

深度神经网络指导下的无线覆盖预测算法*

沈林之, 王少尉

(南京大学 电子科学与工程学院, 江苏 南京 210023)

摘要: 为保证新一代移动无线网络能够根据实时覆盖情况动态地调节小区天线参数, 需要实现高效且准确的无线覆盖预测。传统的求解方法通过精确的场强预测判断天线参数的优劣, 虽然精度很高但需要大量的计算资源, 无法满足 5G 和后 5G 移动网络通过实时覆盖预测进行射频参数动态调整的实际需求。现采用基于深度神经网络的算法对给定天线参数的覆盖效果进行预测, 以取代对目标区域的精确场强预测。数值结果表明: 该方法能够在保持计算准确性的同时显著减少计算量, 为 5G 动态网络规划提供基础性参考数据。

关键词: 动态网络规划; 无线覆盖; 场强预测; 深度神经网络

中图分类号: TN92 文献标志码: A 开放科学(资源服务)标识码(OSID):

文章编号: 1001-2486(2020)04-018-06



听语音
与作者互动
聊科研

Wireless coverage prediction algorithm under the guidance of deep neural network

SHEN Linzhi, WANG Shaowei

(School of Electronic Science and Engineering, Nanjing University, Nanjing 210023, China)

Abstract: In order to adjust the parameters of cell antennas dynamically according to the real-time coverage in the new generation mobile wireless network, it is necessary to predict the wireless coverage efficiently and accurately. The traditional solution method is to judge the antenna parameters by accurate field strength prediction in the target area. The method is accurate but wastes large amounts of computing resources, which cannot meet the actual needs of 5G and beyond 5G mobile networks to dynamically adjust the radio frequency parameters through real-time coverage prediction. Here the algorithm based on deep neural network was proposed to predict the coverage under given antenna parameters in order to replace the accurate field strength prediction of the target area. Numerical results show that the algorithm can keep the accuracy of the calculation while significantly reducing the computing resources, which provides basic reference data for 5G dynamic network planning.

Keywords: dynamic network planning; wireless prediction; field strength prediction; deep neural network

网络规划问题^[1]通常可以规约为一个混合整形规划问题, 这类问题的复杂度会随着问题规模的扩大而急剧增大。随着第五代移动通信技术(5th Generation wireless systems, 5G)的发展, 为满足日益增长的流量需求, 基站设备的数目爆炸式增长^[2], 给实际移动网络的基站部署带来了极大的挑战。

作为网络规划问题的核心子问题, 无线覆盖预测的效率直接影响了网络规划的结果。由于实际天线的各向异性, 要想准确地判断天线对于给定区域的覆盖情况, 传统的做法是建立复杂的无线覆盖模型并对目标区域各位置进行场强计算, 需要大量的计算资源。但在实际网络规划时, 通常只关心整体覆盖情况而非各位置的具体覆盖情

况, 这就造成了大量计算资源的无谓消耗。

近年来, 深度神经网络(Deep Neural Network, DNN)得到了快速发展, 在图像识别和自然语言处理方面已达到统治地位, 且正在逐步渗入其他领域的识别和预测问题^[3]。DNN 能够从海量数据中归纳和总结关键信息, 并通过这些关键信息指导计算机的判断或预测。著名的 AlphaGo^[4]便是通过 DNN 指导计算机判断围棋棋盘的局势, 并依此采取相应对策, 最终通过不断的迭代更新击败了众多职业围棋选手。

本文阐明利用 DNN 预测实际天线整体覆盖的意义, 分析 DNN 预测的可行性, 并选择合适的 DNN 模型参数进行无线覆盖的预测。实验结果

* 收稿日期: 2019-12-25

基金项目: 国家自然科学基金资助项目(61671233, 61801208, 61931023)

作者简介: 沈林之(1995—), 男, 江苏无锡人, 博士研究生, E-mail: 141180100@smail.nju.edu.cn;

王少尉(通信作者), 男, 教授, 博士, 博士生导师, E-mail: wangsw@nju.edu.cn

表明:DNN训练完成后,给定区域信息即可快速获得该区域的整体覆盖情况而无须对区域进行遍历计算,大幅度节约了计算资源,加快了规划速度,为动态的网络规划^[5-6]提供基础性参考数据。

1 无线覆盖场景

1.1 场强预测模型

场强预测是移动无线网络中的重要问题。在实际移动通信系统进行天线部署时受路测条件和成本约束的限制,不可能对目标区域的场强进行大规模的实地测量,需要建立合理的场强预测模型。目前主要的场强预测模型包括统计模型、射线跟踪模型和基于神经网络的模型。

统计模型利用经验的场强测试信息,采用统计学方法拟合出场强关于收发端距离、基站高度、信号频率等参数的方程,Okumura-Hata模型^[7]是其典型代表。统计模型凭借其简易性成为目前最常用的场强预测模型,但由于实际环境中一些影响场强的因素难以通过简单的数学形式有效表示,模型的精度难以得到保证。实际工程中通常把目标区域划分为若干子区域,对每个子区域分别采用统计模型进行预测,以提升预测准确性。子区域划分越细致,场强预测精度越高,但模型复杂度也就越大,且其精度有上限。

射线跟踪模型利用电磁波传播理论,考虑反射、折射等现象,分析电磁波从发射端到接收端经过的实际路径,并通过多条路径的叠加计算出接收端的场强信息。文献[8]和文献[9]分别采用射线跟踪模型,利用正向和反向的算法实现小区域三维空间中场强的精确预测。与统计模型相比,该模型更加贴合实际场景中的电磁波传播方式,预测精度可以达到很高。但对于目标区域中的每一点,射线跟踪模型都要求计算出发射端到该点的路径,而密集城市网络中的电磁波传播路径通常很复杂,因此该模型的复杂度要远远超出统计模型,很难运用在大规模的覆盖区域场景中。

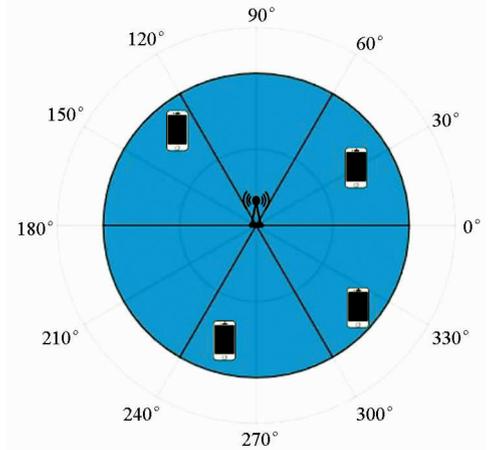
随着计算机性能不断提升,机器学习的算法逐步显示出用武之地,其中神经网络(Neural Network, NN)作为一种泛化性能很强的拟合工具开始在各个领域发挥用途。NN利用采集到的大量场强信息直接进行拟合,同样可以对场强进行预测,且摆脱了统计模型对于场强函数的刻画,也不需要电磁波传播路径有细致的认识。文献[10]和文献[11]分别采用前馈神经网络和模块化神经网络解决场强预测问题,均取得了不错

的效果。但由于数据获取十分困难,该方法的研究还有待进一步深入。

1.2 无线覆盖模型

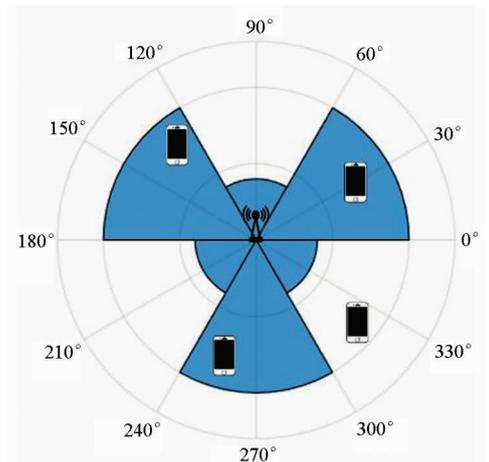
由于电磁波在传播过程中会经历多次衰落,信号从基站端天线发出后经过一段距离便不再能维持足够高的场强,无法为用户提供有效的服务。无线覆盖问题指的是在给定天线参数和目标区域的条件下判断天线有效服务的区域范围,因此需要对目标区域进行场强预测,并根据设定的阈值判断天线是否能够覆盖指定位置,场强超过阈值的区域即为有效覆盖区域^[12]。

传统的无线覆盖问题为简化计算,通常假设天线为全向天线,即天线对各个方向上的增益相同,如图1(a)所示。该简化虽然高效但无法准确判断天线真实的覆盖效果。实际问题中天线常呈现各向异性^[13],主瓣方向上的增益较大,旁瓣方向上的增益较小,如图1(b)所示。故对于无线覆



(a) 全向天线

(a) Omnidirectional antennas



(b) 实际天线

(b) Actual antennas

图1 天线覆盖情况

Fig. 1 Antenna coverage

盖问题,除了对天线的位置进行规划,还需要对天线的主瓣方向进行规划。

为判断实际天线在不同主瓣方向下覆盖的优劣,传统的做法是在给定天线位置和主瓣方向的条件下对指定区域进行精确的场强预测(如采用精度较高的统计模型或射线跟踪模型)并对有效覆盖区域进行统计,最后比较不同主瓣方向下的覆盖率。该方法保证了对于无线覆盖情况判断的准确性,使得天线能够选择合理的部署方式,最大化利用空域上的频带资源,有效增加网络吞吐量。

2 无线覆盖高效预测工具——DNN

上述判断实际无线覆盖优劣的算法,虽然保证了对无线覆盖情况判断的准确性,但在精确求解场强上浪费了大量的计算资源,这是因为无线覆盖问题最后的关注点只是不同主瓣方向下目标区域覆盖情况的优劣,而非该区域被覆盖的具体情况。

随着计算机技术的发展,DNN 在预测领域得到广泛应用。AlphaGo 中利用 DNN 搭建策略网络和价值网络,对棋盘不断学习,通过策略网络识别不同棋盘局势下的落子倾向,通过价值网络归纳总结出不同棋盘局势下特定落子方式带来的胜率,并借助这两张网络指导计算机落子,实现计算机棋力的提升。

受 AlphaGo 中价值网络的启发,认为可以采用深度神经网络拟合上述过程,在给定天线位置和主瓣方向的基础上通过深度神经网络直接获得覆盖率。神经网络训练完成后,可以省略场强预测和有效覆盖区域统计过程,减少大量计算。

2.1 DNN 原理

不同于单纯增加隐藏层层数的传统神经网络,DNN 通过模块化的方式不断堆叠。目前处理图像问题最常用的 DNN 架构是卷积神经网络(Convolutional Neural Network, CNN)^[14],它具有强大的拟合能力,能够从矩阵中提取数据在空间域上的关联信息。CNN 架构由多个模块构成,包括输入层、归一化层、卷积层、池化层、激活层、全连接层和输出层。其中,输入层负责导入数据,在图像处理问题中数据通常是三维矩阵;归一化层负责将数据转化为 0 到 1 之间的值,使梯度维持在一个合理的区间,避免出现梯度爆炸或梯度消失的现象;卷积层负责通过卷积核提取数据之间的关联信息,具体过程可参考文献[14],实际问题往往具有多个特征,需要使用多个卷积核分别进行提取;池化层负责压缩提取到的特征信息,减

少多层网络带来的冗余信息量;激活层负责判断提取到的特征信息是否有效,常用的激活函数有 softmax 函数、tanh 函数以及线性整流(Rectified Linear Unit, ReLU)函数;全连接层负责进一步抽象特征信息,同时将特征信息映射到输出样本空间;输出层负责导出数据,对于分类问题,导出样本最有可能对应的类,对于回归问题,导出样本在输出空间对应的映射。

在实际训练过程中,数据由输入层导入,通过归一化层处理成标准变量,然后采用卷积层、激活层和池化层对特征信息进行提取和压缩,重复多次后利用全连接层将特征映射到输出样本空间,实现了输入数据与输出数据的关联。若 CNN 提取到的特征能够真实反映样本的实际特征,则 CNN 能将输入样本准确地映射到输出样本。在该网络架构中,提取特征的层数越多,最终得到的特征越抽象,越能提取深层次信息,但相应地,网络训练难度越高。

2.2 利用 DNN 求解无线覆盖问题

利用 DNN 求解无线覆盖问题,需要确认无线覆盖问题的输入输出。对于输入,首先需要知道目标区域的地形信息和建筑物信息,以确认发射端到接收端的传播路径。考虑到实际环境中一块区域往往由多个基站多根天线协同服务,该区域已有的覆盖情况也要作为输入。由于天线具有各向异性,天线的方向角同样影响覆盖。综上,输入数据为目标区域的地形信息、建筑物信息、已有覆盖情况和天线方向角信息。本文考虑密集部署小区场景,在该场景下天线密度很高,每根天线的辐射范围较小。现假设天线只影响附近 400 m 范围的区域,为精确描述区域信息,将目标区域划分为若干 5 m × 5 m 的栅格,通过地形信息、建筑物信息和已有覆盖信息刻画每个栅格区域内的统计特征,则目标区域的地形信息、建筑物信息、已有覆盖信息均可表示为 161 × 161 的二维矩阵,而方向角信息可以表示为一个 0 到 360 的实数,故输入信息可以看成一个 161 × 161 × 4 的三维矩阵。对于输出,无线覆盖问题关心的是整体的覆盖效果,因此将整体覆盖率作为输出,它是一个 0 到 1 的实数。这样 DNN 实际是在求解一个输入为 161 × 161 × 4 的矩阵、输出为连续变量的回归问题。

明确定义输入输出后应采用合适的网络架构进行训练。AlexNet 架构^[15]是 CNN 最成功的代表之一,它有效提取了图片数据中的关联信息。相比其他深度网络架构,AlexNet 的框架简洁,需要训练的网络参数较少,各模块功能明确,易于调

整。本文基于 AlexNet 搭建深度网络,结构如图 2 所示。输入数据归一化后利用 96 个大小为 11×11 的卷积核以 4 为步长提取特征,并以 2 为步长进行池化。将信息归一化后再利用 256 个 5×5 的卷积核以 1 为步长提取特征并池化。接着通过三层连续的卷积激活层对深度特征信息进行进一步提取和池化。最后采用两层包含 1024 个结点的全连接层对提取到的特征进行进一步抽象和映射,并通过包含单一结点的全连接层确认回归值。网络搭建完成后便可以用反向传播^[16]的方式进行训练。

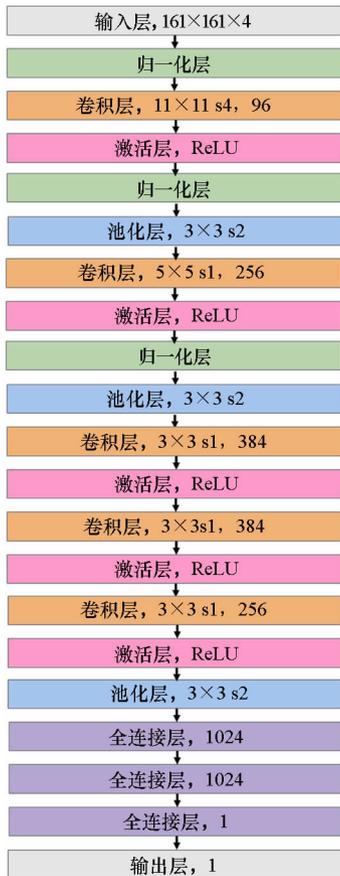


图 2 基于 AlexNet 的深度网络
Fig. 2 DNN based on AlexNet

3 神经网络训练结果

在实际训练中,需要对网络的超参数进行设置。由于 DNN 训练过程实际上是一个最优化损失函数的过程,梯度下降算法^[17]是求解该类优化问题的有效方法,因此梯度下降速率即学习速率的设置对网络性能会起到很大的影响,是一个重要的超参数。同时,DNN 中输入数据规模较大,而计算机存储空间有限,故在实际训练中需要将输入数据划分为若干个小块,逐小块进行处理(该过程也被称为批处理),小块的规模

(batchsize)同样是一个超参数。此外超参数还包含初始参数设置、学习轮次(epoch)、梯度下降方式等^[15]。

在过去关于 DNN 的研究工作中,学习速率对于网络性能的影响最大,故本文主要研究学习速率对于 DNN 性能的影响。地图信息取自我国某大省省会城市,包含 2500 km^2 的区域,目标区域被划分成若干 $5 \text{ m} \times 5 \text{ m}$ 的栅格,每个栅格包含地形信息和建筑物信息,同时站址位置被标记在地图中,数据集通过从地图信息中选择指定区域获得。实验时从数据集中抽取 10 000 例样本,其中 9000 例作为训练集,500 例作为验证集,500 例作为测试集。为研究学习速率对网络性能的影响,学习速率从 $[1\text{E}-7, 1\text{E}-3]$ 范围内选取。考虑到计算机内存性能,批的规模设定为 64。为使 DNN 能够充分学习训练集数据,将学习轮次设置为 60,即每个样本被网络训练 60 次。为避免梯度下降快速陷入局部最优,采用随机梯度下降(Stochastic Gradient Descent, SGD)算法^[18],同时场强的有效覆盖阈值设为 -95 dBm 。训练过程中利用 dropout 方法^[19]改善过拟合问题。仿真参数设置见表 1。

表 1 仿真参数设置

Tab. 1 Simulation parameter setting	
参数名称	属性或数值
样本数目	10 000
学习速率	$[1\text{E}-7, 1\text{E}-3]$
批规模	64
学习轮次	60
梯度下降方式	SGD
有效覆盖阈值/dBm	-95
过拟合优化方法	dropout

仿真结果如图 3 所示,横坐标表示 DNN 的学习速率,纵坐标表示验证集样本通过神经网络求得的天线有效覆盖率与实际天线有效覆盖率的误差,用归一化后的均方根误差(Root Mean Square Error, RMSE)表示。这里认为通过复杂无线覆盖模型得出的有效覆盖率能够精确表征实际天线的有效覆盖率。从图中可以看出,当学习速率较低时,网络在有限的时间内无法有效学习,误差较大。随着学习速率的升高,网络在有限时间内的学习能力不断增强,网络的性能不断提升。当学习速率达到 $1\text{E}-5$ 后,网络在指定时间内能有效

学习到样本的特征,网络性能趋于稳定。当学习速率达到 $3E-4$ 后,随着学习速率的增加,下降的梯度对于样本空间来说愈发庞大,梯度爆炸现象开始出现,网络性能开始下降。事实上,当学习速率超过 $3E-3$,网络参数经过若干轮学习后逐步发散, RMSE 趋于无穷。

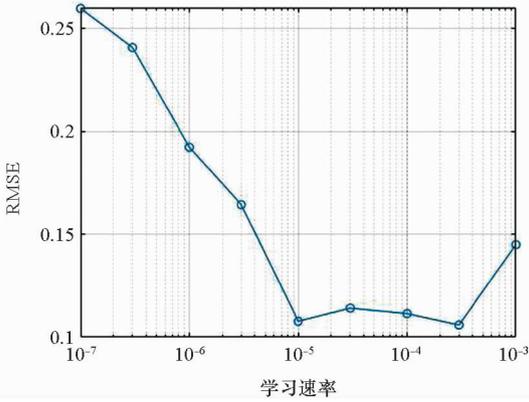
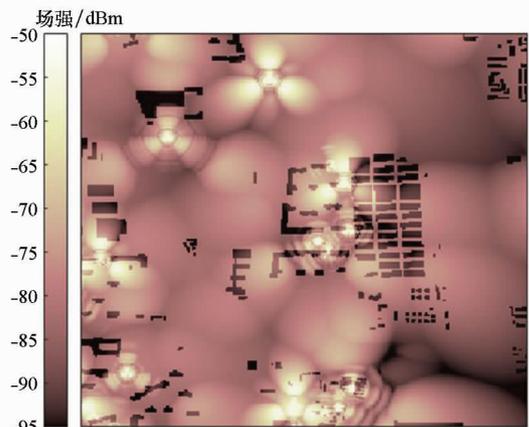


图 3 不同学习速率下的网络性能

Fig. 3 Network performance at different learning rates

基于 DNN 的无线覆盖预测算法与传统预测算法的平均计算时间分别为 $2.24E-3$ s 和 $7.03E-2$ s。DNN 的计算量分为训练阶段和测试阶段,其中训练阶段需要消耗大量的计算资源,但可以作为前置工作,故不计入计算量的比较中。由于训练阶段的学习速率不影响测试阶段的计算量比较,故取学习速率为 $1E-5$ 时的预测算法与传统算法进行比较。可以看到,当网络训练完成后,利用 DNN 预测的速率能够达到传统方法的 30 倍以上,极大提升了整体无线覆盖的预测效率。

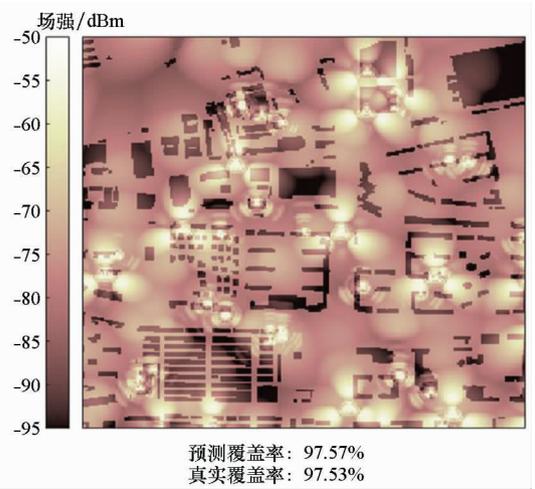
图 4 表示当网络性能稳定(学习速率为 $1E-5$)时网络预测的结果和实际无线覆盖情况的比较。图中天线到目标区域各位置场强的大小用亮度区分,亮度越高表示场强越大。可以看到,虽然



预测覆盖率: 93.91%
真实覆盖率: 94.07%

(a) 测试集样本 1

(a) Sample 1 in test set



预测覆盖率: 97.57%
真实覆盖率: 97.53%

(b) 测试集样本 2

(b) Sample 2 in test set

图 4 测试集样本训练结果

Fig. 4 Training results of samples in test set

深度网络不清楚具体的覆盖情况,但它通过数据之间的关联信息准确地拟合出了整体覆盖率。

4 结论

本文采用深度神经网络预测指定天线参数在目标区域下的覆盖,不需要复杂的场强预测算法,从而节约了大量计算资源,为移动通信网络动态规划和优化提供了新的思路和方法。

参考文献 (References)

- [1] Zhao W T, Wang S W, Wang C G, et al. Cell planning for heterogeneous networks: an approximation algorithm [C]// Proceedings of Conference on Computer Communications, 2014: 1087 - 1095.
- [2] Muñoz P, Sallent O, Pérezromero J. Self-dimensioning and planning of small cell capacity in multi-tenant 5G networks [J]. IEEE Transactions on Vehicular Technology, 2018, 67(5): 4552 - 4564.
- [3] Taigman Y, Yang M, Ranzato M A, et al. Deepface: closing the gap to human-level performance in face verification [C]// Proceedings of Computer Vision and Pattern Recognition, 2014: 1701 - 1708.
- [4] Silver D, Huang A, Maddison C J, et al. Mastering the game of Go with deep neural networks and tree search [J]. Nature, 2016, 529(7587): 484 - 489.
- [5] Shen Q, Ma Z, Wang S W. Deploying C-RAN in cellular radio networks: an efficient way to meet future traffic demands [J]. IEEE Transactions on Vehicular Technology, 2018, 67(8): 7887 - 7891.
- [6] Xu S, Wang S W. Baseband unit pool planning for cloud radio access networks: an approximation algorithm [J]. IEEE Communications Letters, 2017, 21(2): 358 - 361.
- [7] Hata M. Empirical formula for propagation loss in land mobile radio services [J]. IEEE Transactions on Vehicular Technology, 1980, 29(3): 317 - 325.

- [8] Catedra M F, Perez J, de Adana F S, et al. Efficient ray-tracing techniques for three-dimensional analyses of propagation in mobile communications: application to picocell and microcell scenarios [J]. *IEEE Antennas and Propagation Magazine*, 1998, 40(2): 15–28.
- [9] 周力, 毛钧杰, 柴舜连. 基于三维射线跟踪的城市微小区电波传播预测算法 [J]. *电子学报*, 2002, 30(3): 434–436.
ZHOU Li, MAO Junjie, CHAI Shunlian. A method based on 3-D ray tracing for propagation prediction in microcellular environment [J]. *Acta Electronica Sinica*, 2002, 30(3): 434–436. (in Chinese)
- [10] Ostlin E, Zepernick H, Suzuki H. Macrocell path-loss prediction using artificial neural networks [J]. *IEEE Transactions on Vehicular Technology*, 2010, 59(6): 2735–2747.
- [11] 杨晋生, 李亚洲. 一种基于模块化神经网络的场强预测方法 [J]. *小型微型计算机系统*, 2017, 38(11): 2423–2426.
YANG Jinsheng, LI Yazhou. Field strength prediction based on modular neural network [J]. *Journal of Chinese Computer Systems*, 2017, 38(11): 2423–2426. (in Chinese)
- [12] Chandrasekhar V, Kountouris M, Andrews J G. Coverage in multi-antenna two-tier networks [J]. *IEEE Transactions on Wireless Communications*, 2009, 8(10): 5314–5327.
- [13] Zhang S, Chen X M, Strytsin I, et al. A planar switchable 3-D-coverage phased array antenna and its user effects for 28-GHz mobile terminal applications [J]. *IEEE Transactions on Antennas and Propagation*, 2017, 65(12): 6413–6421.
- [14] Zeiler M D, Fergus R. Visualizing and understanding convolutional networks [C]//*Proceedings of European Conference on Computer Vision*, 2014: 818–833.
- [15] Krizhevsky A, Sutskever I, Hinton G E. ImageNet classification with deep convolutional neural networks [J]. *Advances in Neural Information Processing Systems*, 2012: 1097–1105.
- [16] Rumelhart D E, Hinton G E, Williams R J. Learning representations by back propagating errors [J]. *Nature*, 1986, 323(6088): 533–536.
- [17] Lecun Y, Bottou L, Bengio Y, et al. Gradient-based learning applied to document recognition [J]. *Proceedings of the IEEE*, 1998, 86(11): 2278–2324.
- [18] Gemulla R, Nijkamp E, Haas P J, et al. Large-scale matrix factorization with distributed stochastic gradient descent [C]//*Proceedings of the 17th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, 2011.
- [19] Hinton G E, Srivastava N, Krizhevsky A, et al. Improving neural networks by preventing co-adaptation of feature detectors [J]. *arXiv: Neural and Evolutionary Computing*, 2012.