의한 총 투과량의 합으로 계산할 수 있다.

$$d_{bf} = \sum_m d_{tp}^m + \sum_n d_{bp}^n \quad (10)$$

여기서 d_{tp}^m 은 m 번째 지형장애물에 대한 투과두께, d_{bp}^n 은 n 번째 건물에 대한 투과두께를 나타낸다.

4. 회 절(Diffraction)

장애물에 의한 회절파의 경로는 그림 5와 같이 장애물의 끝점을 지나가는 경로 $SL_{diffraction}$ 가 되고, 이 경로는 송수신단간의 주요 전파경로중에 하나가 된다. 이 회절경로 $SL_{diffraction}$ 의 길이와 직선 경로 길이 d_{Tx-Rx} 의 차이는 전파경로상에서 발생하는 회절의 크기를 나타내는 정량적인 수치가 되므로, 이를 신경회로망의 입력에 사용한다. 또한, Ikegami가 제안한 회절 모델에 의하면 회절 영향의 계산에 있어서 송수신기간의 경로상의 수신기 도달전 마지막 장애물에 의한 회절을 중요시하고 있다^[8]. 이를 근거로 하여 그림 5와 같이 수신기에서 가장 가까운 장애물 끝점으로부터의 거리 d_{last} 를 추출하여 회절과 관련된 신경회로망 입력 중에 하나로 사용한다. 그리고, 프레넬 반경에 의한 다중 장애물에 대한 회절 현상을 근사화하기 위하여 장애물 끝점과 전파 직선 경로와의 최대 높이차 Δh_{max} 를 구하여 또 다른 신경회로망 특징값으로 사용한다.

5. 반 사

전파의 반사현상은 전파손실 예측을 어렵게 만드는 요인 중에 하나이다. 반사파에 의한 영향을 근사화하기 위하여 송신 안테나를 떠난 전파가 유

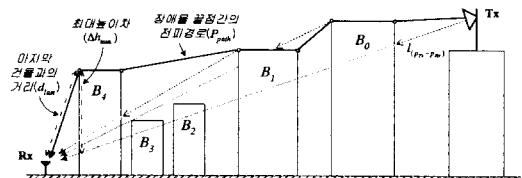


그림 5. 회절 영향을 반영하는 특징들의 추출 예

Fig. 5. Examples of feature extraction for diffraction effects.

효지역내의 임의의 건물벽에 1차 반사된 후 수신 안테나에 도착하는 경우에 반사가 발생한 것으로 가정하고, 이러한 전파경로에 대해서 정량화된 수치를 얻기 위하여 모든 반사파의 송신안테나로부터 수신지점까지의 전파경로길이를 계산한다. 그리고, 이를 모두 누적하여 반사 영향을 나타내는 특징값으로 사용한다.

6. 도로

도로에 의한 전파의 도관효과(ducting effect)를 반영하기 위해 초기의 경험적인 모델에서부터 수신안테나가 위치한 도로의 방위각과 송신안테나 지향방향과의 상관관계나 도로의 넓이 등은 도로에 대한 전파 환경 변수로 사용되었다. 또한, 도로와 송신안테나 간의 거리는 도로에 의한 손실 영향을 나타내는 중요한 변수가 되는 동시에 도로 방위각에 따른 영향도 포함하게 되므로 그림 6과 같이 수신지점이 있는 도로에 대한 두개의 도로 선분 벡터와 송신안테나 지점간의 평균거리 d_c 를 구하여 도로에 대한 신경회로망 특징으로 사용한다.

7. 물

강이나 호수와 같은 수표면 위를 통과할 때의 전파손실은 이론적으로 자유공간상에서의 손실과 같다. 또한 대부분의 전파과정이 지표면위에서 발생하기 때문에 수표면으로 인한 상승효과를 신경회로망의 입력에 적용하기 위해서는 지표면을 통

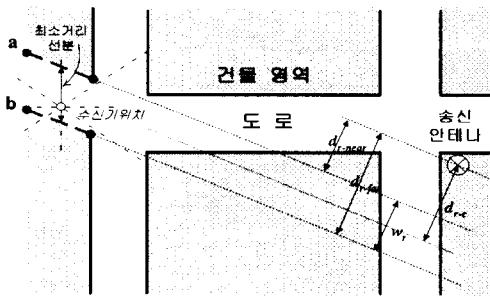


그림 6. 도로 벡터와 기지국과의 거리

Fig. 6. Distance between road vector and base station.

과하는 경우와 분리해야 하며, 수표면에 의한 영향력을 학습을 통해 적용된다. 이를 허리스틱한 수치로 정량화하기 위하여 전파 경로상에 놓인 물의 넓이 d_w 를 벡터 지도로부터 얻고, 송수신기간의 거리에서 다음과 같이 물의 영향을 제거한다.

$$d_{Tx-Rx} = d_{Tx-Rx} - d_w \quad (11)$$

IV. 실험 및 결과

4-1 실험 방법

신경회로망을 사용한 전파 손실 예측을 위해서는 측정 데이터에 기반한 훈련과정을 통해 모델을 생성하게 된다. 훈련과 예측에 사용되는 모든 신경회로망 입력데이터는 지형도와 기지국 설정 정보를 기반으로 각 지점에 대한 특징추출 과정을 통해 얻어진 전파 환경 변수들이다. 훈련을 위해서는 수집된 필드 측정 데이터에 대해서 특징추출을 한 후에 이를 무작위로 훈련에 사용할 데이터와 검증에 사용할 데이터로 나눈다. 이렇게 얻어진 훈련 데이터를 사용하여 반복적인 신경회로망 훈련과정을 거치게 되면 허용 오차이내의 성능을 갖는 신경회로망 모델을 얻을 수 있다. 완성된 신경회로망 모델은 입력층, 은닉층, 출력층을 갖는 다층 퍼셉트론 구조를 가지며, 각 뉴런들간에는 훈련에 의해

결정된 연결강도를 가진다. 다음으로 완성된 모델의 성능을 평가하기 위하여 훈련에 사용되지 않은 데이터를 입력으로 사용한 신경회로망의 예측치와 측정치를 비교한다. 실제 훈련 결과를 판단하기 위해서는 반드시 이와 같은 검증 단계를 거쳐야 하며, 이때 만족할만한 성능을 나타내야만 비로써 임의의 지역에 대한 예측시에 우수한 예측능력을 가질 수 있음을 판단할 수 있다. 그리고나서 임의의 지역에 대한 전파손실을 예측할 수 있다.

본 논문에서 제안하는 신경회로망을 이용한 전파 손실 모델은 그림 7과 같이 구성된 다층 퍼셉트론이며, 2개층의 은닉층을 포함하여 전체 4층 구조로 되어 있다. 각 층별로 입력층 8개, 제1은닉층 10개, 제2은닉층 5개, 출력층 1개의 뉴런을 가지고 있으며, 모든 입력 데이터들은 원천 데이터로부터 III절에서 설명한 방법을 이용하여 추출되어진 후 신경회로망의 입력으로 사용된다.

신경회로망의 훈련과 훈련된 모델의 성능 평가를 위한 검증을 위해서 사용되는 측정 데이터는 표 1과 같으며, 서울 도심 지역의 도로상에서 차량 측정을 통해 얻어진 데이터이다. 필드 측정시에 사

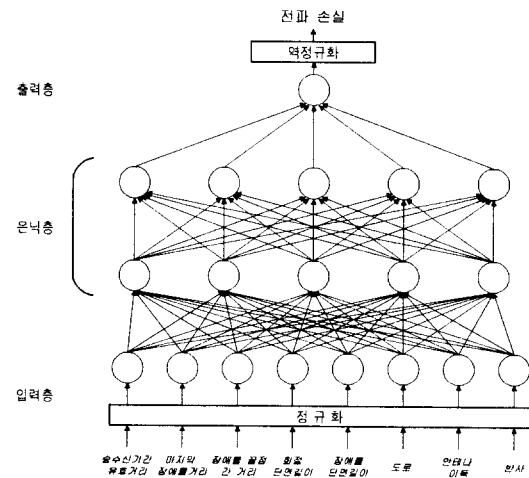


그림 7. 전파 손실 예측을 위한 다층 퍼셉트론 모델

Fig. 7. MLP model for the propagation-loss prediction.

표 1. 훈련과 테스트에 사용된 지역

Table 1. Areas used to training and test.

		훈련						테스트		
지역명		대치	등촌	가락	서울역	을지	합계	잠실	수표	합계
안테나 해발 높이(m)		47	42	42	86	41	-	42	76	-
샘플수	전체	8210	5616	6455	7572	15783	43636	5949	6867	12816
	훈련	1500	1500	1500	1500	1500	6500	-	-	-
	테스트	6710	4116	4955	6072	14283	37136	5949	6867	12816

용된 송신 안테나는 트래픽 밀도가 높은 도심지역에서 주로 사용하는 지향성(directional) 안테나로 최대 이득 11 dB, 수평 범폭 60°이며, 측정시에 설정된 순송신전력은 30 dBm, 주파수는 1.8 GHz이다. 각 기지국에는 각기 다른 방향을 갖는 3개의 섹터 (α , β , γ)가 동시에 존재한다. 차량에는 3 dB 전방향 안테나를 사용하는 수신기와 위치 계측을 위한 GPS 수신기를 동시에 탑재하고 있다.

본 논문에서 제안하는 전파손실 모델링 방법의 우수성을 검증하기 위하여 기존에 잘 알려진 COST-231 Walfish/Ikegami 모델^{[7],[8]}과의 성능을 비교하였다. COST-231 모델은 900~1800 MHz 대역의 도심지 마이크로셀의 전파손실을 계산하기 위한 모델로 전파 손실은 다음과 같이 8개의 파라미터를 갖는 함수로 표현된다.

$$L_p = f'(h_b, h_m, f_c, d, h_r, w, b, \phi) \quad (12)$$

여기서 h_b , f_c , h_m , d 는 II절에서 이미 언급되었고, h_r 은 송수신기간에 있는 건물의 평균 높이, w 는 도로의 넓이, b 는 송수신기간에 있는 건물간의 평균 거리, ϕ 는 도로 벡터와 송신된 전파 직선 경로와의 사이각을 나타낸다. 비교 실험을 위해서 제안하는 신경회로망 모델의 입력 데이터와 COST-231 모델의 파라미터는 같은 조건하에서 추출되었다.

4-2 실험 결과

신경회로망 모델의 훈련을 위하여 표 1에 나열되어 있는 지역 중에서 등촌, 서울역, 을지, 가락, 대치 지역의 필드 측정 데이터 43,636개 중에서 무작위로 6,500개의 데이터를 선택하여 훈련을 하였고, 같은 지역의 데이터 중에 훈련에 사용되지 않은 나머지 데이터를 사용하여 훈련된 모델의 성능을 확인하였다. 그리고, 훈련된 모델의 일반화 성능을 확인하기 위하여 훈련에 포함되지 않은 임의의 지역에 대한 전파손실을 예측하였다. 그림 8과 그림 9는 서울의 임의의 두 지역에서 α -섹터 안테나에 대해 필드 측정된 전파 손실치와 같은 지역에 신경회로망 모델을 적용한 예측치, COST-231 Walfish/Ikegami 모델을 적용한 예측치들을 각각 송신안테나로부터의 거리에 따른 평균 전파 손실치로 도시한 것으로 신경회로망 모델의 경우 두

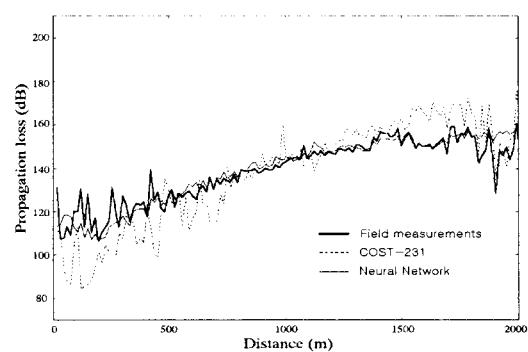


그림 8. 잠실 지역의 필드 측정치와 전파 손실 예측치들과의 비교

Fig. 8. Comparison of predicted propagation-loss by field measurement on Jamsil area.

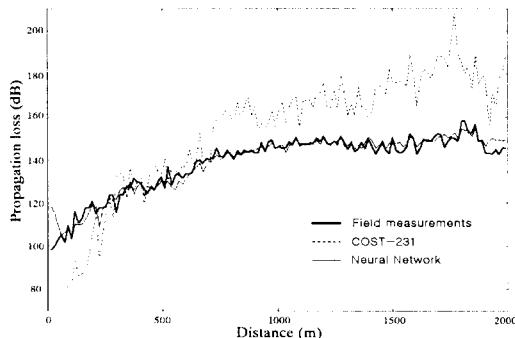


그림 9. 수표 지역의 필드 측정치와 전파 손실 예측치들과의 비교

Fig. 9. Comparison of predicted propagation-loss by field measurement on Supyo area.

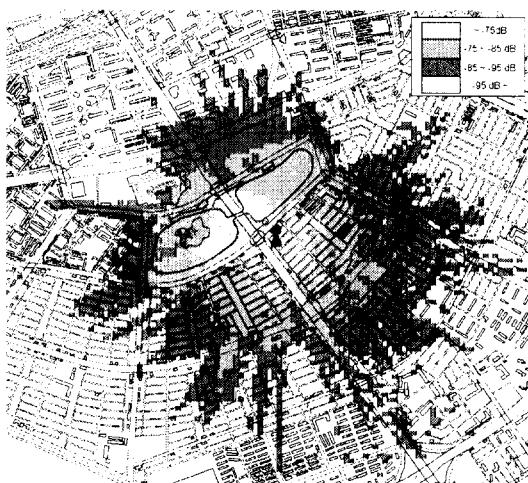


그림 10. 잠실 지역의 전계 강도 분포의 예측결과
Fig. 10. Prediction result of received signal strength distribution on Jamsil area.

표 2. 각 모델별 예측 성능의 비교

Table 2. Performance of propagation-loss prediction for each model.

지 역		잠 실			수 표		
센 터		α	β	γ	α	β	γ
테스트 데이터수	1983	1983	1983	1983	2292	2292	2283
예측성능(MSE) [dB]	COST-231 모델	450.8	351.8	357.9	819.7	896.2	1003.2
	평균			386.8	평균		906.5
	신경회로망 모델	88.2	86.8	110.2	79.9	80.7	74.8
	평균			95.1	평균		77.5

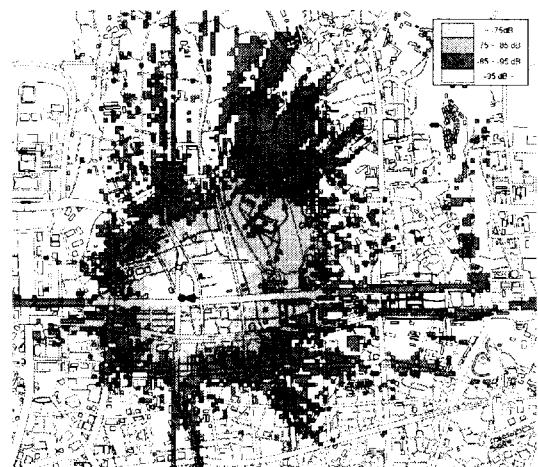


그림 11. 수표 지역의 전계 강도 분포의 예측결과

Fig. 11. Prediction result of received signal strength distribution on Supyo area.

지역 모두에서 거리에 상관없이 측정데이터와 거의 유사한 전파손실 예측결과를 얻을 수 있음을 알 수 있다. 표 2는 두 지역에 대한 예측성능을 필드측정치와 예측치간의 평균제곱오차(mean-squared error, MSE)로 나타낸 것이다.

$$E_{MSE} = \frac{1}{N} \sum_{i=1}^N (L_p(i) - L_{p,net}(i))^2 \quad (13)$$

여기서 N 은 예측지점의 개수이고, $L_p(i)$, $L_{p,net}(i)$ 는 각각 i 번째 예측지점에 대한 필드측정치와 신경회로망 예측치를 나타낸다.

잠실지역에 대한 신경회로망 모델의 평균 예측

성능은 95.1 dB이고, COST-231 모델의 평균 예측 성능은 386.8 dB이다. 수표지역의 경우는 각각 77.5 dB, 906.5 dB로 제안하는 모델이 월등히 우수한 예측 결과를 나타내었다. 또한, 그림 10과 그림 11는 제안하는 모델을 사용하여 송신안테나 주변 전지역에 대한 전파손실을 예측하고, 이를 전계강도의 크기에 따라 색깔로 도시한 것이다.

V. 결 론

무선통신의 매체로 사용되는 전파의 전파현상은 송신안테나 주변의 지형지물에 의해 반사, 회절, 산란의 영향을 받아 복잡한 비선형적인 특성을 갖게 되고, 이로 인해 정확한 모델링에 어려움이 많다. 본 논문에서는 서울 시내 지역과 같이 도심지의 복잡한 지형 조건을 갖는 마이크로셀에서도 전파 손실을 정확히 예측하기 위한 신경회로망 모델링 방법을 제안하였고, 전파전파 현상의 물리적 특성이 직접적으로 고려되도록 3차원 지형 데이터와 벡터데이터 그리고 기지국 설치 파라미터를 이용하여 신경회로망의 입력 데이터를 추출하는 방법을 소개하였다. 또한, 실제 도심 전파 환경에서 얻어진 필드 측정 데이터를 이용하여 신경회로망을 학습시킨후 훈련에 포함되지 않은 임의의 지역에 대한 예측을 통해 제안된 신경회로망 모델이 복잡한 전파 환경에서도 전파전파에 영향을 주는 정량적인 변수들을 사용하여 정확한 전파손실 예측과 다양한 환경에 대한 적응성을 가질 수 있음을 보였다. 제안된 신경회로망 모델을 사용함으로써 단순한 지형을 가정으로 한 기준의 전파 손실 모델의 단점인 예측의 부정확성과 다양한 환경에 대한 부적응을 극복하였다.

참 고 문 헌

- [1] K. Bullington, "Radio propagation for vehicular communications", *IEEE Trans. Veh. Technol.*, vol. VT-26, no. 4, pp. 295-308, Nov. 1977.
- [2] Y. Okumura et al., "Field strength and its variability in VHF and UHF land-mobile radio service", *Rev. Elec. Commun. Lab.*, vol. 16, pp. 825-873, Sept.-Oct. 1968.
- [3] M. Hata, "Empirical formula for propagation loss in land mobile radio services", *IEEE Trans. Veh. Technol.*, vol. VT-29, no. 3, pp. 317-325, Aug. 1980.
- [4] K. R. Schaubach, N. H. Davis, T. S. Rapaport, "A ray tracing method for predicting path loss and delay spread in micro-cellular environments", *IEEE 42nd Veh. Technol. Conf.*, vol. 2, pp. 993-935, May 1992.
- [5] M. C. Lawton, J. P. McGeehan, "The application of deterministic ray launching algorithm for the prediction of radio channel characteristics in small-cell environments", *IEEE Trans. on Veh. Technol.*, vol. 43, no. 4, Nov. 1994.
- [6] J. B. Keller, "Geometrical theory of diffraction." *Journal of the Optical Society of America*, vol. 52, no. 2, pp. 116-130, Feb. 1962.
- [7] J. Walfish and H. L. Bertoni, "A theoretical model of UHF propagation in urban environments." *IEEE Trans. Antennas and Prop.*, vol. 36, pp. 1788-1796, Dec. 1988.
- [8] F. Ikegami, T. Takeuchi, and S. Yoshida., "Theoretical prediction of mean field strength for urban mobile radio." *IEEE Trans. Antennas and Prop.*, vol. 39, pp. 299-302, Mar. 1991.
- [9] T. Kurner, D. J. Cichon, W. Wiesbeck, "Concepts and results for 3D digital terrain-

- based wave propagation models: an overview", *IEEE Journal on Selected Area in Communications*, vol. 11, no. 7, Sep. 1993.
- [10] K. E. Stocker et al., "Neural network approach to prediction of terrestrial wave propagation for mobile radio," *IEE Proc. H*, vol. 140, no. 4, pp. 315-320, Aug. 1993.
- [11] P. R. Chang and W. H. Yang, "Environment-adaptation mobile radio propagation prediction using radial basis function neural
- networks," *IEEE Trans. Veh. Technol.*, vol. 46, no. 1, pp. 155-160, Feb. 1997.
- [12] K. Hornick, M. Stinchcombe, H. White, "Multi-layer feedforward networks are universal approximators", *Neural Networks*, 2:359-366, 1989.
- [13] D. E. Rumelhart, G. E. Hinton, and R. J. Williams, *Parallel Distributed Processing*, MIT Press, pp. 318-362, 1986.

양 서 민



1997년 2월: 광운대학교 컴퓨터공학
과(공학사)
1999년 2월: 광운대학교 컴퓨터공학
과(공학석사)
1999년 3월~현재: 광운대학교 컴퓨
터공학과(박사과정)
[주 관심분야] 신경회로망, 분산컴
퓨팅, 이동컴퓨팅

이 혁 준



1987년 8월: University of Michi-
gan, Computer Science(공학사)
1989년 6월: Syracuse University,
Computer Science(공학석사)
1993년 12월: Syracuse University,
Computer Science(공학박사)
1994년 3월~1996년 2월: 삼성전자
멀티미디어 연구소 선임연구원
1996년 3월~현재: 광운대학교 컴퓨터공학과 조교수
[주 관심분야] 신경회로망, 분산컴퓨팅, 이동컴퓨팅, 컴
퓨터그래픽스