



(12) 发明专利

(10) 授权公告号 CN 112073106 B

(45) 授权公告日 2022.04.22

(21) 申请号 202010820340.4

(22) 申请日 2020.08.14

(65) 同一申请的已公布的文献号  
申请公布号 CN 112073106 A

(43) 申请公布日 2020.12.11

(73) 专利权人 清华大学  
地址 100084 北京市海淀区双清路30号清  
华大学

专利权人 深圳市海思半导体有限公司

(72) 发明人 高飞飞 卞程泓 张涛 钱婧  
汪浩 杨玉雯

(74) 专利代理机构 北京路浩知识产权代理有限  
公司 11002

代理人 马瑞

(51) Int.Cl.

H04B 7/06 (2006.01)

H04B 7/08 (2006.01)

H04B 17/391 (2015.01)

(56) 对比文件

CN 107743103 A, 2018.02.27

CN 107148759 A, 2017.09.08

US 2011014865 A1, 2011.01.20

CN 109379122 A, 2019.02.22

CN 111245493 A, 2020.06.05

CN 111460606 A, 2020.07.28

Muhammad Alrabeiah等. "Deep Learning for mmWave Beam and Blockage Prediction Using Sub-6 GHz Channels".《IEEE Transactions on Communications》.2020,

审查员 王鑫

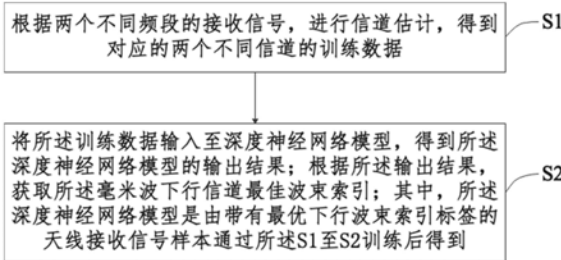
权利要求书4页 说明书12页 附图5页

(54) 发明名称

毫米波波束预测方法及装置、电子设备、可读存储介质

(57) 摘要

本发明实施例提供一种毫米波波束预测方法,包括:根据两个不同频段的接收信号,进行信道估计,得到对应的两个不同信道的训练数据;将所述训练数据输入至神经网络模型,得到所述神经网络模型的输出结果;根据所述输出结果,获取所述毫米波下行信道最佳波束索引;其中,所述神经网络模型是由带有最优下行波束索引标签的天线接收信号样本训练后得到。本发明实施例提供的神经网络模型能够输出预测结果,从而实现快速而准确的下行信道最佳波束检测;训练好的神经网络能够实现高效率、高精度和高鲁棒性的预测,并且与现有技术中的方法相比具有更高的准确度。



1. 一种毫米波波束预测方法,其特征在于,包括:

S1:根据两个不同频段的接收信号,进行信道估计,得到对应的两个不同信道的训练数据;

S2:将所述训练数据输入至深度神经网络模型,得到所述深度神经网络模型的输出结果;根据所述输出结果,获取所述毫米波下行信道最佳波束索引;

其中,神经网络有三个子网络,分别为sub6网络,mmw网络以及classify网络,将两个不同信道向量输入深度神经网络模型的处理流程通过如下方法实现:所述深度神经网络模型是由带有最优下行波束索引标签的天线接收信号样本通过所述S1至S2训练后得到,利用预设损失函数根据样本神经网络预测的分类向量,与样本计算出的真实最佳波束索引标签计算损失值;持续训练一直到损失值收敛,此时训练结束;

将两个不同信道向量输入深度神经网络模型的处理流程通过如下方法实现:

将sub-6GHz与毫米波频段训练向量同时分别输入至sub6网络与mmw网络,利用每一隐藏层和所述隐藏层对应的激活函数,输出经隐藏层后的特征向量;对于sub6网络,深度神经网络总共有 $L_s$ 层,对于毫米波训练数据,深度神经网络总共有 $L_m$ 层;

对于mmw网络,毫米波训练数据经过 $L_m$ 层隐藏层的输出表示为:

$$F_m = NET_m(\mathbf{h}_m, \mathbf{\Omega}_m) = f_m^{L_m-1}(\dots f_m^1(\mathbf{h}_m))$$

其中,  $\mathbf{\Omega}_m = \left\{ \mathbf{W}_m^{(l_m)}, \mathbf{b}_m^{(l_m)} \right\}_{l_m=1}^{L_m}$  是mmw网络需要训练的参数,  $NET_m$  是mmw网络的输出,

$f_m^l$  是第 $l$ 层的非线性转换函数,其表达式为:

$$f_m^l(\mathbf{h}_m) = g(\mathbf{W}_m^l * B_N(\mathbf{h}_m) + \mathbf{b}_m^l) \quad l = 1, 2, \dots, L_m$$

其中,  $\mathbf{W}_m^{(l)}$ ,  $\mathbf{b}_m^{(l)}$ ,  $g^{(1)}$ ,  $B_N(\cdot)$  分别是对应层的权重矩阵,偏置参数,非线性激活函数以及归一化层;对于隐藏层,激活函数是ReLu函数,即  $[g(z)]_p = \max\{0, z_p\}$ , 其中  $z_p$  表示向量 $z$ 的第 $p$ 个元素,  $p=1, 2, \dots, \text{len}(z)$  且  $\text{len}(z)$  代表向量 $z$ 的长度;

将经隐藏层后的两个特征向量进行特征融合:

$$\tilde{\mathbf{x}} = F_s(\mathbf{h}_s) \oplus F_m(\mathbf{h}_m)$$

其中 $F_s(\mathbf{h}_s)$  对应sub-6GHz训练数据经过sub6网络输出的特征向量,  $F_m(\mathbf{h}_m)$  为毫米波训练数据经过mmw网络后输出的特征向量,  $\oplus$  为连接函数,  $\tilde{\mathbf{x}}$  为融合的特征向量;得到的 $\tilde{\mathbf{x}}$  再经过classify网络的前 $L_c$ 层隐藏层之后得到向量 $z$ ,并输入至classify网络的Softmax层,输出长度为码本大小数的分类向量 $p$ ,根据分类向量,确定下行信道最优波束的索引;

所述深度神经网络模型包括至少一个具有相同内部结构的学习单元,所述学习单元包括预设层数的隐藏,且每两个隐藏间包括复数种计算单元,网络结构为各计算单元的相对权重,并采用参数化的变分分布建模所述网络结构。

2. 根据权利要求1所述的毫米波波束预测方法,其特征在于,所述S1中的根据两个不同频段的接收信号,进行信道估计具体包括:

根据基站sub-6GHz天线接收的由用户发送的sub-6GHz信号,通过最小二乘法估计出

sub-6GHz频段子载波上的sub-6GHz信道,其中,所述用户在sub-6GHz频段上所有子载波上均放置导频;

根据基站毫米波天线接收的由用户发送的上行毫米波信号,通过最小二乘法估计出毫米波频段子载波上的毫米波信道,其中,所述用户在毫米波频段上的所有子载波上均放置导频。

3. 根据权利要求1所述的毫米波波束预测方法,其特征在于,所述S1还包括:获取用户发送的两个频段的接收信号:

根据预设参数,改变用户位置,利用Wireless Insite在所述预设参数下生成两个频段的信道向量,在给定用户端传输信号下通过所述两个频段的信道向量获取基站天线上两个频段的接收信号,其中,所述预设参数包括sub-6GHz频段以及毫米波频段预设的载波频率,带宽,天线数,子载波数以及各自径数,以及预设基站位置。

4. 根据权利要求1所述的毫米波波束预测方法,其特征在于,所述S2包括:

将所述两个不同信道的训练数据分别通过输入层输入至所述深度神经网络模型的第一隐藏层和第二隐藏层,利用第一隐藏层和第二隐藏层对应的激活函数,输出经第一隐藏层和第二隐藏层后的两个特征向量;

将经第一隐藏层和第二隐藏层后的两个特征向量连在一起生成一个特定特征向量,并将所述特定特征向量输入至所述深度神经网络模型的分层模块,利用所述神经网络输出层的激活函数,输出预测的最佳下行波束对应的分类向量,根据所述分类向量,获取最佳下行波束在给定码本中的毫米波下行信道最佳波束索引。

5. 根据权利要求4所述的毫米波波束预测方法,其特征在于,所述将所述训练数据输入至深度神经网络模型之前包括:

分别对由所述天线接收信号样本估计出的sub-6GHz信道与毫米波信道进行归一化及向量化处理,作为对应的两个不同信道的训练数据;

根据毫米波信道向量计算出最优下行波束的索引值,并对所述最优下行波束的索引值进行one-hot编码,作为训练的最佳波束标签;

将每个天线接收信号样本对应的估计出的训练数据和计算出的最佳波束标签的组合作为一个训练样本,得到多个训练样本,利用所述多个训练样本对所述深度神经网络模型进行训练;

和/或,在将所述训练数据输入至深度神经网络模型之前包括:

对两个不同信道的训练数据分别乘上一个随机的复相位因子,扩展为两个频段的训练数据集。

6. 根据权利要求5所述的毫米波波束预测方法,其特征在于,所述获取所述毫米波下行信道最佳波束索引,包括:

预定义毫米波下行信道码本:预设下行信道码本大小M,并对码本中的码字进行编号;码本中码字将 $[0, \pi]$ 的空间等分成M份,每一个码字对应角度范围 $\pi/M$ ;

基站利用码本中的任意一个码字预编码,根据所述码字及毫米波信道计算此时用户端达到的频谱效率;通过遍历整个码本中所有码字,找到使频谱效率最高的码字,其编号即为最佳下行波束的索引值。

7. 根据权利要求2所述的毫米波波束预测方法,其特征在于,所述基站毫米波天线采用

毫米波模拟波束赋形构架,所述毫米波模拟波束赋形构架只具有一根射频链路,每根毫米波收发天线具有一个开关与一个移相器,其中,所述开关用于决定这根天线是否收发信号,移相器通过改变天线的相位进行模拟波束赋形,当基站毫米波天线接收由用户发送的上行毫米波信号时,保留小部分的激活天线用于毫米波上行信道估计,通过改变激活天线上移相器的相位,得到不同的上行毫米波信号。

8. 一种毫米波波束预测装置,其特征在于,包括:

并行训练模块,将输入的两个不同信道的训练数据分开同时训练,输出分别对应于sub-6GHz训练数据与毫米波训练数据的两个不同的特征向量;

特征融合模块,连接所述并行训练模块,用于将上述两个不同的特征向量连接成一个大的特定特征向量,即把其中一个向量直接连接到另一个向量后面来实现特征融合;

分类模块,连接所述特征融合模块,用于根据所述特定特征向量,利用深度神经网络模型预测出概率向量,选取所述概率向量中最大的概率值对应的波束作为毫米波下行信道的最佳波束;

其中,神经网络有三个子网络,分别为sub6网络,mmw网络以及classify网络,将两个不同信道向量输入深度神经网络模型的处理流程通过如下方法实现:所述深度神经网络模型是由带有最优下行波束索引标签的天线接收信号样本通过S1至S2训练后得到,利用预设损失函数根据样本神经网络预测的分类向量,与样本计算出的真实最佳波束索引标签计算损失值;持续训练一直到损失值收敛,此时训练结束;

其中,所述S1为:根据两个不同频段的接收信号,进行信道估计,得到对应的两个不同信道的训练数据;

所述S2为:将所述训练数据输入至深度神经网络模型,得到所述深度神经网络模型的输出结果;根据所述输出结果,获取所述毫米波下行信道最佳波束索引;

将两个不同信道向量输入深度神经网络模型的处理流程通过如下方法实现:

将sub-6GHz与毫米波频段训练向量同时分别输入至sub6网络与mmw网络,利用每一隐藏层和所述隐藏层对应的激活函数,输出经隐藏层后的特征向量;对于sub6网络,深度神经网络总共有 $L_s$ 层,对于毫米波训练数据,深度神经网络总共有 $L_m$ 层;

对于mmw网络,毫米波训练数据经过 $L_m$ 层隐藏层的输出表示为:

$$\mathbf{F}_m = \mathbf{NET}_m(\mathbf{h}_m, \mathbf{\Omega}_m) = \mathbf{f}_m^{L_m-1}(\dots \mathbf{f}_m^1(\mathbf{h}_m))$$

其中,  $\mathbf{\Omega}_m = \left\{ \mathbf{W}_m^{(l_m)}, \mathbf{b}_m^{(l_m)} \right\}_{l_m=1}^{L_m}$  是mmw网络需要训练的参数,  $\mathbf{NET}_m$  是mmw网络的输出,

$\mathbf{f}_m^l$  是第 $l$ 层的非线性转换函数,其表达式为:

$$\mathbf{f}_m^l(\mathbf{h}_m) = \mathbf{g}(\mathbf{W}_m^l * \mathbf{B}_N(\mathbf{h}_m) + \mathbf{b}_m^l) \quad l = 1, 2, \dots, L_m$$

其中,  $\mathbf{W}_m^{(l)}$ ,  $\mathbf{b}_m^{(l)}$ ,  $\mathbf{g}^{(1)}$ ,  $\mathbf{B}_N(\cdot)$  分别是对应层的权重矩阵,偏置参数,非线性激活函数以及归一化层;对于隐藏层,激活函数是ReLU函数,即  $[g(z)]_p = \max\{0, z_p\}$ , 其中  $z_p$  表示向量 $z$ 的第 $p$ 个元素,  $p=1, 2, \dots, \text{len}(z)$  且  $\text{len}(z)$  代表向量 $z$ 的长度;

将经隐藏层后的两个特征向量进行特征融合:

$$\tilde{\mathbf{x}} = F_s(\mathbf{h}_s) \oplus F_m(\mathbf{h}_m)$$

其中 $F_s(\mathbf{h}_s)$ 对应sub-6GHz训练数据经过sub6网络输出的特征向量, $F_m(\mathbf{h}_m)$ 为毫米波训练数据经过mmw网络后输出的特征向量 $\oplus$ 为连接函数, $\tilde{\mathbf{x}}$ 为融合的特征向量;得到的 $\tilde{\mathbf{x}}$ 再经过classify网络的前 $L_c$ 层隐藏层之后得到向量 $z$ ,并输入至classify网络的Softmax层,输出长度为码本大小数的分类向量 $p$ ,根据分类向量,确定下行信道最优波束的索引;

所述深度神经网络模型包括至少一个具有相同内部结构的学习单元,所述学习单元包括预设层数的隐藏,且每两个隐藏间包括复数种计算单元,网络结构为各计算单元的相对权重,并采用参数化的变分分布建模所述网络结构。

9.一种电子设备,包括存储器、处理器及存储在存储器上并可在处理器上运行的计算机程序,其特征在于,所述处理器执行所述程序时实现如权利要求1-7任一所述的毫米波波束预测方法的步骤。

10.一种非暂态计算机可读存储介质,其上存储有计算机程序,其特征在于,该计算机程序被处理器执行时实现如权利要求1-7任一所述的毫米波波束预测方法的步骤。

## 毫米波波束预测方法及装置、电子设备、可读存储介质

### 技术领域

[0001] 本发明涉及毫米波波束预测领域,尤其涉及一种毫米波波束预测方法及装置、电子设备、可读存储介质。

### 背景技术

[0002] 毫米波通信的重要问题是如何通过尽可能少的训练数据得到给定码本中毫米波下行信道的最优波束。由于毫米波波长很短,导致其在空间中传播过程中衰减过大,故基站利用波束赋形技术,采用一个波束成形向量来提高接收端的信噪比。传统的方法中,基站依次采用码本中的码字进行波束赋形向用户发送信号,用户检测每次接收到的信号的强度并向基站反馈,基站根据用户每次的反馈最终采用使得用户接收强度最大的信号对应的波束作为毫米波下行信道最优波束。这种方式需要遍历整个码本,导致其复杂度太高。

[0003] 目前开始使用sub-6GHz频段的信号来辅助毫米波波束预测并取得了一定的突破。鉴于sub-6GHz频段信道与毫米波频段信道均来源于(反射,衍射)同一个物理模型,所以两者有着很多相似之处。利用神经网络从sub-6GHz频段的信号中提取信息并将这些信息用于波束预测能够降低波束训练的复杂度。然而,只利用sub-6GHz信道进行训练所能达到的准确率有限,尤其是sub-6GHz接收天线上信噪比低时,波束预测的准确率仅有10%左右。

[0004] 由于神经网络在训练过程中经常出现拟合现象,其中很大的原因来自于有限的数据集。实际应用中由于采集5G毫米波通信数据需要昂贵的设备与复杂的实验设计,这使得毫米波训练集数据量不够,从而降低系统的预测性能。

### 发明内容

[0005] 本发明实施例提供一种能够实现高效率、高精度和高鲁棒性的毫米波波束预测方法及装置、电子设备、可读存储介质。

[0006] 本发明实施例提供一种毫米波波束预测方法,包括:

[0007] S1:根据两个不同频段的接收信号,进行信道估计,得到对应的两个不同信道的训练数据;

[0008] S2:将所述训练数据输入至深度神经网络模型,得到所述深度神经网络模型的输出结果;根据所述输出结果,获取所述毫米波下行信道最佳波束索引;

[0009] 其中,所述深度神经网络模型是由带有最优下行波束索引标签的天线接收信号样本通过所述S1至S2训练后得到。

[0010] 根据本发明一个实施例提供的毫米波波束预测方法,所述S1中的根据两个不同频段的接收信号,进行信道估计具体包括:

[0011] 根据基站sub-6GHz天线接收的由用户发送的sub-6GHz信号,通过最小二乘法估计出sub-6GHz频段子载波上的sub-6GHz信道,其中,所述用户在sub-6GHz频段上所有子载波上均放置导频;

[0012] 根据基站毫米波天线接收的由用户发送的上行毫米波信号,通过最小二乘法估计

出毫米波频段子载波上的毫米波信道,其中,所述用户在毫米波频段上的所有子载波上均放置导频。

[0013] 根据本发明一个实施例提供的毫米波波束预测方法,所述S1还包括:获取用户发送的两个频段的接收信号:

[0014] 根据预设参数,改变用户位置,利用Wireless Insite在所述预设参数下生成两个频段的信道向量,在给定用户端传输信号下通过所述两个频段的信道向量获取基站天线上两个频段的接收信号,其中,所述预设参数包括sub-6GHz频段以及毫米波频段预设的载波频率,带宽,天线数,子载波数以及各自径数,以及预设基站位置。

[0015] 根据本发明一个实施例提供的毫米波波束预测方法,所述S2包括:

[0016] 将所述两个不同信道的训练数据分别通过输入层输入至所述深度神经网络模型的第一隐藏层和第二隐藏层,利用第一隐藏层和第二隐藏层对应的激活函数,输出经第一隐藏层和第二隐藏层后的两个特征向量;

[0017] 将经第一隐藏层和第二隐藏层后的两个特征向量连在一起生成一个特定特征向量,并将所述特定特征向量输入至所述深度神经网络模型的分类模块,利用所述神经网络输出层的激活函数,输出预测的最佳下行波束对应的分类向量,根据所述分类向量,获取最佳下行波束在给定码本中的毫米波下行信道最佳波束索引。

[0018] 根据本发明一个实施例提供的毫米波波束预测方法,所述将所述训练数据输入至深度神经网络模型之前包括:

[0019] 分别对由所述天线接收信号样本估计出的sub-6GHz信道与毫米波信道进行归一化及向量化处理,作为对应的两个不同信道的训练数据;

[0020] 根据毫米波信道向量计算出最优下行波束的索引值,并对所述最优下行波束的索引值进行one-hot编码,作为训练的最佳波束标签;

[0021] 将每个天线接收信号样本对应的估计出的训练数据和计算出的最佳波束标签的组合作为一个训练样本,得到多个训练样本,利用所述多个训练样本对所述深度神经网络模型进行训练;

[0022] 和/或,在将所述训练数据输入至深度神经网络模型之前包括:

[0023] 对两个不同信道的训练数据分别乘上一个随机的复相位因子,扩展为两个频段的训练数据集。

[0024] 根据本发明一个实施例提供的毫米波波束预测方法,所述获取所述毫米波下行信道最佳波束索引,包括:

[0025] 预定义毫米波下行信道码本:预设下行信道码本大小M,并对码本中的码字进行编号;码本中码字将 $[0, \pi]$ 的空间等分成M份,每一个码字对应角度范围 $\pi/M$ ;

[0026] 基站利用码本中的任意一个码字预编码,根据所述码字及毫米波信道计算此时用户端达到的频谱效率;通过遍历整个码本中所有码字,找到使频谱效率最高的码字,其编号即为最佳下行波束的索引值。

[0027] 根据本发明一个实施例提供的毫米波波束预测方法,所述基站毫米波天线采用毫米波模拟波束赋形构架,所述毫米波模拟波束赋形构架只具有一根射频链路,每根毫米波收发天线具有一个开关与一个移相器,其中,所述开关用于决定这根天线是否收发信号,移相器通过改变天线的相位进行模拟波束赋形,当基站毫米波天线接收由用户发送的上行毫

米波信号时,保留小部分的激活天线用于毫米波上行信道估计,通过改变激活天线上移相器的相位,得到不同的上行毫米波信号。

[0028] 本发明实施例提供一种毫米波波束预测装置,包括:

[0029] 并行训练模块,将输入的两个不同信道的训练数据分开同时训练,输出分别对应于sub-6GHz训练数据与毫米波训练数据的两个不同的特征向量;

[0030] 特征融合模块,连接所述并行训练模块,用于将所述两个不同的特征向量连接成一个特定特征向量;

[0031] 分类模块,连接所述特征融合模块,用于根据所述特定特征向量,利用神经网络模型预测出概率向量,选取所述概率向量中最大的概率值对应的波束作为毫米波下行信道的最佳波束。

[0032] 本发明实施例提供一种电子设备,包括存储器、处理器及存储在存储器上并可在处理器上运行的计算机程序,所述处理器执行所述程序时实现所述的毫米波波束预测方法的步骤。

[0033] 本发明实施例提供一种非暂态计算机可读存储介质,其上存储有计算机程序,该计算机程序被处理器执行时实现所述的毫米波波束预测方法的步骤。

[0034] 本发明实施例提供的毫米波波束预测方法及装置、电子设备、可读存储介质,通过对天线接收信号进行信道估计,得到毫米波天线与sub-6GHz天线上的信道。对估计出的信道作归一化,向量化等数据预处理得到训练数据,利用提出的数据增强方法对原本的数据集进行扩充,并将扩充之后的训练数据输入至提出的神经网络中得到预测结果。预设的神经网络模型根据带有最佳波束索引的天线接收信号样本训练后得到,能够输出预测结果,从而实现快速而准确的下行信道最佳波束检测;训练好的神经网络能够实现高效率、高精度和高鲁棒性的预测,并且与现有技术中的方法相比具有更高的准确度。

## 附图说明

[0035] 为了更清楚地说明本发明实施例或现有技术中的技术方案,下面将对实施例或现有技术描述中所需要使用的附图作一简单地介绍,显而易见地,下面描述中的附图是本发明的一些实施例,对于本领域普通技术人员来讲,在不付出创造性劳动的前提下,还可以根据这些附图获得其他的附图。

[0036] 图1为本发明实施例提供的毫米波波束预测方法的流程图;

[0037] 图2.1为本发明一实施例提供的毫米波模拟波束赋形架构;

[0038] 图2.2为本发明一实施例提供的毫米波模拟波束赋形架构;

[0039] 图3为本发明实施例提供的Wireless Insite通信情景仿真结构图;

[0040] 图4为本发明实施例提供的新的神经网络构架;

[0041] 图5.1为本发明一实施例提供的最终效果展示图;

[0042] 图5.2为本发明一实施例提供的最终效果展示图

[0043] 图5.3为本发明一实施例提供的最终效果展示图;

[0044] 图6为本发明实施例提供的毫米波波束预测装置的示意图

[0045] 图7为本发明实施例提供的电子设备的示意图。

[0046] 附图标记:



[0047] 10:并行训练模块;20:特征融合模块;30:分类模块;810:处理器;820:通信接口;830:存储器;840:通信总线。

### 具体实施方式

[0048] 为使本发明实施例的目的、技术方案和优点更加清楚,下面将结合本发明实施例中的附图,对本发明实施例中的技术方案进行清楚、完整地描述,显然,所描述的实施例是本发明一部分实施例,而不是全部的实施例。基于本发明中的实施例,本领域普通技术人员在没有作出创造性劳动前提下所获得的所有其他实施例,都属于本发明保护的范围。

[0049] 图1为本发明实施例提供的毫米波波束预测方法的流程图。如图1所示,本发明实施例提供一种毫米波波束预测方法,包括:

[0050] S1:根据两个不同频段的接收信号,进行信道估计,得到对应的两个不同信道的训练数据;

[0051] S2:将所述训练数据输入至深度神经网络模型,得到所述深度神经网络模型的输出结果;根据所述输出结果,获取所述毫米波下行信道最佳波束索引;

[0052] 其中,所述深度神经网络模型是由带有最优下行波束索引标签的天线接收信号样本通过所述S1至S2训练后得到。

[0053] 在S1中,两个不同频段的天线为位置相邻的线阵(ULA),sub-6GHz阵列天线数是 $M_s$ ,毫米波阵列天线数是 $M_m$ ,则实际系统中可以利用sub-6GHz天线阵列接收信号利用LS,MMSE等信道估计算法估计出sub-6GHz信道参数,记为 $\hat{\mathbf{h}}_s^T$ 。

[0054] 类似地,对于毫米波上行信道估计,本发明中采用模拟波束赋形,如图2.1、2.2所示,基站通过调整毫米波天线上的开关,选择性监听 $M_{\text{test}}$ 根毫米波天线上的信号。这 $M_{\text{test}}$ 根天线上的信号经过各自的移相器和共同的射频链路汇集到基带。通过改变各个天线移相器的相位,并重复测量 $M_{\text{test}}$ 次,我们可以通过最小二乘估计计算出这 $M_{\text{test}}$ 根天线上的毫米波信道,记为 $\hat{\mathbf{h}}_m^T$ 。

[0055] 本发明中,真实的毫米波与sub-6GHz信道由3-d光线跟踪软件Wireless Insite给出。给定参数如下表:

参数值	sub-6GHz	毫米波
载波频率	3.5GHz	28GHz
天线数	4	64
OFDM子载波数	32	512
带宽	0.02GHz	0.5GHz
天线间距(/半波长)	0.5	0.5
径数	15	5

[0057] 图3给出了更具体的仿真场景,本发明通过结合Wireless Insite输出参数与几何信道模型生成sub-6GHz与毫米波信道。更具体地,从Wireless Insite的输出可以得到第1条路径(path)的信道能量 $\rho_1$ ,多普勒频移 $\theta_1$ ,信道延迟 $\tau_1$ ,出射角 $\phi_l^{el}, \phi_l^{az}$ 。则生成的毫米波

频段第k个子载波上的信道为(sub-6GHz同理):

$$[0058] \quad \mathbf{h}_m[k] = \sum_{l=1}^L \sqrt{\frac{\rho_l}{K}} e^{j(v_l + \frac{2\pi k}{K} \tau_l B)} \mathbf{a}(\phi_l^{el}, \phi_l^{az})$$

[0059] 式中B为OFDM的带宽,a为基站天线的阵列响应,由于本发明中采用的sub-6GHz与毫米波天线阵列均为列阵(ULA),所以此时的阵列响应可以简化为:

$$[0060] \quad \mathbf{a}(\phi_{az}, \phi_{el}) = \mathbf{a}_z(\phi_{el})$$

[0061] 式中 $\mathbf{a}_z(\phi_{el})$ 可以写为:

$$[0062] \quad \mathbf{a}_z(\phi_{el}) = \left[ 1, e^{jkdcos(\phi_{el})}, \dots, e^{jk(M_x-1)dcos(\phi_{el})} \right]^T$$

[0063] 带入具体数值即可计算出相应的信道向量。

[0064] 用户端通过wireless insite生成的信道向基站发送两个频段的信号,基站接收信号后利用上述信道估计方法从其sub-6GHz与毫米波天线接收信号中恢复出相应信道矩阵。

[0065] 在S2中,预设的深度神经网络模型是通过样本数据与标签训练后得到的。样本数据是预先估计的sub-6GHz与毫米波信道向量,标签数据是根据真实毫米波信道向量与码本中的波束共同计算得到的。在样本数据输入至预设的神经网络之前,需要先进行归一化处理,仿真中可使用按均值归一化或最大值归一化等方法,本专利采用最大值归一化。上述归一化数据将按照所述数据增强方法来扩充数据集,包括:

[0066] 对毫米波训练数据 $\mathbf{h}_m$ ,所采用随机相位 $\chi \sim U(0, 1)$ ,即服从一个[0, 1]均匀分布,进行数据增强后得到的新的训练数据 $\hat{\mathbf{h}}_m$ 表示为:

$$[0067] \quad \hat{\mathbf{h}}_m = \mathbf{h}_m e^{j2\pi\chi}$$

[0068] 类似的,对于sub-6GHz训练数据 $\mathbf{h}_s$ ,本专利亦采用均匀分布的随机相位 $\psi$ 对其进行数据扩展 $\hat{\mathbf{h}}_s$ :

$$[0069] \quad \hat{\mathbf{h}}_s = \mathbf{h}_s e^{j2\pi\psi}$$

[0070] 注意到对两个频段的信号同时乘一个随机相位因子并不会改变其内部蕴含的信息,于是我们的数据增强方案是可行的。

[0071] 下面将介绍与扩展之后的样本对应的标签数据的具体计算过程:

[0072] 首先,给定码本C,以及数据增强后的毫米波训练数据 $\hat{\mathbf{h}}_m[k]$ ,计算出其对应的频

谱效率 $R(\hat{\mathbf{h}}_m, \mathbf{f}_n)$ :

$$[0073] \quad R(\hat{\mathbf{h}}_m, \mathbf{f}_n) = \sum_{k=1}^K \log_2 \left( 1 + \text{SNR} \left| \hat{\mathbf{h}}_m[k] \mathbf{f}_c \right|^2 \right) = R(\mathbf{h}_m, \mathbf{f}_n)$$

[0074] 其中 $\mathbf{f}_c \in C$ ,即码本中的码字,SNR为接收端的信噪比,K是毫米波OFDM子载波的数

目。(将 $\widehat{\mathbf{h}}_m$ 的表达式展开,我们能够发现,新生成的数据对应的频谱效率与原始数据一致,即 $R(\widehat{\mathbf{h}}_m, \mathbf{f}_n) = R(\mathbf{h}_m, \mathbf{f}_n)$ 。)以下内容中,我们用 $R(\mathbf{h}_m, \mathbf{f}_n)$ 来代替 $R(\widehat{\mathbf{h}}_m, \mathbf{f}_n)$ 。)通过遍历整个码本,可以找到使得频谱效率最大的码字,其对应的索引为:

$$[0075] \quad c^* = \arg \max_{c=1,2,\dots,|C|} R(\mathbf{h}_m, \mathbf{f}_c)$$

[0076] 本实施例中利用该索引生成其对应的one-hot编码 $\mathbf{t}$ ,长度为 $|C|$ ,其第 $c^*$ 个元素为1,其余元素均为零。该编码 $\mathbf{t}$ 即为训练标签。

[0077] 建立深度神经网络模型后,通过大量的此类样本数据及标签进行训练后,得到预设的深度神经网络模型。对于后续天线接收到的信号,进行相应的信道估计后,输入至预设的深度神经网络模型,能够快速准确得到相应的毫米波下行信道最佳波束索引的输出结果。

[0078] 对于不同的通信系统,本专利中的深度神经网络可以根据需求设置,如采取不同的OFDM子载波数目,以及不同的sub-6GHz与毫米波收发天线数。通过改变本发明中神经网络的输入层参数,该发明的方法可以应用在不同的硬件平台上。

[0079] 图4为本发明实施例提供的深度神经网络示意图,如图4所示,所述神经网络有三个子网络,分别为sub6网络,mmw网络以及classify网络,两个频段的信道训练数据通过输入层输入至sub6网络以及mmw网络中。由于sub-6GHz与毫米波频段差距大且sub-6GHz训练数据维度更大,所以其将经过更多的隐藏层。每一个隐藏层均由归一化层,全连接层,Relu激活函数层以及dropout层构成。两个频段的训练数据经过各自的隐藏层得到两个特征向量,并在图中的连接层连接成一个融合的特征向量。该融合的特征向量经过3层结构类似的隐藏层,由最终的激活函数给出分类向量。

[0080] 具体地,将两个不同信道向量输入深度神经网络模型的处理流程可通过如下方法实现:

[0081] 首先,将所述sub-6GHz与毫米波频段训练向量同时分别输入至sub6网络与mmw网络,利用每一隐藏层和隐藏层对应的激活函数,输出经隐藏层后的特征向量。对于sub6网络,深度神经网络总共有 $L_s$ 层, $L_s$ 设置为6,而对于毫米波训练数据,深度神经网络总共有 $L_m$ 层, $L_m=4$ 。

[0082] 对于mmw网络,毫米波训练数据经过 $L_m$ 层隐藏层的输出可以表示为:

$$[0083] \quad \mathbf{F}_m = \mathbf{NET}_m(\mathbf{h}_m, \mathbf{\Omega}_m) = \mathbf{f}_m^{L_m-1}(\dots \mathbf{f}_m^1(\mathbf{h}_m))$$

[0084] 其中, $\mathbf{\Omega}_m = \{\mathbf{W}_m^{(l_m)}, \mathbf{b}_m^{(l_m)}\}_{l_m=1}^{L_m}$ 是mmw网络需要训练的参数, $\mathbf{NET}_m$ 是mmw网络的

输出, $\mathbf{f}_m^l$ 是第 $l$ 层的非线性转换函数,其可以被进一步的表达为:

$$[0085] \quad \mathbf{f}_m^l(\mathbf{h}_m) = \mathbf{g}(\mathbf{W}_m^l * \mathbf{B}_N(\mathbf{h}_m) + \mathbf{b}_m^l) \quad l = 1, 2, \dots, L_m$$

[0086] 其中, $\mathbf{W}_m^{(l)}$ ,  $\mathbf{b}_m^{(l)}$ ,  $\mathbf{g}^{(l)}$ ,  $\mathbf{B}_N(\cdot)$ 分别是对应层的权重矩阵,偏置参数,非线性激活

函数以及归一化层。对于隐藏层,激活函数是ReLU函数,即 $[g(z)]_p = \max\{0, z_p\}$ ,其中 $z_p$ 表示向量 $z$ 的第 $p$ 个元素, $p=1, 2, \dots, \text{len}(z)$ 且 $\text{len}(z)$ 代表向量 $z$ 的长度。对于sub-6GHz训练数据亦有同样的分析,此处从略。

[0087] 将所述经隐藏层后的两个特征向量进行特征融合:

$$[0088] \quad \tilde{x} = F_s(\mathbf{h}_s) \oplus F_m(\mathbf{h}_m)$$

[0089] 其中 $F_s(\mathbf{h}_s)$ 对应sub-6GHz训练数据经过sub6网络输出的特征向量, $F_m(\mathbf{h}_m)$ 为毫米波训练数据经过mmw网络后输出的特征向量, $\oplus$ 为连接函数, $\tilde{x}$ 为融合了的特征向量。得到的 $\tilde{x}$ 再经过classify网络的前 $L_c$ 层隐藏层之后得到向量 $z$ ,并输入至classify网络的Softmax层,输出长度为码本大小数的分类向量 $p$ ,根据该分类向量,确定下行信道最优波束的索引。

[0090] 例如,对于classify网络,输入至输出层的向量为 $z$ ,其维度为 $\text{len}(z)$ ,激活函数是Softmax函数,则输出的分类向量 $p$ 的第 $c$ 个元素 $p_c$ 可以表示为:

$$[0091] \quad p_c = \frac{e^{z_c}}{\sum_{i=1}^{|c|} e^{z_i}}$$

[0092] 神经网络模型通过将输入数据进行层层非线性转换得到预测输出,分类网络的输出神经元数量 $\text{len}(p)$ 与预定义的毫米波码本元素数目一致,其输出是每一预测值对应的分类向量,向量中元素的大小代表着该元素对应的波束为下行信道最佳波束的概率。

[0093] 上述深度神经网络模型包括至少一个具有相同内部结构的学习单元,所述学习单元包括预设层数的隐藏,且每两个隐藏间包括复数种计算单元,定义网络结构为各计算单元的相对权重,并采用参数化的变分分布来建模所述网络结构。

[0094] 所述深度神经网络模型是由带有最优下行波束索引标签的天线接收信号样本通过所述S1至S2训练后得到,利用预设损失函数根据所述样本神经网络预测的分类向量,与所述样本计算出的真实最佳波束索引标签计算损失值;持续训练一直到损失值收敛,此时训练可以结束,深度神经网络模型可以应用。

[0095] 本发明实施例提供的毫米波波束预测方法,通过对天线接收信号进行信道估计,得到毫米波天线与sub-6GHz天线上的信道。对估计出的信道作归一化,向量化等数据预处理得到训练数据,利用提出的数据增强方法对原本的数据集进行扩充,并将扩充之后的训练数据输入至提出的神经网络中得到预测结果。预设的神经网络模型根据带有最佳波束索引的天线接收信号样本训练后得到,能够输出预测结果,从而实现快速而准确的下行信道最佳波束检测。训练好的深度神经网络能够实现高效率、高精度和高鲁棒性的预测,并且与目前的方法相比具有更高的准确度。

[0096] 所述S1中的根据两个不同频段的接收信号,进行信道估计具体包括:

[0097] 根据基站sub-6GHz天线接收的由用户发送的sub-6GHz信号,通过最小二乘法估计出sub-6GHz频段子载波上的sub-6GHz信道,其中,所述用户在sub-6GHz频段上所有子载波上均放置导频;

[0098] 根据基站毫米波天线接收的由用户发送的上行毫米波信号,通过最小二乘法估计出毫米波频段子载波上的毫米波信道,其中,所述用户在毫米波频段上的所有子载波上均

放置导频。

[0099] S1还包括:获取用户发送的两个频段的接收信号:

[0100] 根据预设参数,改变用户位置,利用光线追踪软件Wireless Insite在所述预设参数下生成两个频段的信道向量,在给定用户端传输信号下通过所述两个频段的信道向量获取基站天线上两个频段的接收信号,其中,所述预设参数包括sub-6GHz频段以及毫米波频段预设的载波频率,带宽,天线数,子载波数以及各自径数,以及预设基站位置。

[0101] 所述S2包括:

[0102] 将所述两个不同信道的训练数据分别通过输入层输入至所述深度神经网络模型的第一隐藏层和第二隐藏层,利用第一隐藏层和第二隐藏层对应的激活函数,输出经第一隐藏层和第二隐藏层后的两个特征向量;

[0103] 将经第一隐藏层和第二隐藏层后的两个特征向量连在一起生成一个特定特征向量,并将所述特定特征向量输入至所述深度神经网络模型的分层模块30,利用所述神经网络输出层的激活函数,输出预测的最佳下行波束对应的分类向量,根据所述分类向量,获取最佳下行波束在给定码本中的毫米波下行信道最佳波束索引。也就是,将特定特征向量输入至所述深度神经网络模型的第三隐藏层,最终利用所述神经网络模型输出层的激活函数,输出预测的分类向量,根据所述分类向量,预测最佳波束。

[0104] 所述将所述训练数据输入至深度神经网络模型之前包括:

[0105] 分别对由所述天线接收信号样本估计出的sub-6GHz信道与毫米波信道进行归一化及向量化处理,作为对应的两个不同信道的训练数据;

[0106] 根据毫米波信道向量计算出最优下行波束的索引值,并对所述最优下行波束的索引值进行one-hot编码,作为训练的最佳波束标签;也就是包括:获取sub-6GHz信号与毫米波信号信噪比在[-10dB,20dB]等距改变,且基站用于上行信道估计的毫米波天线数不断改变所对应的训练数据,以及每个接收信号样本对应的信源数量标签。

[0107] 将每个天线接收信号样本对应的估计出的训练数据和计算出的最佳波束标签的组合作为一个训练样本,得到多个训练样本,利用所述多个训练样本对所述深度神经网络模型进行训练,具体的训练过程如下:

[0108] 首先,从天线接收信号样本中选取任一样本,将由该天线接收信号估计出的信道矩阵输入至预设的深度神经网络模型,经非线性转换,在输出层输出对应的分类向量,并利用预先计算好的最佳波束对应的分类向量,计算损失函数对应的损失值。

[0109] 例如,在仿真中,网络的损失函数可以是交叉熵损失函数,即为:

$$[0110] \quad Loss(\Omega) = \frac{1}{V} \sum_{v=0}^{V-1} \sum_{c=1}^{len(|C|)} [y(v)]_c \log [\hat{y}(v)]_c$$

[0111] 其中,V是单个批次中样本的数量,v代表样本在批次中的序号, $\hat{y}(v)$ 是网络输出的分类向量,y(v)代表分类训练的标签,即最佳波束的0,1编码,其长度为len(|C|)且对应最佳波束索引的元素值为1,其余元素均为0。

[0112] 在训练阶段,网络得到损失函数对应的损失值后,可通过ADAM算法对损失函数进行逐步优化,不断更新网络的参数直到损失函数收敛。训练结束后,网络的参数保持不变,

利用测试集的两个频段训练数据的输入获得毫米波下行信道最佳波束的估计值,通过计算估计值和真实值之间的误差来评价其性能。

[0113] 在本发明中,所提供的7000个离线训练样本能够完整表达实际环境中接收信号的特征,因此所提供的分类网络仅需单次离线训练,即可实现实际场景中的下行信道最优波束预测,而无需针对测试时用户位置不同重新收集训练样本训练。

[0114] 图5.1至5.3描述了利用3000个样本对所述神经网络的预测结果进行检测,这里评判指标为top-1预测准确度,即预测的最佳波束正为真实的最佳波束的概率:

$$[0115] \quad Acc_{top1} = \sum_{k=1}^{N_{test}} \frac{1}{N_{test}} I_{\hat{c}_k=c_k^*}$$

[0116] 其中 $\hat{c}_k$ 为神经网络预测的第k个样本的波束索引, $c_k^*$ 代表第k个样本真实的波束索引。其他的评判指标还有top-3预测精度与频谱效率。top-3预测精度与top-1预测精度定义类似,由于本发明用了多余的毫米波导频数据来对sub-6GHz的预测结果进行了校准,top-1预测精度已经很高。即使在很低的毫米波以及sub-6GHz信号信噪比下,其top-3准确率也能基本达到100%,于是在本发明实施例中将不在讨论top-3准确率。频谱效率的定义见上述S2。

[0117] 图5.1中展示了神经网络预测的 $Acc_{top1}$ 随sub-6GHz信道SNR的变化情况。仿真中,系统利用了8根毫米波天线以及4根sub-6GHz天线分别进行毫米波与sub-6GHz上行信道估计(其中毫米波信噪比固定为20dB)。图中“sub-6G”代表之前工作中只利用sub-6GHz信道预测所能到达的 $Acc_{top1}$ ，“Fusion”为本专利提出的方案,能够看出通过很少的一部分毫米波信号,神经网络预测的准确率大大提高了;相似的,图5.2展示了频谱效率随sub-6GHz信道的信噪比的变化,可以看出,即使在sub-6GHz信噪比很低时,频谱效率也相当高,随着sub-6GHz训练数据信噪比提高系统很快达到最高频谱效率。对比之前的工作,本专利提出的方法能够大大提高预测的准确度。

[0118] 图5.3展示了本专利提出的数据增强方法带来的效果提升。系统估计了两个毫米波天线上的信道(信噪比为20dB)。并利用sub-6GHz信道与估计出的毫米波信道进行预测。图中“data augmented”为实施数据增强后的效果图,仿真中,本专利提出的数据增强方法将原始数据集扩展成为原来的8倍。能够看出,在sub-6GHz信道信噪比低时,数据增强方法能够大幅度提高预测精度,随着sub-6GHz信道信噪比提高,该方法带来的提升慢慢减弱,不过依然还能带来预测准确度增益。

[0119] 由于篇幅限制,本专利中没有展示改变其他参数如毫米波上行信道接收天线数,毫米波导频信噪比等,具体结果可自行得到。

[0120] 进一步的,本发明实施例提供一种新型针对无线信道的数据增强方式,包括:

[0121] 原始训练数据集中每一个训练样本均对应于基站与某一个用户之间的sub-6GHz与mmw频段的复数信道。对于任意一个用户而言,对任一频段的复数信道同时乘上一个随机的相位因子,其反应的信道信息(如角度,延时,衰减)没有发生任何改变。于是,我们通过每一个用户的复数信道乘上相位因子进行数据增强,来减轻网络过拟合带来的影响从而提高预测准确率。

[0122] 根据本发明一个实施例提供的毫米波波束预测方法,所述获取所述毫米波下行信

道最佳波束索引,包括:

[0123] 预定义毫米波下行信道码本:预设下行信道码本大小M,并对码本中的码字进行编号;码本中码字将 $[0, \pi]$ 的空间等分成M份,每一个码字对应角度范围 $\pi/M$ ;

[0124] 基站利用码本中的任意一个码字预编码,根据所述码字及毫米波信道计算此时用户端达到的频谱效率;通过遍历整个码本中所有码字,找到使频谱效率最高的码字,其编号即为最佳下行波束的索引值。

[0125] 根据本发明一个实施例提供的毫米波波束预测方法,所述基站毫米波天线采用毫米波模拟波束赋形构架,所述毫米波模拟波束赋形构架只具有一根射频链路,每根毫米波收发天线具有一个开关与一个移相器,其中,所述开关用于决定这根天线是否收发信号,移相器通过改变天线的相位进行模拟波束赋形,当基站毫米波天线接收由用户发送的上行毫米波信号时,保留给的激活天线用于毫米波上行信道估计,通过改变激活天线上移相器的相位,得到不同的上行毫米波信号。上行信道估计时,为了节省基站功率并降低信道估计复杂度,将大部分天线上开关断开,只保留一小部分天线(M根)用于毫米波上行信道估计。重复测量与毫米波工作天线数目相同的次数(M次),通过改变工作天线上移相器的相位,在基带得到不同的接收信号,并用这些接收信号最小二乘估计出M根天线上的信道。对于下行信道估计,为了尽量提高用户端的数据率,基站将使用所有的毫米波天线进行模拟波束赋形。

[0126] 如图6所示,本发明实施例提供一种毫米波波束预测装置,包括:

[0127] 并行训练模块10,对应神经网络结构中的sub6网络与mmw网络,用于将输入的sub-6GHz信道与毫米波信道训练数据分别输入至sub6网络与mmw网络中进行训练,由于不同信道训练数据的维度不同,mmw与sub6网络的输入层大小以及隐藏层层数会有不同,以使得不同频段的训练数据得到适当的训练。最终并行训练模块10输出对应于不同频段训练数据的不同的特征向量。

[0128] 特征融合模块20,用于将上述两个不同的特征向量连接成一个大的特定特征向量,即把其中一个向量直接连接到另一个向量后面来实现特征融合。

[0129] 分类模块30,对应网络结构中的classify网络。其利用上述特征融合模块20的输出作为输入,该分类模块30利用深度神经网络模型预测出概率向量,通过选取所述概率向量中最大的概率值的索引获取毫米波下行信道的最佳波束。

[0130] 本案实施例的毫米波波束预测装置工作原理与上述实施例的毫米波波束预测方法是相应的,此处不再一一赘述。

[0131] 图7示例了一种电子设备的实体结构示意图,该电子设备可以包括:处理器(processor)810、通信接口(Communications Interface)820、存储器(memory)830和通信总线840,其中,处理器810,通信接口820,存储器830通过通信总线840完成相互间的通信。处理器810可以调用存储器830中的逻辑指令,以执行一种毫米波波束预测方法,该方法包括:

[0132] S1:根据两个不同频段的接收信号,进行信道估计,得到对应的两个不同信道的训练数据;

[0133] S2:将所述训练数据输入至深度神经网络模型,得到所述深度神经网络模型的输出结果;根据所述输出结果,获取所述毫米波下行信道最佳波束索引;

[0134] 其中,所述深度神经网络模型是由带有最优下行波束索引标签的天线接收信号样

本通过所述S1至S2训练后得到。

[0135] 此外,上述的存储器830中的逻辑指令可以通过软件功能单元的形式实现并作为独立的产品销售或使用,可以存储在一个计算机可读取存储介质中。基于这样的理解,本发明的技术方案本质上或者说对现有技术做出贡献的部分或者该技术方案的部分可以以软件产品的形式体现出来,该计算机软件产品存储在一个存储介质中,包括若干指令用以使得一台计算机设备(可以是个人计算机,服务器,或者网络设备等)执行本发明各个实施例所述方法的全部或部分步骤。而前述的存储介质包括:U盘、移动硬盘、只读存储器(ROM, Read-Only Memory)、随机存取存储器(RAM, Random Access Memory)、磁碟或者光盘等各种可以存储程序代码的介质。

[0136] 另一方面,本发明实施例还提供一种计算机程序产品,所述计算机程序产品包括存储在非暂态计算机可读存储介质上的计算机程序,所述计算机程序包括程序指令,当所述程序指令被计算机执行时,计算机能够执行上述各方法实施例所提供的一种毫米波波束预测方法,该方法包括:

[0137] S1:根据两个不同频段的接收信号,进行信道估计,得到对应的两个不同信道的训练数据;

[0138] S2:将所述训练数据输入至深度神经网络模型,得到所述深度神经网络模型的输出结果;根据所述输出结果,获取所述毫米波下行信道最佳波束索引;

[0139] 其中,所述深度神经网络模型是由带有最优下行波束索引标签的天线接收信号样本通过所述S1至S2训练后得到。

[0140] 又一方面,本发明实施例还提供一种非暂态计算机可读存储介质,其上存储有计算机程序,该计算机程序被处理器执行时实现以执行上述各实施例提供的一种毫米波波束预测方法,该方法包括:

[0141] S1:根据两个不同频段的接收信号,进行信道估计,得到对应的两个不同信道的训练数据;

[0142] S2:将所述训练数据输入至深度神经网络模型,得到所述深度神经网络模型的输出结果;根据所述输出结果,获取所述毫米波下行信道最佳波束索引;

[0143] 其中,所述深度神经网络模型是由带有最优下行波束索引标签的天线接收信号样本通过所述S1至S2训练后得到。

[0144] 以上所描述的装置实施例仅仅是示意性的,其中所述作为分离部件说明的单元可以是或者也可以不是物理上分开的,作为单元显示的部件可以是或者也可以不是物理单元,即可以位于一个地方,或者也可以分布到多个网络单元上。可以根据实际的需要选择其中的部分或者全部模块来实现本实施例方案的目的。本领域普通技术人员在不付出创造性的劳动的情况下,即可以理解并实施。

[0145] 通过以上的实施方式的描述,本领域的技术人员可以清楚地了解到各实施方式可借助软件加必需的通用硬件平台的方式来实现,当然也可以通过硬件。基于这样的理解,上述技术方案本质上或者说对现有技术做出贡献的部分可以以软件产品的形式体现出来,该计算机软件产品可以存储在计算机可读存储介质中,如ROM/RAM、磁碟、光盘等,包括若干指令用以使得一台计算机设备(可以是个人计算机,服务器,或者网络设备等)执行各个实施例或者实施例的某些部分所述的方法。



[0146] 最后应说明的是：以上实施例仅用以说明本发明的技术方案，而非对其限制；尽管参照前述实施例对本发明进行了详细的说明，本领域的普通技术人员应当理解：其依然可以对前述各实施例所记载的技术方案进行修改，或者对其中部分技术特征进行等同替换；而这些修改或者替换，并不使相应技术方案的本质脱离本发明各实施例技术方案的精神和范围。

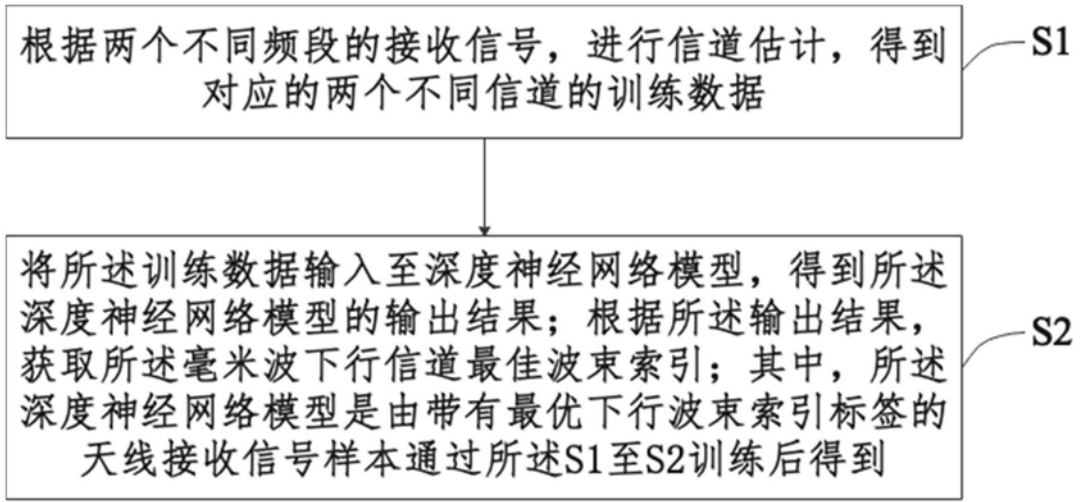


图1




图2.1




图2.2

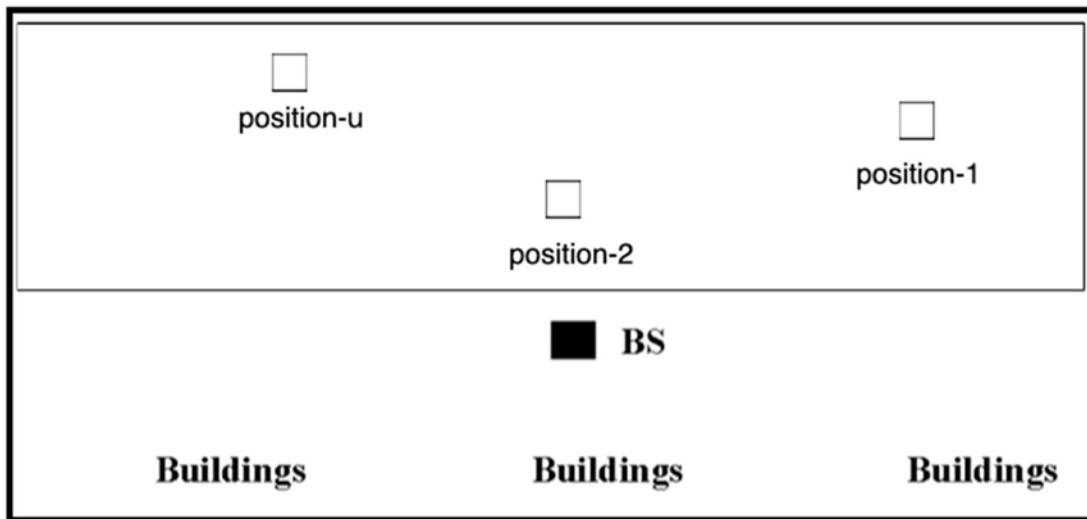


图3

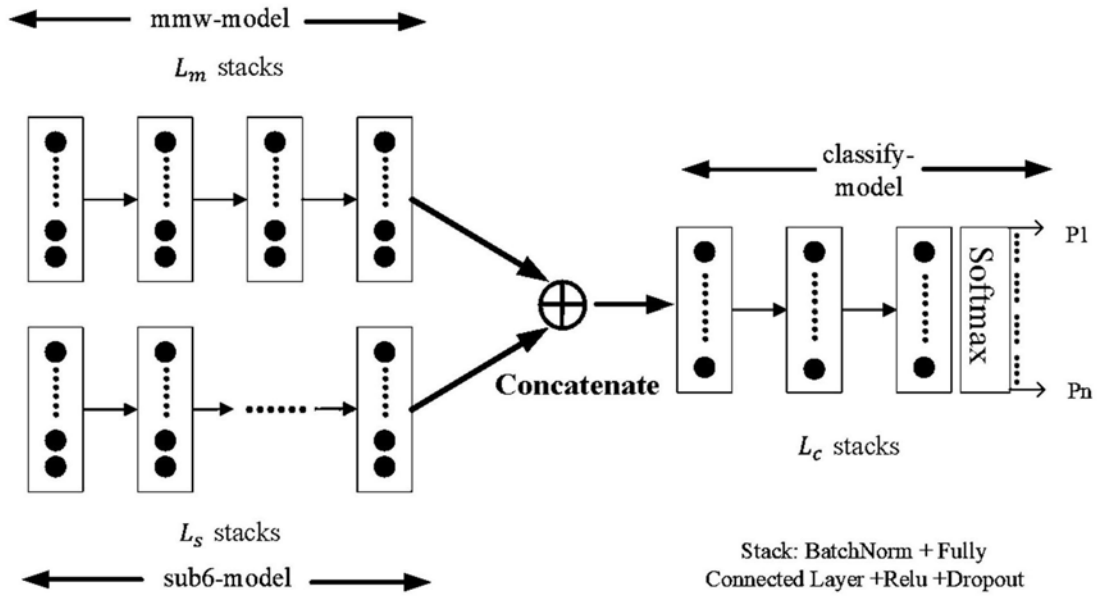


图4




图5.1




图5.2




图5.3

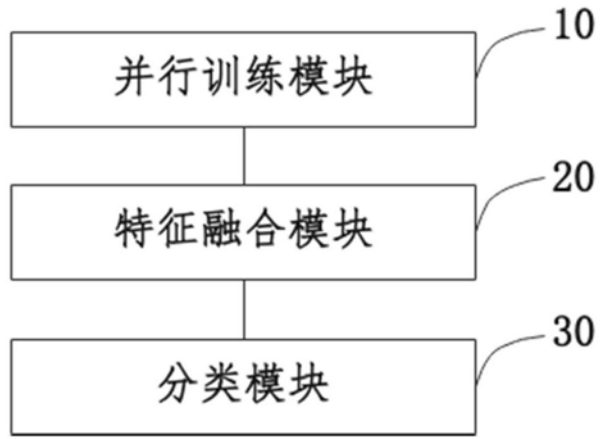


图6

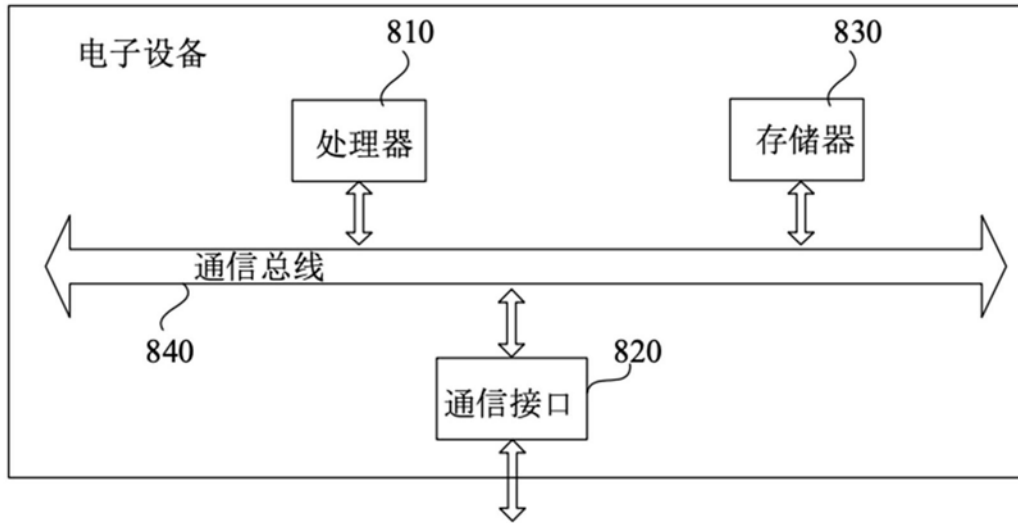


图7