南京工业职业技术大学

NANJING VOCATIONAL UNIVERSITY OF INDUSTRY TECHNOLOGY



专利申请案例汇编

科技处

2025年9月

目录

一种电压源风电机组柔性并网控制方法（发明）..... 1
技术交底书..... 1
申请材料分析说明..... 14
申请稿..... 15
一种双馈电压源风电机组转速-惯量组合控制方法（发明）..... 30
技术交底书..... 30
申请材料分析说明..... 43
申请稿..... 44
一种构网型全功率风电机组功率-转速柔性切换自调频控制方法（发明）..... 56
技术交底书..... 56
申请材料分析说明..... 70
申请稿..... 71
一种单幅图像超分辨率重建方法及其交互式推理网络（发明）..... 88
技术交底书..... 88
申请材料分析说明..... 116
申请稿..... 118
一种基于 Transformer 架构的单碱基编辑结果预测方法（发明）..... 145
技术交底书..... 145
申请材料分析说明..... 160
申请稿..... 161
一种基于表面激子极化子增强光子自旋霍尔效应的方法（发明）..... 188
技术交底书..... 188
申请材料分析说明..... 195
申请稿..... 197
一种非参数化表示学习的大规模点云语义分割方法（发明）..... 204
技术交底书..... 204
申请材料分析说明..... 215
申请稿..... 216
一种雷达通信一体化控制方法、装置、介质、程序产品（发明）..... 231

技术交底书 231
申请材料分析说明 262
申请稿 263
一种基于磁力曲轴的自由活塞发电装置（发明） 293
技术交底书 293
申请材料分析说明 296
申请稿 297
一种双向切削刨床（实用新型） 308
技术交底书 308
申请材料分析说明 315
申请稿 316
一种基于压电材料的俘能地板（实用新型） 322
技术交底书 322
申请材料分析说明 332
申请稿 333
一种粮食晒收装置（非正常） 341
技术交底书 341
申请材料分析说明 349
一种阻尼减振刀柄（非正常） 350
技术交底书 350
申请材料分析说明 359

一种电压源风电机组柔性并网控制方法（发明）

技术交底书

1. 相关背景技术及现有技术发展情况：

1.1 背景技术

能源一直在人类的经济和社会发展中扮演着举足轻重的角色。如今，我们正在经历绿色能源的革命。通过发展风能、太阳能、潮汐能、生物质能等可再生能源，我们正试图替代传统的化石燃料。这些可再生能源已经成为全球各国研究应对能源短缺问题的重要方向，并推动着人类对于自然资源利用的新篇章。高比例的可再生能源的并网也将会改革传统的电力系统的控制和调度。在这其中，风能因其分布广泛、环保、技术成熟度高、可实现性和成本方面的优势而越来越受到世界各国的重视，在全球可再生能源的发展和利用方面成为关键的增长点。同时，风电在能源结构调整、增加社会就业、提高能源自给率等方面都起到了非常重要的作用。

大型风力发电机组通过变流器接入电网，相比于传统的同步发电机，具有控制灵活、响应迅速等优点，但是由于变流器的隔离作用，机组对电网缺少必要的惯量和频率阻尼。对于双馈风电机组（Doubly-fed Induction Generator，DFIG），定子直接挂接电网，转子通过三相交-直-交变流器实现交流励磁，电功率可以通过定子、转子与电网进行交换，由于风电变流器采用双闭环控制，电网频率的变化并不会体现在控制策略中，因此不会对风机的转速产生影响，无法利用转子的旋转动能为系统提供惯量支撑。

随着风电渗透率的增加，传统同步发电机在电力系统中所占的比例逐渐降低，风电机组无法参与电网频率的调节，这将引发严重的频率稳定问题，而当电网的频率变化超过限额，则将导致电网切除电源或负荷甚至引发严重的停电事故。

因此，为了使得双馈风电机组取得和同步发电机类似的惯量和阻尼特性，体现“电网友好型”型并网发电特性，一种改进方式为“风电机组电压控制型技术路线”，即：将风电机组控制为电压源，其外特性与同步发电机类似，能够自主建立电压，实时响应功率平衡，输出功率能够自动响应负荷的变化，体现出和传统同步发电机类似的“电网友好型”并网发电特点。

1.2 与本发明创造相关的现有技术

1.2.1 现有技术的技术方案

现有的双馈电压源风电机组的控制技术方法如下：通常采用转子侧变换器虚拟同步控制-网侧变换器惯性同步控制的组合控制技术方案，如图 1-1 所示。

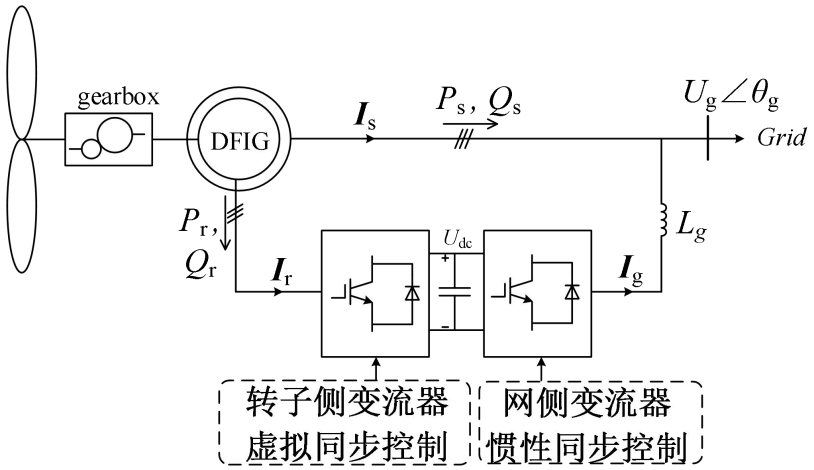


图 1-1 转子侧虚拟同步-网侧惯性同步控制示意图

在转子侧变换器虚拟同步控制方式中，将发电机的定子和转子分别等效为传统同步发电机的定子回路和转子回路，建立电网同步参考系和同步发电机转子参考系，将双馈发电机的转子磁链按照同步发电机的转子参考系定向，从而实现励磁控制。如图 1-2 所示，同步控制环模拟同步发电机的转子运动方程，实现最大功率跟踪并输出转子磁链定向的转子角；励磁控制环用于在风电机组运行过程中保持转子磁链恒定，进而保持内电势的稳定。

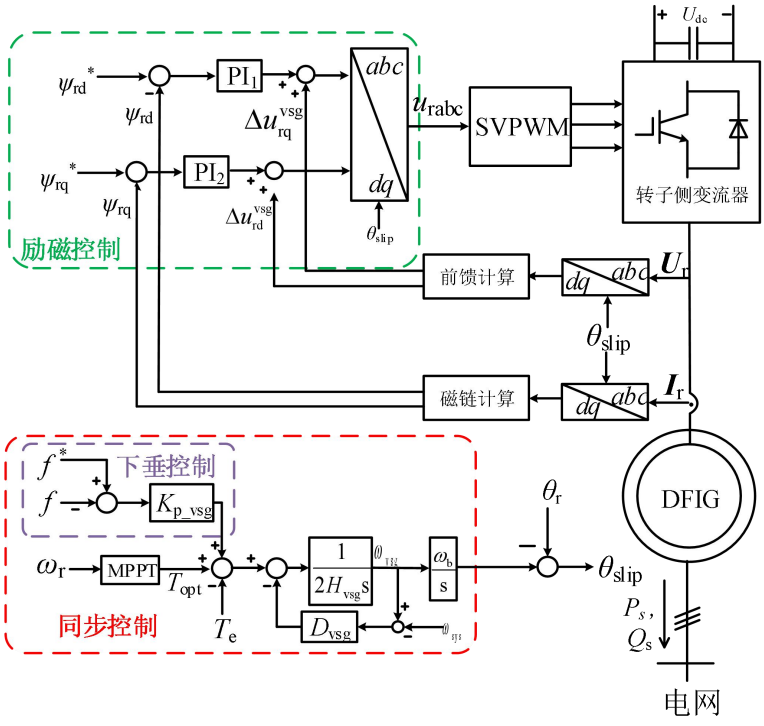


图 1-2 双馈风电机组转子侧虚拟同步控制框图

在网侧变换器惯性同步控制方式中，利用直流母线电容充当电网同步过程中的能量缓冲元件，不需要锁相环就可以实现和电网的同步，控制框图如图 1-3 所示，图中直流母线电压标幺值经过积分器得到网侧变换器输出电压 u_g 的相位θ_{isyn}，通过控制调制比 m 实现对于网侧无功功率的动态调节，其中 m_n 为额定调制比。

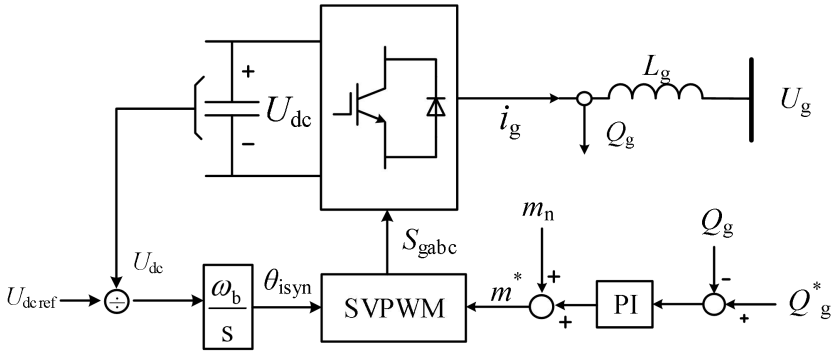


图 1-3 双馈风电机组网侧变换器惯性同步控制框图

1.2.2 现有技术的缺点

常规风电机组的柔性并网启动，包括风电机组的机械启动和电气启动两个部分，其中风电机组的机械启动是指风力机由停机状态加速到并网转速的过程，电气启动指的则是机组并网发电的过程。

针对传统风电机组的柔性并网启动控制，相关技术已经较为成熟，但是在双馈风电机组电压源控制方式中，不论是转子侧变换器虚拟同步控制方式，还是网侧变换器惯性同步控制方式，均针对的是风电机组稳态运行时的控制方案，而在双馈电压源风电机组的柔性并网启动领域，目前仍缺乏针对性的柔性并网启动控制策略，如果不设计特定的柔性并网控制策略，而强行进行并网启动，则会在并网瞬间产生巨大的冲击电流，对电力系统的稳定运行产生巨大的消极影响，因此，有必要提出一种针对双馈电压源风电机组的柔性并网控制方法，实现电压源双馈风电机组的柔性并网的控制效果，减少并网瞬间的冲击电流。

2．本发明创造技术方案详细阐述：

2.1 本发明创造所要解决的技术问题

针对上述现有技术中的缺陷，本发明要解决的技术问题体现在以下几点：

1) **实现双馈电压源风电机组网侧变换器的柔性并网。**重新设计网侧变换器的控制策略，使得网侧变换器具备直流母线预充电、与电网同步等控制效果。

2) **实现双馈电压源风电机组转子侧变换器的柔性并网控制。**重新设计转子侧变换器的控制策略，使得转子侧变换器具备与电网同步的控制效果。

3) **实现风电机组并网瞬间无明显冲击电流。**重新设计并网控制逻辑，当满足电压源风电机组并网条件时闭合并网开关，实现并网发电。

2.2 本发明创造完整的技术方案阐述

双馈电压源风电机组柔性并网控制系统包括如下模块，如图 2-1 所示：

1) **双馈电压源网侧变换器柔性并网控制模块：**其用于控制电压源网侧变换器与电网同步，并对直流母线预充电，为转子侧变换器的柔性并网控制提供条件。

2) **双馈电压源转子侧变换器柔性并网控制模块：**其用于控制风电机组的转子侧变换器，使得定子侧电压和电网电压满足并网条件。

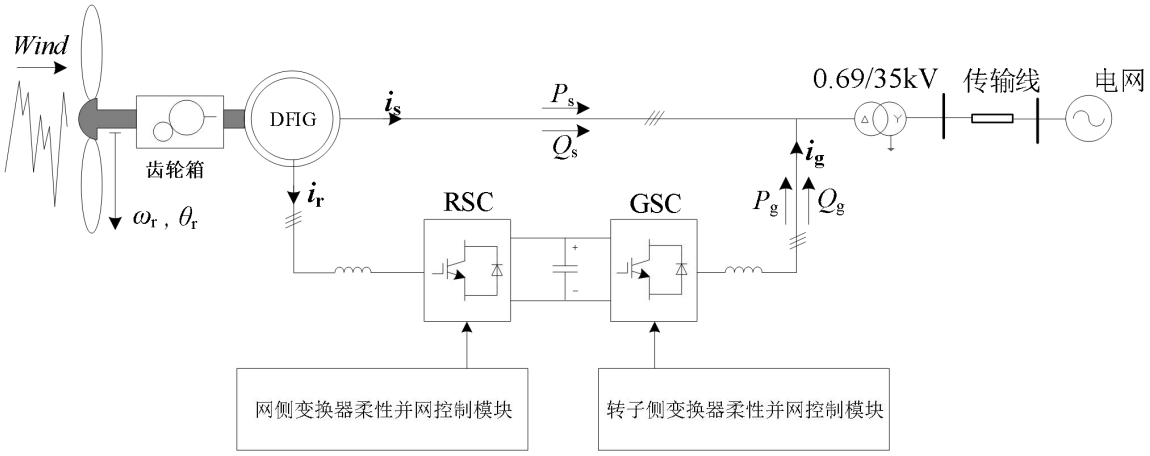


图 2-1 双馈电压源风电机组柔性并网控制系统

其中，**双馈电压源网侧变换器柔性并网控制模块**包括如下模块，如图 2-2 所示：

1) **网侧变换器预同步控制模块：**该模块用于实现网侧变换器的预同步控制，控制网侧变换器的输出电压和电网电压的幅值、频率、相位均相同，实现与电网同步。

2) **网侧变换器无功功率控制模块：**该模块用于通过 PI 控制器实现对于网侧变换器无功功率的无差精准控制。

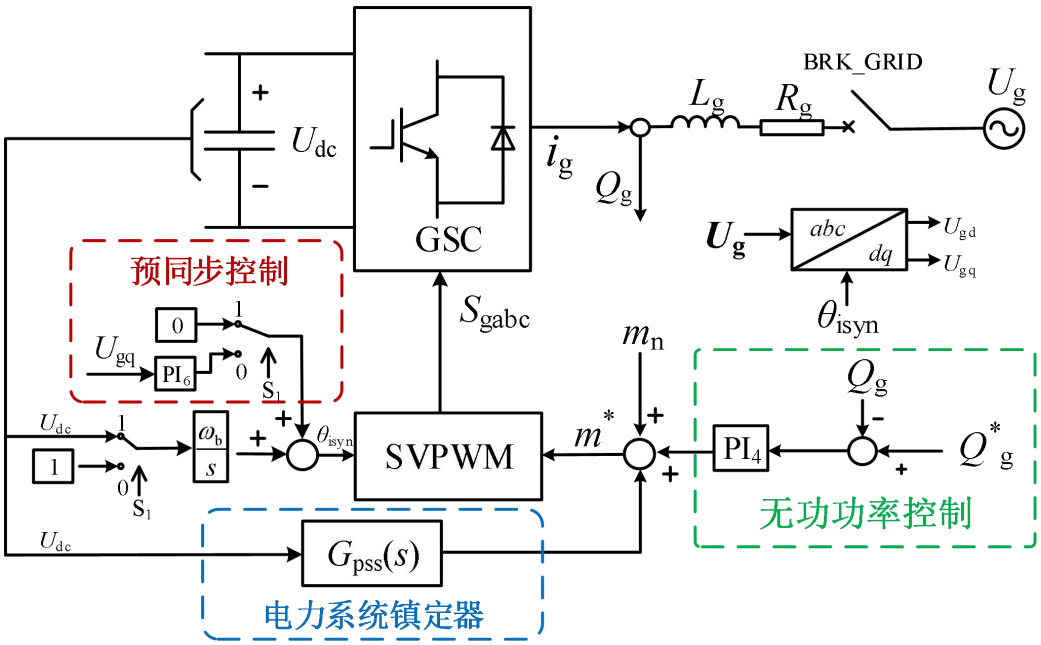


图 2-2 网侧变换器柔性并网控制框图（展开图）

其中，**双馈电压源转子侧变换器柔性并网控制模块**包括如下模块，如图 2-3 所示：

1) **转子侧变换器预同步控制模块：**该模块用于实现转子侧变换器的预同步控制，控制风电机组的定子电压和电网电压的幅值、频率、相位均相同，实现与电网同步。

2) **转子侧变换器有功功率控制模块：**该模块用于模拟同步发电机的转子运动方程，将虚拟惯量和虚拟阻尼引入控制环路，实现和同步发电机类似的虚拟惯量控制效果。

3) **转子侧变换器无功功率控制模块：**该模块用于通过 PI 控制器实现对于转子侧变换器无功功率的无差精准控制。

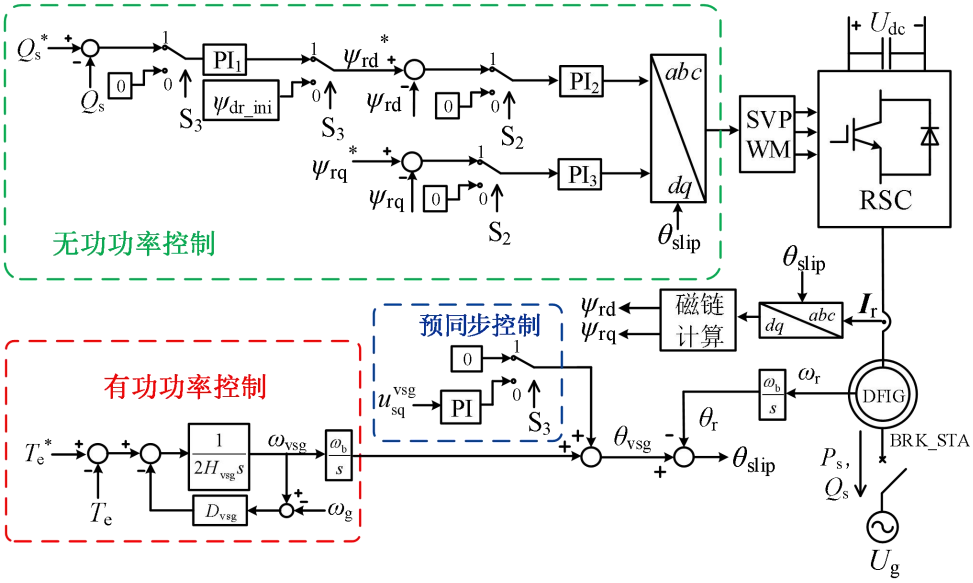


图 2-3 转子侧变换器柔性并网控制框图（展开图）

包含定子侧以及网侧并网开关的双馈风电机组电气拓扑图如图 2-4 所示。在风电机组电

气启动并网发电之前，双馈风电机组的定子侧与网侧并网开关均处于断开的状态，当风电机组的转速达到其并网转速，随后机组开始其柔性并网过程，主要包括以下四个主要步骤。

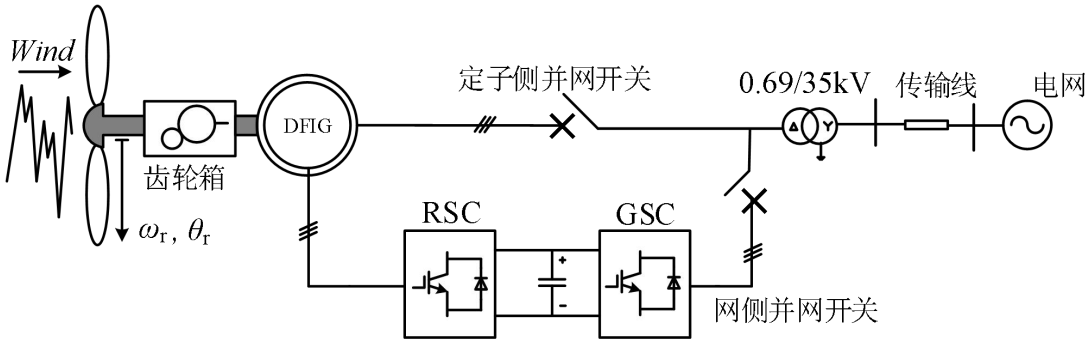


图 2-4 双馈风电机组电气拓扑图

步骤 1：直流母线预充电，网侧变换器与电网同步

当风电机组的转速已经稳定在并网转速后，网侧并网开关闭合，网侧变换器开始进行预同步控制，在预同步控制策略中，当网侧并网开关 BRK_GRID 闭合之后，网侧预同步触发信号 S1 = 0，通过 PI 控制器实现电网电压的 q 轴分量 Ugq = 0，以此达到与电网同步的控制目的，同时直流电压 U_{dc} 此时不影响相角 θ_{isyn} 的变化，该状态将一直保持至预同步阶段完成。

步骤 2：预充电与同步完成，网侧变换器切换至电压源控制策略

在步骤 2 中，网侧变换器的电网同步工作已经完成，正式切换至电压源控制策略，图 2-2 中网侧预同步触发信号 $S_1 = 1$，并同时将直流母线电压 U_{dc} 引入相角 θ_{isyn} 的控制，实现网侧变换器电压源控制的切换。

步骤 3：转子侧变换器工作在并网控制策略，实现与电网的相角同步

当网侧变换器的并网启动完成之后，直流母线电压稳定，随即进入转子侧变换器的预同步控制策略，此时励磁控制触发信号 $S_2 = 1$，并网触发信号 $S_3 = 0$，保持定子侧并网开关 BKR_STA 处于断开的状态。

有功功率控制环的柔性并网控制目标是实现定子电压和电网电压的同步，即定子电压和电网电压频率相同，幅值相等，相位相同，从而避免在定子侧并网开关闭合瞬间产生巨大的冲击电流，在虚拟转子角 θ_{vsg} 生成框图中引入定子电压 q 轴分量的 PI 控制环节，通过控制在旋转坐标系下定子电压 q 轴分量为 0，实现定子电压和电网电压同步的控制目的。

无功功率控制环的柔性并网控制目标是建立类似于同步发电机的励磁电势，在转子侧变换器预同步控制阶段，转子磁链的 d 轴分量和 q 轴分量各自经过 PI 控制器实现无静差控制，建立起稳定的转子磁链幅值。

步骤 4：与电网的相角同步完成，闭合定子侧并网开关，实现柔性并网

当转子磁链幅值稳定并同时完成定子电压的同步之后，风电机组具备了并网的条件，接

收到并网信号之后，并网触发信号 S_3=1，励磁控制触发信号仍保持 S_2 = 1，退出预同步控制，并同步闭合定子侧并网开关 BKR_STA，至此，转子侧变换器预同步与柔性并网控制策略基本完成。

2.3 本发明创造技术方案带来的有益效果

1) **减小网侧变换器并网时的冲击电流，实现柔性并网。**重新设计网侧变换器的控制策略，减小网侧变换器并网时的冲击电流。
2) **减小转子侧变换器并网时的冲击电流，实现柔性并网。**重新设计转子侧变换器的控制策略，减小转子侧变换器并网时的冲击电流。
3) **实现风电机组并网瞬间无明显冲击电流。**重新设计并网控制逻辑，当满足电压源风电机组并网条件时闭合并网开关，实现并网发电。

3．本发明创造的技术关键点和拟保护点：

1) 保护整套双馈电压源风电机组柔性并网控制系统

2) 保护 1)中所述柔性并网控制系统中网侧变换器柔性并网控制策略

3) 保护 1)中所述柔性并网控制系统中转子侧变换器柔性并网控制策略

4) 保护方案阐述中步骤 1 至步骤 4 的柔性启动控制顺序

4.本发明创造的替代方案：

暂无

5．具体实施例及附图：

（实施例是实施发明内容的具体例子，可有多个实施例；对实施例的描述应当详细，有附图的，应当对照附图。如有附图的，请提供；附图应该是清晰的线条图，黑白方式，且最好是可编辑的。）

附图信息如下：

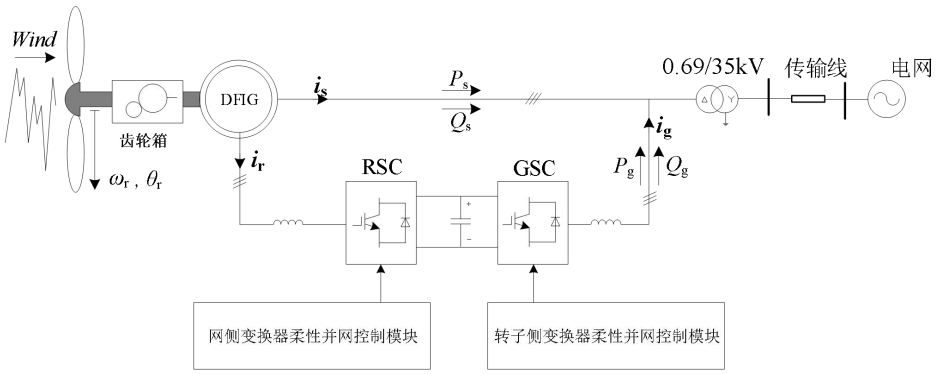


图 5-1 双馈电压源风电机组柔性并网控制系统

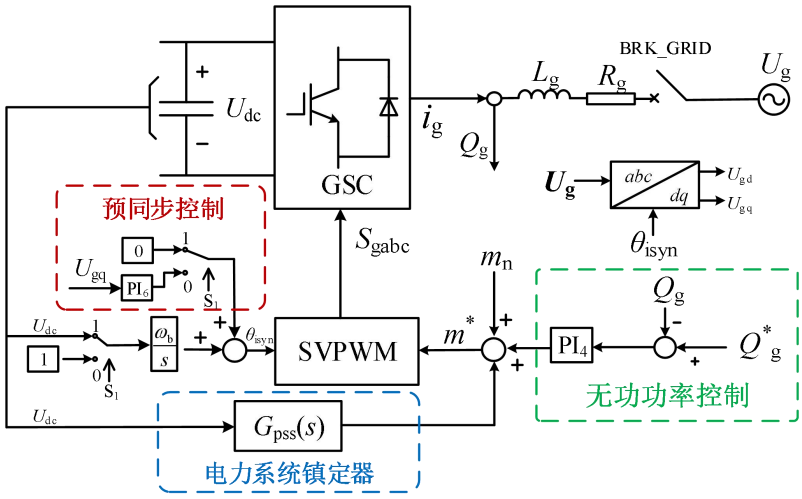


图 5-2 网侧变换器柔性并网控制框图

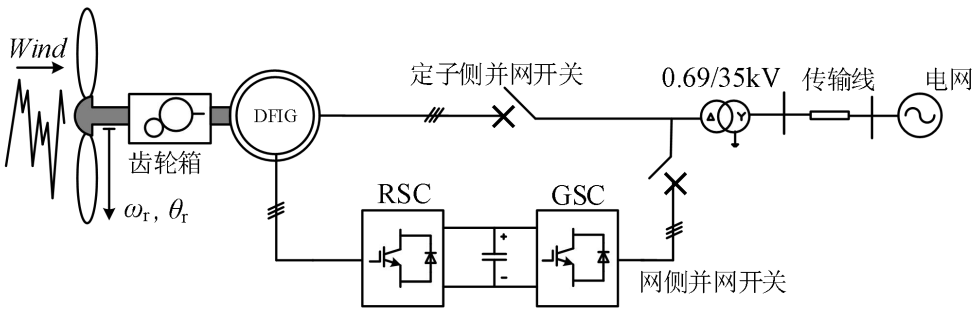


图 5-3 双馈风电机组电气拓扑图

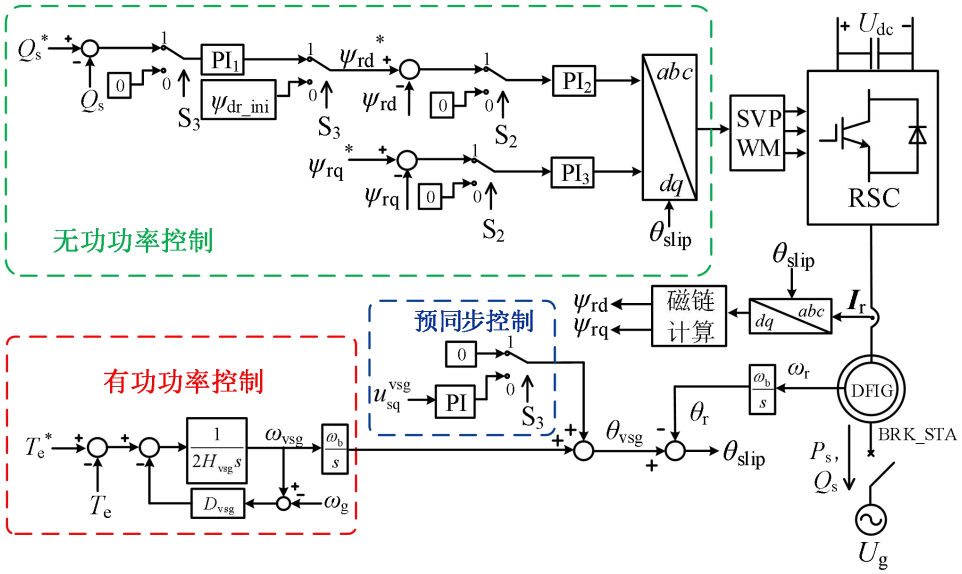


图 5-4 转子侧变换器柔性并网控制框图

具体实施案例如下：

在 RTDS 实时数字仿真器中搭建 2MW 双馈风电机组并网模型，仿真系统结构如图 5-5 所示，双馈风电机组的相关参数见表 5-1、表 5-2。

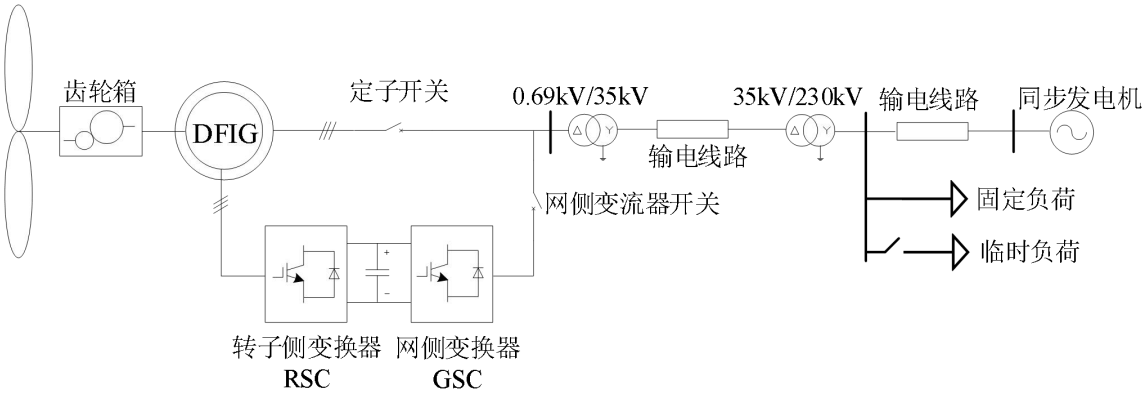


图 5-5 仿真结构示意图

表 5-1 2MW 风力机参数

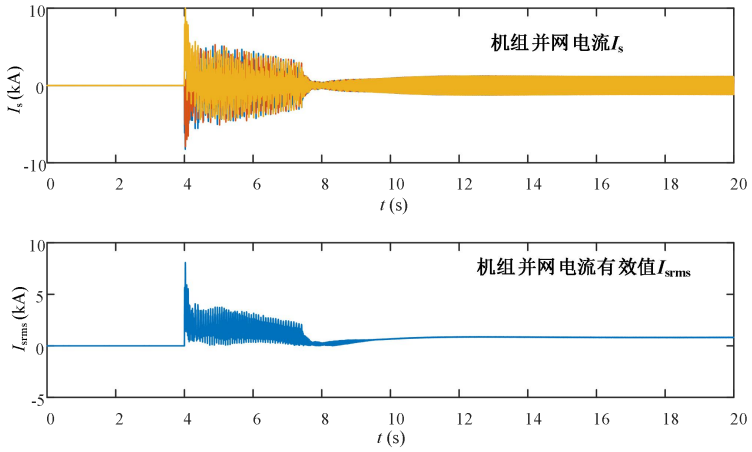
参数名	数值	参数名	数值

额定定子电压/kV	0.69	定子电阻/pu	0.0344
定转子绕组比/pu	0.333	定子漏抗/pu	0.2748
额定功率/MWA	2	励磁电抗/pu	12.97
额定频率/Hz	50	转子电阻/pu	0.0273
直流母线电容/mF	3.6	转子漏抗/pu	0.3979

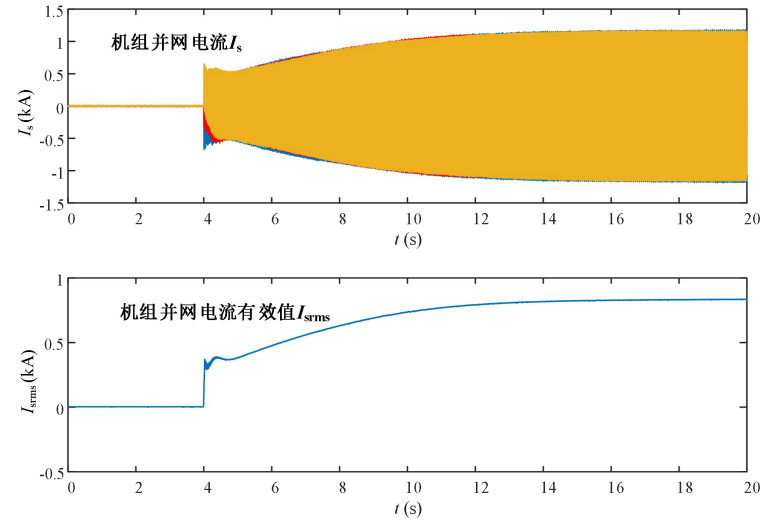
表 5-2 2MW 双馈风电机组电气参数

参数名	数值	参数名	数值
机组气动功率/MW	2.18	额定风速/m/s	11.8
切入风速/m/s	3	切出风速/m/s	25
风轮直径/m	90.76	齿轮箱变比	84.26
C_{pmax}	0.483	最佳叶尖速比	8.37

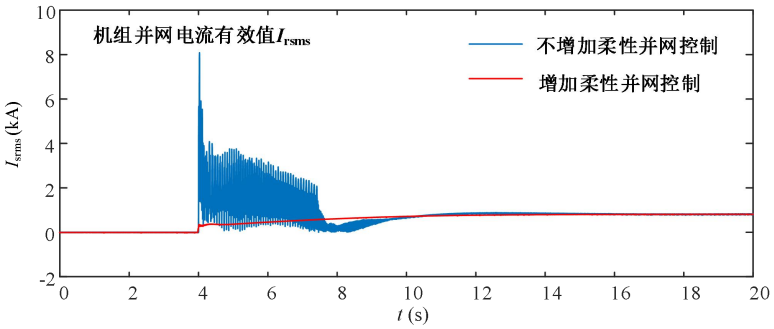
自同步电压源控制柔性并网启动的对比图如图 5-6 所示。当不包含柔性并网策略时，在双馈风电机组的并网瞬间将出现巨大的并网冲击电流，无法体现“柔性并网”的控制需求。当系统中加入柔性并网之后，由于在并网之前已经完成了定子侧电压与电网电压的同步，在电压相角、幅值以及频率上都与电网相同，因此在并网瞬间并没有出现并网冲击电流，体现出巨大的并网优势。



(a)不增加柔性并网控制



(b)　增加柔性并网控制



(c)　机组并网电流对比图

图 5-6　并网策略对比图

6. 其他有助于理解本发明创造的技术资料：

相关专利、公知技术检索结果及其与本发明/实用新型的异同点

关键词：风力发电 柔性并网 双馈风电机组

相关检索结果 1：

申请（专利）号: 201810021480.8

名称: 一种大型风电机组惯量响应优化控制方法

摘要:一种大型风电机组惯量响应优化控制方法，包括以下步骤：1)检测得到发电机、电网频率、风速、桨距角；2)判断风电机组是否运行在变速阶段，是否进入惯量响应控制模式；3)如果是，存储进入该运行模式时刻的初始风速和初始发电机转速；4)对风速进行低通滤波；5)计算得到发电机最优目标控制转速；6)计算得到变速控制环输出的期望发电机转矩；7)计算得到实际输出的发电机期望转矩；8)发电机期望转矩输出给风电机组变流器控制发电机电磁力矩的控制；9)根据电网频率判断惯量响应控制模式是否退出，如果退出，发电机期望转矩以设定斜率恢复跟踪到发电机最优转矩。本发明有效解决惯量响应控制环与变速控制环之间的协调控制和平稳切换。

技术要点比较：

检索到的专利文件提出了一种型风电机组惯量响应优化控制方法，但是，检索到的专利文件所提出的控制方法聚焦于对于风电机组的转矩控制，并没有解决柔性并网控制的问题。

本专利创新性的提出了电压源风电机组在启动阶段的柔性并网控制方法，通过网侧变换器和转子侧变换器的柔性并网控制策略，较好的解决了检索专利中存在的问题。

相关检索结果 2：

申请（专利）号:　201610851761.7

名称: 整流侧变流器的柔性并网方法和装置

摘要: 本发明涉及一种整流侧变流器的柔性并网方法和装置，该方法包括：获取电网实时输入的三相相电压信号；通过坐标变换确定所述三相相电压信号的相位角度；当所述三相相电压信号的相位角度与最佳切换角度的偏差在设定范围内时，驱动整流侧变流器并入电网。本发明依据电网实时输入的三相相电压信号的相位角度，根据预定的策略来进行并网相位角度的控制，即当电网实时输入的三相相电压信号的相位角度与最佳切换角度的偏差在设定范围内时，驱动整流侧变流器并入电网，此时整流侧变流器三相输出电压的幅值与电网三相电压幅值的差值最小，并网冲击电流也较小。因此本发明可以有效减少整流侧变流器并网过程中的冲击电流，实现柔性并网的目的。

技术要点比较：

检索到的专利发明提出了一种整流侧变流器的柔性并网方法和装置，根据预定的策略来进行并网相位角度的控制减小并网冲击电流。然而，检索到的文件提出的控制策略无法适用于双馈电压源风电机组，双馈风电机组的网侧变换器和转子侧变换器均需要重新设计，并针对性提出柔性并网控制策略。

本专利提出了双馈电压源风电机组的柔性并网控制策略，能够避免在并网瞬间产生严重的冲击电流，能够有效解决检索专利中存在的控制问题。

申请材料分析说明

1.基础信息

专利名称：一种电压源风电机组柔性并网控制方法

状态：授权（2024 年 6 月 7 日、优先审查）

2.交底材料

内容较为完整，给出了背景技术、现有技术、现有技术的缺点、本发明的技术方案及其优势，并给出详实的附图以及测试数据。

但是交底材料中对于本发明技术方案的表述不太符合专利撰写的规范，更多是以一种技术说明手册的方式做的操作指导，难以满足专利法所要求的“清楚、完整”。

3.权利要求书

申请时给出了 10 条权利要求，将技术方案的各技术点逐条拆解，为后期审查中针对审查意见答复提供了较为清楚且充足的修改空间。

4.说明书

背景技术部分，清楚交代了本发明所要针对的技术问题——缺乏柔性并网控制，在并网瞬间会产生巨大的冲击电流。

具体实施方式部分，结合附图给出了针对上述技术问题，本发明所提出的柔性并网控制方案；同时还给出了仿真测试数据，用以佐证本发明技术效果的真实有效性，为后期通过审查获得专利授权提供了充足的材料支持。

有益效果部分，结合权利要求的布局，分层次地给出了多条技术效果，并且各条技术效果均做到结合技术特征进行分析说明，说服力强。

申请稿

说明书摘要

本发明提供了一种电压源风电机组柔性并网控制方法，包括网侧变换器柔性并网控制和转子侧变换器柔性并网控制，其中网侧变换器柔性并网控制为控制网侧变换器与电网同步并对直流母线预充电，为转子侧变换器的柔性并网控制提供条件；转子侧变换器柔性并网控制为控制风电机组的转子侧变换器，使定子侧电压满足并网条件。本发明通过分别重新设计网侧变换器的控制策略和转子侧变换器的控制策略，显著减小并网瞬间所出现的并网冲击电流，成功实现柔性并网发电。

权利要求书

1.一种电压源风电机组柔性并网控制方法，其特征在于：包括网侧变换器柔性并网控制和转子侧变换器柔性并网控制，其中先进行网侧变换器柔性并网控制，具体为控制网侧变换器与电网同步并对直流母线预充电，为转子侧变换器的柔性并网控制提供条件；之后进行转子侧变换器柔性并网控制，具体为控制风电机组的转子侧变换器，使定子侧电压满足并网条件。

2.根据权利要求 1 所述的电压源风电机组柔性并网控制方法，其特征在于：所述网侧变换器柔性并网控制为在网侧变换器惯性同步控制的基础上，增加预同步控制，用于控制网侧变换器的输出电压幅值、频率、相位与电网同步；

所述转子侧变换器柔性并网控制包括预同步控制、有功功率控制和无功功率控制；其中转子侧变换器预同步控制为控制风电机组定子电压幅值、频率、相位与电网同步；转子侧变换器有功功率控制为模拟同步发电机的转子运动方程，将虚拟惯量和虚拟阻尼引入控制环路；转子侧变换器无功功率控制为通过 PI 控制器对转子侧变换器无功功率的无差精准控制。

3.根据权利要求 2 所述的电压源风电机组柔性并网控制方法，其特征在于：所述网侧变换器柔性并网控制中，预同步控制为：

初始时，常量 1 输入积分器ω_b/s，电网电压 q 轴分量 u_{gq} 输入 PI 控制器，由所述积分器ω_b/s 与所述 PI 控制器两者结果相加得到网侧变换器电压源控制相角θ_{isyn}；

预充电与同步完成后，切换为将直流母线电压 U_{dc} 输入积分器ω_b/s，并将所述积分器ω_b/s 结果与常量 0 相加，得到网侧变换器电压源控制相角θ_{isyn}。

4.根据权利要求 3 所述的电压源风电机组柔性并网控制方法，其特征在于：所述网侧变换器柔性并网控制还包括无功功率控制：网侧变换器无功功率给定值 Q_g^*与实际值 Q_g 之差输

入 PI 控制器，所述 PI 控制器结果与额定调制比 m_n 以及直流母线电压 U_{dc} 相加，得到网侧变换器的调制比 m^*；

上述调制比 m^* 与预同步控制中得到的电压源控制相角 θ_{isyn} 共同输入 SVPWM 模块，生成脉冲控制信号 S_{gabc} 控制网侧变换器运行。

5.根据权利要求 2 所述的电压源风电机组柔性并网控制方法，其特征在于：所述转子侧变换器无功功率控制为：转子磁链 d 轴分量给定值 ψ_{rd}^* 与实际值 ψ_{rd} 之差输入 PI 控制器，得到反坐标变换的输入 U_{md}；转子磁链 q 轴分量给定值 ψ_{rq}^* 与实际值 ψ_{rq} 之差输入到 PI 控制器，得到反坐标变换的输入 U_{mq}；

其中初始时 ψ_{rd}^* 的取值为转子磁链启动阶段的给定值 ψ_{rd_ini}；与电网的相角同步完成后，定子侧无功功率给定值 Q_s^* 与实际值 Q_s 之差输入 PI 控制器，所得结果作为 ψ_{rd}^* 的取值。

6.根据权利要求 5 所述的电压源风电机组柔性并网控制方法，其特征在于：所述转子侧变换器有功功率控制为：电磁转矩给定值 T_e^* 与实际值 T_e 做差得到转矩差 ΔT_e，虚拟同步角速度 ω_{vsg} 与电网实际频率 ω_g 之差乘以虚拟惯量系数 D_{vsg} 得到虚拟惯量偏差 ΔD；转矩差 ΔT_e 与虚拟惯量偏差 ΔD 的差值输入积分器 $1/2H_{vsg}s$ 得到虚拟同步角速度 ω_{vsg}，虚拟同步角速度 ω_{vsg} 输入积分器 ω_b/s 得到虚拟转矩相角 θ_{Te}。

7.根据权利要求 6 所述的电压源风电机组柔性并网控制方法，其特征在于：所述转子侧预同步控制为：将虚拟转子角 θ_{vsg} 与转子角 θ_r 做差，得到滑差角 θ_{slip}；

其中，初始时定子电压 q 轴分量 u_{sq} 输入 PI 控制器，所得结果与虚拟转矩相角 θ_{Te} 相加，得到虚拟转子角 θ_{vsg}；与电网的相角同步完成后，切换为常量 0 与虚拟转矩相角 θ_{Te} 相加，得到虚拟转子角 θ_{vsg}。

8.根据权利要求 7 所述的电压源风电机组柔性并网控制方法，其特征在于：所述转子侧变换器柔性并网控制中，将 U_{md}、U_{mq} 和 θ_{slip} 输入反坐标变换，所得结果输入 SVPWM 模块，生成脉冲控制信号 S_{rabc} 控制转子侧变换器运行。

9.根据权利要求 2 所述的电压源风电机组柔性并网控制方法，其特征在于：包括以下步骤：

步骤 1，风电机组转速稳定在并网转速后，闭合网侧并网开关，网侧变换器进行预同步控制和无功功率控制，其中预同步控制中，常量 1 输入积分器 ω_b/s，电网电压 q 轴分量 u_{gq} 输入 PI 控制器，上述积分器 ω_b/s 与 PI 控制器两者结果相加，得到网侧变换器电压源控制相角 θ_{isyn}；无功功率控制中，网侧变换器无功功率给定值 Q_g^* 与实际值 Q_g 之差输入 PI 控制器，所得结果与额定调制比 m_n 以及直流母线电压 U_{dc} 相加，得到网侧变换器的调制比 m^*；

步骤 2，网侧变换器直流侧的直流电压 U_{dc} 预充电以及网侧变换器的输出电压与电网电压

之间的同步完成后，网侧变换器切换至电压源控制策略，其中预同步控制中切换为将直流母线电压 U_{dc} 输入积分器ω_b/s，所得结果与常量 0 相加，得到网侧变换器电压源控制相角θ_{isyn}；无功功率控制保持不变；

步骤 3，网侧变换器柔性并网控制完成后，转子侧变换器开始与电网同步；其中无功功率控制中，将转子磁链启动阶段的给定值ψ_{rd_ini}作为转子磁链 d 轴分量给定值ψ_{rd}^*的取值，之后取ψ_{rd}^*与实际的转子磁链 d 轴分量ψ_{rd}之差输入 PI 控制器，得到反坐标变换的输入 U_{md}，将转子磁链 q 轴分量给定值ψ_{rq}^*与实际值ψ_{rq}之差输入到 PI 控制器，得到反坐标变换的输入 U_{mq}；有功功率控制中，电磁转矩给定值 T_e^*与实际值 T_e 做差得到转矩差ΔT_e，虚拟同步角速度ω_{vsg}与电网实际频率ω_g之差乘以虚拟惯量系数 D_{vsg} 得到虚拟惯量偏差ΔD，转矩差ΔT_e 与虚拟惯量偏差ΔD 的差值输入积分器 $1/2H_{vsg}s$ 得到虚拟同步角速度ω_{vsg}，虚拟同步角速度ω_{vsg} 输入积分器ω_b/s 得到虚拟转矩相角θ_{Te}；预同步控制中，定子电压 q 轴分量 u_{sq} 输入 PI 控制器，所得结果与虚拟转矩相角θ_{Te} 相加，得到虚拟转子角θ_{vsg}，虚拟转子角θ_{vsg} 与转子角θ_r 做差，得到滑差角θ_{slip}。

步骤 4，与电网的相角同步完成后，闭合定子侧并网开关进行柔性并网，其中无功功率控制中，切换为将定子侧无功功率给定值 Q_s^*与实际值 Q_s 之差输入 PI 控制器，所得结果作为转子磁链 d 轴分量给定值ψ_{rd}^*的取值，其余保持步骤 3 不变；有功功率控制保持步骤 3 不变；预同步控制中，切换为将常量 0 与虚拟转矩相角θ_{Te} 相加，得到虚拟转子角θ_{vsg}。

10.根据权利要求 9 所述的电压源风电机组柔性并网控制方法，其特征在于：电网电压 U_g 基于θ_{isyn} 进行从 abc 坐标系转换到 dq 坐标系，其中 q 轴分量为 u_{gq}，d 轴分量为 u_{gd}；

转子电流 I_r 基于滑差角θ_{slip} 做 abc 至 dq 的坐标系转换，之后进行磁链计算得到发电机转子磁链的 d 轴分量ψ_{rd}和 q 轴分量ψ_{rq}；定子电压 U_s 基于滑差角θ_{slip} 做 abc 至 dq 的坐标系转换，得到其 d 轴分量 u_{sd} 和 q 轴分量 u_{sq}。

说明书

一种电压源风电机组柔性并网控制方法

本发明属于电力控制技术领域，具体涉及一种电压源风电机组柔性并网控制方法。

背景技术

大型风力发电机组通过变流器接入电网，相比传统的同步发电机，具有控制灵活、响应迅速等优点。但是由于变流器的隔离作用，机组对电网缺少必要的惯量和频率阻尼。对于双馈风电机组（Doubly-fed Induction Generator，DFIG），定子直接挂接电网，转子通过三相交-直-交变流器实现交流励磁；电功率通过定子、转子与电网进行交换。由于风电变流器采用双

闭环控制，电网频率的变化并不会体现在控制策略中，因此不会对风机的转速产生影响，无法利用转子的旋转动能为系统提供惯量支撑。

随着风电渗透率的增加，传统同步发电机在电力系统中所占比例逐渐降低。在此大背景下，风电机组无法参与电网频率调节这一问题，将引发严重的频率稳定问题。一旦电网频率变化超过限额时，将会导致电网切除电源和负荷，甚至引发严重的停电事故。因此使双馈风电机组取得和同步发电机类似的惯量和阻尼特性，体现“电网友好型”并网发电特性，显得尤为重要。

现有常规的双馈风电机组电压源控制方式中，不论是转子侧变换器虚拟同步控制方式，还是网侧变换器惯性同步控制方式，均是针对风电机组稳态运行时的控制方案。但在双馈电压源风电机组的柔性并网启动领域，目前仍缺乏有针对性的柔性并网启动控制策略。而如果不设计特定的柔性并网控制策略，直接采取强行并行并网启动的话；则会在并网瞬间产生巨大的冲击电流，对电力系统的稳定运行产生巨大负面影响。

发明内容

针对现有技术中存在的不足，本发明提供了一种电压源风电机组柔性并网控制方法，实现电压源双馈风电机组的柔性并网控制效果，减少并网瞬间的冲击电流。

本发明通过以下技术手段实现上述技术目的。

一种电压源风电机组柔性并网控制方法：包括网侧变换器柔性并网控制和转子侧变换器柔性并网控制，其中先进行网侧变换器柔性并网控制，具体为控制网侧变换器与电网同步并对直流母线预充电，为转子侧变换器的柔性并网控制提供条件；之后进行转子侧变换器柔性并网控制，具体为控制风电机组的转子侧变换器，使定子侧电压满足并网条件。

进一步地，所述网侧变换器柔性并网控制为在网侧变换器惯性同步控制的基础上，增加预同步控制，用于控制网侧变换器的输出电压幅值、频率、相位与电网同步；

所述转子侧变换器柔性并网控制包括预同步控制、有功功率控制和无功功率控制；其中转子侧变换器预同步控制为控制风电机组定子电压幅值、频率、相位与电网同步；转子侧变换器有功功率控制为模拟同步发电机的转子运动方程，将虚拟惯量和虚拟阻尼引入控制环路；转子侧变换器无功功率控制为通过 PI 控制器对转子侧变换器无功功率的无差精准控制。

进一步地，所述网侧变换器柔性并网控制中，预同步控制为：

初始时，常量 1 输入积分器ω_b/s，电网电压 q 轴分量 u_{gq} 输入 PI 控制器，由所述积分器ω_b/s 与所述 PI 控制器两者结果相加得到网侧变换器电压源控制相角θ_{isyn}；

预充电与同步完成后，切换为将直流母线电压 U_{dc} 输入积分器ω_b/s，并将所述积分器ω_b/s

结果与常量 0 相加，得到网侧变换器电压源控制相角θ_{isyn}。

进一步地，所述网侧变换器柔性并网控制还包括无功功率控制：网侧变换器无功功率给定值 Q_g^*与实际值 Q_g之差输入 PI 控制器，所述 PI 控制器结果与额定调制比 m_n 以及直流母线电压 U_{dc}相加，得到网侧变换器的调制比 m^*；

上述调制比 m^*与预同步控制中得到的电压源控制相角θ_{isyn}共同输入 SVPWM 模块，生成脉冲控制信号 S_{gabc}控制网侧变换器运行。

进一步地，所述转子侧变换器无功功率控制为：转子磁链 d 轴分量给定值ψ_{rd}^*与实际值ψ_{rd}之差输入 PI 控制器，得到反坐标变换的输入 U_{md}；转子磁链 q 轴分量给定值ψ_{rq}^*与实际值ψ_{rq}之差输入到 PI 控制器，得到反坐标变换的输入 U_{mq}；

其中初始时ψ_{rd}^*的取值为转子磁链启动阶段的给定值ψ_{rd_ini}；与电网的相角同步完成后，定子侧无功功率给定值 Q_s^*与实际值 Q_s之差输入 PI 控制器，所得结果作为ψ_{rd}^*的取值。

进一步地，所述转子侧变换器有功功率控制为：电磁转矩给定值 T_e^*与实际值 T_e做差得到转矩差ΔT_e，虚拟同步角速度ω_{vsg}与电网实际频率ω_g之差乘以虚拟惯量系数 D_{vsg}得到虚拟惯量偏差ΔD；转矩差ΔT_e与虚拟惯量偏差ΔD的差值输入积分器 $1/2H_{vsg}s$ 得到虚拟同步角速度ω_{vsg}，虚拟同步角速度ω_{vsg}输入积分器ω_b/s 得到虚拟转矩相角θ_{Te}。

进一步地，所述转子侧预同步控制为：将虚拟转子角θ_{vsg}与转子角θ_r做差，得到滑差角θ_{slip}；

其中，初始时定子电压 q 轴分量 u_{sq}输入 PI 控制器，所得结果与虚拟转矩相角θ_{Te}相加，得到虚拟转子角θ_{vsg}；与电网的相角同步完成后，切换为常量 0 与虚拟转矩相角θ_{Te}相加，得到虚拟转子角θ_{vsg}。

进一步地，所述转子侧变换器柔性并网控制中，将 U_{md}、U_{mq}和θ_{slip}输入反坐标变换，所得结果输入 SVPWM 模块，生成脉冲控制信号 S_{rabc}控制转子侧变换器运行。

进一步地，包括以下步骤：

步骤 1，风电机组转速稳定在并网转速后，闭合网侧并网开关，网侧变换器进行预同步控制和无功功率控制，其中预同步控制中，常量 1 输入积分器ω_b/s，电网电压 q 轴分量 u_{gq}输入 PI 控制器，上述积分器ω_b/s 与 PI 控制器两者结果相加，得到网侧变换器电压源控制相角θ_{isyn}；无功功率控制中，网侧变换器无功功率给定值 Q_g^*与实际值 Q_g之差输入 PI 控制器，所得结果与额定调制比 m_n 以及直流母线电压 U_{dc}相加，得到网侧变换器的调制比 m^*；

步骤 2，网侧变换器直流侧的直流电压 U_{dc}预充电以及网侧变换器的输出电压与电网电压之间的同步完成后，网侧变换器切换至电压源控制策略，其中预同步控制中切换为将直流母线电压 U_{dc}输入积分器ω_b/s，所得结果与常量 0 相加，得到网侧变换器电压源控制相角θ_{isyn}；无功功率控制保持不变；

步骤 3，网侧变换器柔性并网控制完成后，转子侧变换器开始与电网同步；其中无功功率控制中，将转子磁链启动阶段的给定值ψ_{rd_ini}作为转子磁链 d 轴分量给定值ψ_{rd}^{*}的取值，之后取ψ_{rd}^{*}与实际的转子磁链 d 轴分量ψ_{rd}之差输入 PI 控制器，得到反坐标变换的输入 U_{md}，将转子磁链 q 轴分量给定值ψ_{rq}^{*}与实际值ψ_{rq}之差输入到 PI 控制器，得到反坐标变换的输入 U_{mq}；有功功率控制中，电磁转矩给定值 T_e^{*}与实际值 T_e 做差得到转矩差ΔT_e，虚拟同步角速度ω_{vsg}与电网实际频率ω_g之差乘以虚拟惯量系数 D_{vsg} 得到虚拟惯量偏差ΔD，转矩差ΔT_e 与虚拟惯量偏差ΔD 的差值输入积分器 $1/2H_{vsg}s$ 得到虚拟同步角速度ω_{vsg}，虚拟同步角速度ω_{vsg} 输入积分器ω_b/s 得到虚拟转矩相角θ_{Te}；预同步控制中，定子电压 q 轴分量 u_{sq} 输入 PI 控制器，所得结果与虚拟转矩相角θ_{Te} 相加，得到虚拟转子角θ_{vsg}，虚拟转子角θ_{vsg} 与转子角θ_r 做差，得到滑差角θ_{slip}。

步骤 4，与电网的相角同步完成后，闭合定子侧并网开关进行柔性并网，其中无功功率控制中，切换为将定子侧无功功率给定值 Q_s^{*}与实际值 Q_s 之差输入 PI 控制器，所得结果作为转子磁链 d 轴分量给定值ψ_{rd}^{*}的取值，其余保持步骤 3 不变；有功功率控制保持步骤 3 不变；预同步控制中，切换为将常量 0 与虚拟转矩相角θ_{Te} 相加，得到虚拟转子角θ_{vsg}。

进一步地，电网电压 U_g 基于θ_{isyn} 进行从 abc 坐标系转换到 dq 坐标系，其中 q 轴分量为 u_{gq}，d 轴分量为 u_{gd}；

转子电流 I_r 基于滑差角θ_{slip} 做 abc 至 dq 的坐标系转换，之后进行磁链计算得到发电机转子磁链的 d 轴分量ψ_{rd} 和 q 轴分量ψ_{rq}；定子电压 U_s 基于滑差角θ_{slip} 做 abc 至 dq 的坐标系转换，得到其 d 轴分量 u_{sd} 和 q 轴分量 u_{sq}。

本发明的有益效果为：

（1）本发明提供了一种电压源风电机组柔性并网控制方法，其中通过重新设计网侧变换器的控制策略，有效减小了网侧变换器并网时的冲击电流；通过重新设计转子侧变换器的控制策略，减小转子侧变换器并网时的冲击电流。最终通过重新渗剂并网控制逻辑，当满足电压源风电机组并网条件时闭合并网开关，与现有控制方式相比，能够显著减小并网瞬间所出现的并网冲击电流，成功实现柔性并网发电。

（2）本发明网侧变换器控制策略中，通过引入预同步控制，以控制网侧变换器的输出电压和电网电压的幅值、频率、相位均相同，实现与电网同步。

（3）本发明转子侧变换器控制策略中，通过预同步控制使风电机组定子电压幅值、频率、相位与电网同步；通过有功功率控制模拟同步发电机的转子运动方程，将虚拟惯量和虚拟阻尼引入控制环路；最后无功功率控制，则利用 PI 控制器对转子侧变换器无功功率的无差精准控制。

附图说明

图 1 为双馈风电机组电器拓扑图；

图 2 为本发明改进的网侧变换器柔性并网控制框图；

图 3 为现有网侧变换器惯性同步控制框图；

图 4 为本发明改进的转子侧变换器柔性并网控制框图；

图 5 为现有转子侧变换器虚拟同步控制框图；

图 6 为用于测试所搭建的双馈风电机组并网模型结构图；

图 7 为按现有并网控制方式测得的机组并网电流数据变化图；

图 8 为按本发明控制方式测得的机组并网电流数据变化图；

图 9 为本发明与现有控制方式的数据对比图。

具体实施方式

下面详细描述本发明的实施例，所示实施例的示例在附图中示出，其中自始至终相通或类似的标号表示相同或类似的元件或具有相同或类似功能的元件。下面通过参考附图描述的实施例是示例性的，旨在用于解释本发明，而不能理解为对本发明的限制。

一、现有技术

如图 1 所示为双馈风电机组电器拓扑图，图中 RSC 表示转子侧变换器，GSC 表示网侧变换器。针对上述双馈风电机组，现有常见的是采用转子侧变换器虚拟同步控制加网侧变换器惯性同步控制的组合控制方式。其中（1）在转子侧虚拟同步控制中，将发电机的定子和转子分别等效为传统同步发电机的定子回路和转子回路，建立电网同步参考系和同步发电机转子参考系，将双馈发电机的转子磁链按照同步发电机的转子参考系定向，以此实现励磁控制。相应的转子侧控制框图如图 5 所示。（2）在网侧变换器惯性同步控制中，利用直流母线电容充当电网同步过程中的能量缓冲元件，无需锁相环即实现与电网的同步。相应的网侧控制框图如图 3 所示。

二、本发明

在现有技术的基础上，图 2 所示为本发明网侧变换器柔性并网控制框图，图 4 所示为本发明转子侧变换器柔性并网控制框图。

附图中符号含义说明：

图 2 中 U_g 为电网电压，u_{gq} 和 u_{gd} 分别为 U_g 在 dq 坐标系下的 q 轴分量和 d 轴分量，L_g 和 R_g 分别为等效的电网电感和电网电阻，Q_g^* 为网侧变换器的无功功率给定值，Q_g 为网侧变换器的无功功率实际值，U_{dc} 为网侧变换器直流侧的直流电压，θ_{isyn} 为网侧变换器电压源控制相

角，m_n为额定调制比，m^*为网侧变换器的调制比，S_{gabc}为脉冲控制信号；BRK_GRID 表示网侧并网开关，PI 表示 PI 控制器（比例积分控制器），ω_b/s 表示积分器，SVPWM 表示空间矢量脉宽调制模块。

图 4 中 U_s 为定子电压，u_{sq} 和 u_{sd} 分别为 U_s 在 dq 坐标系下的 q 轴分量和 d 轴分量，Q_s^*为定子侧无功功率给定值，Q_s 为定子侧无功功率实际值，I_r 为转子电流，θ_r 为转子角度，T_e^*为发电机电磁转矩给定值，T_e 为实际值，ΔT_e 为给定值 T_e^*与实际值 T_e 之间的转矩差，ω_g 为电网频率，ω_{vsg} 为虚拟同步角速度，D_{vsg} 为虚拟惯量系数，ΔD 为虚拟惯量偏差，θ_{slip} 为滑差角，θ_{Te} 为虚拟转矩相角，θ_{vsg} 为虚拟转子角，ψ_{rq} 和ψ_{rd} 分别为发电机转子磁链的 q 轴分量和 d 轴分量，ψ_{rq}^*为转子磁链 q 轴分量的给定值，ψ_{rd}^*为转子磁链 d 轴分量的给定值，ψ_{rd_ini} 为转子磁链启动阶段的给定值，S_{rabc} 为脉冲控制信号；BRK_STA 表示定子侧并网开关。

参照图 2 和图 4，本发明电压源风电机组柔性并网控制方法包括网侧变换器柔性并网控制和转子侧变换器柔性并网控制。其中网侧变换器柔性并网控制用于控制电压源网侧变换器与电网同步，并对直流母线预充电，为转子侧变换器的柔性并网控制提供条件。转子侧变换器柔性并网控制用于控制风电机组的转子侧变换器，使得定子侧电压和电网电压满足并网条件。具体包括以下步骤：

步骤 1，直流母线预充电，网侧变换器与电网同步

如图 2 所示，当风电机组的转速已经稳定在并网转速后，闭合网侧并网开关 BRK_GRID，网侧变换器开始进行①预同步控制和②无功功率控制。其中①预同步控制为控制网侧变换器的输出电压和电网电压的幅值、频率、相位均相同，实现与电网同步。②无功功率控制为通过 PI 控制器实现对网侧变换器无功功率的无差精准控制。具体控制策略如下：

（1）预同步控制：此时输入选择模块（图中标号“输入选择 2”）将常量 1 输入积分器ω_b/s，电网电压 U_g 的 q 轴分量 u_{gq} 输入 PI 控制器；之后输入选择模块（图中标号“输入选择 1”）将上述 PI 控制器的结果与所述积分器ω_b/s 两者结果相加，得到网侧变换器电压源控制相角θ_{isyn}。

注：所得到的网侧变换器电压源控制相角θ_{isyn} 又反过来影响 u_{gq}。电网电压 U_g 基于θ_{isyn} 进行坐标转换，从 abc 坐标系转换到 dq 坐标系，其中 q 轴分量为 u_{gq}，d 轴分量为 u_{gd}。

（2）无功功率控制：网侧变换器无功功率给定值 Q_g^*减去实际值 Q_g，将两者之差输入 PI 控制器。上述 PI 控制器的结果与额定调制比 m_n 以及直流母线电压 U_{dc} 相加，得到网侧变换器的调制比 m^*。

最终，网侧变换器的调制比 m^*与网侧变换器电压源控制相角θ_{isyn} 共同输入到 SVPWM 模块，生成脉冲控制信号 S_{gabc}。将脉冲控制信号 S_{gabc} 输入到网侧变换器 GSC，控制网侧变换器运行。

步骤 2，预充电（指网侧变换器直流侧的直流电压 U_{dc} 预充电）与同步（指网侧变换器的输出电压与电网电压之间的同步）完成后，网侧变换器切换至电压源控制策略。此时在步骤 1 的基础上：

（1）预同步控制中，图中“输入选择 2”切换为将直流母线电压 U_{dc} 输入积分器ω_b/s，“输入选择 1”切换为将常量 0 与上述积分器ω_b/s 的结果相加，得到网侧变换器电压源控制相角θ_{isyn}。

（2）无功功率控制保持步骤 1 不变，得到网侧变换器的调制比 m^*。

最终，网侧变换器电压源控制相角θ_{isyn}和网侧变换器的调制比 m^*共同输入到 SVPWM 模块生成脉冲控制信号 S_{gabc}，基于脉冲控制信号 S_{gabc} 控制网侧变换器运行。

至此，网侧变换器预同步与柔性并网控制完成，接下来进行转子侧变换器的柔性并网控制。

步骤 3，转子侧变换器与电网同步

如图 4 所示，转子侧变换器柔性并网控制包括①预同步控制、②有功功率控制和③无功功率控制。其中①转子侧变换器的预同步控制用于控制风电机组的定子电压幅值、频率、相位保持与电网电压相同，实现与电网同步；②转子侧变换器的有功功率控制用于模拟同步发电机的转子运动方程，将虚拟惯量和虚拟阻尼引入控制环路，实现和同步发电机类似的虚拟惯量控制效果；③转子侧变换器的无功功率控制用于通过 PI 控制器实现对转子侧变换器无功功率的无差精准控制。各部分控制具体如下：

（1）无功功率控制：输入选择模块（图中标号“输入选择 4”）将转子磁链启动阶段的给定值ψ_{rd_ini}作为转子磁链 d 轴分量给定值ψ_{rd}^*的取值（注：当前与ψ_{rd_ini}并行作为“输入选择 4”选项之一的 PI 控制器暂时无需工作，未避免所述 PI 控制器始终保持积分状态进而导致饱和失效，此时可通过图中“输入选择 3”输入常量 0 给此 PI 控制器使其停止工作），之后取ψ_{rd}^*与实际的转子磁链 d 轴分量ψ_{rd}之差输入到 PI 控制器，得到反坐标变换的输入 U_{md}；将转子磁链 q 轴分量给定值ψ_{rq}^*与实际的转子磁链 q 轴分量ψ_{rq}之差输入到 PI 控制器，得到反坐标变换的输入 U_{mq}。

（2）有功功率控制：电磁转矩给定值 T_e^*与实际值 T_e 做差得到转矩差ΔT_e；虚拟同步角速度ω_{vsg}与电网实际频率ω_g之差乘以虚拟惯量系数 D_{vsg}，得到虚拟惯量偏差ΔD；转矩差ΔT_e与虚拟惯量偏差ΔD 的差值输入到积分器 $1/2H_{vsg}s$，得到虚拟同步角速度ω_{vsg}；最后，虚拟同步角速度ω_{vsg}输入到积分器ω_b/s，得到虚拟转矩相角θ_{Te}。

（3）预同步控制：定子电压 q 轴分量 u_{sq} 输入到 PI 控制器，输入选择模块（图中标号“输入选择 5”）将上述 PI 控制器的输出结果与虚拟转矩相角θ_{Te}相加，得到虚拟转子角θ_{vsg}；虚拟

转子角θ_{vsg}与转子角θ_r做差，得到滑差角θ_{slip}。

最终，U_{md}、U_{mq}和滑差角θ_{slip}输入到反坐标变换，反坐标变换的结果输入到 SVPWM 模块，生成脉冲控制信号 S_{rabc}。S_{rabc}输入到转子侧变换器 RSC，控制转子侧变换器运行。

注：基于滑差角θ_{slip}将转子电流 I_r做 abc 至 dq 的坐标系转换，之后进行磁链计算得到发电机转子磁链的 d 轴分量ψ_{rd}和 q 轴分量ψ_{rq}。基于滑差角θ_{slip}将定子电压 U_s做 abc 至 dq 的坐标系转换，得到其 d 轴分量 u_{sd}和 q 轴分量 u_{sq}。

步骤 4，与电网的相角同步完成后，闭合定子侧并网开关 BRK_STA，以进行柔性并网。此时，在步骤 3 的基础上：

（1）无功功率控制中，图中“输入选择 3”切换为将定子侧无功功率给定值 Q_s^*与实际值 Q_s之差输入 PI 控制器，之后图中“输入选择 4”将上述 PI 控制器的输出结果作为转子磁链 d 轴分量给定值ψ_{rd}^*的取值。其余保持步骤 3 不变，从而分别得到反坐标变换的输入 U_{md}和 U_{mq}。

（2）有功功率控制保持步骤 3 不变，得到虚拟转矩相角θ_{Te}。

（3）预同步控制中，图中“输入选择 5”切换为将常量 0 与虚拟转矩相角θ_{Te}相加，得到虚拟转子角θ_{vsg}。

最终，U_{md}、U_{mq}和滑差角θ_{slip}输入到反坐标变换，反坐标变换的结果输入到 SVPWM 模块生成脉冲控制信号 S_{rabc}。S_{rabc}输入到转子侧变换器 RSC，控制转子侧侧变换器运行。

至此，转子侧变换器预同步与柔性并网控制完成。

三、仿真测试

在 RTDS 实时数字仿真器中搭建 2MW 双馈风电机组并网模型，相应仿真系统结构图如图 6 所示；双馈风电机组的相关参数设置如下表 1 和表 2 所示：

表 1：2MW 风力机参数

参数名	数值	参数名	数值
额定定子电压/kV	0.69	定子电阻/pu	0.0344
定转子绕组比/pu	0.333	定子漏抗/pu	0.2748
额定功率/MWA	2	励磁电抗/pu	12.97
额定频率/Hz	50	转子电阻/pu	0.0273
直流母线电容/mF	3.6	转子漏抗/pu	0.3979

表 2：2MW 双馈风电机组电气参数

参数名	数值	参数名	数值
机组气动功率/MW	2.18	额定风速/m/s	11.8
切入风速/m/s	3	切出风速/m/s	25
风轮直径/m	90.76	齿轮箱变比	84.26

	C_{pmax}	0.483	最佳叶尖速比	8.37

基于上述搭建的双馈风电机组并网模型做对比测试，相关测试结果如图 7~图 9 所示。其中图 7 为按现有控制方式进行的并网控制，图 8 所示为按本发明控制方式进行的柔性并网控制，图 9 为现有并网控制与本发明柔细并网控制两者并网电流对比。基于图 7~图 9 所示可直观看出，当采用现有控制方式直接进行并网控制时，在双馈风电机组的并网瞬间出现巨大的并网冲击电流。而当采用本发明柔性并网控制时，通过在并网之前已经完成了定子侧电压相角、幅值以及频率与电网的同步，由此在并网瞬间没有出现并网冲击电流，体现出非常显著的并网优势。

本发明并不限于上述实施方式，在不背离本发明的实质内容的情况下，本领域技术人员能够做出的任何显而易见的改进、替换或变形均属于本发明的保护范围。

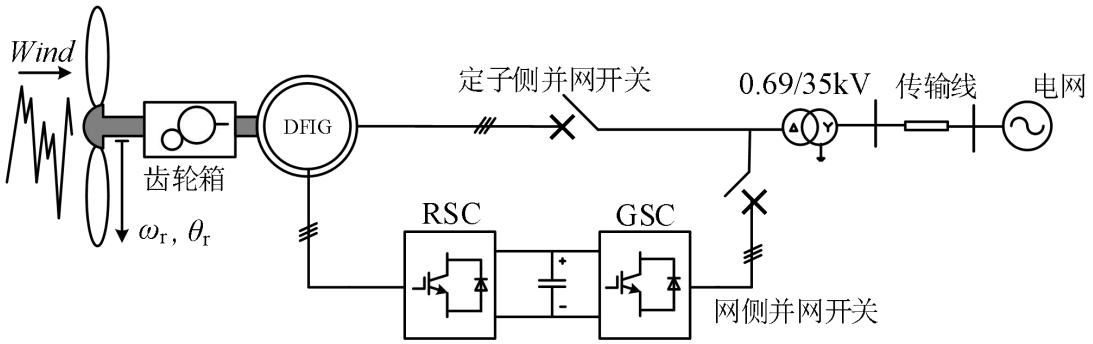

Wind
齿轮箱
ω_r, θ_r
DFIG
定子侧并网开关
0.69/35kV
传输线
电网
RSC
GSC
网侧并网开关

图 1

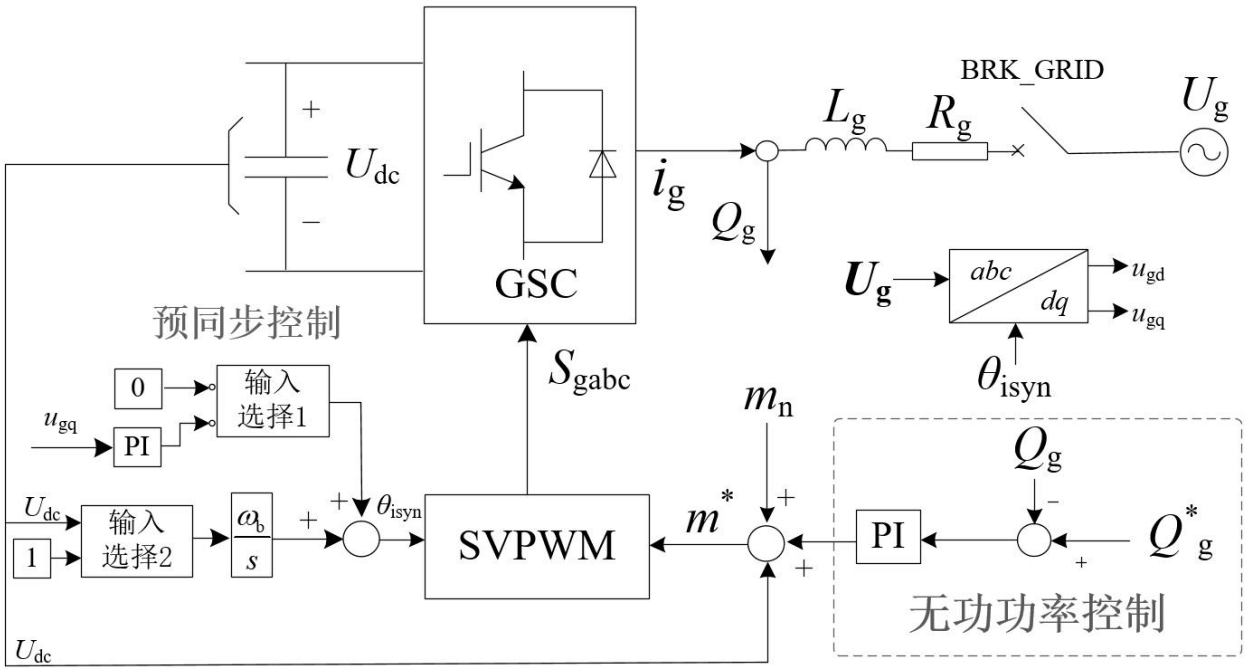

BRK_GRID
L_g
R_g
U_g
U_{dc}
i_g
Q_g
GSC
预同步控制
U_g
abc
dq
u_{gd}
u_{gq}
θ_{isyn}
S_{gabc}
m_n
0
输入选择1
u_{gq}
PI
U_{dc}
1
输入选择2
ω_b
s
θ_{isyn}
SVPWM
m^*
PI
Q_g
Q^*_g
无功功率控制
U_{dc}

图 2

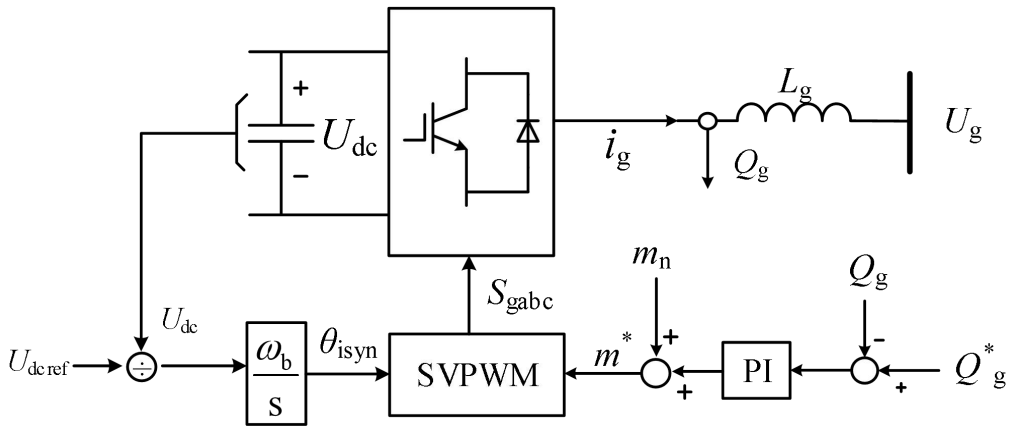

U_{dc}
i_g
L_g
Q_g
U_g
S_{gabc}
m_n
Q_g
U_{dc}
$U_{dc\,ref}$
ω_b
S
θ_{isyn}
SVPWM
m^*
PI
Q^*_g

图 3

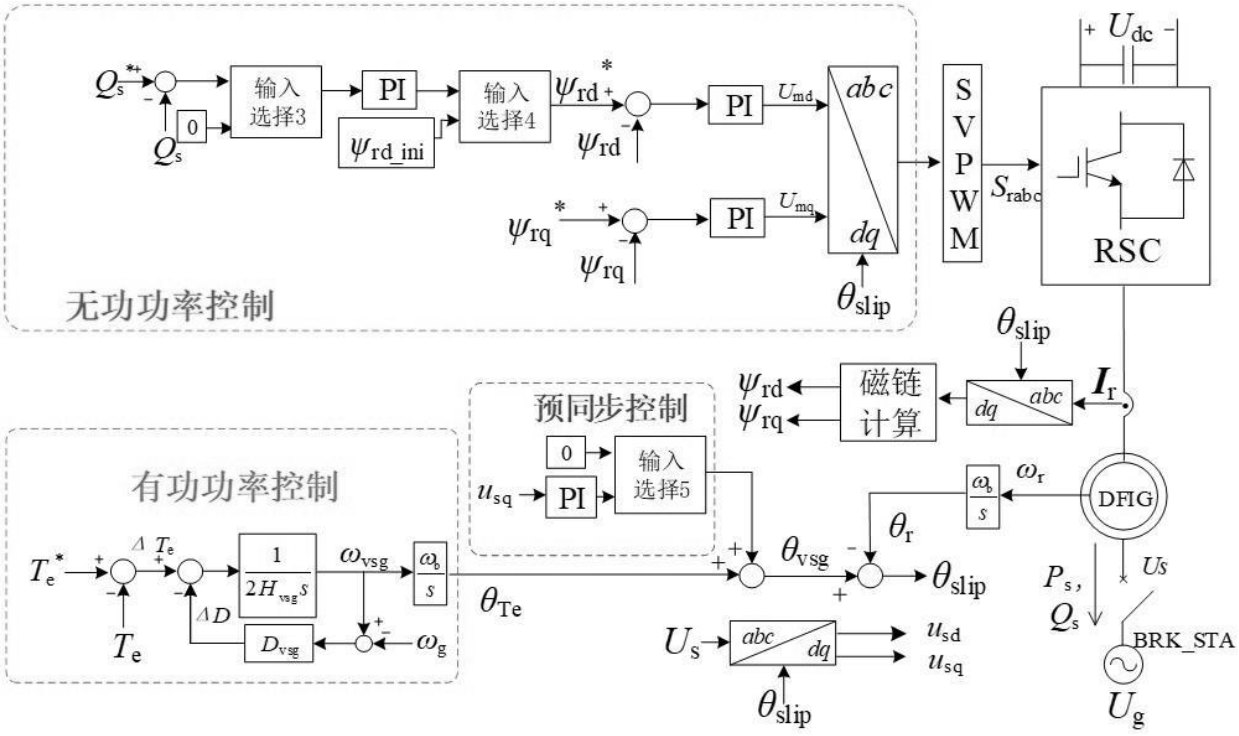

无功功率控制
输入选择3
PI
输入选择4
PI
PI
SVPWM
RSC
abc
dq
磁链计算
预同步控制
输入选择5
有功功率控制
DFIG
BRK_STA
前馈计算
磁链计算

图 4

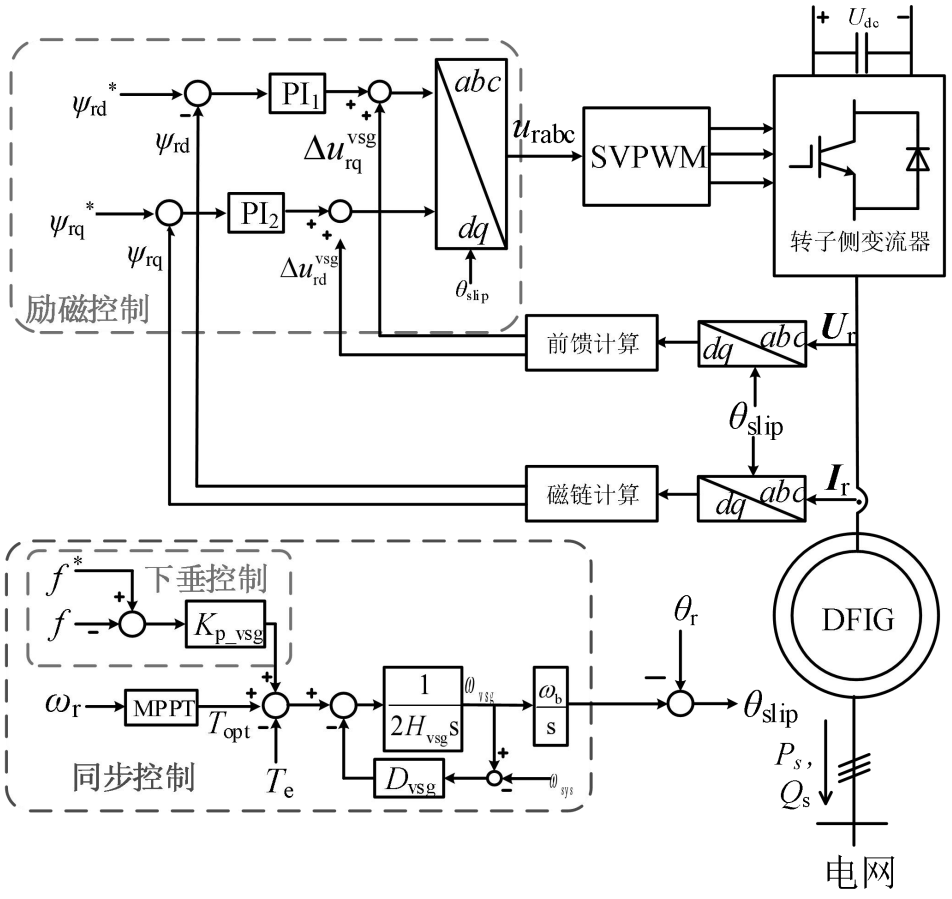

励磁控制
SVPWM
转子侧变流器
前馈计算
磁链计算
下垂控制
同步控制
MPPT
DFIG
电网

图 5

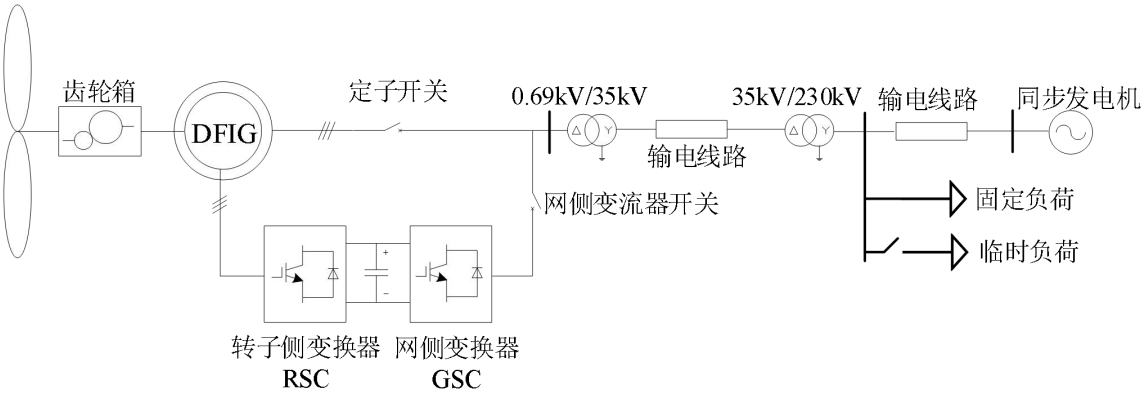

齿轮箱
DFIG
定子开关
0.69kV/35kV
35kV/230kV
输电线路
同步发电机
输电线路
网侧变流器开关
固定负荷
临时负荷
转子侧变换器
RSC
网侧变换器
GSC

图 6

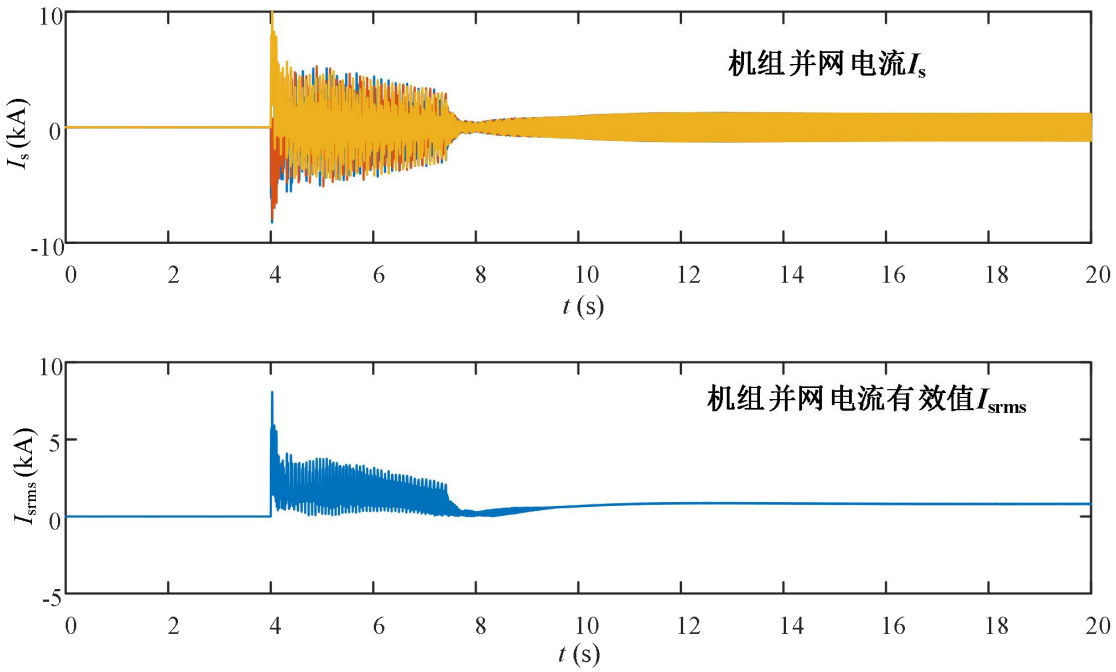

机组并网电流I_s
I_s (kA)
t (s)
机组并网电流有效值I_{srms}
I_{srms} (kA)
t (s)

图 7

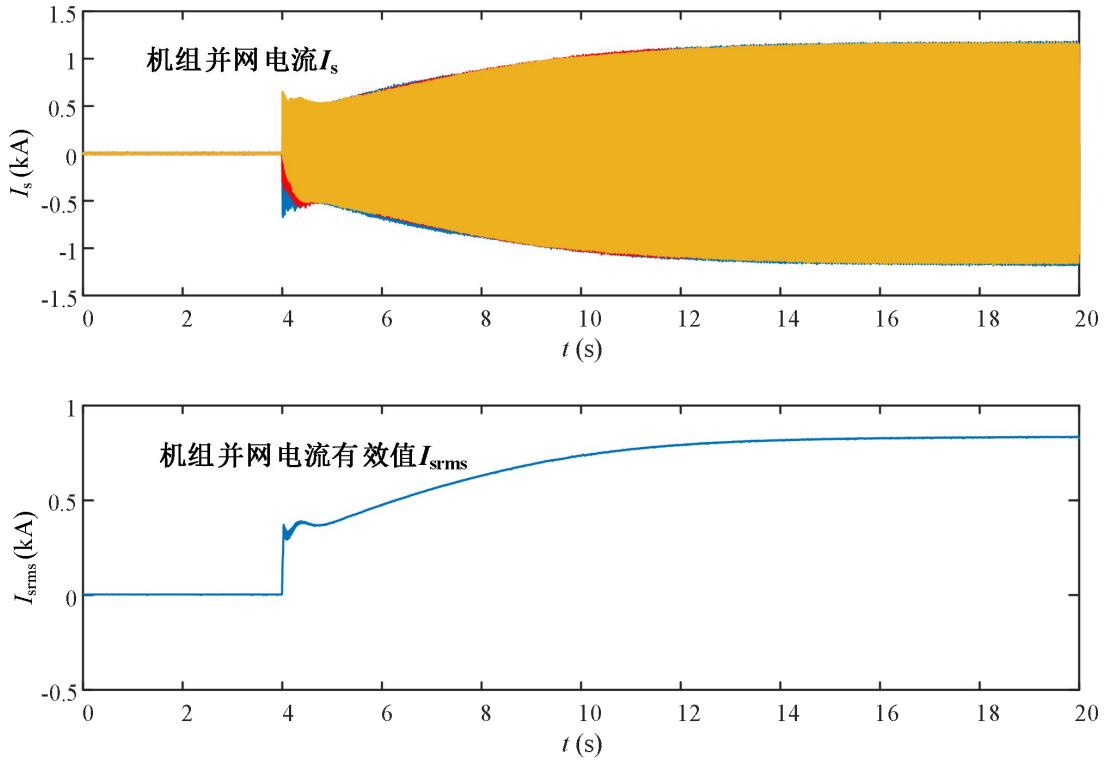

机组并网电流I_s
I_s (kA)
t (s)
机组并网电流有效值I_{srms}
I_{srms} (kA)
t (s)

图 8

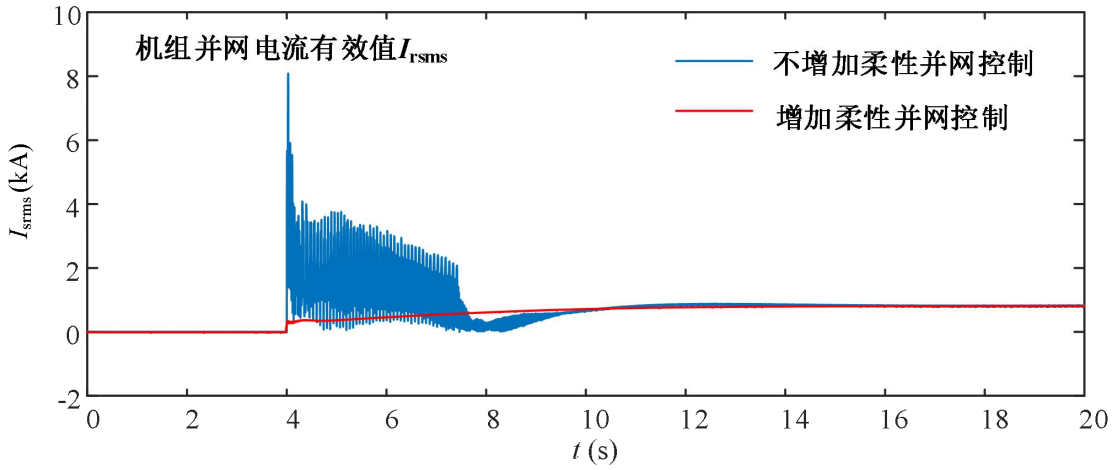

机组并网电流有效值I_{rsms}
不增加柔性并网控制
增加柔性并网控制
I_{srms} (kA)
t (s)

图 9

一种双馈电压源风电机组转速-惯量组合控制方法（发明）

技术交底书

1. 相关背景技术及现有技术发展情况：

1.1 背景技术

人类的经济和社会发展离不开能源的支撑。目前，绿色能源的发展正处于一个转折点。我们正在努力开发风能、太阳能、潮汐能、生物质能等可再生能源，以取代传统的化石燃料。这些可再生能源已经成为全球各国应对能源危机的重要途径，并开启了人类对自然资源利用的新时代。高比例的可再生能源的接入也将会对传统的电力系统的运行和管理带来变革。在这些可再生能源中，风能因其广泛分布、环境友好、技术成熟、可行性和成本优势而受到世界各国的青睐，在全球可再生能源的发展和利用中占据了核心地位。同时，风电在优化能源结构、增加社会就业、提高能源自给率等方面都发挥了重要作用。

大型风力发电机组通过变流器接入电网，相比于传统的同步发电机，具有控制灵活、响应迅速等优点，但是由于变流器的隔离作用，机组对电网缺少必要的惯量和频率阻尼。对于双馈风电机组（Doubly-fed Induction Generator，DFIG），定子直接挂接电网，转子通过三相交-直-交变流器实现交流励磁，电功率可以通过定子、转子与电网进行交换，在双馈风电机组传统的控制方法中，通常采用基于矢量控制的双闭环控制结构来实现有功功率和无功功率的解耦控制，将有功功率和无功功率作为功率外环的控制给定，定子电压定向的控制中控制转子电流的 d 轴分量 i_{rd} 即可控制双馈发电机的有功功率，控制转子电流的 q 轴分量 i_{rq} 即可控制双馈发电机的无功功率，但是这种控制方法本质上属于电流源的控制方式，电网频率的变化并不会体现在控制策略中，因此不会对风机的转速产生影响，无法利用转子的旋转动能为系统提供惯量支撑。随着风电渗透率的增加，传统同步发电机在电力系统中所占的比例逐渐降低，风电机组无法参与电网频率的调节，这将引发严重的频率稳定问题，而当电网的频率变化超过限额，则将导致电网切除电源或负荷甚至引发严重的停电事故。

因此，为了使得双馈风电机组取得和同步发电机类似的惯量和阻尼特性，体现“电网友好型”型并网发电特性，一种改进方式为“风电机组电压控制型技术路线”，即：将风电机组控制为电压源，其外特性与同步发电机类似，能够自主建立电压，实时响应功率平衡，输出功率能够自动响应负荷的变化，体现出和传统同步发电机类似的“电网友好型”并网发电特点。

1.2 与本发明创造相关的现有技术

1.2.1 现有技术的技术方案

现有的双馈电压源风电机组的控制技术方法如下：通常采用转子侧变换器虚拟同步控制-

网侧变换器惯性同步控制的组合控制技术方案，如图 1-1 所示。

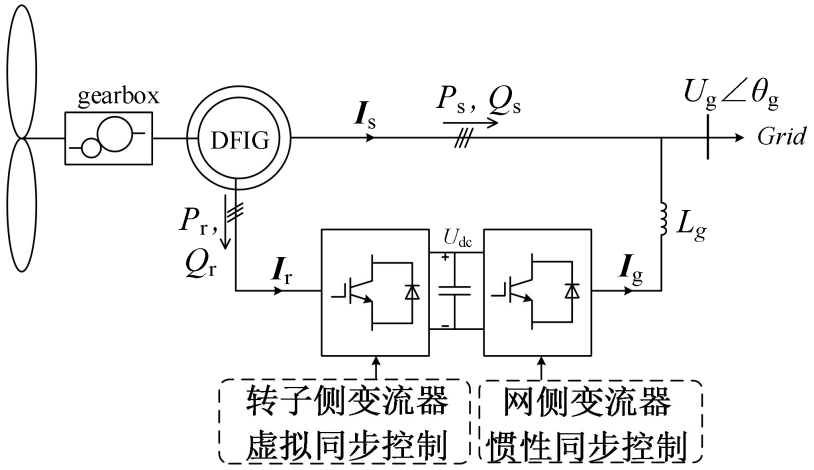


图 1-1 转子侧虚拟同步-网侧惯性同步控制示意图

在转子侧变换器虚拟同步控制方式中，将发电机的定子和转子分别等效为传统同步发电机的定子回路和转子回路，建立电网同步参考系和同步发电机转子参考系，将双馈发电机的转子磁链按照同步发电机的转子参考系定向，从而实现励磁控制。如图 1-2 所示，同步控制环模拟同步发电机的转子运动方程，实现最大功率跟踪并输出转子磁链定向的转子角；励磁控制环用于在风电机组运行过程中保持转子磁链恒定，进而保持内电势的稳定。

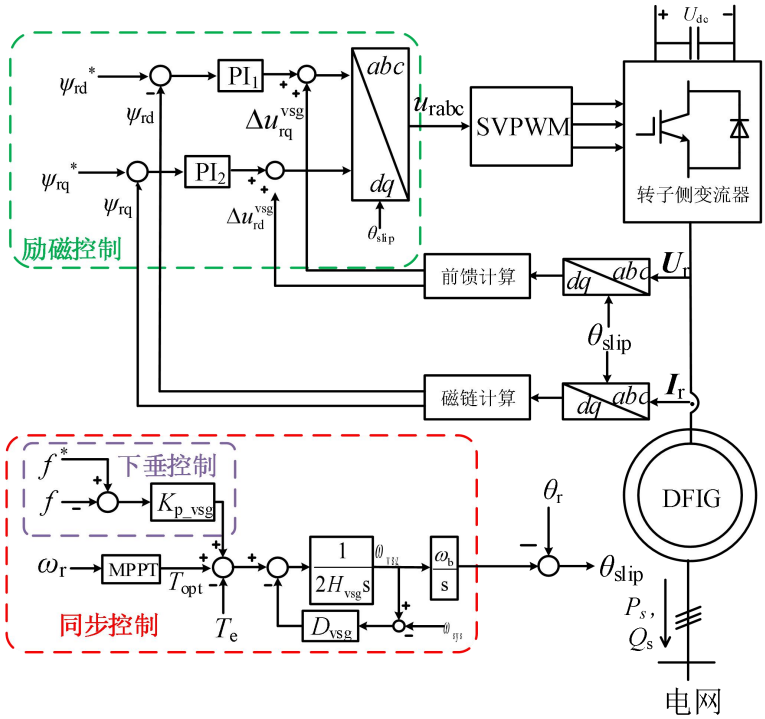


图 1-2 双馈风电机组转子侧虚拟同步控制框图

在网侧变换器惯性同步控制方式中，利用直流母线电容充当电网同步过程中的能量缓冲元件，不需要锁相环就可以实现和电网的同步，控制框图如图 1-3 所示，图中直流母线电压标幺值经过积分器得到网侧变换器输出电压 u_g 的相位θ_{isyn}，通过控制调制比 m 实现对于网侧

无功功率的动态调节，其中 m_n 为额定调制比。

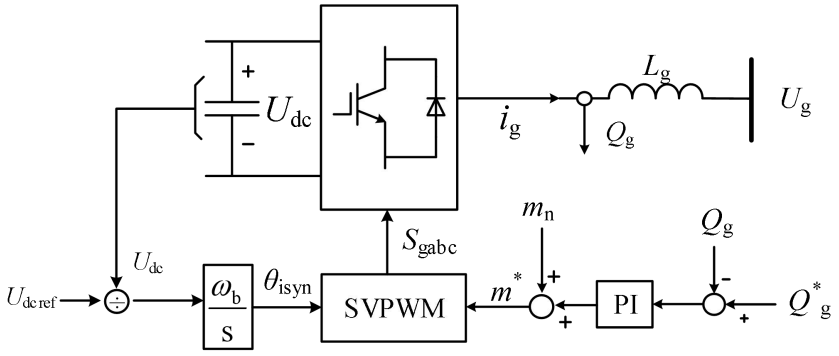


图 1-3 双馈风电机组网侧变换器惯性同步控制框图

1.2.2 现有技术的缺点

在现有的双馈电压源风电机组的控制方式中，均是将风电机组的转矩作为被控对象，使得风电机组的功率外特性趋近于传统同步发电机，但是不足之处体现在：无法对于电压源风电机组的转速进行直接控制，这是由于模拟同步发电机转子运动方程的有功控制环的输入为电磁转矩信号的给定值，因此在控制过程中仅能够实现电磁转矩的无差跟踪控制，无法控制风电机组的实际转速，在对于风电机组的转速控制精度要求较高的场景，转速直接控制策略的缺失将严重影响风电机组的稳态运行，因此有必要在电压源虚拟惯量控制的基础之上，针对性提出双馈电压源风电机组的转速直接控制方法，实现风电机组转速控制和惯量控制的结合，进一步提高双馈风电机组的可控性。

2．本发明创造技术方案详细阐述：

2.1 本发明创造所要解决的技术问题

1) **实现双馈电压源风电机组的转速直接控制。**提出双馈电压源风电机组的转速直接控制策略，通过转速闭环实现对于风电机组转速的无差控制。

2) **实现转速直接控制和 MPPT 控制的自由切换。**增加转速-MPPT 切换控制环节，可以根据实际的控制需要，在转速直接控制和 MPPT 控制之间自由切换，扩展控制策略的使用范围。

3) **实现虚拟惯量控制、MPPT 最大功率控制和转速直接控制的组合控制。**通过转速-MPPT 切换控制环节和虚拟惯量切换控制环节，实现 MPPT 控制、转速直接控制和虚拟惯量控制的组合，可以实现四种不同的控制效果：①MPPT 控制+无惯量响应；②MPPT 控制+惯量响应；③转速直接控制+无惯量响应；④转速直接控制+惯量响应。

2.2 本发明创造完整的技术方案阐述

针对现有技术存在的不足，本发明提供了一种双馈电压源风电机组转速-惯量组合控制方法，可以实现风电机组的转速控制和惯量响应控制的组合，实现四种不同的控制效果，大大扩展了控制策略的使用范围。

本发明通过以下技术手段实现上述技术目的。

一种双馈电压源风电机组转速-惯量组合控制方法：包括转子侧变换器的电压源有功功率控制和电压源无功功率控制，电压源有功功率控制的目的是控制风电机组的转速和有功功率，实现转速控制和惯量响应控制的组合，电压源无功功率控制的目的是控制风电机组定子侧的无功功率，实现风电机组的单位功率因数运行。

进一步的，电压源有功功率控制包含如下 6 个控制模块：1 转速直接控制外环、2 转速-MPPT 切换控制模块、3 转速限速控制模块、4 虚拟转子运动方程模块、5 虚拟惯量切换控制模块以及 6 滑差角计算模块。

上述转速直接控制外环中，风电机组的给定转速ω_r^*和风电机组实际转速ω_r之差，经过 PI 控制器，输出为转速外环的转矩输出给定 $T_{\omega r}^*$。上述转速-MPPT 切换控制模块包含一个二选一的信号输入选择 1 模块，两路信号输入分别为转速外环的转矩输出给定 $T_{\omega r}^*$，以及最优转矩给定 $k_{opt}\omega_r^2$，k_{opt} 表示为最优转矩系数，根据控制需要，将输入信号 $T_{\omega r}^*$、$k_{opt}\omega_r^2$ 之一作为输入选择 1 模块的输出 T_{set}。

上述转速限速控制模块中，风电机组实际转速ω_r 和额定的最大转速ω_{rmax}之差，经过 PI 控制器，此 PI 控制器的下限为输入选择 1 模块的输出 T_{set}，上限为额定的最大电磁转矩 T_{max}，

此 PI 控制器的输出为 T_{e1}^*；风电机组实际转速ω_r和额定的最低转速ω_{rmin}之差，经过 PI 控制器，此 PI 控制器的下限为 0，上限为输入选择 1 模块的输出 T_{set}，此 PI 控制器的输出为 T_{e2}^*；风电机组的实际转速ω_r经过一个判断模块，判断当ω_r大于ω_{rmid}时，风电机组电磁转矩的给定 $T_e^*= T_{e1}^*$，在其他情况下，$T_e^*= T_{e2}^*$，其中$\omega_{rmid}=(\omega_{rmin}+\omega_{rmax})/2$。

上述虚拟转子运动方程模块中，电磁转矩给定值 T_e^*与电磁转矩实际值 T_e做差得到转矩差ΔT_e，转矩角速度ω_{Te1}乘以虚拟惯量系数 D_{vsg}得到虚拟惯量偏差ΔD，转矩差ΔT_e与虚拟惯量偏差ΔD 的差值输入积分器 $1/2H_{vsg}s$ 得到转矩角速度ω_{Te1}，H_{vsg}表示虚拟惯量系数；

上述虚拟惯量切换控制模块中，电网频率ω_g输入到一阶惯性模块 $1/k_cs+1$，输出为电网阻尼频率ω_{g_damp}，k_c表示虚拟惯量系数，虚拟惯量控制模块包含一个二选一的信号输入选择 2 模块，两路信号输入分别为电网阻尼频率ω_{g_damp}，以及电网频率ω_g，根据控制需要，将输入信号ω_{g_damp}、ω_g之一作为输入选择 2 模块的输出ω_{Te2}；将ω_{Te1}和ω_{Te2}相加，得到虚拟同步角速度ω_{vsg}。

上述滑差角计算模块中，虚拟同步角速度ω_{vsg}输入积分器ω_b/s 得到虚拟转子角θ_{vsg}，ω_b表示电网基准频率，风电机组的实际转速ω_r输入积分器ω_b/s 得到转子角θ_r，虚拟转子角θ_{vsg}与转子角θ_r做差，得到滑差角θ_{slip}，转子电流 I_r基于滑差角θ_{slip}做 abc 至 dq 的坐标系转换，之后进行磁链计算得到发电机转子磁链的 d 轴分量ψ_{rd}和 q 轴分量ψ_{rq}。

进一步的，电压源无功功率控制中，定子侧无功功率给定值 Q_s^*与实际值 Q_s之差输入 PI 控制器，得到转子磁链 d 轴分量给定值ψ_{rd}^*，ψ_{rd}^*和转子磁链 d 轴分量实际值ψ_{rd}之差输入 PI 控制器，得到反坐标变换的输入 U_{md}；转子磁链 q 轴分量给定值ψ_{rq}^*与实际值ψ_{rq}之差输入到 PI 控制器，得到反坐标变换的输入 U_{mq}，将 U_{md}、U_{mq}和θ_{slip}输入反坐标变换，所得结果输入 SVPWM 模块，生成脉冲控制信号 S_{rabc}控制转子侧变换器运行。

2.3 本发明创造技术方案带来的有益效果

1) **直接控制双馈电压源风电机组的转速。**提出双馈电压源风电机组的转速直接控制策略，通过转速闭环实现对于风电机组转速的无差控制。

2) **自由切换转速直接控制和 MPPT 最大功率跟踪控制。**增加转速-MPPT 切换控制环节，可以根据实际的控制需要，在转速直接控制和 MPPT 控制之间自由切换，扩展控制策略的适用范围。

3) **自由组合虚拟惯量控制、MPPT 最大功率控制和转速直接控制。**通过转速-MPPT 切换控制环节和虚拟惯量切换控制环节，可以选择在 MPPT 控制下是否进行进行虚拟惯量控制，以及在转速直接控制下是否进行虚拟惯量控制，可以实现四种不同的控制效果：①MPPT 控制+无惯量响应；②MPPT 控制+惯量响应；③转速直接控制+无惯量响应；④转速直接控制+

惯量响应。

3．本发明创造的技术关键点和拟保护点：

5) 保护双馈电压源风电机组转速直接控制策略

6) 保护双馈电压源风电机组中，转速直接控制和 MPPT 控制二者进行自由切换的控制策略

7) 保护双馈电压源风电机组中，风电机组虚拟惯量控制、MPPT 最大功率控制和转速直接控制的组合控制策略，即技术方案阐述中的 4 种组合控制策略

4.本发明创造的替代方案：

暂无

5．具体实施例及附图：

一、 附图信息如下：

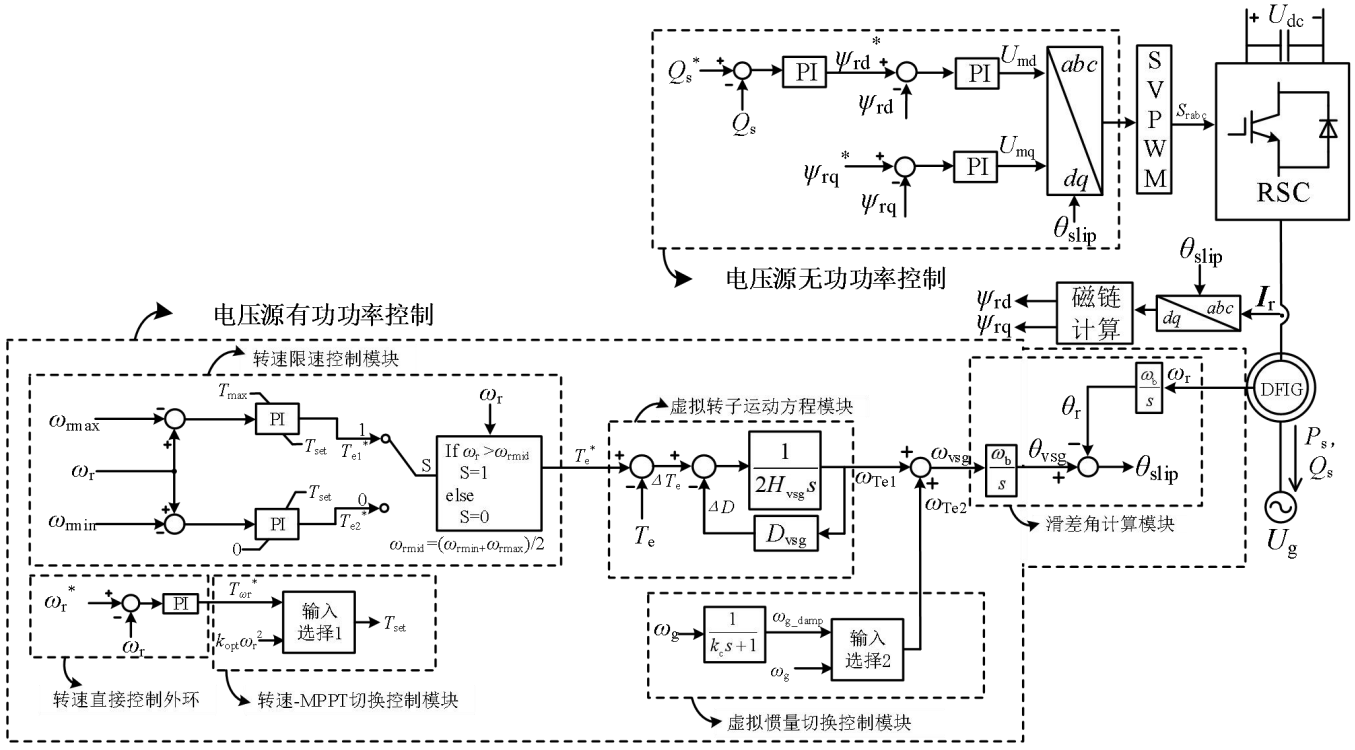


图 5-1 总图-双馈电压源风电机组转速-惯量组合控制方法

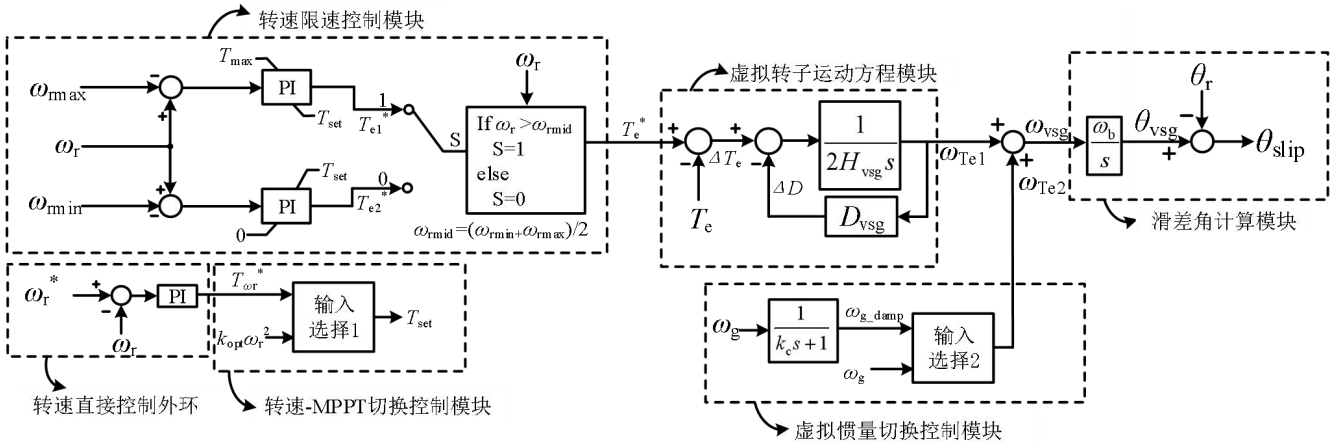


图 5-2 电压源有功功率控制模块

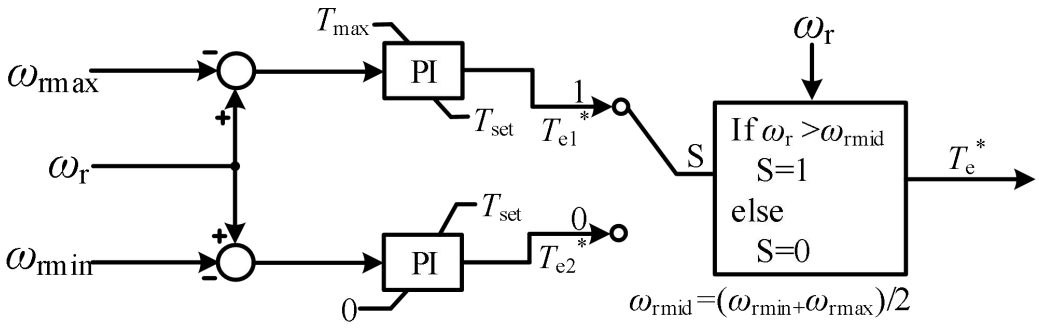


图 5-3 转速限速控制模块

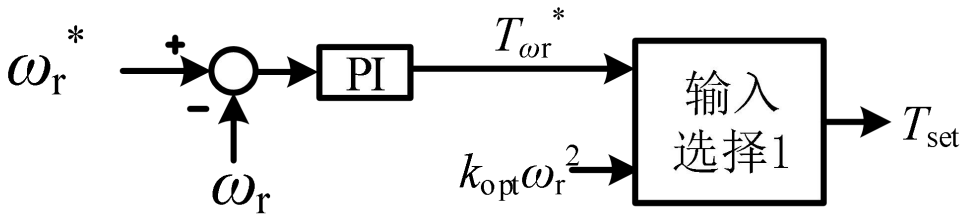


图 5-4 转速直接控制外环和转速-MPPT 切换控制模块

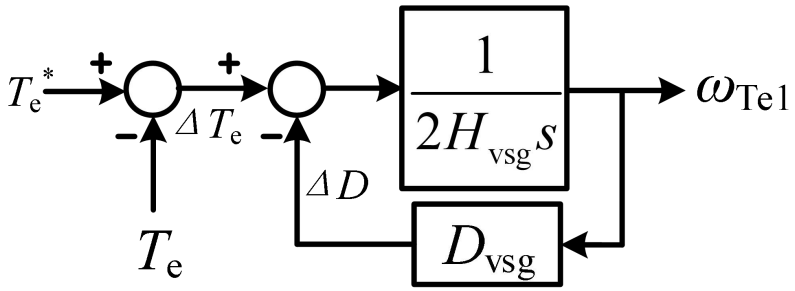


图 5-5 虚拟转子运动方程模块

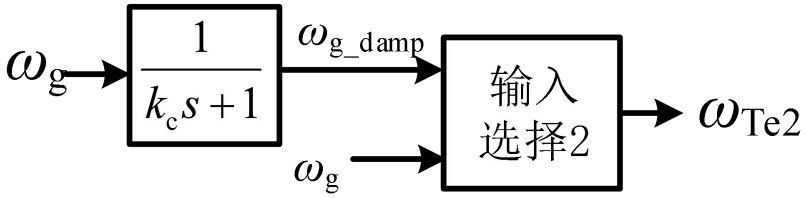


图 5-6 虚拟惯量切换控制模块

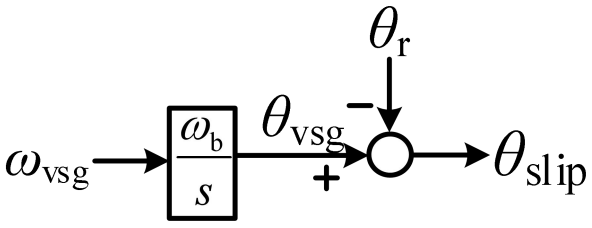


图 5-7 滑差角计算模块

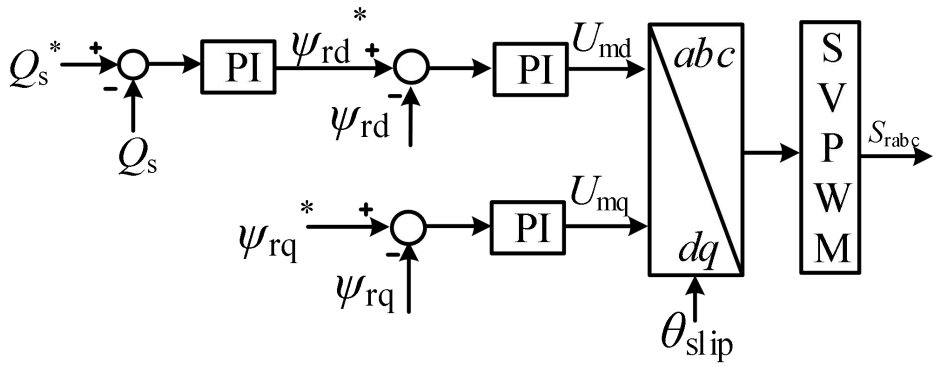


图 5-8 电压源无功功率控制模块

二、 具体实施案例如下：

本发明专利提出了一种双馈电压源风电机组转速-惯量组合控制方法，能够控制电压源风电机组在 MPPT 模式和转速直接控制模式之间切换，可以实现四种不同的控制效果：①MPPT 控制+无惯量响应；②MPPT 控制+惯量响应；③转速直接控制+无惯量响应；④转速直接控制+惯量响应。

具体实施方案如下：

- **控制组合 1：MPPT 控制+无惯量响应**

在该控制组合下，双馈电压源风电机组能够按照常规 MPPT 算法进行控制，无法对于风电机组的转速直接控制；电网的频率和风电机组的有功功率之间存在“解耦”的关系，电网频率的波动并不会引发风电机组有功出力的变化。

具体的控制方法为：输入选择 1 模块的输出 T_{set} 等于最优转矩给定 $k_{opt}\omega_r^2$，输入选择 2 模块的输出ω_{Te2} 等于电网频率ω_g，即：$T_{set}= k_{opt}\omega_r^2$，$\omega_{Te2}=\omega_g$。

- **控制组合 2：MPPT 控制+惯量响应**

在该控制组合下，双馈电压源风电机组能够按照常规 MPPT 算法进行控制，无法对于风电机组的转速直接控制；电压源风电机组能够主动响应电网频率的变化，起到虚拟惯量控制的效果，可以有效提高电力系统的等效惯量和等效阻尼，提高电力系统的频率稳定性。

具体的控制方法为：输入选择 1 模块的输出 T_{set} 等于最优转矩给定 $k_{opt}\omega_r^2$，输入选择 2 模块的输出ω_{Te2} 等于电网阻尼频率ω_{g_damp}，即：$T_{set}= k_{opt}\omega_r^2$，$\omega_{Te2}=\omega_{g_damp}$。

- **控制组合 3：转速直接控制+无惯量响应**

在该控制组合下，双馈电压源风电机组能够实现对于转速的直接控制；电网的频率和风电机组的有功功率之间存在“解耦”的关系，电网频率的波动并不会引发风电机组有功出力的变化。

具体的控制方法为：输入选择 1 模块的输出 T_{set} 等于转矩输出给定 $T_{\omega r}^*$，输入选择 2 模块

的输出ω_{Te2}等于电网频率ω_g，即：$T_{set}= T_{\omega r}^*$，$\omega_{Te2}=\omega_g$。

- **控制组合 4：转速直接控制+惯量响应**

在该控制组合下，双馈电压源风电机组能够实现对于转速的直接控制；电压源风电机组能够主动响应电网频率的变化，起到虚拟惯量控制的效果，可以有效提高电力系统的等效惯量和等效阻尼，提高电力系统的频率稳定性。

具体的控制方法为：输入选择 1 模块的输出 T_{set} 等于转矩输出给定 $T_{\omega r}^*$，输入选择 2 模块的输出ω_{Te2}等于电网阻尼频率ω_{g_damp}，即：$T_{set}= T_{\omega r}^*$，$\omega_{Te2}=\omega_{g_damp}$。

上述四种控制组合对应的输入选择如表 2-1 所示。

表 2-1 输入选择对应列表

模式 / 信号	MPPT 控制+无惯量响应	MPPT 控制+惯量响应	转速直接控制+无惯量响应	转速直接控制+惯量响应
T_{set}	$k_{opt}\omega_r^2$	$k_{opt}\omega_r^2$	$T_{\omega r}^*$	$T_{\omega r}^*$
ω_{Te2}	ω_g	ω_{g_damp}	ω_g	ω_{g_damp}

三、 仿真测试如下：

在 RTDS 实时数字仿真器中搭建 2MW 双馈风电机组并网模型，仿真系统结构如图 5-9 所示，双馈风电机组的相关参数见表 5-1、表 5-2。

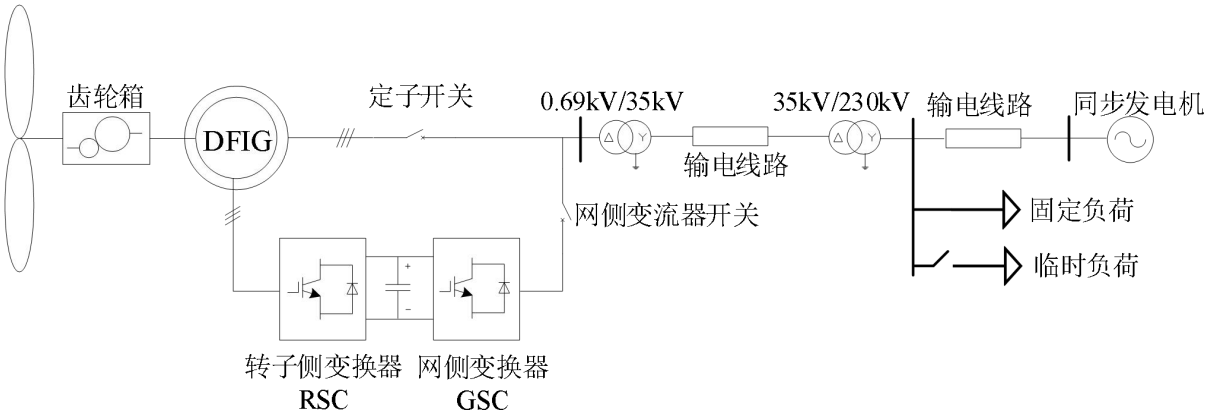


图 5-9 仿真结构示意图

表 5-1 2MW 风力机参数

参数名	数值	参数名	数值
额定定子电压/kV	0.69	定子电阻/pu	0.0344
定转子绕组比/pu	0.333	定子漏抗/pu	0.2748

额定功率/MWA	2	励磁电抗/pu	12.97
额定频率/Hz	50	转子电阻/pu	0.0273
直流母线电容/mF	3.6	转子漏抗/pu	0.3979

表 5-2 2MW 双馈风电机组电气参数

参数名	数值	参数名	数值
机组气动功率/MW	2.18	额定风速/m/s	11.8
切入风速/m/s	3	切出风速/m/s	25
风轮直径/m	90.76	齿轮箱变比	84.26
C_{pmax}	0.483	最佳叶尖速比	8.37

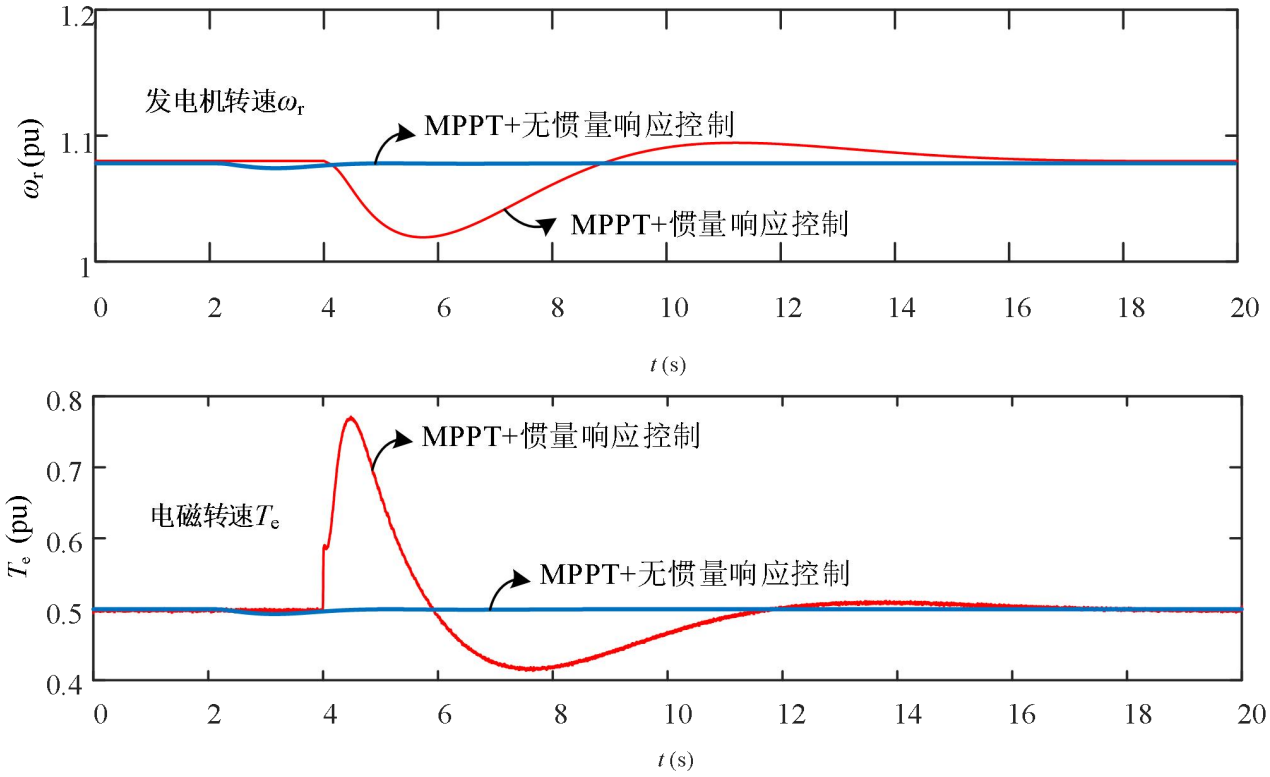


图 5-10 MPPT 模式下有（无）惯量响应控制对比图

令 $T_{set}= k_{opt}\omega_r^2$，风电机组工作在 MPPT 最大功率跟踪模式，环境风速为 10.5m/s，此时在 MPPT 最大功率跟踪控制方式下，风电机组的转速为 1.08pu，发电机的电磁转矩为 0.5pu，分别切换ω_{Te2}的值，当$\omega_{Te2}=\omega_g$时，风电机组工作模式为 MPPT+无惯量响应控制，当$\omega_{Te2}=\omega_{g_damp}$时，风电机组工作模式为 MPPT+惯量响应控制，分别在两种模式下，在仿真时间 4s 投入 2MW 负载，发电机转速和电磁转矩的对比图图 5-10 所示。

当风电机组具备惯量响应能力时，在负载投入瞬间风电机组电磁转矩增加，电磁功率也

随之增加，增加的功率用于抑制电网频率的跌落，并且风电机组的转速下降，释放转子中储存的动能，体现出虚拟惯量的控制效果。而当风电机组不具备惯量响应能力时，发电机转速和电磁转矩均不响应负载变化，无法体现虚拟惯量的控制效果。

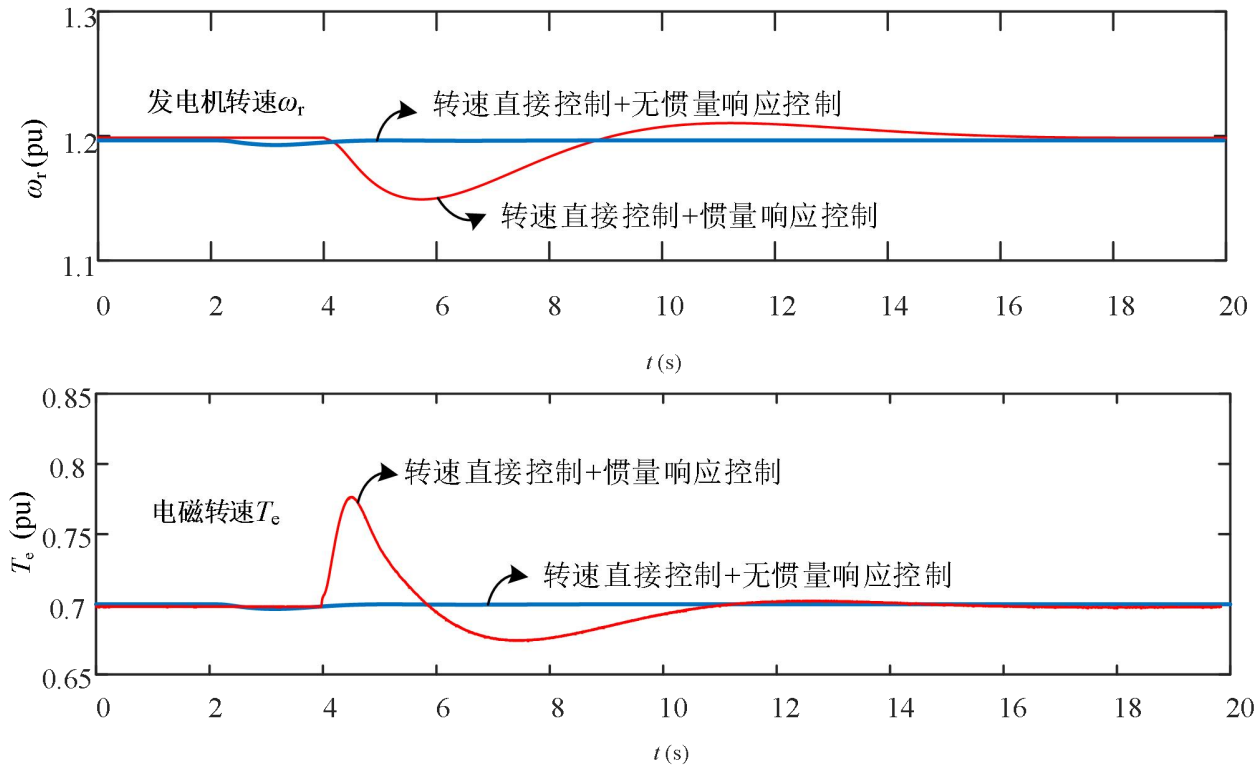


图 5-11 转速直接控制模式下有（无）惯量响应控制对比图

令 $T_{set}= T_{\omega r}^{*}$，风电机组工作在转速直接控制模式，环境风速为 12.5m/s，此时在转速直接控制模式下，风电机组的转速被控制为转速的上限 1.2pu，发电机的电磁转矩为 0.7pu，分别切换ω_{Te2}的值，$\omega_{Te2}=\omega_g$时，风电机组工作模式为转速直接控制+无惯量响应控制，当$\omega_{Te2}=\omega_{g_damp}$时，风电机组工作模式为转速直接控制+惯量响应控制，分别在两种模式下，在仿真时间 4s 投入 2MW 负载，发电机转速和电磁转矩的对比图如图 5-11 所示。

和 MPPT 模式的对比结果类似，当风电机组具备惯量响应能力时，能够体现出虚拟惯量的控制效果。而当风电机组不具备惯量响应能力时，发电机转速和电磁转矩均不响应负载变化，无法体现虚拟惯量的控制效果。

图 5-10~图 5-11 证明，通过设置 T_{set} 以及ω_{Te2}的值，能够较好实现风电机组在四种不同的控制模式之间进行切换，且均能够体现出对应的控制效果，

6. 其他有助于理解本发明创造的技术资料：

相关专利、公知技术检索结果及其与本发明/实用新型的异同点

关键词：风力发电 切换控制 调频能力 (填写专利与公知技术检索需要的关键词)

相关检索结果 1：

申请（专利）号: 202110236107.6

名称: 一种风电参与电网调频的时变调频参数设定方法及系统

摘要: 本发明公开了一种风电参与电网调频的时变调频参数设定方法及系统，包括：基于不同机型和容量下同步机的转动惯量和蓄热能量关系，构建风电调频能量联动分配模型；所述能量联动分配模型能够在总量约束下联动分配虚拟惯量和一次调频环节的能量；考虑风机运行点偏移造成的机械功率减载能量，量化分析风机不同转速分区下对应的可利用转子动能；根据所述能量联动分配模型计算等效时变调频参数。本发明所提调频参数设定方法在中低风速下能够提供涵盖惯量响应和一次调频，并具备明确的变系数计算方法，同时可实现调频能量在两个调频环节的合理分配。

技术要点比较：

检索到的专利文件提出了一种风电参与电网调频的时变调频参数设定方法及系统，但是，该发明中是通过附加功率的方式实现惯量响应，本质上仍然为电流源控制方法，不能够适应弱电网的运行工况，并且该发明专利中采用功率外环+电流内环的控制方法，不能够实现对于风机转速的直接控制。

而本发明专利提出了电压源控制的策略，本质上体现为电压源，弱网运行稳定性高，并且能够实现 MPPT 控制和转速直接控制之间的切换，有效扩大了风电机组的控制范围。

相关检索结果 2：

申请（专利）号: 201911135568.3

名称: 双馈风机虚拟惯量调频的动态转速保护方法及系统

摘要: 本发明公开了一种双馈风机虚拟惯量调频的动态转速保护方法及系统，包括：根据风机的转速得到 MPPT 曲线功率参考值；对实际频率与额定频率之间的偏差进行虚拟惯量控制得到在 MPPT 曲线功率参考值的基础上附加的额外有功参考信号；上一时刻实际输出的风机电磁功率、风机的转速以及Δf 与虚拟惯量控制微分系数的乘积经过动态转速保护后得到输出功率；根据功率参考值、额外有功参考信号以及输出功率，得到当前时刻风机输出的电磁功率。本发明能根据调频过程中转子转速的变化使风机的输出功率缓慢地降落到最大功率跟踪曲线上，避免了风机转速的过度降低，调频结束后风机将自动地恢复到原来的最大功率点，从而保证了调频过程中风机自身的稳定性和经济性。

技术要点比较：

检索到的专利发明提出了一种双馈风机虚拟惯量调频的动态转速保护方法及系统，但是，

该检索文件中的转速控制仅仅局限于在惯量响应恢复后期加快转速的恢复，但是在风电机组的稳态运行控制中，仍然采用功率外环+电流内环的控制方法，因此仍然无法实现对于风电机组转速的直接控制。

而本申请专利则针对性设计了转速直接控制的模块，通过增加的转速控制外环实现对于发电机转速的精准控制，并且还能够和虚拟惯量的使能开关相互配合，体现出不同的组合控制效果。

申请材料分析说明

1.基础信息

专利名称：一种双馈电压源风电机组转速-惯量组合控制方法

状态：授权（2024 年 6 月 7 日、优先审查）

2.交底材料

内容较为完整，给出了背景技术、现有技术、现有技术的缺点、本发明的技术方案及其优势，并给出详实的附图以及测试数据。

背景技术过于冗长，例如其中“人类的经济和社会发展离不开能源的支撑…发挥了重要作用”等与技术本身无关的内容可以不用。背景技术应当聚焦于技术本身，重点是揭示当下存在的技术层面问题，且此技术问题应当是本发明技术方案所要针对解决的。

提供的附图中，由于尺寸限制，部分内容模糊不清；对于尺寸较大的图，最好做到合理拆分，以保证在标准专利文稿版面下可以清楚显示。

3.权利要求书

申请时给出了 10 条权利要求，将技术方案的各技术点逐条拆解，为后期审查中针对审查意见答复提供了较为清楚且充足的修改空间。

4.说明书

背景技术部分，清楚交代了本发明所要针对的技术问题——双馈电压源风电机组无法实现转速直接控制。

将交底材料中原本整张的大尺寸附图做了合理拆分为多个小图，每个小图分别对应一个子控制逻辑。在具体实施方式部分，采用总分的形式，先对总的控制逻辑进行表述，再结合各个子图将各子控制逻辑进行展开说明，做到清楚表述，便于阅读理解。

表 1 至表 2 以及图 8 至图 11 给出了非常详细的对比测试数据，佐证本发明技术效果的真实有效性。

申请稿

说明书摘要

本发明提供了一种双馈电压源风电机组转速-惯量组合控制方法，包括转子侧变换器的电压源有功功率控制和电压源无功功率控制，有功功率控制中具体包含有六个子模块控制项，分别为转速直接控制外环、转速-MPPT 切换控制模块、转速限速控制模块、虚拟转子运动方程模块、虚拟惯量切换控制模块、滑差角计算模块。其中通过本发明提出的转速直接控制外环和转速限速控制模块实现转速的直接控制功能，通过转速-MPPT 切换控制模块实现转速直接控制与 MPPT 控制两者的切换，通过虚拟惯量切换控制模块实现有无惯量响应的切换；从而综合能够实现四种不同的组合控制方式。

权利要求书

1.一种双馈电压源风电机组转速-惯量组合控制方法，其特征在于：转子侧变换器的电压源有功功率控制中包括有：

转速直接控制外环：风电机组的给定转速ω_r^*与实际转速ω_r之差输入 PI 控制器，得到转速外环的转矩输出给定 $T_{\omega r}^*$；

在执行转速直接控制时，令 $T_{set}= T_{\omega r}^*$；

转速限速控制模块：风电机组的实际转速ω_r与额定最大转速ω_{rmax}之差输入 PI 控制器，得到 T_{e1}^*，其中 PI 控制器的上限为风电机组的额定最大电磁转矩 T_{max}，下限为 T_{set}；风电机组的实际转速ω_r与额定最小转速ω_{rmin}之差输入 PI 控制器，得到 T_{e2}^*，其中 PI 控制器的上限为 T_{set}，下限为 0；风电机组电磁转矩的给定值 T_e^*为：

$$T_e^* = \begin{cases} T_{e1}^*, & \omega_r > \omega_{rmid} \\ T_{e2}^*, & \omega_r \le \omega_{rmid} \end{cases}$$

其中 $\omega_{rmid} = (\omega_{rmin} + \omega_{rmax})/2$。

2.根据权利要求 1 所述的双馈电压源风电机组转速-惯量组合控制方法，其特征在于：设有转速-MPPT 切换控制模块，用于切换 T_{set}，其中在执行 MPPT 控制时，令 $T_{set}= k_{opt}\omega_r^2$；$k_{opt}\omega_r^2$为最优转矩给定，$k_{opt}$为最优转矩系数。

3.根据权利要求 1 所述的双馈电压源风电机组转速-惯量组合控制方法，其特征在于：所述电压源有功功率控制中，T_e^*经虚拟转子运动方程模块得到转矩角速度ω_{Te1}，并将ω_{Te1}代入滑差角计算，得到滑差角θ_{slip}。

4.根据权利要求 3 所述的双馈电压源风电机组转速-惯量组合控制方法，其特征在于：所述电压源有功功率控制中设有虚拟惯量切换控制模块，用于控制切换是否进行虚拟惯量响应，

其中：

不进行虚拟惯量响应时，将电网频率ω_g作为输出信号ω_{Te2}；

进行虚拟惯量响应时，将电网阻尼频率ω_{g_damp}作为输出信号ω_{Te2}；

在所述滑差角计算中，先将ω_{Te1}与ω_{Te2}求和得到虚拟同步角速度ω_{vsg}，之后将ω_{vsg}输入积分器ω_b/s得到虚拟转子角θ_{vsg}，最后将θ_{vsg}与转子角θ_r作差，得到滑差角θ_{slip}。

5.根据权利要求 4 所述的双馈电压源风电机组转速-惯量组合控制方法，其特征在于：所述转子角θ_r由风电机组实际转速ω_r输入积分器ω_b/s得到。

6.根据权利要求 4 所述的双馈电压源风电机组转速-惯量组合控制方法，其特征在于：所述电网阻尼频率ω_{g_damp}由ω_g输入一阶惯性模块$1/k_\omega s+1$求解得到。

7.根据权利要求 6 所述的双馈电压源风电机组转速-惯量组合控制方法，其特征在于：还包括转子侧变换器的电压源无功功率控制，用于控制风电机组定子侧的无功功率，实现风电机组的单位功率因数运行。

8.根据权利要求 7 所述的双馈电压源风电机组转速-惯量组合控制方法，其特征在于：所述电压源无功功率控制中，转子磁链 d 轴分量的给定值ψ_{rd}^*与实际值ψ_{rd}之差输入 PI 控制器，得到反坐标变换的输入U_{md}；转子磁链 q 轴分量的给定值ψ_{rq}^*与实际值ψ_{rq}之差输入到 PI 控制器，得到反坐标变换的输入U_{mq}；

最后，将U_{md}、U_{mq}和θ_{slip}输入反坐标变换，并将变换结果输入 SVPWM 模块，生成脉冲控制信号S_{rabc}控制转子侧变换器运行。

9.根据权利要求 8 所述的双馈电压源风电机组转速-惯量组合控制方法，其特征在于：转子电流I_r基于滑差角θ_{slip}做 abc 至 dq 的坐标系转换，并经磁链计算得到发电机转子磁链的 d 轴分量实际值ψ_{rd}和 q 轴分量实际值ψ_{rq}。

10.根据权利要求 8 所述的双馈电压源风电机组转速-惯量组合控制方法，其特征在于：所述转子磁链 d 轴分量的给定值ψ_{rd}^*由定子侧无功功率的给定值Q_s^*与实际值Q_s之差输入 PI 控制器得到。

说明书

一种双馈电压源风电机组转速-惯量组合控制方法

技术领域

本发明属于电力控制技术领域，具体涉及一种双馈电压源风电机组转速-惯量组合控制方法。

背景技术

大型风力发电机组通过变流器接入电网，相比传统的同步发电机，具有控制灵活、响应迅速等优点。其中双馈风电机组（Doubly-fed Induction Generator，DFIG）中，定子直接挂接电网，转子通过三相交-直-交变流器实现交流励磁；电功率通过定子、转子与电网进行交换。现有的对于上述双馈电压源风电机组的控制，通常采用转子侧变换器虚拟同步控制-网侧变换器惯性同步控制的组合控制技术方案。

现有的双馈电压源风电机组的控制方式中，均是将风电机组的转矩作为被控对象，使得风电机组的功率外特性趋近于传统同步发电机。但是上述控制方式的不足之处体现在：无法对于电压源风电机组的转速进行直接控制。这是由于模拟同步发电机转子运动方程的有功控制环的输入为电磁转矩信号的给定值，因此在控制过程中仅能够实现电磁转矩的无差跟踪控制，无法控制风电机组的实际转速。

在对于风电机组的转速控制精度要求较高的场景，转速直接控制策略的缺失将严重影响风电机组的稳态运行，因此有必要在电压源虚拟惯量控制的基础之上，针对性提出双馈电压源风电机组的转速直接控制方法，实现风电机组转速控制和惯量控制的结合，进一步提高双馈风电机组的可控性。

发明内容

针对现有技术中存在的不足，本发明提供了一种双馈电压源风电机组转速-惯量组合控制方法，用以解决当前双馈电压源风电机组无法实现转速直接控制的问题。

本发明通过以下技术手段实现上述技术目的。

一种双馈电压源风电机组转速-惯量组合控制方法：转子侧变换器的电压源有功功率控制中包括有：

转速直接控制外环：风电机组的给定转速ω_r^*与实际转速ω_r之差输入 PI 控制器，得到转速外环的转矩输出给定 $T_{\omega r}^*$；

在执行转速直接控制时，令 $T_{set}= T_{\omega r}^*$；

转速限速控制模块：风电机组的实际转速ω_r与额定最大转速ω_{rmax}之差输入 PI 控制器，得到 T_{e1}^*，其中 PI 控制器的上限为风电机组的额定最大电磁转矩 T_{max}，下限为 T_{set}；风电机组的实际转速ω_r与额定最小转速ω_{rmin}之差输入 PI 控制器，得到 T_{e2}^*，其中 PI 控制器的上限为 T_{set}，下限为 0；风电机组电磁转矩的给定值 T_e^*为：

$$T_e^* = \begin{cases} T_{e1}^*, & \omega_r > \omega_{rmid} \\ T_{e2}^*, & \omega_r \le \omega_{rmid} \end{cases}$$

其中　　$\omega_{rmid}=(\omega_{rmin}+\omega_{rmax})/2$。

进一步地，设有转速-MPPT 切换控制模块，用于切换 T_{set}，其中在执行 MPPT 控制时，令 $T_{set}=k_{opt}\omega_r^2$；$k_{opt}\omega_r^2$ 为最优转矩给定，k_{opt} 为最优转矩系数。

进一步地，所述电压源有功功率控制中，T_e^*经虚拟转子运动方程模块得到转矩角速度 ω_{Te1}，并将ω_{Te1} 代入滑差角计算，得到滑差角θ_{slip}。

进一步地，所述电压源有功功率控制中设有虚拟惯量切换控制模块，用于控制切换是否进行虚拟惯量响应，其中：

不进行虚拟惯量响应时，将电网频率ω_g 作为输出信号ω_{Te2}；

进行虚拟惯量响应时，将电网阻尼频率ω_{g_damp} 作为输出信号ω_{Te2}；

在所述滑差角计算中，先将ω_{Te1} 与ω_{Te2} 求和得到虚拟同步角速度ω_{vsg}，之后将ω_{vsg} 输入积分器ω_b/s 得到虚拟转子角θ_{vsg}，最后将θ_{vsg} 与转子角θ_r 作差，得到滑差角θ_{slip}。

进一步地，所述转子角θ_r 由风电机组实际转速ω_r 输入积分器ω_b/s 得到。

进一步地，所述电网阻尼频率ω_{g_damp} 由ω_g 输入一阶惯性模块 $1/k_cs+1$ 求解得到。

进一步地，还包括转子侧变换器的电压源无功功率控制，用于控制风电机组定子侧的无功功率，实现风电机组的单位功率因数运行。

进一步地，所述电压源无功功率控制中，转子磁链 d 轴分量的给定值ψ_{rd}^*与实际值ψ_{rd} 之差输入 PI 控制器，得到反坐标变换的输入 U_{md}；转子磁链 q 轴分量的给定值ψ_{rq}^*与实际值ψ_{rq} 之差输入到 PI 控制器，得到反坐标变换的输入 U_{mq}；

最后，将 U_{md}、U_{mq} 和θ_{slip} 输入反坐标变换，并将变换结果输入 SVPWM 模块，生成脉冲控制信号 S_{rabc} 控制转子侧变换器运行。

进一步地，转子电流 I_r 基于滑差角θ_{slip} 做 abc 至 dq 的坐标系转换，并经磁链计算得到发电机转子磁链的 d 轴分量实际值ψ_{rd} 和 q 轴分量实际值ψ_{rq}。

进一步地，所述转子磁链 d 轴分量的给定值ψ_{rd}^*由定子侧无功功率的给定值 Q_s^*与实际值 Q_s 之差输入 PI 控制器得到

本发明的有益效果为：

（1）本发明提供了一种双馈电压源风电机组转速-惯量组合控制方法，能够有效实现转速直接控制。

（2）保留了常规 MPPT 控制环节，可以根据实际的控制需要，在转速直接控制和 MPPT 控制之间自由切换，扩展控制策略的适用范围。且还能实现是否加入惯量响应控制，综合能够实现四种不同的组合控制方式。

附图说明

图 1 为本发明双馈电压源风电机组控制方法的控制框图总览；

图 2 为本发明中电压源有功功率的控制框图；

图 3 为本发明中转速直接控制外环以及切换模块的控制框图；

图 4 为本发明中转速限速控制模块的控制框图；

图 5 为本发明电压源有功功率控制中的其他子模块控制框图；

图 6 为本发明中电压源无功功率的控制框图；

图 7 为测试所搭建的仿真模型结构图；

图 8 为 MPPT 控制模式下有无惯量响应的发电机转速对比图；

图 9 为 MPPT 控制模式下有无惯量响应的电磁转矩对比图；

图 10 为转速直接控制模式下有无惯量响应的发电机转速对比图；

图 11 为转速直接控制模式下有无惯量响应的电磁转矩对比图。

具体实施方式

下面详细描述本发明的实施例，所示实施例的示例在附图中示出，其中自始至终相通或类似的标号表示相同或类似的元件或具有相同或类似功能的元件。下面通过参考附图描述的实施例是示例性的，旨在用于解释本发明，而不能理解为对本发明的限制。

一、控制框架

如图 1 所示，本发明针对双馈电压源风电机组的转速-惯量组合控制方法，包括转子侧变换器（RSC，rotor-side converter）的①电压源有功功率控制和②电压源无功功率控制两部分。其中①电压源有功功率控制用于控制风电机组的转速和有功功率，实现转速控制和惯量响应控制的组合控制。②电压源无功功率控制则是用于控制风电机组定子侧的无功功率，实现风电机组的单位功率因数运行。

如图 2 所示，本发明电压源有功功率控制具体包括以下 6 个子模块控制项：（1）转速直接控制外环，（2）转速-MPPT 切换控制模块，（3）转速限速控制模块，（4）虚拟转子运动方程模块，（5）虚拟惯量切换控制模块，（6）滑差角计算模块。

如图 3 所示：

（1）转速直接控制外环中，对风电机组的给定转速ω_r^*和风电机组实际转速ω_r求差，之后将上述转速差输入 PI 控制器，得到转速外环的转矩输出给定 $T_{\omega r}^*$。

（2）转速-MPPT 切换控制模块中，设有一个信号切换开关，即图示中的“输入选择 1”，用于在两个输入信号之间选择其一作为输出信号 T_{set}。选择输入 1 的两个输入信号分别为 $T_{\omega r}^*$

和最优转矩给定 $k_{opt}\omega_r^2$；其中 k_{opt} 为最优转矩系数。选择输入 1 具体选择哪一信号输出，由人为指定。其中当需要执行转速直接控制时，则选择 $T_{\omega r}^*$作为输出信号；反之需要执行 MPPT 控制时，则选择 $k_{opt}\omega_r^2$ 作为输出信号。

如图 4 所示：

（3）转速限速控制模块中：

一方面，风电机组的实际转速ω_r与额定最大转速ω_{rmax}之差输入 PI 控制器，得到 T_{e1}^*；其中上述 PI 控制器的上限为风电机组的额定最大电磁转矩 T_{max}，下限为 T_{set}。

另一方面，风电机组的实际转速ω_r与额定最小转速ω_{rmin}之差输入 PI 控制器，得到 T_{e2}^*；其中上述 PI 控制器的上限为 T_{set}，下限为 0。

最后，根据ω_r在 T_{e1}^*与 T_{e2}^*之间择一作为输出信号 T_e^*：

$$T_e^* = \begin{cases} T_{e1}^*, & \omega_r > \omega_{rmid} \\ T_{e2}^*, & \omega_r \le \omega_{rmid} \end{cases}$$

其中 T_e^*为风电机组电磁转矩的给定值，　　$\omega_{rmid} = (\omega_{rmin} + \omega_{rmax})/2$。

如图 5 所示：

（4）虚拟转子运动方程模块中，风电机组电磁转矩的给定值 T_e^*与实际值 T_e 做差，得到转矩差ΔT_e。之后转矩差ΔT_e与虚拟惯量偏差ΔD 的两者之差输入积分器 $1/2H_{vsg}s$，得到转矩角速度ω_{Te1}。转矩角速度ω_{Te1}一方面作为虚拟转子运动方程模块的输出信号，另一方面则作为反馈信号乘以虚拟惯量系数 D_{vsg} 得到虚拟惯量偏差ΔD。

（5）虚拟惯量切换控制模块中，设有一个信号切换开关，即图示中的“输入选择 2”，用于在两个输入信号之间选择其一作为输出信号ω_{Te2}。输入选择 2 的两个输入信号分别为电网阻尼频率ω_{g_damp}和电网频率ω_g；其中电网阻尼频率ω_{g_damp}通过电网频率ω_g输入一阶惯性模块 $1/k_c s+1$ 求解得到。选择输入 2 具体选择哪一信号输出，由人为指定。其中当需要惯量响应时，则选择ω_{g_damp}作为输出信号；反之不需要惯量响应时，则选择ω_g作为输出信号。

将ω_{Te1}与ω_{Te2}求和得到虚拟同步角速度ω_{vsg}。

（6）滑差角计算模块中，首先虚拟同步角速度ω_{vsg}输入积分器ω_b/s 得到虚拟转子角θ_{vsg}；积分器ω_b/s 中ω_b表示电网基准频率。之后将虚拟转子角θ_{vsg}与转子角θ_r作差，得到滑差角θ_{slip}；其中转子角θ_r由风电机组实际转速ω_r输入积分器ω_b/s 得到。

如图 1 所示，基于上述电压源有功功率控制获得的滑差角θ_{slip}，转子电流 I_r 做 abc 至 dq 的坐标系转换，而后经磁链计算得到发电机转子磁链的 d 轴分量ψ_{rd}和 q 轴分量ψ_{rq}。

如图 6 所示，本发明电压源无功功率控中：

定子侧无功功率的给定值 Q_s^*与实际值 Q_s之差输入 PI 控制器，得到转子磁链 d 轴分量的给定值ψ_{rd}^*。转子磁链 d 轴分量的给定值ψ_{rd}^*与实际值ψ_{rd}之差输入 PI 控制器，得到反坐标变换的输入 U_{md}。

转子磁链 q 轴分量的给定值ψ_{rq}^*与实际值ψ_{rq}之差输入到 PI 控制器，得到反坐标变换的输入 U_{mq}。

最后，将 U_{md}、U_{mq}和θ_{slip}输入反坐标变换，并将变换结果输入 SVPWM 模块，生成脉冲控制信号 S_{rabc}控制转子侧变换器运行。

本发明提出的上述控制方法，一方面可以实现直接控制双馈电压源风电机组的转速。另一方面通过转速-MPPT 切换控制模块可以实现转速直接控制和 MPPT 最大功率跟踪控制两模式的切换，通过虚拟惯量切换控制模块可以实现是否启用虚拟惯量控制的切换；也即可实现①MPPT 控制+无惯量响应；②MPPT 控制+惯量响应；③转速直接控制+无惯量响应；④转速直接控制+惯量响应四种不同的控制效果

二、测试

如图 7 所示搭建 2MW 的双馈风电机组并网模型进行仿真测试。相关参数设置如下表 1 和表 2 所示：

表 1：风力机参数

参数名	数值	参数名	数值
额定定子电压/kV	0.69	定子电阻/pu	0.0344
定转子绕组比/pu	0.333	定子漏抗/pu	0.2748
额定功率/MWA	2	励磁电抗/pu	12.97
额定频率/Hz	50	转子电阻/pu	0.0273
直流母线电容/mF	3.6	转子漏抗/pu	0.3979

表 2：双馈风电机组电气参数

参数名	数值	参数名	数值
机组气动功率/MW	2.18	额定风速/m/s	11.8
切入风速/m/s	3	切出风速/m/s	25
风轮直径/m	90.76	齿轮箱变比	84.26
C_{pmax}	0.483	最佳叶尖速比	8.37

如图 8 和图 9 所示为风电机组工作在常规的 MPPT 最大功率跟踪模式下，有无惯量响应两种情况的发电机转速和电磁转矩对比。其中环境风速为 10.5m/s，风电机组的转速为 1.08pu，发电机的电磁转矩为 0.5pu。在仿真时间第 4s 时投入 2MW 的负载。当风电机组具备惯量响应能力时，在负载投入瞬间风电机组电磁转矩增加，电磁功率也随之增加，增加的功率用于

抑制电网频率的跌落，并且风电机组的转速下降，释放转子中储存的动能，体现出虚拟惯量的控制效果。而当风电机组不具备惯量响应能力时，发电机转速和电磁转矩均不响应负载变化，无法体现虚拟惯量的控制效果。

如图 10 和图 11 所示为风电机组工作在转速直接控制模式下，有无惯量响应两种情况的发电机转速和电磁转矩对比。其中环境风速为 12.5m/s，风电机组的转速被控制为转速的上限 1.2pu，发电机的电磁转矩为 0.7pu。在仿真时间第 4s 时投入 2MW 的负载。与 MPPT 模式的对比结果类似，当风电机组具备惯量响应能力时，能够体现出虚拟惯量的控制效果。而当风电机组不具备惯量响应能力时，发电机转速和电磁转矩均不响应负载变化，无法体现虚拟惯量的控制效果。

综上对比测试证明，本发明提出的控制方法，能够有效实现转速直接控制。在此基础上，还通过设置两处功能切换模块，实现了转速直接控制与 MPPT 控制的自由切换，以及是否进行惯量响应控制的自由切换。

本发明并不限于上述实施方式，在不背离本发明的实质内容的情况下，本领域技术人员能够做出的任何显而易见的改进、替换或变形均属于本发明的保护范围。

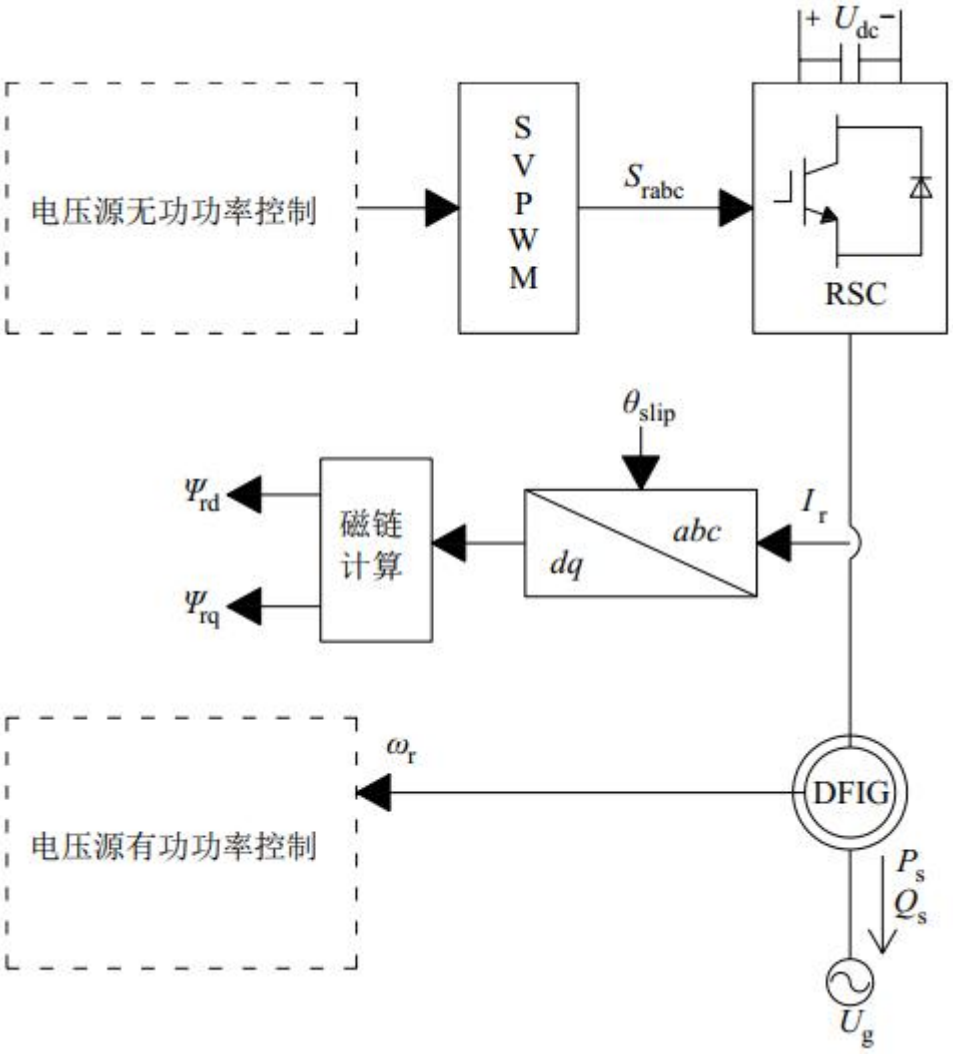

+ U_{dc} −
电压源无功功率控制
SVPWM
S_{rabc}
RSC
θ_{slip}
Ψ_{rd}
Ψ_{rq}
磁链计算
dq
abc
I_r
ω_r
电压源有功功率控制
DFIG
P_s
Q_s
U_g

图 1

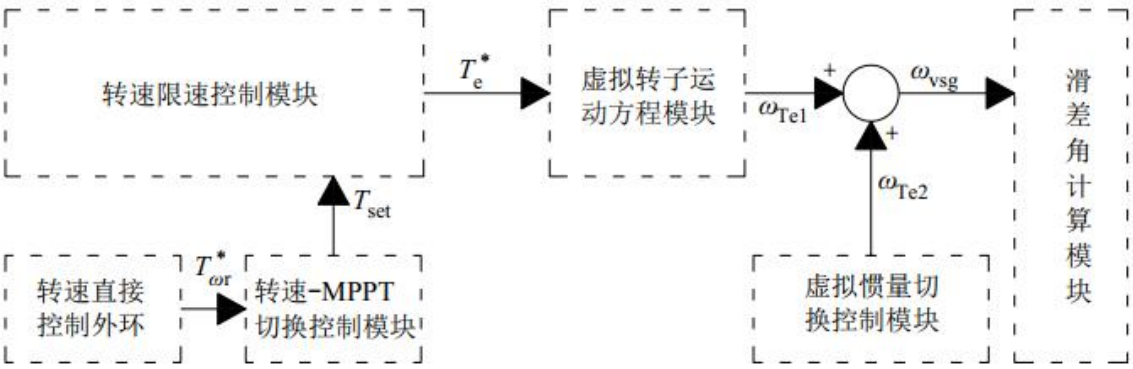

转速限速控制模块
T_e^*
虚拟转子运动方程模块
ω_{vsg}
滑差角计算模块
ω_{Te1}
ω_{Te2}
T_{set}
$T_{\omega r}^*$
转速直接控制外环
转速-MPPT切换控制模块
虚拟惯量切换控制模块

图 2

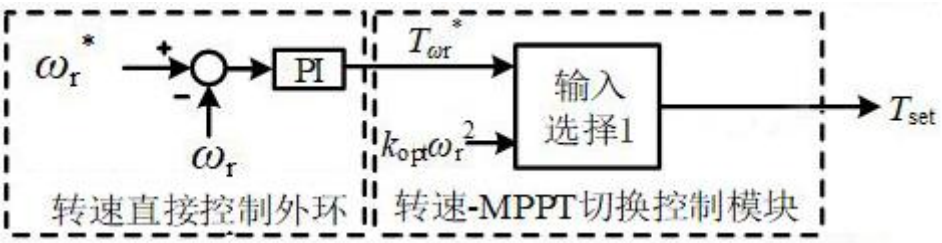

ω_r^*
PI
ω_r
转速直接控制外环
$T_{\omega r}^*$
$k_{opt}\omega_r^2$
输入
选择1
T_{set}
转速-MPPT切换控制模块

图 3

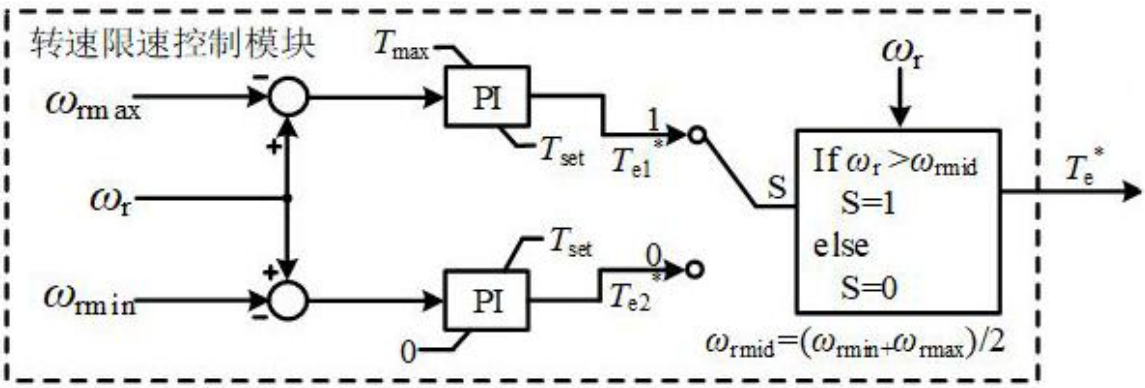

转速限速控制模块
T_{max}
ω_{rmax}
PI
T_{set}
T_{e1}^*
1
ω_r
ω_r
S
If $\omega_r > \omega_{rmid}$
S=1
else
S=0
T_e^*
T_{set}
0
ω_{rmin}
PI
T_{e2}^*
0
$\omega_{rmid}=(\omega_{rmin}+\omega_{rmax})/2$

图 4

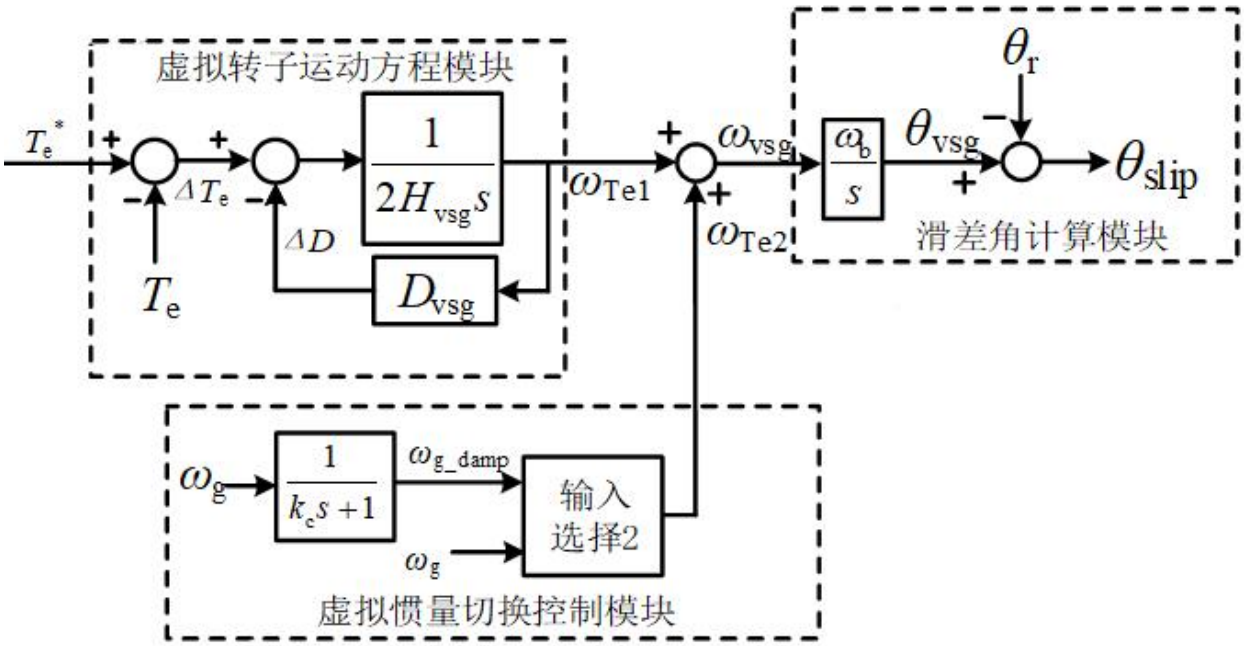

虚拟转子运动方程模块
T_e^*
ΔT_e
$\frac{1}{2H_{vsg}s}$
ω_{Te1}
ω_{vsg}
ω_b
s
θ_{vsg}
θ_r
θ_{slip}
滑差角计算模块
ΔD
T_e
D_{vsg}
ω_{Te2}
ω_g
$\frac{1}{k_c s+1}$
ω_{g_damp}
输入
选择2
ω_g
虚拟惯量切换控制模块

图 5

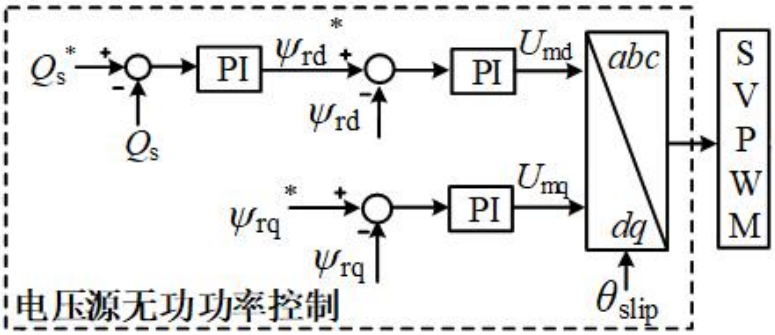

PI
PI
PI
abc
dq
SVPM
电压源无功功率控制

图 6

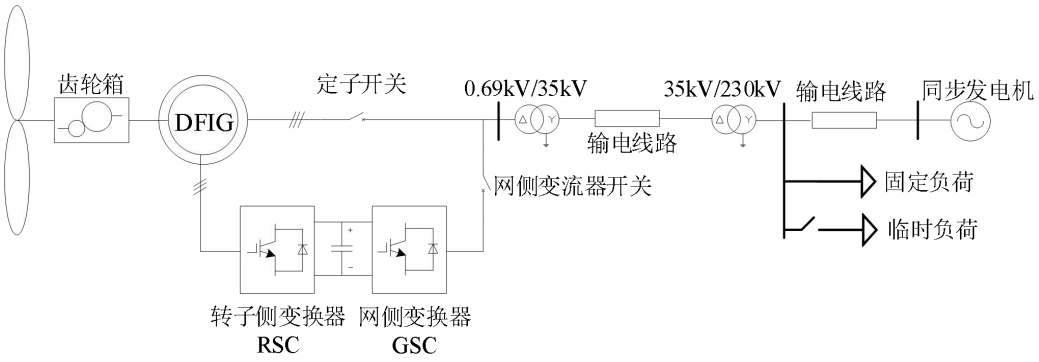

齿轮箱
DFIG
定子开关
0.69kV/35kV
35kV/230kV
输电线路
同步发电机
输电线路
网侧变流器开关
固定负荷
临时负荷
转子侧变换器
RSC
网侧变换器
GSC

图 7

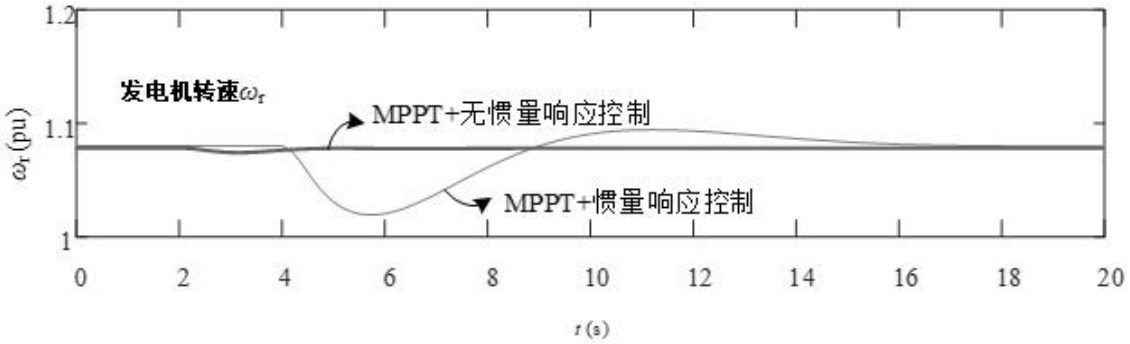

发电机转速ω_r
MPPT+无惯量响应控制
MPPT+惯量响应控制
ω_r(pu)
t (s)

图 8

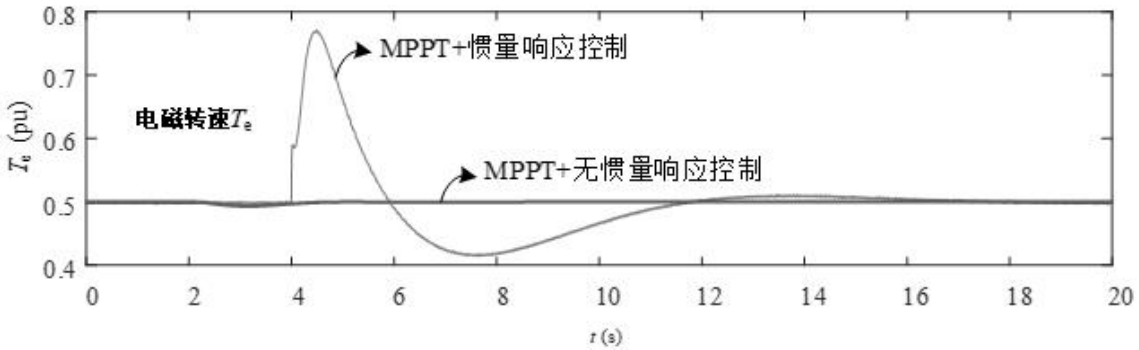

MPPT+惯量响应控制
电磁转速T_e
MPPT+无惯量响应控制
T_e (pu)
t (s)

图 9

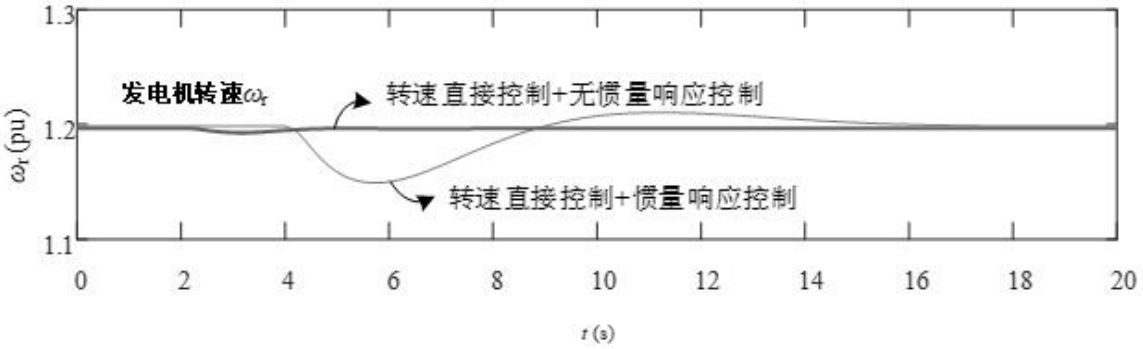

1.3
1.2
1.1
ω_r(pu)
发电机转速ω_r
转速直接控制+无惯量响应控制
转速直接控制+惯量响应控制
0
2
4
6
8
10
12
14
16
18
20
t (s)

图 10

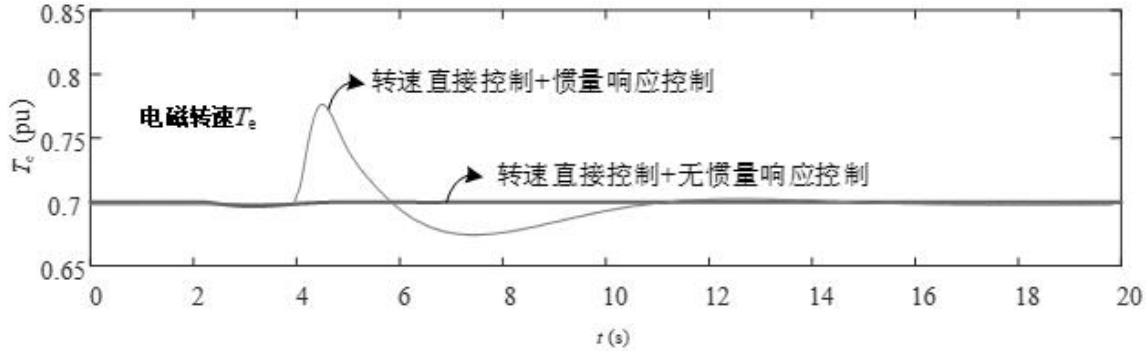

0.85
0.8
0.75
0.7
0.65
T_e (pu)
电磁转速T_e
转速直接控制+惯量响应控制
转速直接控制+无惯量响应控制
0
2
4
6
8
10
12
14
16
18
20
t (s)

图 11

一种构网型全功率风电机组功率-转速柔性切换自调频控制方法（发明）技术交底书

1. 相关背景技术及现有技术发展情况：

1.1 背景技术

在“双碳”政策的大背景下，中国新能源将迎来前所未有的发展机遇，中国将加强新能源与传统能源协同，加大新能源技术创新力度，实现绿色、低碳、可持续发展。因此，大力发展包括风力发电在内的新能源将成为未来的重要发展方向。

传统的全功率风电机组采用基于矢量控制的变流器控制方式，本质上属于电流源控制方式，采用双闭环的控制策略实现有解耦控制，外环可以是有功功率环，也可以是转速环，通常采用的是有功功率外环。由于在有功功率外环中无法表征电网频率对于风机出力的影响，因此传统电流源控制的全功率风电机组不具备参与电网调频的能力，需要在传统的矢量控制基础上增加反应电网频率变化的虚拟惯量控制环节，实现虚拟惯量控制的效果，使得全功率风电机组能够对电网提供惯量与功率支撑，具备此能力的全功率风电机组可被称为构网型风电机组。

目前主流的全功率风电机组构网型控制方式，其特征体现为保留传统矢量控制的结构，即双闭环控制，外环可根据控制需要选择功率环或者是转速环，内环为电流环，通过 PLL 锁相环实现和电网同步，改变之处体现为外环给定中增加了反应电网频率变化的虚拟惯量控制环节，从而当系统频率发生变化时能够改变风电机组的有功功率出力，体现出有功支撑的控制效果。

然而，目前提出的虚拟惯量控制方法仅能适配于一种控制外环，当选择了有功功率作为功率外环的控制对象，则风电机组的转速就不再受到直接控制，尤其在风电机组具备了虚拟惯量的控制效果之后，在体现惯量响应的过程中转速有可能出现失控的情况。

因此有必要针对性提出一种具备自调频能力的全功率风电机组功率-转速切换控制方法，使得风电机组具备能够根据需要自动切换控制对象的能力，既可以切换为构网型控制，又可以在一定条件下切换为转速外环控制，控制风电机组的转速在合理范围内，进一步提高风电机组的安全性和可控性。

1.2 与本发明创造相关的现有技术

1.2.1 现有技术的技术方案

现有的全功率风电机组构网型技术方法如下：网侧变换器通常保留传统的矢量控制策略，机侧变换器采用矢量控制策略，同时在机侧控制策略的功率给定上增加反应电网频率变化的

虚拟惯量控制环节，体现虚拟惯量的控制效果，如图 1-1 所示。

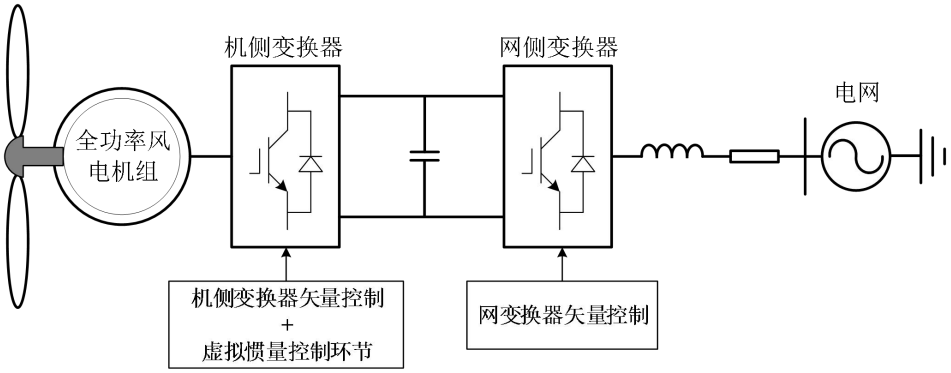


图 1-1 全功率风电机组构网型控制策略结构

在机侧变换器的控制策略中，在传统矢量控制的基础之上增加反应电网频率变化的虚拟惯量控制环节，如图 1-2 所示。

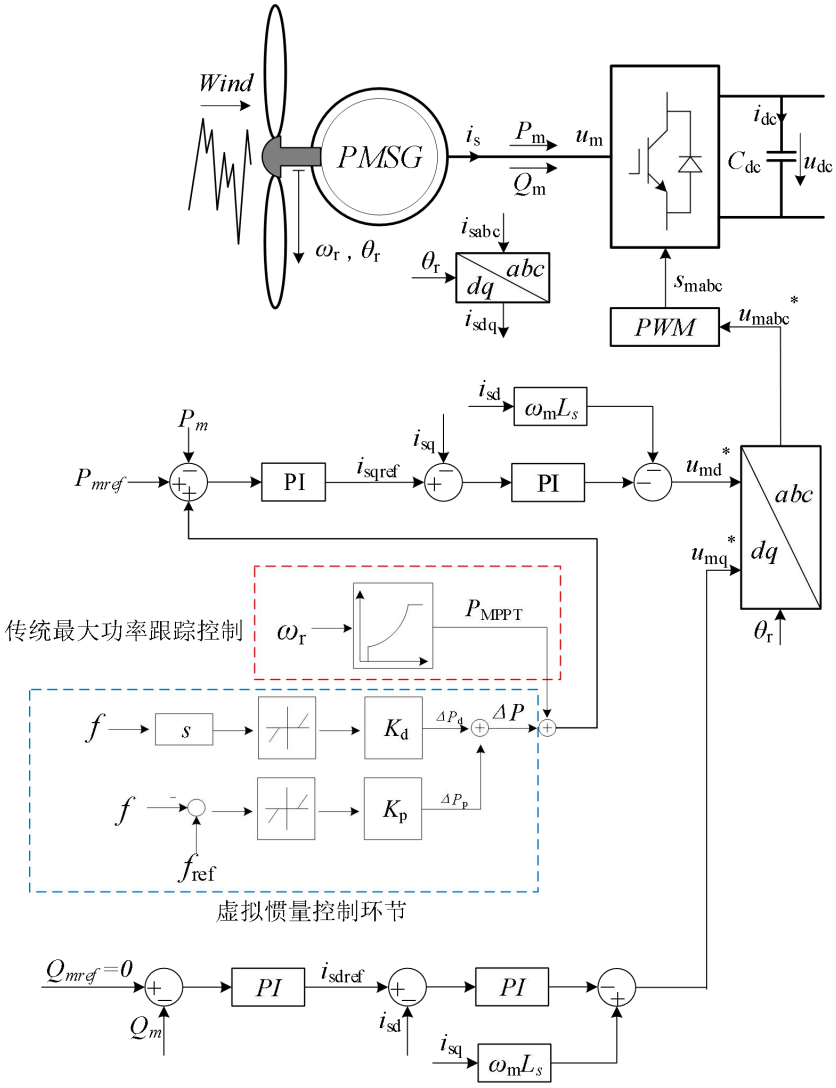


图 1-2 构网型全功率风电机组机侧变换器控制框图

在网侧变换器控制方式中，仍采用传统的矢量控制策略，实现对于直接母线电压，以及网侧变换器无功功率的控制。

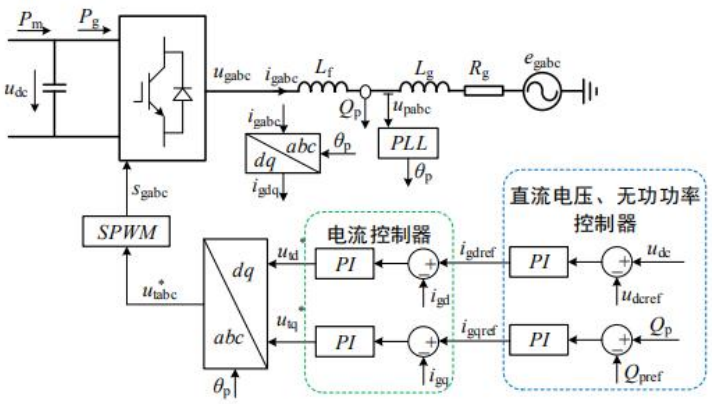


图 1-3 构网型全功率风电机组网侧变换器控制框图

1.2.2 现有技术的缺点

目前提出的构网型全功率风电机组控制方法仅能适配于一种控制外环，当选择了有功功率作为功率外环的控制对象，则风电机组的转速就不再受到直接控制，尤其在风电机组具备了虚拟惯量的控制效果之后，在体现惯量响应的过程中转速有可能出现失控的情况。因此有必要针对性提出一种具备自调频能力的全功率风电机组功率-转速切换控制方法，使得风电机组具备能够根据需要自动切换控制对象的能力，既可以切换为构网型控制，又可以在一定条件下切换为转速外环控制，控制风电机组的转速在合理范围内，进一步提高风电机组的安全性和可控性。

2．本发明创造技术方案详细阐述：

2.1 本发明创造所要解决的技术问题

4) **实现风电机组自调频控制。**将电网频率的变化反映到风电机组有功出力上，体现出虚拟惯量控制的效果，使得风电机组具备参与电网调频的能力。

5) **实现转速与功率外环柔性切换控制。**充分结合风电机组虚拟惯量控制中功率外环控制和转速外环控制的优点，通过合理设计切换逻辑，实现转速外环和功率外环的柔性切换，起到平稳柔性切换的控制目的。

6) **实现转速与功率外环自动、手动切换控制。**当机组工作在自动切换模式下，通过专门设计的切换判断模块，可以根据设定条件自动实现转速、功率外环柔性切换，也可以设置为手动切换模式，根据外部指令实现转速、功率外环柔性切换。

2.2 本发明创造完整的技术方案阐述

针对现有技术存在的不足，本发明提供了一种构网型全功率风电机组功率-转速柔性切换自调频控制方法，使得风电机组既可以切换为构网型控制，又可以在一定条件下切换为转速外环控制，控制风电机组的转速在合理范围内，进一步提高风电机组的安全性和可控性。

本发明通过以下技术手段实现上述技术目的。

一种构网型全功率风电机组功率-转速柔性切换自调频控制方法：包括机侧变换器的有功功率控制策略和无功功率控制策略。其中有功功率控制策略的目的是控制全功率风电机组的有功功率，并根据控制指令实现功率外环和转速外环之间的手动或者自动切换，实现功率控制和转速控制的组合；无功功率控制策略的目的是控制全功率风电机组定子侧的无功功率，实现风电机组的单位功率因数运行。

进一步的，本发明中的有功功率控制策略包括以下 6 个子模块控制项：（1）虚拟惯量控制模块，（2）有功功率外环控制模块，（3）转速外环控制模块，（4）有功电流切换模块，（5）有功功率内环控制模块，（6）切换判断模块。

上述（1）虚拟惯量控制模块中，电网频率实际值 f 经过微分传递函数 s，其结果和微分系数 K_{d} 相乘，得到微分附加功率 ΔP_{d}，微分附加功率 ΔP_{d} 和电网频率 f 之间满足如下关系：

$$\Delta P_{\mathrm{d}} = K_{\mathrm{d}} \frac{df}{dt}$$

电网频率基准值 f_{ref} 和实际值 f 之差，和比例系数 K_{p} 相乘，得到比例附加功率 ΔP_{p}，比例附加功率 ΔP_{p} 和电网频率 f 之间满足如下关系：

$$\Delta P_{\mathrm{p}} = K_{\mathrm{p}}(f_{\mathrm{ref}} - f)$$

微分附加功率 ΔP_{d} 和比例附加功率 ΔP_{p} 相加，得到整个风电机组的附加功率 ΔP，如下式所示：

$$\Delta P = \Delta P_{\mathrm{d}} + \Delta P_{\mathrm{p}}$$

上述（2）有功功率外环控制模块中，全功率风电机组的有功功率给定 P_{mref} 减去全功率风电机组有功功率的实际值 P_{m}，其结果与风电机组的附加功率 ΔP 相加，作为 PI 控制器的输入信号 P_{in}，P_{in} 经过 PI 控制器，输出风力发电机定子电流 q 轴分量的给定值 i_{sqref1}，i_{sqref1} 表示有功功率外环 PI 控制器的输出结果。

i_{sqref1} 和锁存器控制信号#1 一并输入至锁存器，输出信号为复位赋值 1。锁存器功能如下：当锁存器控制信号#1 等于 0 时，复位赋值 1 始终等于 i_{sqref1} 信号，当锁存器控制信号#1 从 0 变为 1 的瞬间，复位赋值 1 等于此刻 i_{sqref1} 的值并保持锁定不变，直到锁存器控制信号#1 变为 0 为止。

另一方面，PI 控制器的复位信号#1 也作为 PI 控制器的输入，复位信号功能如下：当复位信号#1 等于 1 时，PI 控制器的输出 i_{sqref1} 等于复位赋值 1，其他情况下 PI 控制器的输出由 P_{in} 经过 PI 计算（比例-积分计算）生成。

上述（3）转速外环控制模块中，全功率风电机组的转速给定ω_{rref}减去全功率风电机组转速的实际值ω_r，其结果作为 PI 控制器的输入信号ω_{rin}，ω_{rin}经过 PI 控制器，输出风力发电机定子电流 q 轴分量的给定值 i_{sqref2}，i_{sqref2}表示转速外环的 PI 控制器输出结果。

i_{sqref2}和锁存器控制信号#2 一并输入至锁存器，输出信号为复位赋值 2。锁存器功能如下：当锁存器控制信号#2 等于 0 时，复位赋值 2 始终等于 i_{sqref2}信号，当锁存器控制信号#2 从 0 变为 1 的瞬间，复位赋值 2 等于此刻 i_{sqref2}的值并保持锁定不变，直到锁存器控制信号#2 变为 0 为止。

另一方面，PI 控制器的复位信号#2 也作为 PI 控制器的输入，复位信号功能如下：当复位信号#2 等于 1 时，PI 控制器的输出 i_{sqref2}等于复位赋值 2，其他情况下 PI 控制器的输出由ω_{rin}经过 PI 计算生成。

上述（4）有功电流切换模块中，包含两个输入信号，分别是功率外环 PI 控制器的输出 i_{sqref1}，以及转速外环 PI 控制器的输出 i_{sqref2}，输出信号为有功功率内环电流的给定值 i_{sqref}，i_{sqref}值的大小由切换控制信号决定，当切换控制信号等于 0 时，$i_{sqref}=i_{sqref2}$，当切换控制信号等于 1 时，$i_{sqref}=i_{sqref1}$。

上述（5）有功功率内环控制模块中，有功电流切换模块的输出信号 i_{sqref}减去定子电流的 q 轴分量 i_{sq}后输入到 PI 控制器中，上述 PI 控制器的结果取反后减去定子电流的 d 轴分量 i_{sd}、额定频率ω_m以及定子电感 L_s三者之积，得到反坐标变换的输入 U_{md}。

上述（6）切换判断模块中，分为自动切换和手动切换两种情况，分别通过自动切换流程图以及手动切换流程图表示。

在自动切换流程图中，初始切换控制信号为 1，风电机组工作在功率外环构网型控制模式，当风电机组运行之后开始首先检测风机是否达到额定转速，如果达到额定转速，则切换控制信号赋值为 0，如果没有达到额定转速，则维持切换控制信号为 1 不变。同时检测切换控制信号是否出现上升沿，如果出现上升沿，则进行如下操作：将复位信号#1 的值由 1 变为 0，将锁存器控制信号#1 的值由 1 变为 0，将复位信号#2 的值由 0 变为 1，将锁存器控制信号#2 的值由 0 变为 1。如果没有出现上升沿，则检测是否出现下降沿，如果出现下降沿，则进行如下操作：将复位信号#1 的值由 0 变为 1，将锁存器控制信号#1 的值由 0 变为 1，将复位信号#2 的值由 1 变为 0，将锁存器控制信号#2 的值由 1 变为 0，如果没有检测到下降沿，则继续判断是否出现上升沿。

在手动切换流程图中，通过手动赋值的方式改变切换控制信号的值，后续对于切换控制信号变化的处理同自动切换流程图，此处不做赘述。

进一步的，本发明中的无功功率控制策略中，风电机组的无功功率给定 Q_{mref} 和无功功率实际值 Q_m 之差输入到 PI 控制器，输出定子电流 d 轴分量的给定值 i_{sdref}，i_{sdref} 随后减去定子电流 d 轴分量的实际值 i_{sd}，其结果输入到 PI 控制器，输出的结果取反后加上定子电流的 q 轴分量 i_{sq}、额定频率 ω_m 以及定子电感 L_s 三者之积，得到反坐标变换的输入 U_{mq}。

最后，将反坐标变换的输入 U_{md}、U_{mq} 以及转子角 θ_r 输入反坐标变换，并将变换结果输入 SVPWM 模块，生成脉冲控制信号控制转子侧变换器运行。

2.3 本发明创造技术方案带来的有益效果

1) **实现风电机组自调频控制。**将电网频率的变化反映到风电机组有功出力上，体现出虚拟惯量控制的效果，使得风电机组具备参与电网调频的能力。
2) **实现转速与功率外环柔性切换控制。**充分结合风电机组虚拟惯量控制中功率外环控制和转速外环控制的优点，通过合理设计切换逻辑，实现转速外环和功率外环的柔性切换，能够起到平稳柔性切换的控制目的。
3) **实现转速与功率外环自动、手动切换控制。**当机组工作在自动切换模式下，通过专门设计的自动切换流程图，可以根据设定条件实现转速、功率外环柔性自动切换，也可以设置为手动切换模式，根据外部指令以及手动切换流程图实现转速、功率外环柔性手动切换。

3．本发明创造的技术关键点和拟保护点：

8) 保护构网型全功率风电机组实现**自调频**功能的控制方法。
9) 保护构网型全功率风电机组实现转速外环与功率外环**柔性切换**的控制方法。
10) 保护构网型全功率风电机组实现转速外环与功率外环**自动**切换的控制流程方法。
11) 保护构网型全功率风电机组实现转速外环与功率外环**手动**切换的控制流程方法。

4.本发明创造的替代方案：

暂无

5．具体实施例及附图：

四、 附图信息如下：

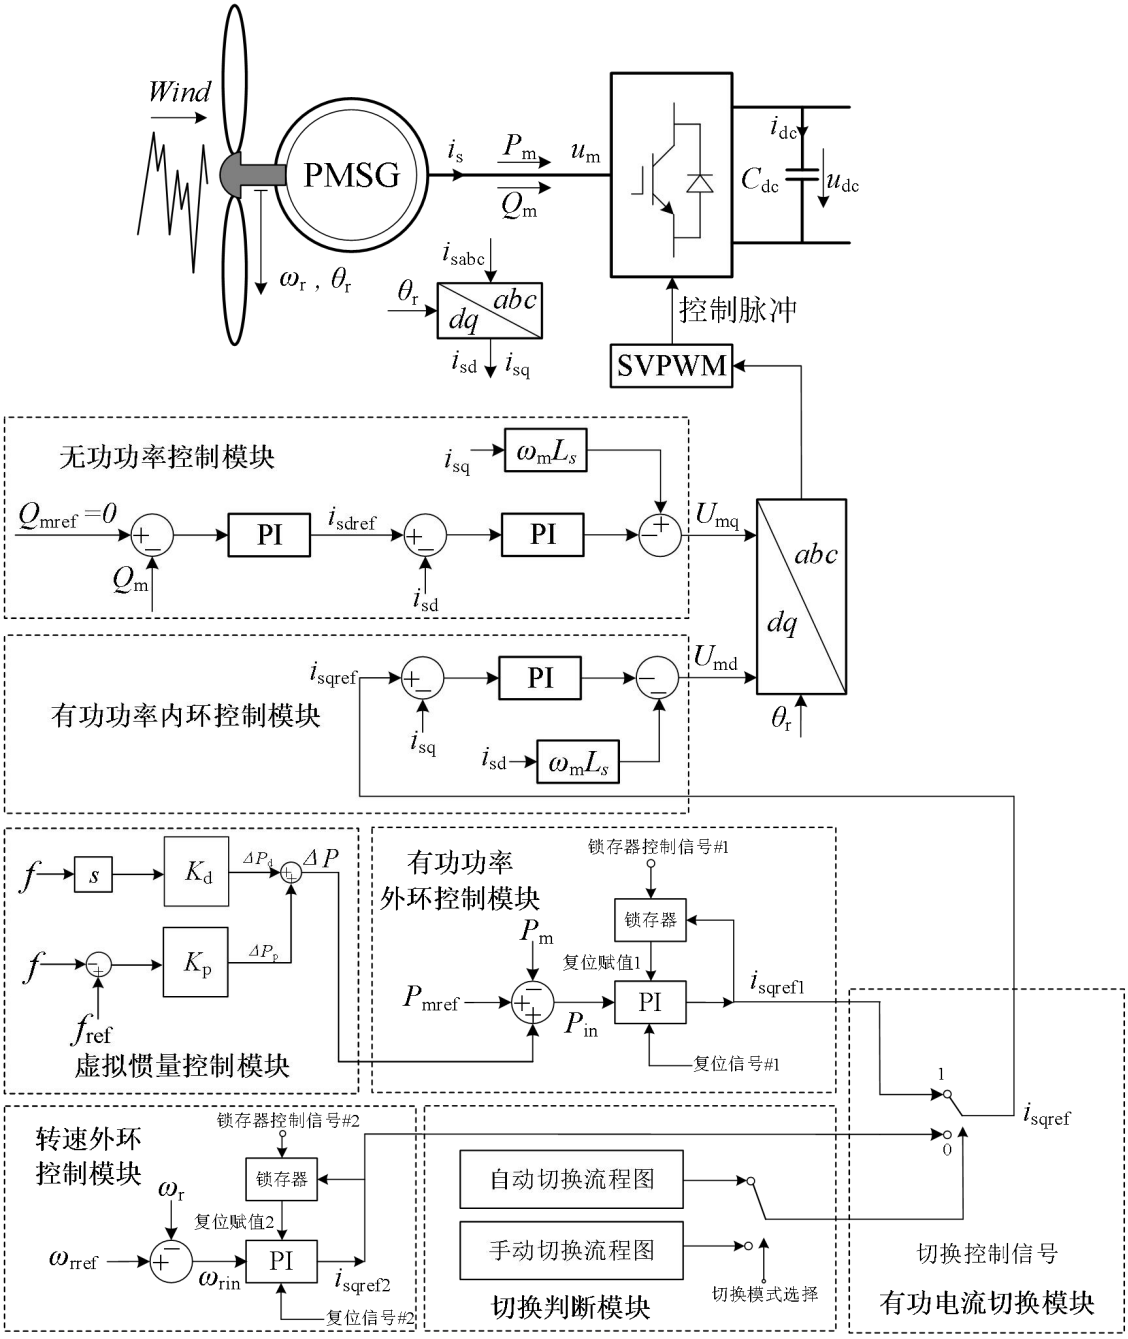


图 5-1 总图-构网型全功率风电机组功率-转速柔性切换自调频控制方法

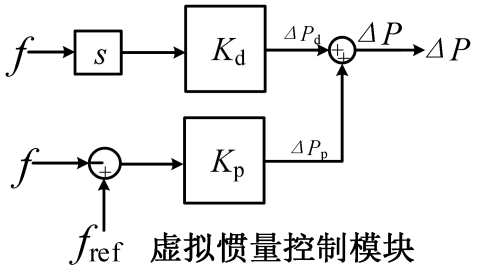
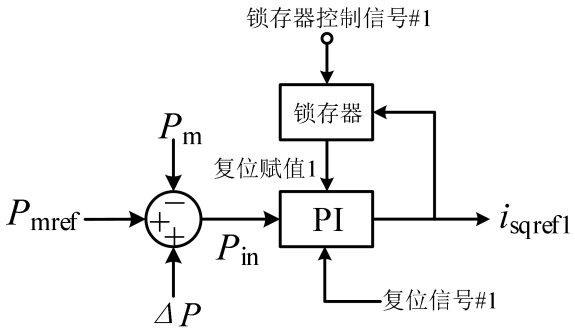
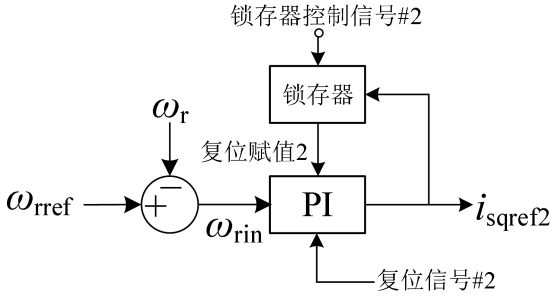


图 5-2 虚拟惯量控制模块



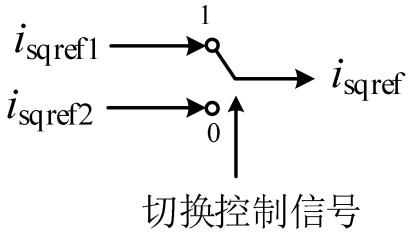
有功功率外环控制模块

图 5-3 有功功率外环控制模块



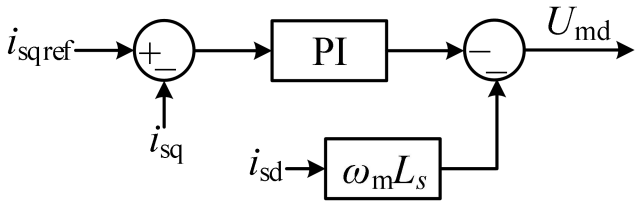
转速外环控制模块

图 5-4 转速外环控制模块



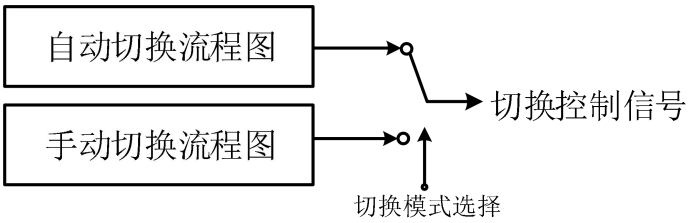
有功电流切换模块

图 5-5 有功电流切换模块



有功功率内环控制模块

图 5-6 有功功率内环控制模块



切换判断模块

图 5-7 切换判断模块

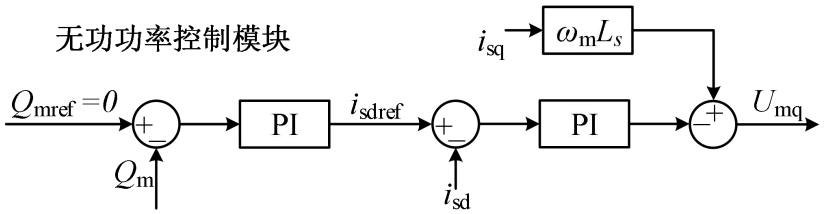


图 5-8 无功功率控制模块

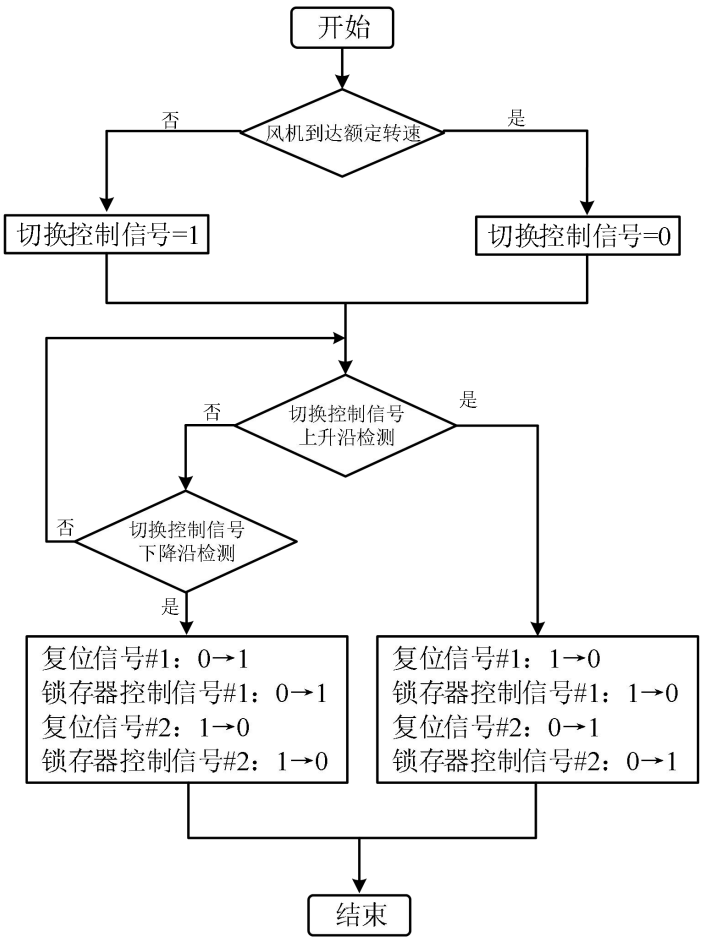


图 5-9 自动切换流程图

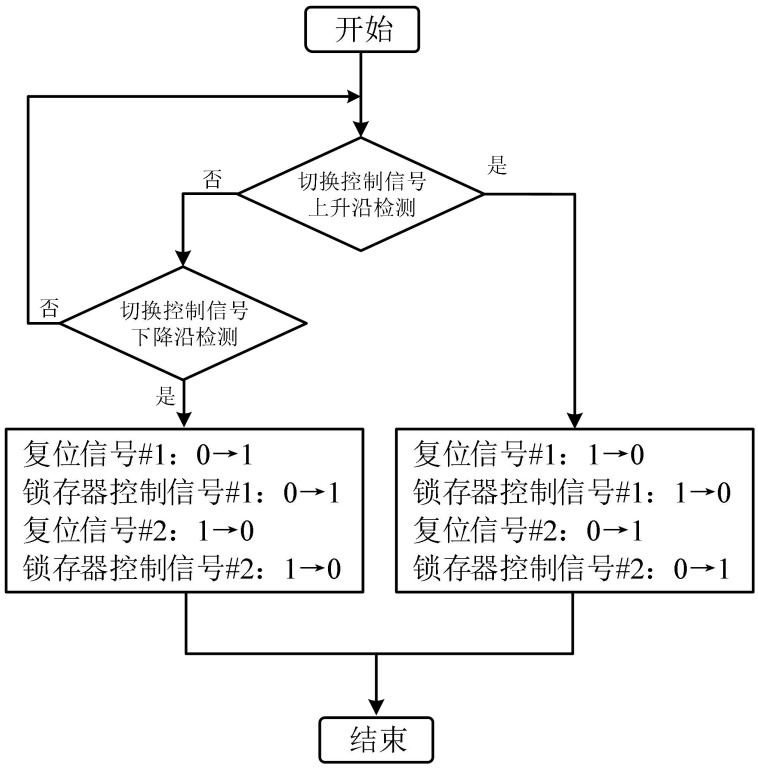


图 5-10 手动切换流程图

五、 具体实施案例如下：

风电机组正常启动运行之后，默认的切换控制信号初始值为 1，全功率风电机组工作在构网型控制方式下，外环是功率环。

首先根据控制要求选择实行自动切换还是手动切换。

当工作在自动切换模式下，伴随风速的增加，风电机组的转速随之增加，只要风电机组的转速不超过额定转速，那么就不发生切换操作，切换控制信号保持为 1，风电机组始终工作在构网型控制方式下，有功外环为功率环。当检测到风电机组转速达到额定转速之后，切换控制信号从默认的 1 变为 0，随后检测控制信号是否有上升沿，检测到未产生上升沿，随后检测是否有下降沿，检测到产生下降沿（因为换控制信号从默认的 1 变为 0），随即进行如下操作：将复位信号#1 的值由 0 变为 1，将锁存器控制信号#1 的值由 0 变为 1，这样操作的目的是通过锁存器将切换瞬间的功率 PI 控制器输出赋值给复位赋值 1，并通过复位操作将功率 PI 控制器的输出始终保持为切换瞬间的功率 PI 控制器输出值，从而减少从转速外环切换回功率外环时的冲击电流，实现柔性切换的控制目的；同时，将复位信号#2 的值由 1 变为 0，将锁存器控制信号#2 的值由 1 变为 0，这样操作的目的是使转速外环的锁存器停止工作，禁止转速外环 PI 控制器进行复位操作，此时转速外环 PI 控制器正常工作，风电机组工作在转速外环模式下，实现对于转速的直接控制，避免大风速情况下风电机组转速失控的情况发生。

如果风电机组在转速外环情况下工作了一段时间之后，风速的下降使得风电机组的转速

小于额定转速，此时切换控制信号从 0 切换回 1，此时可以检测出上升沿信号，并进行如下操作：将复位信号#1 的值由 1 变为 0，将锁存器控制信号#1 的值由 1 变为 0，这样操作的目的是使功率外环的锁存器停止工作，禁止功率外环 PI 控制器进行复位操作，意味着此时功率外环的 PI 控制器开始恢复正常工作，功率外环 PI 控制器的初始输出是上一次切换后的锁存值，从而可以减少切换瞬间产生的冲击电流，实现柔性平稳切换；同时，将复位信号#2 的值由 0 变为 1，将锁存器控制信号#2 的值由 0 变为 1，这样操作的目的是通过锁存器将切换瞬间的转速 PI 控制器输出赋值给复位赋值 2，并通过复位操作将转速 PI 控制器的输出始终保持为切换瞬间的转速 PI 控制器输出值，从而减少从功率外环切换回转速外环时的冲击电流，实现柔性切换的控制目的。

当工作在手动切换模式下，可以在风电机组运行的过程中的任意时刻进行手动切换操作，实现转速外环和功率外环的切换，详细的切换过程以及复位信号、锁存器控制信号的变化方式和自动切换相同，此处不予赘述。

六、　仿真测试如下：

在 RTDS 实时数字仿真器中搭建 6.25MW 全功率风电机组并网模型，仿真系统结构如图 5-11 所示，双馈风电机组的相关参数见表 5-1。

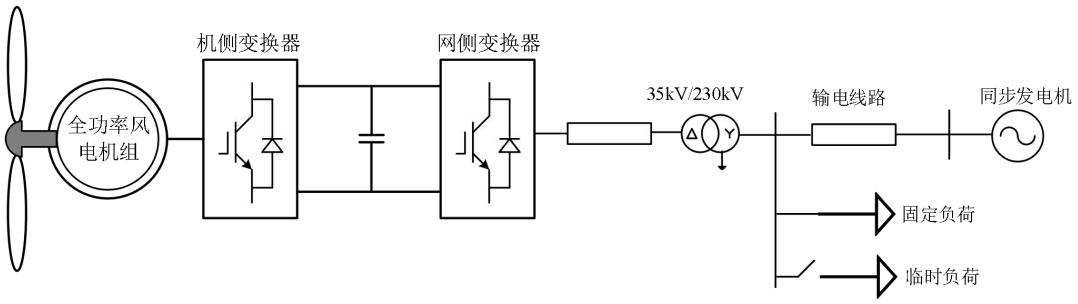


图 5-11 仿真结构示意图

表 5-1 6.25MW 全功率风电机组主要参数

物理量	数值	物理量	数值
额定功率/MW	6.25	最佳叶片利用系数 Cp	0.416
叶轮半径/m	84	最佳叶尖速度比λ	10.3
切入风速 m/s	3	风机惯性时间常数/s	10.8
额定风速 m/s	10.7	永磁机极对数	72
网侧滤波电感	25uH	直流母线电容	96mF
网侧滤波电容	2005.2uF(星型)	卸荷电阻	0.125ohm

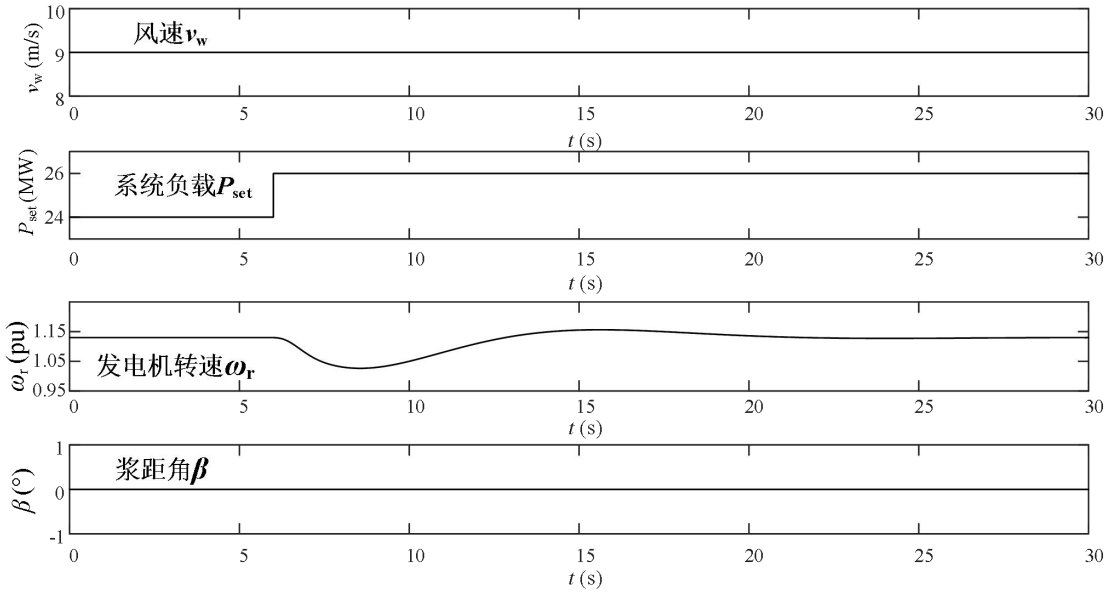


图 5-12 最大功率跟踪阶段频率响应波形图（功率外环）

当环境风速为 9m/s，对应着风电机组运行在 MPPT 最大功率跟踪阶段，风电机组的外环为功率环，体现为构网型风电机组的控制策略，当仿真时间 t=6s 时投入临时负载，系统的惯量响应如图 5-12 所示。当系统负载投入时，系统的频率变化使得风电机组的有功功率给定发生变化，进一步影响了风电机组的有功功率输出以及风电机组转速，风电机组转速呈现出明显的降速过程以体现虚拟惯量的控制效果，由于在响应的全过程中转速未超过额定值，因此未发生功率外环和转速外环的切换。

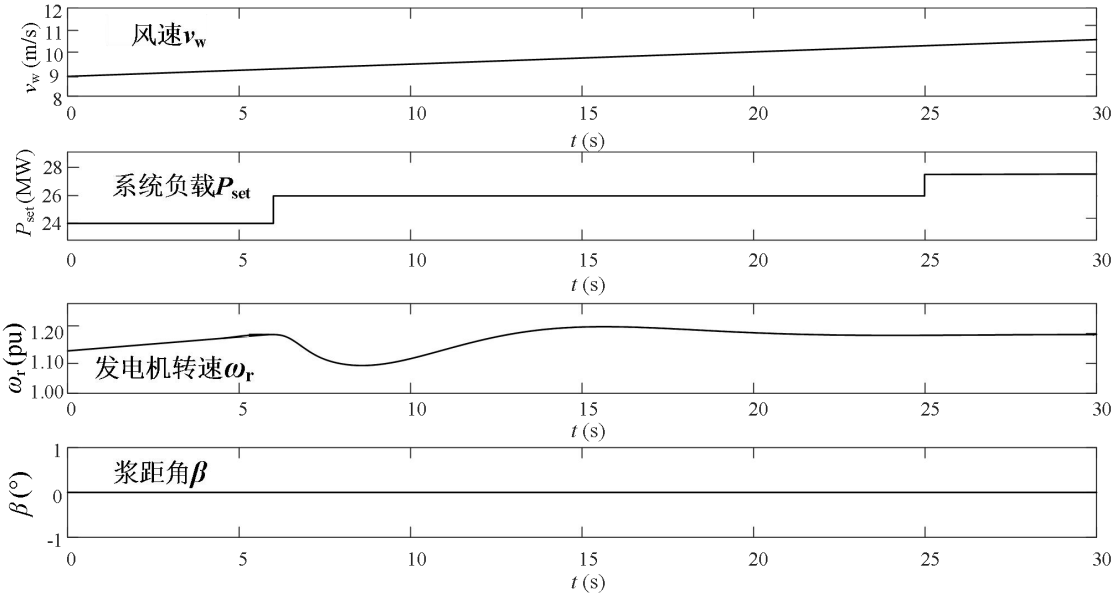


图 5-13 功率外环与转速外环柔性切换示意图

当环境风速从 9m/s 渐变为 10.5m/s，风电机组的转速随着风速的增加而增加，而在达到额定转速之前，当仿真时间 t=6s 时投入临时负载，系统的惯量响应如图 5-13 所示，当负载投入之后，风电机组的转速呈现出下降的趋势，体现出虚拟惯量响应的控制效果，而在转速恢

复的后期，伴随风速的增加，转速达到了额定转速，风电机组切换到了转速外环，控制风电机组的转速稳定在了 1.2pu 的额定转速处，在 t=25s 时，尽管再次发生了负载投入的情况，但是风电机组仍工作在转速外环，不响应电网频率变化，起到了保护风电机组的作用，避免转速变化超过额定转速的情况发生。

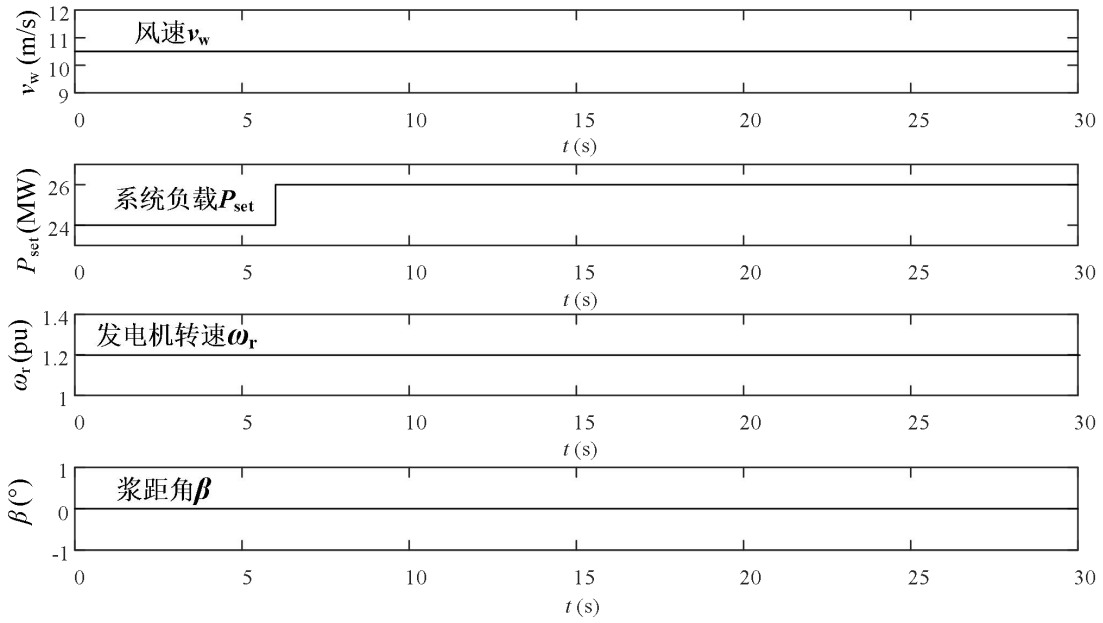


图 5-14 恒转速阶段频率响应波形图（转速外环）

当环境风速为 10.5m/s，此时风电机组的转速已经稳定在额定转速 1.2pu 处，风电机组的控制策略已经切换为转速外环控制策略，当仿真时间 t=6s 时投入临时负载，系统的惯量响应如图 5-14 所示。当系统负载投入时，转速外环不响应电网频率的变化，因此风电机组的转速始终维持在额定转速处，起到了保护风电机组的作用，避免转速变化超过额定转速的情况发生。

6. 其他有助于理解本发明创造的技术资料：

相关专利、公知技术检索结果及其与本发明/实用新型的异同点

关键词：风力发电 切换控制 调频能力 (填写专利与公知技术检索需要的关键词)

相关检索结果 1：

申请（专利）号: 201810021480.8

名称: 一种大型风电机组惯量响应优化控制方法

摘要:一种大型风电机组惯量响应优化控制方法，包括以下步骤：1)检测得到发电机、电网频率、风速、桨距角；2)判断风电机组是否运行在变速阶段，是否进入惯量响应控制模式；3)如果是，存储进入该运行模式时刻的初始风速和初始发电机转速；4)对风速进行低通滤波；5)计算得到发电机最优目标控制转速；6)计算得到变速控制环输出的期望发电机转矩；7)计算

得到实际输出的发电机期望转矩；8)发电机期望转矩输出给风电机组变流器控制发电机电磁力矩的控制；9)根据电网频率判断惯量响应控制模式是否退出，如果退出，发电机期望转矩以设定斜率恢复跟踪到发电机最优转矩。本发明有效解决惯量响应控制环与变速控制环之间的协调控制和平稳切换。

技术要点比较：

检索到的专利文件提出了一种型风电机组惯量响应优化控制方法，但是，检索到的专利文件所提出的控制方法聚焦于对于风电机组的转矩控制，无法有效控制风电机组的转速，也无法实现对于并网功率的精准控制。

本专利创新性的提出了风电机组在保证具备自调频能力前提下功率-转速切换控制方法，可以实现转速外环和功率外环的柔性切换，较好的解决了检索专利中存在的问题。

相关检索结果 2：

申请（专利）号:　201711217269.5

名称: 一种基于双馈异步风力发电机的风电并网调频方法及系统

摘要: 本发明公开了一种基于双馈异步风力发电机的风电并网调频方法，所述风力发电机连接有用于控制风力发电机参考转矩的变频器，包括以下步骤：判断风力发电机的转子是否已经达到额定转速；若否，则采用惯量响应调频方法；若是，则采用一次调频方法；采用改变风力发电机的有功功率输出，而改变风力发电机的转速，从而实现电网调频。本发明还公开了一种调频系统，包括风力发电机、变频器以及控制器，所述控制器内配置有惯量响应调频模块以及一次调频模块。本发明跟随风速的随机波动性，进行调频策略的响应，电网频率恢复迅速，并且能抑制频率的二次跌落，不依赖硬件储能设备，大大降低了成本。

技术要点比较：

检索到的专利发明提出了一种基于双馈异步风力发电机的风电并网调频方法，能够跟随风速的随机波动性，进行调频策略的响应，并且能抑制频率的二次跌落。然而该发明专利并不能应对转速精确控制的应用场景，仅适用于功率外环控制的情况，更无法实现转速外环和功率外环之间的柔性切换。

本专利提出了通过锁存器实现柔性切换，避免产生冲击电流影响机组安全运行，在控制上具有明显的优越性，能够有效解决检索专利中存在的控制问题。

申请材料分析说明

1.基础信息

专利名称：一种构网型风电机组功率-转速柔性切换自调频控制方法

状态：授权（2025 年 4 月 4 日、优先审查）

2.交底材料

内容较为完整，给出了背景技术、现有技术、现有技术的缺点、本发明的技术方案及其优势，并给出详实的附图以及测试数据。

背景技术过于冗长，应当聚焦于技术本身，重点是揭示当下存在的技术层面问题；“双碳政策”这类政治相关的词汇及内容表述最好不要出现在专利中。

3.权利要求书

申请时给出了 10 条权利要求，将技术方案的各技术点逐条拆解，为后期审查中针对审查意见答复提供了较为清楚且充足的修改空间。

4.说明书

背景技术部分，清楚交代了本发明所要针对的技术问题——虚拟惯量控制方法仅能适配于一种控制外环。但是背景技术的内容量还有缩短的空间，当前第一段可以删去，直接以第二段作为开头；通过控制背景技术的字数，使得读者能够快速且准确的锁定本发明所要针对的技术问题，从而帮助审查员理解本发明的技术创新点所在。

具体实施方式部分，以列标题的形式，对本发明技术方案进行分拆讲解，其中控制方案第一层分为有功功率控制和无功功率控制，并在有功功率控制中进一步细分为虚拟惯量控制模块、有功功率外环控制模块、转速外环控制模块、有功电流切换模块、有功功率内环控制模块、切换控制模块，这六个子模块。使控制结构层次分明，做到说明书撰写的清楚完整。

有益效果部分，针对 3 处创新点进行了逐条讲解，并给出了较为详实的测试数据进行验证。

申请稿

说明书摘要

本发明提供了一种构网型风电机组功率-转速柔性切换自调频控制方法，设有有功功率外环控制模块和转速外环控制模块，其中在进行功率外环控制时，所述有功功率外环控制模块接入机侧变换器有功功率控制中；在进行转速外环控制时，所述转速外环控制模块接入机侧变换器有功功率控制中。本发明提风电机组控制方法，在能够实现风电机组自调频控制的基础上，实现转速与功率外环之间的切换控制，防止风机转速超过额定转速，避免风机转速出现失控问题。

权利要求书

1.一种构网型风电机组功率-转速柔性切换自调频控制方法，其特征在于：设有有功功率外环控制模块和转速外环控制模块，其中在进行功率外环控制时，所述有功功率外环控制模块接入机侧变换器有功功率控制中；在进行转速外环控制时，所述转速外环控制模块接入机侧变换器有功功率控制中。

2.根据权利要求 1 所述的构网型风电机组功率-转速柔性切换自调频控制方法，其特征在于：依据风机转速，在功率外环控制与转速外环控制之间进行切换，其中当风机转速达到额定转速时，切换为转速外环控制；反之则进行功率外环控制。

3.根据权利要求 2 所述的构网型风电机组功率-转速柔性切换自调频控制方法，其特征在于：所述有功功率外环控制模块中，信号 P_{in} 经 PI 控制器，得到风力发电机定子电流 q 轴分量的给定值 i_{sqref1}，其中 P_{in} 由下式获得：

$$P_{\mathrm{in}} = \Delta P + P_{\mathrm{mref}} - P_{\mathrm{m}}$$

式中，P_{mref} 为风电机组的有功功率给定，P_{m} 为风电机组有功功率的实际值，ΔP 为附加功率，由下式获得：

$$\Delta P = \Delta P_{\mathrm{d}} + \Delta P_{\mathrm{p}}$$

$$\Delta P_{\mathrm{d}} = K_{\mathrm{d}} \frac{df}{dt}$$

$$\Delta P_{\mathrm{p}} = K_{\mathrm{p}} (f_{\mathrm{ref}} - f)$$

式中，f为电网频率实际值，K_d为微分系数，ΔP_d为微分附加功率，f_{ref}为电网频率基准值，K_p为比例系数，ΔP_p为比例附加功率。

4.根据权利要求 3 所述的构网型风电机组功率-转速柔性切换自调频控制方法，其特征在于：所述转速外环控制模块中，信号ω_{rin}经 PI 控制器，得到风力发电机定子电流 q 轴分量的给定值 i_{sqref2}，其中ω_{rin}由下式获得：

$$\omega_{rin} = \omega_{rref} - \omega_r$$

式中，ω_{rref}为风电机组的转速给定值，ω_r为风电机组的转速实际值。

5.根据权利要求 4 所述的构网型风电机组功率-转速柔性切换自调频控制方法，其特征在于：设有有功电流切换模块，用于控制功率外环控制与转速外环控制之间的切换：

$$i_{sqref} = \begin{cases} i_{sqref1}，\text{功率外环控制时} \\ i_{sqref2}，\text{转速外环控制时} \end{cases}$$

式中，i_{sqref}为最终送入机侧变换器有功功率控制的风力发电机定子电流 q 轴分量给定值。

6.根据权利要求 5 所述的构网型风电机组功率-转速柔性切换自调频控制方法，其特征在于：所述机侧变换器有功功率控制中，i_{sqref}减去定子电流的 q 轴分量 i_{sq}后输入 PI 控制器，所得结果取反后，再减去定子电流 d 轴分量 i_{sd}、额定频率ω_m、定子电感 L_s的三者之积，得到反坐标变换的输入 U_{md}。

7.根据权利要求 1 所述的构网型风电机组功率-转速柔性切换自调频控制方法，其特征在于：还包括机侧变换器无功功率控制：风电机组的无功功率给定 Q_{mref}和无功功率实际值 Q_m之差输入到 PI 控制器，得到定子电流 d 轴分量的给定值 i_{sdref}；再由 i_{sdref}减去定子电流 d 轴分量的实际值 i_{sd}，并将结果输入到 PI 控制器，PI 控制器的输出结果取反后，加上定子电流 q 轴分量 i_{sq}、额定频率ω_m、定子电感 L_s的三者之积，得到反坐标变换的输入 U_{mq}；

最后将上述 U_{mq}、机侧变换器有功功率控制所得反坐标变换输入 U_{md}以及转子角θ_r输入反坐标变换，变换结果经 SVPWM 模块生成脉冲控制信号控制转子侧变换器运行。

8.根据权利要求 5 所述的构网型风电机组功率-转速柔性切换自调频控制方法，其特征在于：设有切换控制模块，用于控制切换信号 H，所述有功电流切换模块根据信号 H 执行操作，其中：

H=1 时，有功电流切换模块中 $i_{sqref} = i_{sqref1}$；

H=0 时，有功电流切换模块中 $i_{sqref} = i_{sqref2}$；

切换控制模块中分为手动切换模式和自动切换模式，其中手动切换模式下，信号 H 由人为指定；自动切换模式下：

$$H=\begin{cases}1，\ \omega_r < 额定转速\\0，\ \omega_r \geq 额定转速\end{cases}$$

式中，ω_r 为风电机组实际转速。

9.根据权利要求 8 所述的构网型风电机组功率-转速柔性切换自调频控制方法，其特征在于：当由转速外环控制切换为功率外环控制时，所述有功功率外环控制模块中 PI 控制器开始正常根据 P_{in} 实时计算 i_{sqref1}；所述转速外环控制模块中 PI 控制器的输出值锁定保持在切换瞬间时刻的输出值；

当由功率外环控制切换为转速外环控制时，所述转速外环控制模块中 PI 控制器开始正常根据 ω_{rin} 实时计算 i_{sqref2}；所述有功功率外环控制模块中 PI 控制器的输出值锁定保持在切换瞬间时刻的输出值。

10.根据权利要求 8 所述的构网型风电机组功率-转速柔性切换自调频控制方法，其特征在于：所述有功功率外环控制模块和转速外环控制模块中分别设有锁存器，所述切换控制模块中，根据切换信号的变化情况，输出锁存信号 S_1、S_2 和复位信号 F_1、F_2，其中：

当切换信号 H 出现上升沿时，设定 $S_1=F_1=0$、$S_2=F_2=1$；

当切换信号 H 出现下降沿时，设定 $S_1=F_1=1$、$S_2=F_2=0$；

所述有功功率外环控制模块中：

当 $S_1=F_1=1$ 时，锁存器锁定记录下当前时刻的 i_{sqref1}，并将记录下的 i_{sqref1} 作为复位值 j_{S1} 发送给 PI 控制器，PI 控制器执行复位操作，将复位值 j_{S1} 作为输出；反之 $S_1=F_1=0$ 时，锁存器不执行锁定操作，PI 控制器不执行复位操作。

所述转速外环控制模块中：

当 $S_2=F_2=1$ 时，锁存器锁定记录下当前时刻的 i_{sqref2}，并将记录下的 i_{sqref2} 作为复位值 j_{S2} 发送给 PI 控制器，PI 控制器执行复位操作，将复位值 j_{S2} 作为输出；反之 $S_2=F_2=0$ 时，锁存器不执行锁定操作，PI 控制器不执行复位操作。

说明书

一种构网型风电机组功率-转速柔性切换自调频控制方法

技术领域

本发明属于风电机组电气控制技术领域，具体涉及一种构网型风电机组功率-转速柔性切换自调频控制方法。

背景技术

传统的全功率风电机组采用基于矢量控制的变流器控制方式，本质上属于电流源控制方式，采用双闭环的控制策略实现有解耦控制；外环可以是有功功率环，也可以是转速环；通常采用的是有功功率外环。由于在有功功率外环中无法表征电网频率对于风机出力的影响，因此传统电流源控制的全功率风电机组不具备参与电网调频的能力，需要在传统的矢量控制基础上增加反应电网频率变化的虚拟惯量控制环节，实现虚拟惯量控制的效果，使得全功率风电机组能够对电网提供惯量与功率支撑，具备此能力的全功率风电机组可被称为构网型风电机组。

目前主流的全功率风电机组构网型控制方式，主要特征为保留传统矢量控制结构，即双闭环控制。外环可根据控制需要选择功率环或者是转速环。内环为电流环，通过 PLL 锁相环实现和电网同步。在此基础上，改变之处体现为外环给定中增加了反应电网频率变化的虚拟惯量控制环节，从而当系统频率发生变化时能够改变风电机组的有功功率出力，体现出有功支撑的控制效果。

然而，目前提出的虚拟惯量控制方法仅能适配于一种控制外环，当选择了有功功率作为功率外环的控制对象，则风电机组的转速就不再受到直接控制。导致在体现惯量响应的控制过程中风机转速有可能出现失控情况。

发明内容

针对现有技术中存在的不足，本发明提供了一种构网型风电机组功率-转速柔性切换自调频控制方法，使风电机组具备能够根据需要自动切换控制对象的能力，解决传统惯量响应过程中可能出现的转速失控问题。

本发明通过以下技术手段实现上述技术目的。

一种构网型风电机组功率-转速柔性切换自调频控制方法：设有有功功率外环控制模块和转速外环控制模块，其中在进行功率外环控制时，所述有功功率外环控制模块接入机侧变换

器有功功率控制中；在进行转速外环控制时，所述转速外环控制模块接入机侧变换器有功功率控制中。

进一步地，依据风机转速，在功率外环控制与转速外环控制之间进行切换，其中当风机转速达到额定转速时，切换为转速外环控制；反之则进行功率外环控制。

进一步地，所述有功功率外环控制模块中，信号 P_{in} 经 PI 控制器，得到风力发电机定子电流 q 轴分量的给定值 i_{sqref1}，其中 P_{in} 由下式获得：

$$P_{in} = \Delta P + P_{mref} - P_{m}$$

式中，P_{mref} 为风电机组的有功功率给定，P_{m} 为风电机组有功功率的实际值，ΔP 为附加功率，由下式获得：

$$\Delta P = \Delta P_{d} + \Delta P_{p}$$

$$\Delta P_{d} = K_{d}\frac{df}{dt}$$

$$\Delta P_{p} = K_{p}(f_{ref} - f)$$

式中，f 为电网频率实际值，K_{d} 为微分系数，ΔP_{d} 为微分附加功率，f_{ref} 为电网频率基准值，K_{p} 为比例系数，ΔP_{p} 为比例附加功率。

进一步地，所述转速外环控制模块中，信号ω_{rin} 经 PI 控制器，得到风力发电机定子电流 q 轴分量的给定值 i_{sqref2}，其中ω_{rin} 由下式获得：

$$\omega_{rin} = \omega_{rref} - \omega_{r}$$

式中，ω_{rref} 为风电机组的转速给定值，ω_{r} 为风电机组的转速实际值。

进一步地，设有有功电流切换模块，用于控制功率外环控制与转速外环控制之间的切换：

$$i_{sqref} = \begin{cases} i_{sqref1}，\text{功率外环控制时} \\ i_{sqref2}，\text{转速外环控制时} \end{cases}$$

式中，i_{sqref} 为最终送入机侧变换器有功功率控制的风力发电机定子电流 q 轴分量给定值。

进一步地，所述机侧变换器有功功率控制中，i_{sqref} 减去定子电流的 q 轴分量 i_{sq} 后输入 PI 控制器，所得结果取反后，再减去定子电流 d 轴分量 i_{sd}、额定频率ω_{m}、定子电感 L_{s} 的三者之积，得到反坐标变换的输入 U_{md}。

进一步地，还包括机侧变换器无功功率控制：风电机组的无功功率给定 Q_{mref} 和无功功率实际值 Q_{m} 之差输入到 PI 控制器，得到定子电流 d 轴分量的给定值 i_{sdref}；再由 i_{sdref} 减去定子电流 d 轴分量的实际值 i_{sd}，并将结果输入到 PI 控制器，PI 控制器的输出结果取反后，加上定子电流 q 轴分量 i_{sq}、额定频率ω_{m}、定子电感 L_{s} 的三者之积，得到反坐标变换的输入 U_{mq}；

最后将上述 U_{mq}、机侧变换器有功功率控制所得反坐标变换输入 U_{md} 以及转子角θ_r 输入反坐标变换，变换结果经 SVPWM 模块生成脉冲控制信号控制转子侧变换器运行。

进一步地，设有切换控制模块，用于控制切换信号 H，所述有功电流切换模块根据信号 H 执行操作，其中：

H=1 时，有功电流切换模块中 $i_{sqref} = i_{sqref1}$；

H=0 时，有功电流切换模块中 $i_{sqref} = i_{sqref2}$；

切换控制模块中分为手动切换模式和自动切换模式，其中手动切换模式下，信号 H 由人为指定；自动切换模式下：

$$H = \begin{cases} 1, & \omega_r < \text{额定转速} \\ 0, & \omega_r \geq \text{额定转速} \end{cases}$$

式中，ω_r 为风电机组实际转速。

进一步地，当由转速外环控制切换为功率外环控制时，所述有功功率外环控制模块中 PI 控制器开始正常根据 P_{in} 实时计算 i_{sqref1}；所述转速外环控制模块中 PI 控制器的输出值锁定保持在切换瞬间时刻的输出值；

当由功率外环控制切换为转速外环控制时，所述转速外环控制模块中 PI 控制器开始正常根据 ω_{rin}实时计算 i_{sqref2}；所述有功功率外环控制模块中 PI 控制器的输出值锁定保持在切换瞬间时刻的输出值。

进一步地，所述有功功率外环控制模块和转速外环控制模块中分别设有锁存器，所述切换控制模块中，根据切换信号的变化情况，输出锁存信号 S_1、S_2 和复位信号 F_1、F_2，其中：

当切换信号 H 出现上升沿时，设定 S_1= F_1=0、S_2= F_2=1；

当切换信号 H 出现下降沿时，设定 S_1= F_1=1、S_2= F_2=0；

所述有功功率外环控制模块中：

当 S_1= F_1=1 时，锁存器锁定记录下当前时刻的 i_{sqref1}，并将记录下的 i_{sqref1}作为复位值 j_{S1} 发送给 PI 控制器，PI 控制器执行复位操作，将复位值 j_{S1} 作为输出；反之 S_1= F_1=0 时，锁存器不执行锁定操作，PI 控制器不执行复位操作。

所述转速外环控制模块中：

当 S_2= F_2=1 时，锁存器锁定记录下当前时刻的 i_{sqref2}，并将记录下的 i_{sqref2}作为复位值 j_{S2} 发送给 PI 控制器，PI 控制器执行复位操作，将复位值 j_{S2} 作为输出；反之 S_2= F_2=0 时，锁存器不执行锁定操作，PI 控制器不执行复位操作。

本发明的有益效果为：

（1）本发明提供了一种构网型风电机组功率-转速柔性切换自调频控制方法，在能够实现风电机组自调频控制的基础上，实现转速与功率外环之间的切换控制；一方面将电网频率的变化反映到风电机组有功出力上，体现出虚拟惯量控制的效果，使得风电机组具备参与电网调频的能力；另一方面根据风机转速情况即使切换控制方式，防止风机转速超过额定转速，避免风机转速出现失控问题。

（2）本发明中，通过在功率外环和转速外环两者 PI 控制器中，加入复位操作，利用复位操作将 PI 控制器锁定保持在切出瞬间的输出值，减少后续再次切入时所产生的冲击电流，实现柔性切换的控制目的。

（3）在自动切换的基础上，还增加手动切换功能，做到根据外部指令实现转速外环与功率外环之间的自由柔性切换。

附图说明

图 1 为本发明构网型风电机组自调频控制方法的控制框图；

图 2 为本发明切换控制模块的控制逻辑流程图；

图 3 为现有常规全功率风电机组构网型控制部分电气结构图；

图 4 为现有风电机组机侧变换器部分控制策略框图；

图 5 为本发明测试例所设置的风电机组控制结构图；

图 6 为本发明测试例中最大功率跟踪阶段频率响应波形图（功率外环）；

图 7 为本发明测试例中功率外环与转速外环柔性切换过程时的波形图；

图 8 为本发明测试例中恒转速阶段频率响应波形图（转速外环）。

具体实施方式

下面详细描述本发明的实施例，所示实施例的示例在附图中示出，其中自始至终相通或类似的标号表示相同或类似的元件或具有相同或类似功能的元件。下面通过参考附图描述的实施例是示例性的，旨在用于解释本发明，而不能理解为对本发明的限制。

第一部分，技术方案说明

如图 3 所示为现有常规全功率风电机组构网型控制部分电气结构图，图 4 所示为其中对

于机侧变换器部分的控制策略框图。相应控制策略为在传统矢量控制的基础上，增加反应电网频率变化的虚拟惯量控制环节。但是上述控
制策略在体现惯量响应的过程中，风机转速就不再受到直接控制，导致风机转速有可能出现失速问题。

如图 1 所示为本发明构网型风电机组功率-转速柔性切换自调频控制方法的控制框图，包括对机侧变换器的①有功功率控制和②无功功率控制。其中：

一、无功功率控制

无功功率控制为控制全功率风电机组定子侧的无功功率，实现风电机组的单位功率因数运行。具体控制方法为：

风电机组的无功功率给定 Q_{mref} 和无功功率实际值 Q_m 之差输入到 PI 控制器，得到定子电流 d 轴分量的给定值 i_{sdref}；再由 i_{sdref} 减去定子电流 d 轴分量的实际值 i_{sd}，并将结果输入到 PI 控制器，PI 控制器的输出结果取反后，加上定子电流 q 轴分量 i_{sq}、额定频率 ω_m、定子电感 L_s 的三者之积，最终得到反坐标变换的输入 U_{mq}。

二、有功功率控制

有功功率控制为控制全功率风电机组的有功功率，并根据控制指令，实现功率外环和转速外环之间的手动或自动切换功能，实现功率控制和转速控制的组合控制。具体包括以下六个子控制模块：①虚拟惯量控制模块、②有功功率外环控制模块、③转速外环控制模块、④有功电流切换模块、⑤有功功率内环控制模块、⑥切换控制模块。其中：

1，虚拟惯量控制模块

电网频率实际值 f 经过微分传递函数 s 后与微分系数 K_d 相乘，得到微分附加功率 ΔP_d：

$$\Delta P_d = K_d \frac{df}{dt}$$

电网频率基准值 f_{ref} 与实际值 f 之差，和比例系数 K_p 相乘，得到比例附加功率 ΔP_p：

$$\Delta P_p = K_p(f_{ref} - f)$$

微分附加功率 ΔP_d 和比例附加功率 ΔP_p 相加，得到整个风电机组的附加功率 ΔP：

$$\Delta P = \Delta P_d + \Delta P_p$$

2，有功功率外环控制模块

上述附加功率 ΔP 加上全功率风电机组的有功功率给定 P_{mref} 并减去全功率风电机组有功功率的实际值 P_m，得到 PI 控制器的输入信号 P_{in}：

$$P_{in} = \Delta P + P_{mref} - P_m$$

P_{in} 经过 PI 控制器，得到风力发电机定子电流 q 轴分量的给定值 i_{sqref1}。

3，转速外环控制模块

全功率风电机组的转速给定值ω_{rref}减去转速实际值ω_r，得到 PI 控制器的输入信号ω_{rin}：

$$\omega_{rin} = \omega_{rref} - \omega_r$$

ω_{rin} 经过 PI 控制器，得到风力发电机定子电流 q 轴分量的给定值 i_{sqref2}。

4，有功电流切换模块

在有功功率外环控制模块与转速外环控制模块之间，设计了一个有功电流切换模块，用于调控有功功率与转速两个控制对象之间的自由切换。其中当选择有功功率控制时，则接入②有功功率外环控制模块；反之当选择转速控制时，则接入③转速外环控制模块。也即在 i_{sqref1} 与 i_{sqref2} 之间选择其中之一作为最终的风力发电机定子电流 q 轴分量的给定值 i_{sqref}：

$$i_{sqref} = \begin{cases} i_{sqref1}，\text{功率外环控制时} \\ i_{sqref2}，\text{转速外环控制时} \end{cases}$$

5，有功功率内环控制模块

上述 i_{sqref} 减去定子电流的 q 轴分量 i_{sq} 后输入 PI 控制器，所述 PI 控制器的输出结果取反后，减去定子电流 d 轴分量 i_{sd}、额定频率ω_m、定子电感 L_s 的三者之积，得到反坐标变换的输入 U_{md}。

最终，将反坐标变换的输入 U_{md}、U_{mq} 以及转子角θ_r 输入反坐标变换，所得变换结果再输入 SVPWM 模块，生成脉冲控制信号控制转子侧变换器运行。

6，切换控制模块

为实现功率外环与转速外环两者之间的自动切换功能、手动切换功能，以及在切换过程中保证柔性切换，达到平稳切换的控制目的；设计以下切换控制模块：

（1）切换信号 H

切换控制模块输出切换信号 H，其中 H=1 时，有功电流切换模块选择中选择将有功功率外环控制模块接入，$i_{sqref} = i_{sqref1}$；H=0 时，有功电流切换模块选择中将转速外环控制模块接入，$i_{sqref} = i_{sqref2}$：

$$\begin{cases} \text{选择功率外环控制}，H = 1 \\ \text{选择转速外环控制}，H = 0 \end{cases}$$

（2）设换模式选择

包括自动切换模式和手动切换模式两项，其中选择手动切换时，则由人为指定切换信号 H。

自动切换模式时，则根据风电机组的实际转速ω_r来设定切换信号 H；其中当风机达到额定转速时，则 H=0，选择转速外环控制；反之则 H=1，选择功率外环控制：

$$H=\begin{cases}1，\ \omega_r < 额定转速\\ 0，\ \omega_r \geq 额定转速\end{cases}$$

在自动切换模式下，依据风机是否达到额定转速来进行功率外环控制与转速外环控制之间的切换。其中当风机转速达到额定转速时，则自动转为转速直接控制，避免大风速情况下风电机组转速失控，以此提升风电机组的安全性。

（3）柔性切换

1）为保证功率外环与转速外环两者之间在切换时能够做到柔性切换，在有功功率外环控制模块中设置有锁存器以及相应的锁存信号 S_1、复位信号 F_1、复位值 j_{S1}；在转速外环控制模块中设置有锁存器以及相应的锁存信号 S_2、复位信号 F_2、复位值 j_{S2}。

以有功功率外环控制模块为例（转速外环控制模块同理），首先锁存器根据接收到的锁存信号 S_1，判断是否锁定并存储记录下当前时刻的 PI 控制器输出值 i_{sqref1}；其中当 S_1=1 时，则锁定记录下当前时刻的 i_{sqref1}，并将记录下的 i_{sqref1}作为复位值 j_{S1} 发送给 PI 控制器；反之 S_1=0 则不锁定。

PI 控制器根据接收到的复位信号 F_1，判断是否进行复位操作；其中当 F_1=1 时，则 PI 控制器执行复位操作，将复位值 j_{S1} 作为 i_{sqref1}输出；反之 F_1=0 时，则 PI 控制正常通过输入的 P_{in} 实时计算 i_{sqref1}。

2）功率外环的锁存信号 S_1、复位信号 F_1 和转速外环的锁存信号 S_2、复位信号 F_2，均由切换控制模块控制。具体通过检测切换信号 H 的变化情况来进行相应设定，其中当检测到切换信号 H 出现上升沿（H 由 0 变为 1）时，设定 S_1= F_1=0、S_2= F_2=1；而当检测到切换信号 H 出现下降沿（H 由 1 变为 0）时，则设定 S_1= F_1=1、S_2= F_2=0；其余时则保持当前时刻 S_1、F_1、S_2、F_2 的值不变。

综上，①当由转速外环控制切换为功率外环控制时，则有功功率外环控制模块中 PI 控制

器开始正常根据 P_{in} 实时计算 i_{sqref1}；转速外环控制模块中 PI 控制器的输出值锁定保持在切换瞬间时刻的输出值。②当由功率外环控制切换为转速外环控制时，则转速外环控制模块中 PI 控制器开始正常根据 ω_{rin} 实时计算 i_{sqref2}；有功功率外环控制模块中 PI 控制器的输出值锁定保持在切换瞬间时刻的输出值。上述切换控制模块控制逻辑的流程框图如图 2 所示。

上述通过在有功功率外环控制模块和转速外环控制模块的 PI 控制器中，加入复位操作；当某一外环控制模块切出时，利用复位操作将该控制模块中的 PI 控制器锁定保持在切出瞬间的输出值；从而减少后续再次切换回该控制模块时所产生的冲击电流，实现柔性切换的控制目的。

第二部分，仿真测试

在 RTDS 实时数字仿真器中搭建 6.25MW 全功率风电机组并网模型，仿真系统结构如图 5 所示，详细参数设置如下表 1 所示：

表 1：6.25MW 全功率风电机组参数设置

物理量	数值	物理量	数值
额定功率/MW	6.25	最佳叶片利用系数 Cp	0.416
叶轮半径/m	84	最佳叶尖速度比λ	10.3
切入风速 m/s	3	风机惯性时间常数/s	10.8
额定风速 m/s	10.7	永磁机极对数	72
网侧滤波电感	25uH	直流母线电容	96mF
网侧滤波电容	2005.2uF(星型)	卸荷电阻	0.125ohm

如图 6 所示，当环境风速为 9m/s，对应着风电机组运行在 MPPT 最大功率跟踪阶段，风电机组的外环为功率环，体现为构网型风电机组的控制策略。当仿真时间 t=6s 时投入临时负载时，系统的频率变化使得风电机组的有功功率给定发生变化，进一步影响了风电机组的有功功率输出以及风电机组转速，风电机组转速呈现出明显的降速过程以体现虚拟惯量的控制效果，由于在响应的全过程中转速未超过额定值，因此未发生功率外环和转速外环的切换。

如图 7 所示，当环境风速从 9m/s 渐变为 10.5m/s，风电机组的转速随着风速的增加而增加。当仿真时间 t=6s 时投入临时负载，风电机组的转速呈现出下降的趋势，体现出虚拟惯量响应的控制效果；而在转速恢复的后期，伴随风速的增加，转速达到了额定转速，风电机组切换到了转速外环，控制风电机组的转速稳定在了 1.2pu 的额定转速处。在 t=25s 时，尽管再

次发生了负载投入的情况，但是风电机组仍工作在转速外环，不响应电网频率变化，起到了保护风电机组的作用，避免转速变化超过额定转速的情况发生。

如图 8 所示，当环境风速为 10.5m/s，此时风电机组的转速已经稳定在额定转速 1.2pu 处，风电机组的控制策略已经切换为转速外环控制策略。当仿真时间 t=6s 时投入临时负载，转速外环不响应电网频率的变化，因此风电机组的转速始终维持在额定转速处，起到了保护风电机组的作用，避免转速变化超过额定转速的情况发生。

本发明并不限于上述实施方式，在不背离本发明的实质内容的情况下，本领域技术人员能够做出的任何显而易见的改进、替换或变形均属于本发明的保护范围。

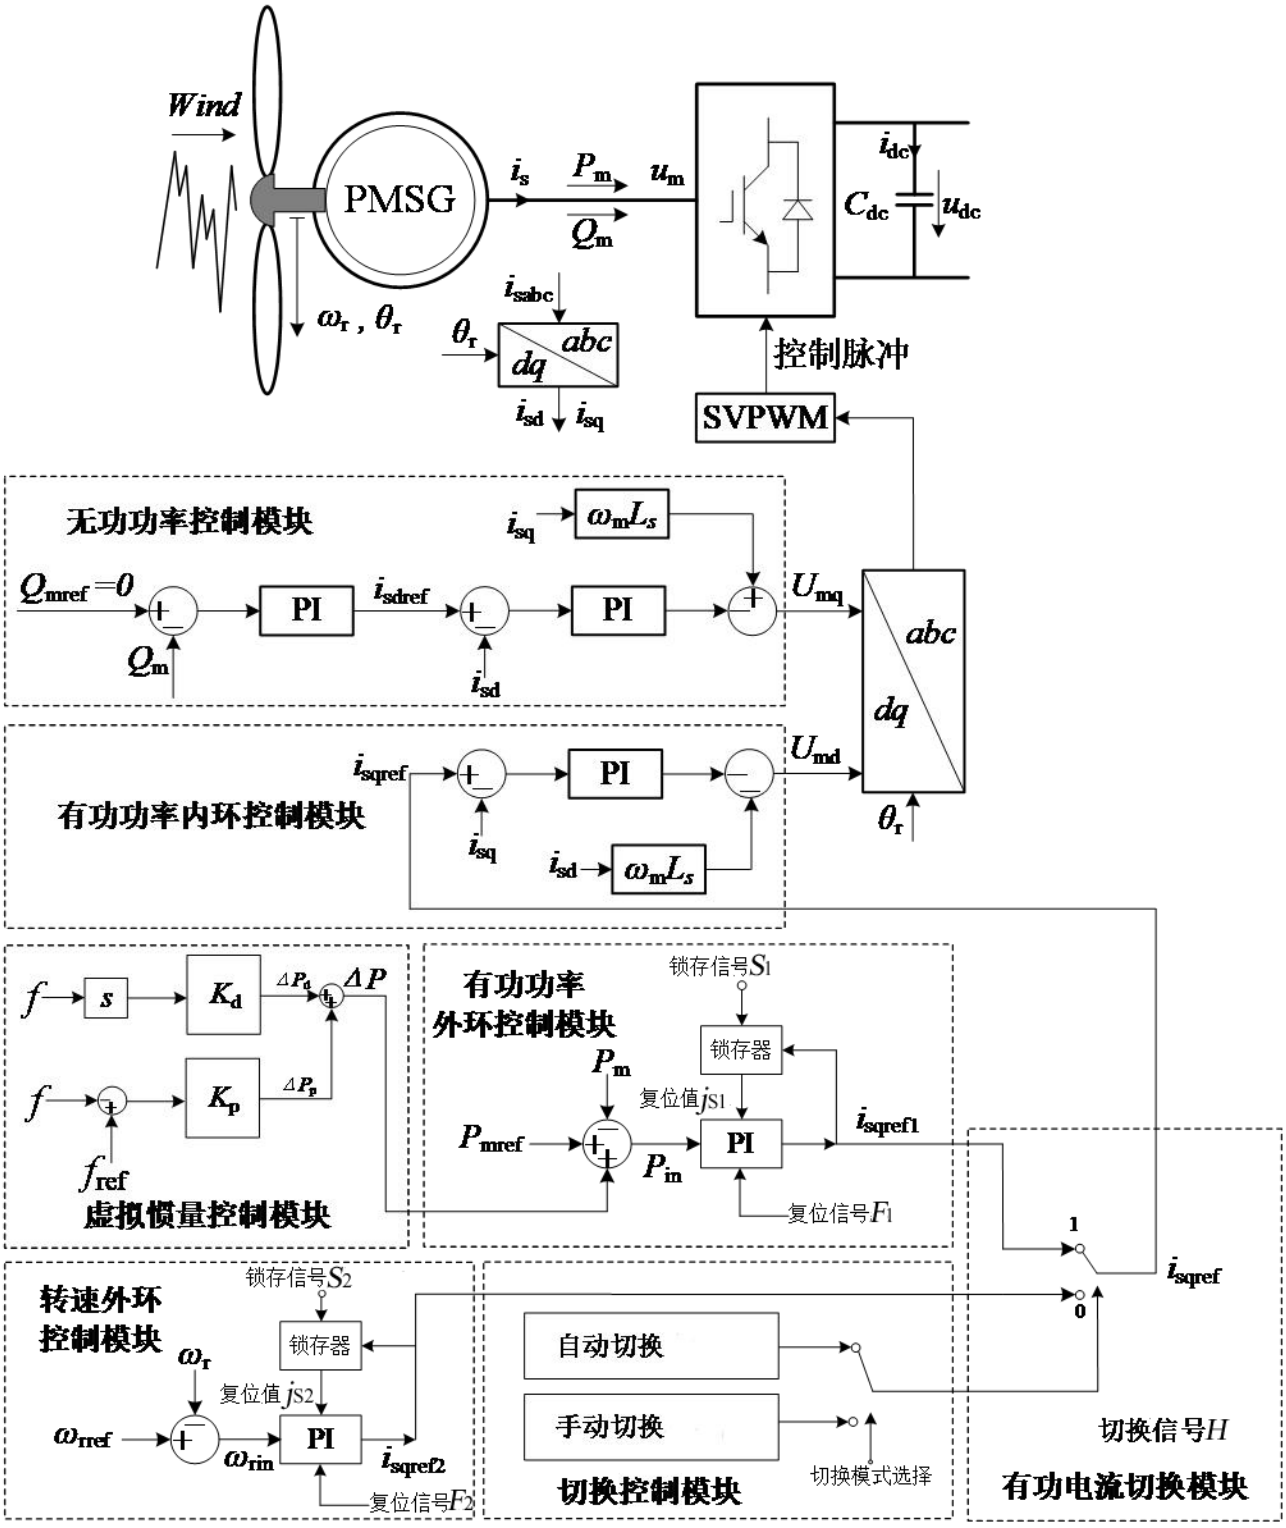

Wind
PMSG
i_s
P_m
Q_m
u_m
i_{dc}
C_{dc}
u_{dc}
ω_r , θ_r
i_{sabc}
θ_r
abc
dq
i_{sd} i_{sq}
控制脉冲
SVPWM
无功功率控制模块
i_{sq}
$\omega_m L_s$
$Q_{mref}=0$
PI
i_{sdref}
PI
U_{mq}
Q_m
i_{sd}
abc
dq
U_{md}
θ_r
i_{sqref}
PI
有功功率内环控制模块
i_{sq}
i_{sd}
$\omega_m L_s$
f
s
K_d
ΔP_d
ΔP
f
K_p
ΔP_p
f_{ref}
虚拟惯量控制模块
有功功率
外环控制模块
锁存信号S_1
锁存器
P_m
复位值j_{S1}
P_{mref}
PI
P_{in}
i_{sqref1}
复位信号F_1
1
0
i_{sqref}
转速外环
控制模块
锁存信号S_2
锁存器
ω_r
复位值j_{S2}
ω_{rref}
PI
ω_{rin}
i_{sqref2}
复位信号F_2
自动切换
手动切换
切换模式选择
切换控制模块
切换信号H
有功电流切换模块

图 1

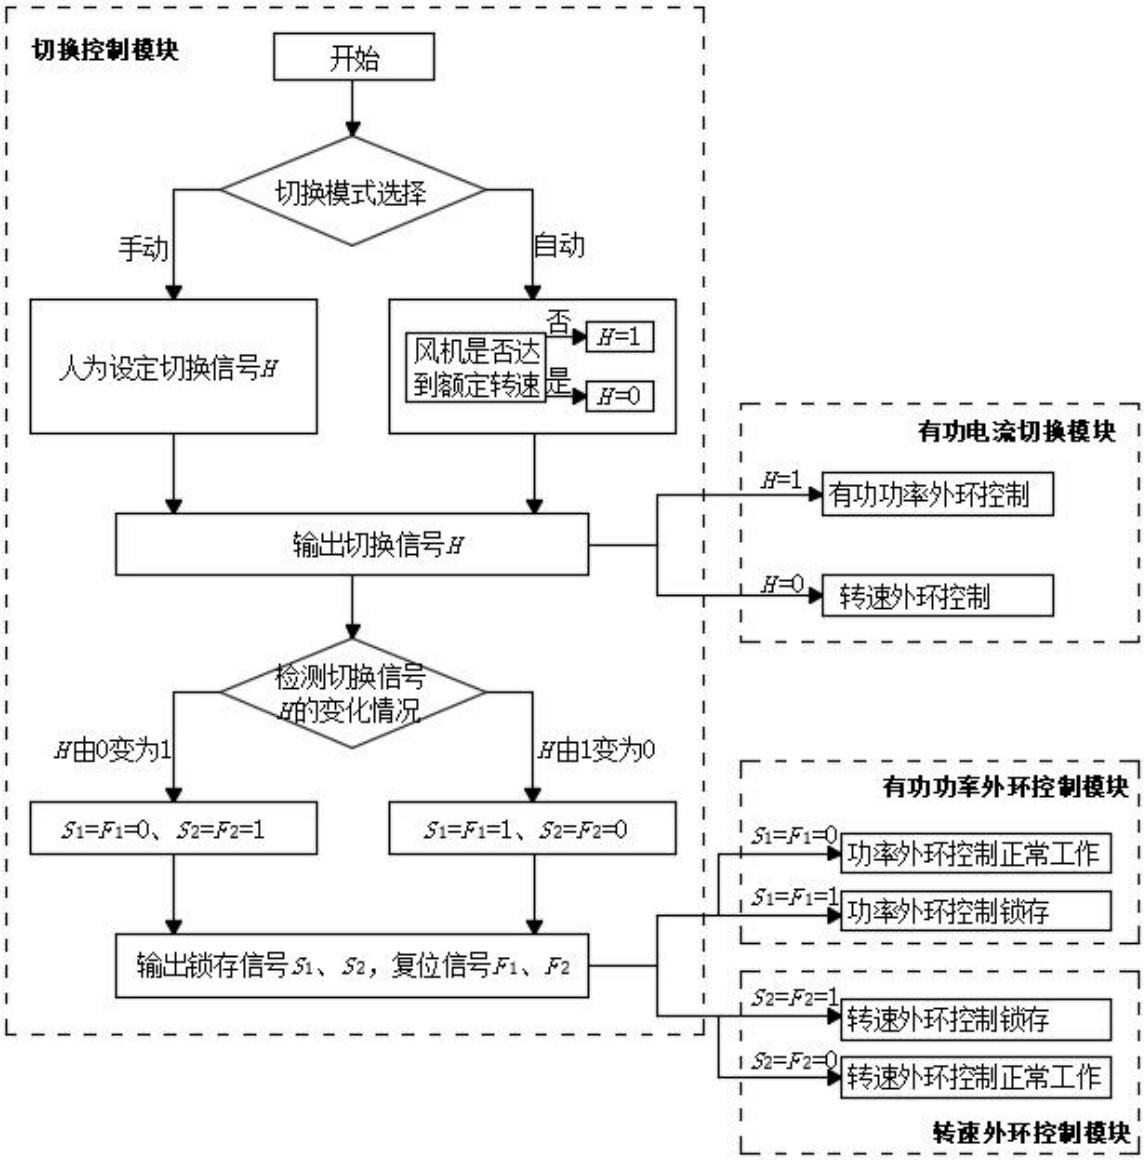

切换控制模块
开始
切换模式选择
手动
自动
人为设定切换信号H
否
风机是否达到额定转速
是
H=1
H=0
输出切换信号H
检测切换信号H的变化情况
H由0变为1
H由1变为0
S1=F1=0、S2=F2=1
S1=F1=1、S2=F2=0
输出锁存信号S1、S2，复位信号F1、F2
有功电流切换模块
H=1
有功功率外环控制
H=0
转速外环控制
有功功率外环控制模块
S1=F1=0
功率外环控制正常工作
S1=F1=1
功率外环控制锁存
转速外环控制模块
S2=F2=1
转速外环控制锁存
S2=F2=0
转速外环控制正常工作

图 2

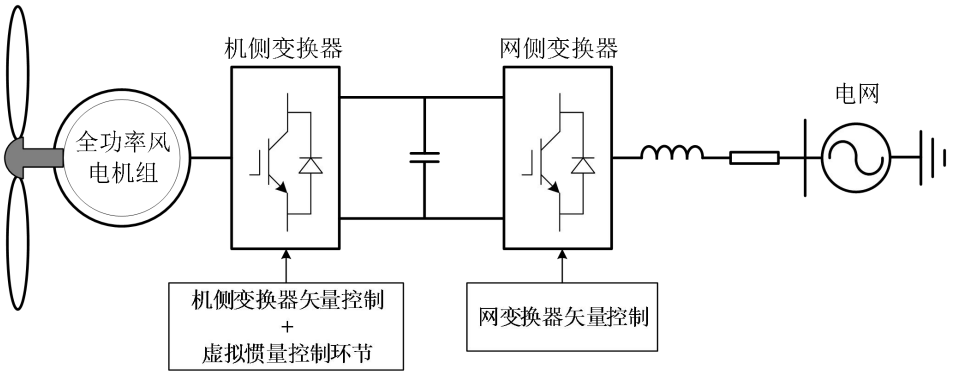

机侧变换器
网侧变换器
电网
全功率风电机组
机侧变换器矢量控制
+
虚拟惯量控制环节
网变换器矢量控制

图 3

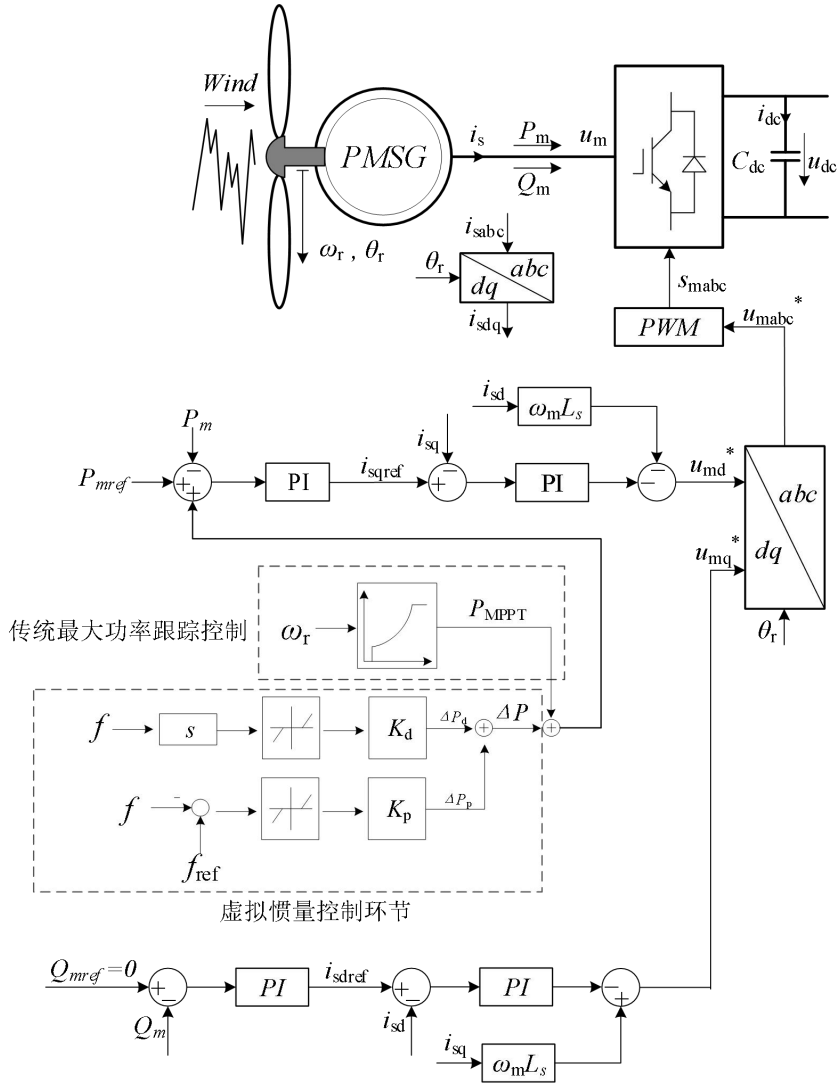

Wind
PMSG
i_s
P_m
Q_m
u_m
i_{dc}
C_{dc}
u_{dc}
i_{sabc}
θ_r
abc
dq
i_{sdq}
ω_r , θ_r
s_{mabc}
PWM
u_{mabc}^*
i_{sd}
$\omega_m L_s$
P_m
P_{mref}
PI
i_{sqref}
i_{sq}
PI
u_{md}^*
u_{mq}^*
abc
dq
θ_r
传统最大功率跟踪控制
ω_r
P_{MPPT}
f
s
K_d
ΔP_d
ΔP
f
K_p
ΔP_p
f_{ref}
虚拟惯量控制环节
$Q_{mref}=0$
PI
i_{sdref}
PI
Q_m
i_{sd}
i_{sq}
$\omega_m L_s$

图 4

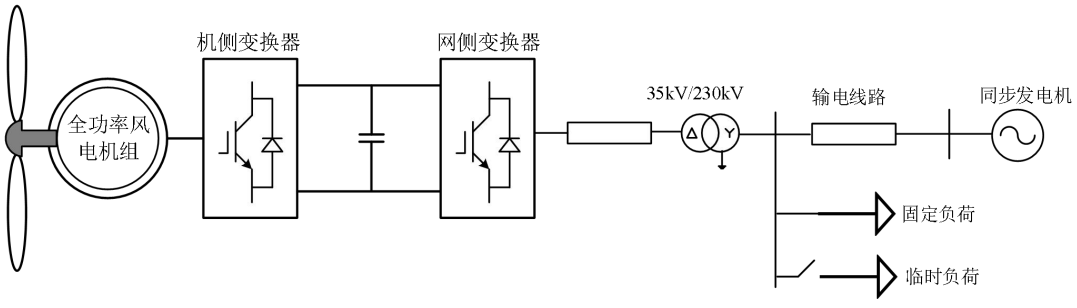

机侧变换器
网侧变换器
全功率风
电机组
35kV/230kV
输电线路
同步发电机
固定负荷
临时负荷

图 5

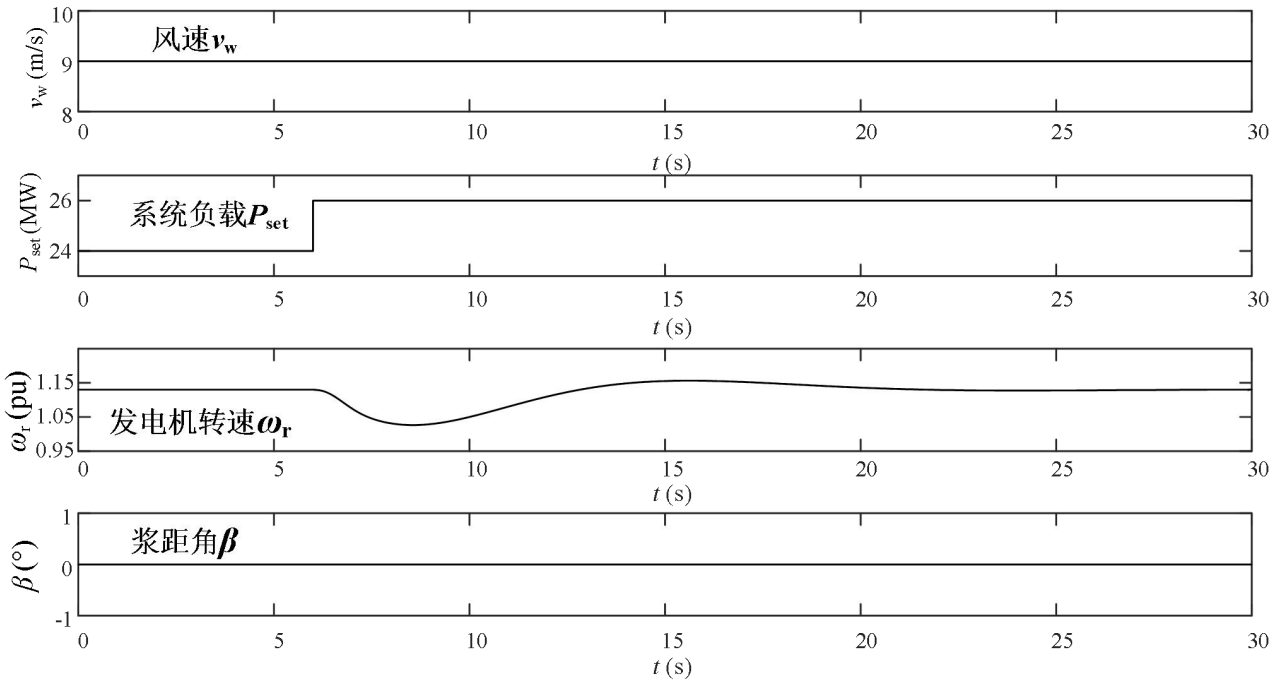

风速v_w
v_w (m/s)
系统负载P_{set}
P_{set} (MW)
发电机转速ω_r
ω_r (pu)
浆距角β
β (°)
t (s)

图 6

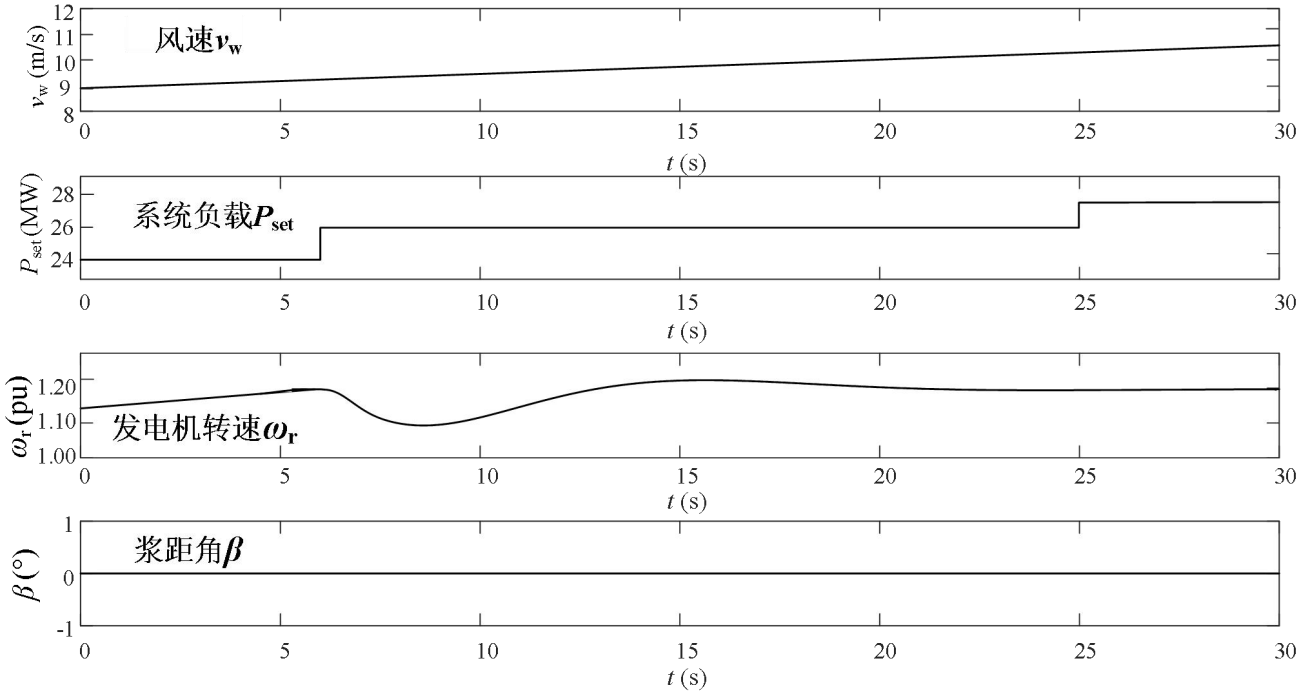

风速v_w
v_w (m/s)
系统负载P_{set}
P_{set} (MW)
发电机转速ω_r
ω_r (pu)
浆距角β
β (°)
t (s)

图 7

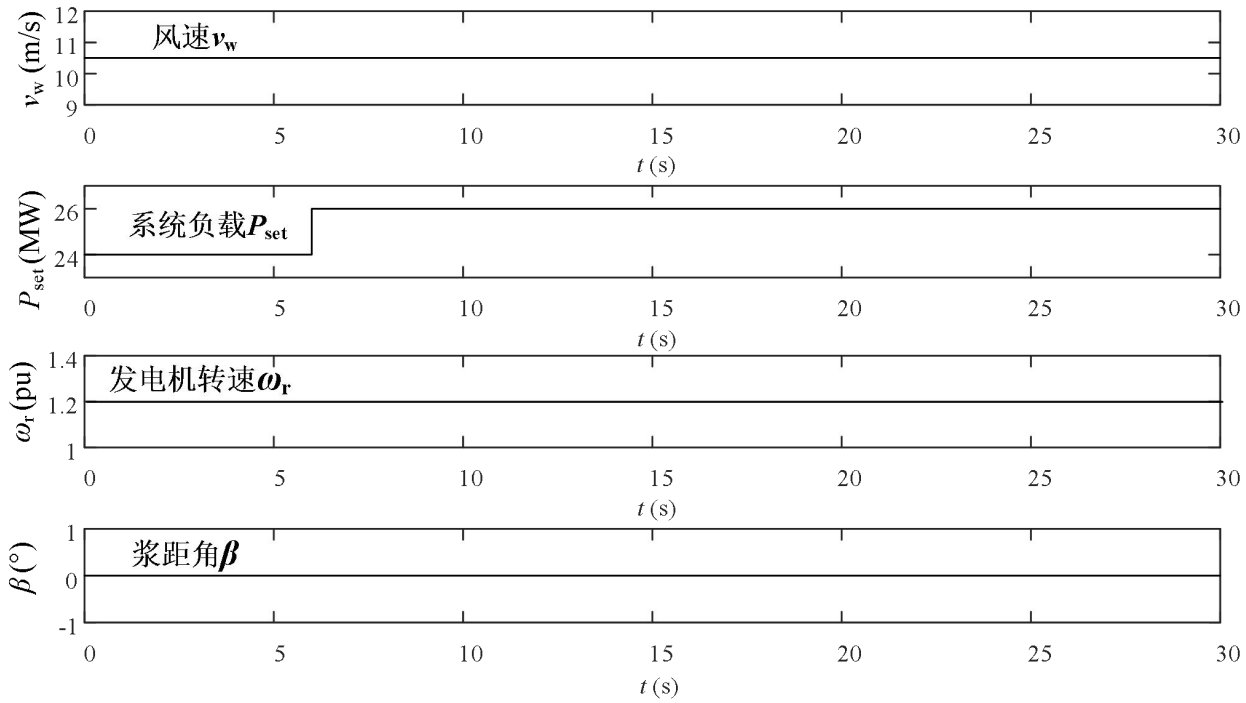

风速v_w
v_w (m/s)
12
11
10
9
0
5
10
15
20
25
30
t (s)
系统负载P_{set}
P_{set}(MW)
26
24
发电机转速ω_r
ω_r(pu)
1.4
1.2
1
浆距角β
β(°)
1
0
-1

图 8

一种单幅图像超分辨率重建方法及其交互式推理网络（发明）技术交底书

说明书摘要

本发明公开一种基于轻量级交互式推理网络的单幅图像超分辨率重构方法，通过构建交互式聚合模块作为网络主干并进行训练，交互式聚合模块由结构感知注意力块、Swin Transformer 块和增强空间自适应块组成；输入低分辨率图像并利用卷积层提取浅层特征；将浅层特征传递到网络主干，利用构建好的交互式聚合模块进行抽象语义特征学习，从而探索更深层次特征；对更深层次特征进行上采样操作，得到理想的高分辨率图像尺寸。本发明设计轻量且高效的交互式推理网络，不仅保持较低的计算需求，而且在大量基准数据集上获得最优越的结果，还能够产生更清晰的纹理细节，展示出更精细、更准确的图像超分辨率重构结果。

权利要求书

1、一种基于轻量级交互式推理网络的单幅图像超分辨率重构方法，其特征在于，包括如下步骤：

S1：构建交互式推理网络进行单幅图像超分辨率重构实验，其包括如下步骤：

A1：浅层提取模块：

对输入的低分辨率图像，将交互式推理网络的输入，利用 3×3 卷积层提取浅层特征如边缘、纹理等。

A2：交互式聚合模块作为交互式推理网络主干，其包括如下组成部分：

A21：结构感知注意力块：

结构感知注意力块输入特征张量，利用非对称卷积，提取图像特征水平和垂直方向信息，同时叠加多个卷积层对结构信息进行融合并利用 Sigmoid 激活函数归一化到 0 至 1 之间，再通过空间级别方式自适应地校准输入特征，从而突出图像局部结构信息。

A22：Swin Transformer 块：

Swin Transformer 块引入局部注意力和移位窗口机制来降低模型复杂度并学习和捕获丰富的全局上下文信息。对输入特征张量，采用两个连续的 Swin Transformer 块增强网络复原性能，第一个块提取图像的局部特征，并通过局部自注意力机制增强这些特征。第二个块则利用移位窗口机制，将第一个块输出的特征进行跨窗口的信息交互，从而捕获更丰富的全局上下文信息。

A23：增强型空间自适应块：

将步骤A1学习的局部结构显著特征和A2学习的全局上下文信息作为增强型空间自适应块的输入，以协同的方式集成局部和全局这两种不同的特征属性，从而促进更加鲁棒纹理结构特征提取，恢复出更加自然和真实的高分辨率图像。

A3：上采样重建模块：

将步骤A2经过交互式聚合模块学习的深层语义特征作为上采样重建模块的输入，利用两个不同卷积大小的卷积层和亚像素卷积层分别上采样初始信息和深层语义信息，最后利用元素相加操作进行融合和集成，重建细节丰富的高分辨率图像。

S2：训练交互式推理网络：

将预处理好的训练集中的低分辨图像$I^{LR} \in {}^{H\times W\times 3}$作为交互式推理网络的输入，对应的高分辨率图像$I^{HR} \in {}^{rH\times rW\times 3}$作为目标图像，训练网络中的浅层提取模块、链式堆叠的交互式聚合模块以及上采样重建模块以获取最佳的权值和偏置，得到能够实现低分辨率图像到高分辨率图像重构的交互式推理网络。

S3:利用训练好的交互式推理网络进行单幅图像超分辨率重构。

2、根据权利要求1所述的一种交互式推理网络的单幅图像超分辨率重构方法，其特征在于，所述步骤S2中训练集的预处理过程为：首先将具有高质量和高分辨率数据集进行数据增强；然后使用MATLAB在缩放因子为×2、×3和×4情况下，利用双三次插值下采样以获得对应的低分辨率图像；最后存储对应的高分辨图像和低分辨率图像数据，作为整个交互式推理网络的训练集。低分辨率图像输入到交互式推理网络中生成高分辨率图像，生成的高分辨率图像和目标高分辨率图像带入损失函数进行计算，最小化损失函数求得网络的最佳权重和偏置。

3、根据权利要求1所述的一种交互式推理网络的单幅图像超分辨率重构方法，其特征在于，所述步骤S2中交互式推理网络训练过程为：

A1：使用Kaiming初始化来初始化交互式推理网络，其中参数初始化值服从均值为0，方差为$2/n$的高斯分布，其中n该层输入神经元的数量。

A2：将低分辨率图像I^{LR}输入到交互式推理网络中，生成浅层特征F_0，再将浅层特征传递到由T个链式堆叠的交互式聚合模块中学习更加复杂和抽象的深层语义特征，进一步将深层语义特征作为上采样重建模块的输入，输出目标高分辨率图像大小一致的输出图像；

A3：将交互式推理网络生成的高分辨率图像和目标高分辨率图像做交互式推理网络的损失函数$L(\Theta)$，依次迭代使得损失函数降低直至趋于稳定；

A4：训练整个交互式推理网络，计算网络的损失函数，同时更新整个网络的参数，直到所有损失函数趋于稳定，得到最终的超分辨率重构模型。

4、根据权利要求 3 所述的一种交互式推理网络的单幅图像超分辨率重构方法，其特征在于，所述步骤 S3 中训练好的交互式推理网络的损失函数如下：给定一个训练数据集 $\{I_i^{LR}, I_i^{SR}\}_{i=1}^{N}$，其中 I_i^{LR} 是第 i 个低分辨率输入图像，I_i^{SR} 是对应的目标高分辨率图像。主要目标是获得 I_i^{LR} 和 I_i^{SR} 之间的端到端映射函数 $F(\cdot)$，使用 L_1 损失函数对交互式推理网络进行优化：

$$L(\Theta)=\frac{1}{N}\sum_{i=1}^{N}\left\|I_i^{SR}-F\left(I_i^{LR}\right)\right\|_1=\frac{1}{N}\sum_{i=1}^{N}\left\|I_i^{SR}-I_i^{HR}\right\|_1 \tag{1}$$

其中，Θ 为交互式推理网络的权值和偏置（可训练参数）。通过最小化 $L(\Theta)$ 获得交互式推理网络的最佳权值和偏置。

5、根据权利要求 1 所述的一种基于轻量级交互式推理网络的单幅图像超分辨率重构方法，其特征在于，所述步骤 A2 中第 t 个链式堆叠的交互式聚合模块获取最佳的更深层次语义特征 F_t 为：

$$F_t = H_{\mathrm{IFAM}}^{t}\left(F_{t-1}\right)=H_{\mathrm{IFAM}}^{t}\left(H_{\mathrm{IFAM}}^{t-1}\left(\cdots H_{\mathrm{IFAM}}^{1}\left(F_0\right)\cdots\right)\right) \tag{2}$$

其中 $H_{\mathrm{IFAM}}^{t}(\ )$ 表示第 t 个交互式聚合模块的函数。$F_{t-1}\in{}^{H\times W\times C}$ 和 $F_t\in{}^{H\times W\times C}$ 是第 t 个 交互式聚合模块的输入和输出特征张量。

6、根据权利要求 2 所述的一种基于轻量级交互式推理网络的单图像超分辨率重构方法，其特征在于，所述第 t 个 IFAM 的训练过程 $H_{\mathrm{IFAM}}^{t}(\ )$ 如下：

A1：将特征 F_{IFAM}^{t-1} 传递进结构感知注意模块，从 1×3 和 3×1 卷积开始进行结构信息探索，然后传递到三个 3×3 卷积进行特征学习，通过 sigmoid 生成 3D 调制系数，最后通过 3D 调制系数重新校准输入特征，输出丰富的局部特征 F_{SAAB}^{t} 表示以实现准确的超分辨率重建。

A2：将特征 F_{IFAM}^{t-1} 传递进两个连续的 Swin Transformer 块，基于窗口划分机制，输入特征 F_{IFAM}^{t-1} 在基于窗口的多头自注意（W-MSA）单元中被线性投影并重塑为 $\hat{F}_{IFAM}^{t-1}$，通过多层感知器（MLP）获得 $\tilde{F}_{SWTB}^{t}$，将其连续传递进基于移位窗口的多头自注意（SW-MSA）单元和多层感知器（MLP），获得 SW-MSA 模块输出 $\bar{F}_{SWTB}^{t}$ 和 Swin Transformer 块全局特征信息输出 F_{SWTB}^{t}。

A3：将结构感知注意块和 Swin Transformer 块的训练输出特征 F_{SAAB}^{t} 和 F_{SWTB}^{t} 传递进到增强型空间自适应块，首先通过 1×1 卷积层连接和处理，得到不同类型的融合特征。然后，应用 3×3 卷积层生成调制参数 α_1 和 β_1，并将 F_{SAAB}^{t} 用融合特征的均值和标准差进行更新。随后，应用 sigmoid 运算来生成调制系数。最后，将经过 1×1 卷积增强的空间特征与调制系数相乘，然后与 β_1 相加 ，得到空间调制特征 $\hat{F}_{SAAB}^{t}$。将调制特征 $\hat{F}_{SAAB}^{t}$ 进行卷积以产生另一个调制参数 α_2 和 β_2，将其相乘并添加到增强的全局特征 $\hat{F}_{\mathrm{SWTB}}^{t}$，从而提取全局深层次语义特征 F_{ESAB}^{t}。

7、根据权利要求 1 所述的一种基于轻量级交互式推理网络的单图像超分辨率重构方法，其特征在于，所述训练过程 A21 中结构感知注意块提取的局部特征信息如下：

$$\alpha^{t}=\sigma\left(H_{3\times3}(f_{1\times3}(F_{IFAM}^{t-1})+f_{3\times1}(F_{IFAM}^{t-1}))\right) \tag{3}$$

$$F_{SAAB}^{t}=\alpha^{t}\cdot F_{gen}^{t} \tag{4}$$

$$F_{gen}^{t}=f_{3\times3}(f_{3\times3}(F_{IFAM}^{t-1})) \tag{5}$$

其中，α^{t} 是 3D 调制系数，$\sigma(\cdot)$ 是 sigmoid 运算，$H(\cdot)$ 和 $f(\cdot)$ 是不同的卷积运算，其中下标表示卷积大小。

8、根据权利要求 1 所述的一种基于轻量级交互式推理网络的单图像超分辨率重构方法，其特征在于，所述训练过程 A22 中 Swin Transformer 块的提取的全局信息如下：

$$\hat{F}_{SWTB}^{t}=W\text{-}MSA\left(LN\left(F_{IFAM}^{t-1}\right)\right)+F_{IFAM}^{t-1} \tag{5}$$

$$\tilde{F}_{SWTB}^{t}=MLP\left(LN\left(\hat{F}_{SWTB}^{t}\right)\right)+\hat{F}_{SWTB}^{t} \tag{7}$$

$$\bar{F}_{SWTB}^{t}=SW\text{-}MSA\left(LN\left(\tilde{F}_{SWTB}^{t}\right)\right)+\tilde{F}_{SWTB}^{t} \tag{8}$$

$$F_{SWTB}^{t}=MLP\left(LN\left(\bar{F}_{SWTB}^{t}\right)\right)+\bar{F}_{SWTB}^{t} \tag{9}$$

其中 $\hat{F}_{SWTB}^{t}$、$\bar{F}_{SWTB}^{t}$、$\tilde{F}_{SWTB}^{t}$ 和 F_{SWTB}^{t} 分别是第 t 个(S)W-MSA 和 MLP 的输出。

7、根据权利要求 1 所述的一种基于轻量级交互式推理网络的单图像超分辨率重构方法，其特征在于，所述训练过程 A23 中增强型空间自适应块提取的调制特征函数如下：

$$\hat{F}_{SAAB}^{t}=F_{SAAB}^{t}\cdot\sigma(\alpha_1)+\beta_1 \tag{10}$$

$$F_{ESAB}^{t}=\hat{F}_{SWTB}^{t}\cdot\sigma(\alpha_2)+\beta_2 \tag{11}$$

说明书

一种基于轻量级交互式推理网络的单幅图像超分辨率重构方法

技术领域

本发明涉及一种基于轻量级交互式推理网络的单幅图像超分辨率重构，具体是指将受到自然环境因素及成像设备影响的低分辨率图像，通过设计端到端的深度神经网络，并用大量数据对该网络进行训练，学习低分辨率图像到高分辨率图像的非线性映射关系，从而实现低分辨率图像重构高分辨率图像的功能。本发明属于数字图像领域，涉及深度学习技术及图像超分辨率重构技术，具体涉及了一种基于轻量级交互式推理网络的单幅图像超分辨率重构方法。

背景技术

图像超分辨率（Super-resolurion, SR）重建技术旨在从信息缺失严重的单张或多张低分辨率图像中重建出信息丰富的高分辨率图像。由于图像超分辨率重建过程中存在着诸多不确定的因素，因而是一个病态欠定问题（Ill-posed Problem），即一张低分辨率图像能够恢复出多个对应的高分辨率图像。深度学习的出现对 SR 任务产生了革命性的影响，从卷积神经网络的提出到 Transformer 的出现，网络深度、宽度和复杂度地不断增加，进一步提高网络的表征能力和重建性能。图像超分辨率重构是使用低分辨的单帧或多帧序列图像来重建一张高分辨率图像，高分辨率指图像的像素密度尽可能的高，并且尽可能多的包含图像高频信息。这样的图像可以更好的描述真实目标场景的细节信息，并给予人眼更良好的直观体验。由于计算机视觉发展也极大依赖于图像的采集和分析，因此对低分辨率图像进行超分辨率重构具有十分重要的理论意义和应用价值。

目前，绝大多数超分辨率图像重构方法具有较大的模型参数量和较高的计算成本，尽管研究者们已经做出了许多努力来减少参数和操作的数量，但大多数方法难以在模型规模和重建性能之间取得良好平衡。此外，一些方法没有关注到图像超分辨率重构的特殊性，即忽略图像固有结构信息如物体的外轮廓、线条和曲线等的探究，难以恢复出真实的高分辨率图像。

发明内容

发明目的：为了克服现有技术中存在的不足，提供一种基于轻量级交互式推理网络的单幅图像超分辨率重构方法，通过嵌入结构先验，提升细节信息重建的鲁棒性，同时在保持较低的计算需求基础上获得优异的图像超分辨率重构效果。

技术方案：为实现上述目的，本发明提供一种基于轻量级交互式推理网络的单图像超分辨率重构方法，包括如下步骤：

1、一种基于轻量级交互式推理网络的单幅图像超分辨率重构方法，其特征在于，包括如下步骤：

S1：构建交互式推理网络进行单幅图像超分辨率重构实验，其包括如下步骤：

A1：浅层提取模块：

对输入的低分辨率图像，将交互式推理网络的输入，利用 3×3 卷积层提取浅层特征如边缘、纹理等。

A2：交互式聚合模块作为交互式推理网络主干，其包括如下组成部分：

A21：结构感知注意力块：

结构感知注意力块输入特征张量，利用非对称卷积，提取图像特征水平和垂直方向信息，同时叠加多个卷积层对结构信息进行融合并利用 Sigmoid 激活函数归一化到 0 至 1 之间，再通过空间级别方式自适应地校准输入特征，从而突出图像局部结构信息。

A22：Swin Transformer 块：

Swin Transformer 块引入局部注意力和移位窗口机制来降低模型复杂度并学习和捕获丰富的全局上下文信息。对输入特征张量，采用两个连续的 Swin Transformer 块增强网络复原性能，第一个块提取图像的局部特征，并通过局部自注意力机制增强这些特征。第二个块则利用移位窗口机制，将第一个块输出的特征进行跨窗口的信息交互，从而捕获更丰富的全局上下文信息。

A23：增强型空间自适应块：

将步骤 A1 学习的局部结构显著特征和 A2 学习的全局上下文信息作为增强型空间自适应块的输入，以协同的方式集成局部和全局这两种不同的特征属性，从而促进更加鲁棒纹理结构特征提取，恢复出更加自然和真实的高分辨率图像。

A3：上采样重建模块：

将步骤 A2 经过交互式聚合模块学习的深层语义特征作为上采样重建模块的输入，利用两个不同卷积大小的卷积层和亚像素卷积层分别上采样初始信息和深层语义信息，最后利用元素相加操作进行融合和集成，重建细节丰富的高分辨率图像。

S2：训练交互式推理网络

将预处理好的训练集中的低分辨图像 $I^{LR} \in {}^{H\times W\times 3}$ 作为交互式推理网络的输入，

H 和 W 表示图像的高度和宽度，对应的高分辨率图像作为目标高分辨图像 $I^{HR} \in {}^{rH\times rW\times 3}$，训练网络中的交互式聚合模块以获得最佳的更深层次语义特征 $F_t \in {}^{H\times W\times C}$，得到能够实现低分辨率视频图像到高分辨率重构的交互式推理网络。

S3：利用训练好的交互式推理网络进行单幅图像超分辨率重构。

进一步地，所述步骤 S2 中交互式推理网络训练过程为：

A1：使用 Kaiming 初始化来初始化交互式推理网络，其中参数初始化值服从均值为 0，方差为 $2/n$ 的高斯分布，其中 n 该层输入神经元的数量。

A2：将低分辨率图像 I^{LR} 输入到交互式推理网络中，生成浅层特征 F_0，再将浅层特征传递到由 T 个链式堆叠的交互式聚合模块中学习更加复杂和抽象的深层语义特征，进一步将深层语义特征作为上采样重建模块的输入，输出目标高分辨率图像大小一致的输出图像；

A3：将交互式推理网络生成的高分辨率图像和目标高分辨率图像做交互式推理网络的损失函数 $L(\Theta)$，依次迭代使得损失函数降低直至趋于稳定；

A4：训练整个交互式推理网络，计算网络的损失函数，同时更新整个网络的参数，直到所有损失函数趋于稳定，得到最终的超分辨率重构模型。

进一步地，所述步骤 S3 中训练好的交互式推理网络的损失函数如下：给定一个训练数据集 $\{I_i^{LR}, I_i^{SR}\}_{i=1}^{N}$，其中 I_i^{LR} 是第 i 个低分辨率输入图像，I_i^{SR} 是对应的目标高分辨率图像。主要目标是获得 I_i^{LR} 和 I_i^{SR} 之间的端到端映射函数 $F(\cdot)$，使用 L_1 损失函数对交互式推理网络进行优化：

$$L(\Theta)=\frac{1}{N}\sum_{i=1}^{N}\left\|I_i^{SR}-F\left(I_i^{LR}\right)\right\|_1=\frac{1}{N}\sum_{i=1}^{N}\left\|I_i^{SR}-I_i^{HR}\right\|_1 \tag{1}$$

其中，Θ 为交互式推理网络的权值和偏置（可训练参数）。通过最小化 $L(\Theta)$ 获得交互式推理网络的最佳权值和偏置。

进一步地，所述步骤 A2 中第 t 个链式堆叠的交互式聚合模块获取最佳的更深层次语义特征 F_t 为：

$$F_t = H_{\mathrm{IFAM}}^{t}\left(F_{t-1}\right) = H_{\mathrm{IFAM}}^{t}\left(H_{\mathrm{IFAM}}^{t-1}\left(\cdots H_{\mathrm{IFAM}}^{1}\left(F_0\right)\cdots\right)\right) \tag{2}$$

其中 $H_{\mathrm{IFAM}}^{t}(\ )$ 表示第 t 个交互式聚合模块的训练过程。$F_{t-1} \in {}^{H\times W\times C}$ 和 $F_t \in {}^{H\times W\times C}$ 是第 t 个交互式聚合模块的输入和输出特征。

进一步地，所述第 t 个交互式聚合模块的训练过程 $H_{\mathrm{IFAM}}^{t}(\ )$ 如下：

A1：将浅层特征 F_{IFAM}^{t-1} 传递进结构感知注意模块，从 1×3 和 3×1 卷积开始进行结构信息探索，然后传递到三个 3×3 卷积进行特征学习，通过 sigmoid 生成 3D 调制系数，最后通过 3D 调制系数来重新校准广义特征，输出丰富的局部特征 F_{SAAB}^{t} 表示以实现准确的超分辨率重建。

A2：将特征 F_{IFAM}^{t-1} 传递进两个连续的 Swin Transformer 块，基于窗口划分机制，输入特征 F_{IFAM}^{t-1} 在基于窗口的多头自注意（W-MSA）单元中被线性投影并重塑为 $\hat{F}_{IFAM}^{t-1}$，通过多层感知器（MLP）获得 $\tilde{F}_{SWTB}^{t}$，将其连续传递进基于移位窗口的多头自注意（SW-MSA）单元和多层感知器（MLP），获得 SW-MSA 单元输出 $\overline{F}_{SWTB}^{t}$ 和 Swin Transformer 块全局特征信息输出 F_{SWTB}^{t}。

A3：将结构感知注意力块和 Swin Transformer 块的训练输出特征 F_{SAAB}^{t} 和 F_{SWTB}^{t} 同时传递到增强型空间自适应块中。首先利用 1×1 卷积层进行连接和融合，获取不同类型的融合特征；然后，使用 3×3 卷积层生成调制参数 α_1 和 β_1，并将 F_{SAAB}^{t} 用融合特征的均值和标准差进行更新；随后，应用 Sigmoid 函数生成调制系数。最后，将经过 1×1 卷积后的增强空间特征与调制系数相乘，再与 β_1 进行元素级求和，得到空间调制特征 $\hat{F}_{SAAB}^{t}$；最后将调制特征 $\hat{F}_{SAAB}^{t}$ 进行卷积以产生另一个调制参数 α_2 和 β_2，将其相乘并添加到增强的全局特征 $\hat{F}_{SWTB}^{t}$ 中，从而提取全局深层次语义特征 F_{ESAB}^{t}。

进一步地，所述训练过程 A1 中结构感知注意力块的 3D 调制系数 α^t 为：

$$\alpha^t = \sigma\left(H_{3\times3}(f_{1\times3}(F_{IFAM}^{t-1}) + f_{3\times1}(F_{IFAM}^{t-1}))\right) \tag{3}$$

进一步地，所述训练过程 A1 中结构感知注意块的局部特征信息函数如下：

$$F_{SAAB}^{t} = \alpha^{t} \cdot F_{gen}^{t} \tag{4}$$

$$F_{gen}^{t} = f_{3\times3}(f_{3\times3}(F_{IFAM}^{t-1})) \tag{5}$$

其中，$\sigma(\cdot)$是 sigmoid 运算，$H(\cdot)$和$f(\cdot)$是不同的卷积运算，其中下标表示卷积的大小。

进一步地，所述训练过程 A2 中 Swin Transformer 块的输出函数如下：

$$\hat{F}_{SWTB}^{t} = W\text{-}MSA\left(LN\left(F_{IFAM}^{t-1}\right)\right) + F_{IFAM}^{t-1} \tag{6}$$

$$\tilde{F}_{SWTB}^{t} = MLP\left(LN\left(\hat{F}_{SWTB}^{t}\right)\right) + \hat{F}_{SWTB}^{t} \tag{7}$$

$$\bar{F}_{SWTB}^{t} = SW\text{-}MSA\left(LN\left(\tilde{F}_{SWTB}^{t}\right)\right) + \tilde{F}_{SWTB}^{t} \tag{8}$$

$$F_{SWTB}^{t} = MLP\left(LN\left(\bar{F}_{SWTB}^{t}\right)\right) + \bar{F}_{SWTB}^{t} \tag{9}$$

其中$\hat{F}_{SWTB}^{t}$、$\bar{F}_{SWTB}^{t}$、$\tilde{F}_{SWTB}^{t}$和F_{SWTB}^{t}分别是第t个(S)W-MSA 单元和 MLP 的输出。

进一步地，所述训练过程 A3 中增强型空间自适应块的调制特征函数如下：

$$\hat{F}_{SAAB}^{t} = F_{SAAB}^{t} \cdot \sigma(\alpha_1) + \beta_1 \tag{10}$$

$$F_{ESAB}^{t} = \hat{F}_{SWTB}^{t} \cdot \sigma(\alpha_2) + \beta_2 \tag{11}$$

附图说明

图 1 为本发明设计的交互式推理网络用于单幅图像超分辨率重构的总框图。

图 2 为本发明设计的结构感知注意力块。

图 3 为本发明基于窗口划分机制的 Swin Transformer 块。

图 4 是本发明设计的增强型空间自适应块。

图 5 是本发明方法在基准数据集上与主流 SR 方法之间的定量对比图。

图 6 是本发明方法在基准数据集 Set5 上比例因子×2 与主流 SR 方法之间的定性对比图。

图 7 是本发明在基准数据集 B100 上比例因子×3 与主流 SR 方法之间的定性对比图。

图 8 是本发明在基准数据集 Urban 上比例因子×4 与主流 SR 方法之间的定性对比图。

图 9 是本发明在遥感图像数据集上与现有的 SR 方法之间的定性对比图。

表 1 是本发明在基准数据集上比例因子×2 的实验定量结果。

表 2 是本发明在基准数据集上比例因子×3 的实验定量结果。

表 3 是本发明在基准数据集上比例因子×4 的实验定量结果。

表 4 是本发明在 RS-T1 和 RS-T2 遥感数据集的实验定量结果。

表 5 是本发明在 B100 数据集上的时间测试结果。

具体实施方式

下面结合附图和具体实施例，进一步阐明本发明，应理解这些实施例仅用于说明本发明而不用于限制本发明的范围，在阅读了本发明之后，本领域技术人员对本发明的各种等价形式的修改均落于本申请所附权利要求所限定的范围。

本发明提供一种基于轻量级交互式推理网络的单幅图像超分辨率重构方法，如图 1 所示，其包括如下步骤：

1、训练集预处理：

首先将具有高质量和高分辨率数据集进行数据增强；然后使用 MATLAB 在缩放因子为×2、×3 和×4 情况下，利用双三次插值下采样以获得对应的低分辨率图像；最后存储对应的高分辨图像和低分辨率图像数据，作为整个交互式推理网络的训练集。低分辨率图像输入到交互式推理网络中生成高分辨率图像，生成的高分辨率图像和目标高分辨率图像带入损失函数进行计算，最小化损失函数求得网络的最佳权重和偏置。

2、构建交互式推理网络进行单幅图像超分辨率重构实验，其包括如下步骤：

A1：浅层提取模块：

对输入的低分辨率图像，将交互式推理网络的输入，利用 3×3 卷积层提取浅层特征如边缘、纹理等。

A2：交互式聚合模块作为交互式推理网络主干，其包括如下组成部分：

A21：结构感知注意力块：

如图 2 所示，结构感知注意力块输入特征张量，利用非对称卷积，提取图像特征水平和垂直方向信息，同时叠加多个卷积层对结构信息进行融合并利用 Sigmoid 激活函数归一化到 0 至 1 之间，再通过空间级别方式自适应地校准输入特征，从而突出图像局部结构信息。

A22：Swin Transformer 块：

如图 3 所示，Swin Transformer 块引入局部注意力和移位窗口机制来降低模型复杂度并学习和捕获丰富的全局上下文信息。对输入特征张量，采用两个连续的 Swin Transformer 块增强网络复原性能，第一个块提取图像的局部特征，并通过局部自注意力机制增强这些特征。第二个块则利用移位窗口机制，将第一个块输出的特征进行跨窗口的信息交互，从而捕获更丰富的全局上下文信息。

A23：增强型空间自适应块：

如图 4 所示，将步骤 A21 学习的局部结构显著特征和 A22 学习的全局上下文信息作为增强型空间自适应块的输入，以协同的方式集成局部和全局这两种不同的特征属性，从而促进更加鲁棒纹理结构特征提取，恢复出更加自然和真实的高分辨率图像。

A3：上采样重建模块：

将步骤 A2 经过交互式聚合模块学习的深层语义特征作为上采样重建模块的输入，利用两个不同卷积大小的卷积层和亚像素卷积层分别上采样初始信息和深层语义信息，最后利用元素相加操作进行融合和集成，重建细节丰富的高分辨率图像。

3、训练交互式推理网络

将预处理好的训练集中的低分辨图像 $I^{LR} \in {}^{H\times W\times 3}$ 作为交互式推理网络的输入，H 和 W 表示图像的高度和宽度，对应的高分辨率图像作为目标高分辨图像 I^{HR}，训练网络中的交互式聚合模块以获得最佳的更深层次语义特征 F_t，得到能够实现低分辨率视频图像到高分辨率重构的交互式推理网络。

具体的交互式推理网络训练过程如下步骤 A1~A4：

A1：使用 Kaiming 初始化来初始化交互式推理网络，其中参数初始化值服从均值为 0，方差为 $2/n$ 的高斯分布，其中 n 该层输入神经元的数量。

A2：将低分辨率图像 I^{LR} 输入到交互式推理网络中，生成浅层特征 F_0，再将浅层特征传递到由 T 个链式堆叠的交互式聚合模块中学习更加复杂和抽象的深层语义特征，进一步将深层语义特征作为上采样重建模块的输入，输出目标高分辨率图像大小一致的输出图像；

A3：将交互式推理网络生成的高分辨率图像和目标高分辨率图像做交互式推理网络的损失函数 $L(\Theta)$，依次迭代使得损失函数降低直至趋于稳定；

A4：训练整个交互式推理网络，计算网络的损失函数，同时更新整个网络的参数，直到所有损失函数趋于稳定，得到最终的超分辨率重构模型。

本实施例中训练好的交互式推理网络的损失函数如下：

$$L(\Theta)=\frac{1}{N}\sum_{i=1}^{N}\left\|I_i^{SR}-F\left(I_i^{LR}\right)\right\|_1=\frac{1}{N}\sum_{i=1}^{N}\left\|I_i^{SR}-I_i^{HR}\right\|_1 \tag{1}$$

其中，Θ为交互式推理网络的权值和偏置（可训练参数）。通过最小化$L(\Theta)$获得交互式推理网络的最佳权值和偏置。

进一步地，所述第t个交互式聚合模块的训练过程$H_{\mathrm{IFAM}}^{t}(\ )$如下：

本实施例中训练好的交互式推理网络的第t个链式堆叠的交互式聚合模块获取最佳的更深层次语义特征F_t为：

$$F_t=H_{\mathrm{IFAM}}^{t}\left(F_{t-1}\right)=H_{\mathrm{IFAM}}^{t}\left(H_{\mathrm{IFAM}}^{t-1}\left(\cdots H_{\mathrm{IFAM}}^{1}\left(F_0\right)\cdots\right)\right) \tag{2}$$

其中$H_{\mathrm{IFAM}}^{t}(\ )$表示第$t$个交互式聚合模块的训练过程。$F_{t-1}\in{}^{H\times W\times C}$和$F_t\in{}^{H\times W\times C}$是第$t$个交互式聚合模块的输入和输出特征。

所述第t个交互式聚合模块的具体训练过程$H_{IFIM}^{t}(\ )$如下步骤A1~A3：

A1：将浅层特征F_{IFAM}^{t-1}传递进结构感知注意模块，从1×3和3×1卷积开始进行结构信息探索，然后传递到三个3×3卷积进行特征学习，通过sigmoid生成3D调制系数，最后通过3D调制系数重新校准广义特征，输出丰富的局部特征F_{SAAB}^{t}表示以实现准确的 SR 重建。

A2：将浅层特征F_{IFAM}^{t-1}传递进两个连续的Swin Transformer块，基于窗口划分机制，输入特征F_{IFAM}^{t-1}在基于窗口的多头自注意（W-MSA）单元中被线性投影并重塑为$\hat{F}_{IFAM}^{t-1}$，通过多层感知器（MLP）获得$\tilde{F}_{SWTB}^{t}$，将其连续传递进基于移位窗口的多头自注意（SW-MSA）单元和多层感知器（MLP），获得SW-MSA单元输出$\bar{F}_{SWTB}^{t}$和Swin Transformer 块全局特征信息输出F_{SWTB}^{t}。

A3：将结构感知注意力块和Swin Transformer 块的训练输出特征F_{SAAB}^{t}和F_{SWTB}^{t}同时传递到增强型空间自适应块中。首先利用1×1卷积层进行连接和融合，获取不同类型的融合特征；然后，使用3×3卷积层生成调制参数α_1和β_1，并将F_{SAAB}^{t}用融合特征的均值和标准差进行更新；随后，应用Sigmoid函数生成调制系数。

最后，将经过1×1卷积后的增强空间特征与调制系数相乘，再与β_1进行元素级求和，得

到空间调制特征 $\hat{F}_{SAAB}^{t}$；最后将调制特征 $\hat{F}_{SAAB}^{t}$ 进行卷积以产生另一个调制参数 α_2 和 β_2，将其相乘并添加到增强的全局特征 $\hat{F}_{SWTB}^{t}$ 中，从而提取全局深层次语义特征 F_{ESAB}^{t}。

本实施例中结构感知注意块的 3D 调制系数 α^t 为：

$$\alpha^t = \sigma\left(H_{3\times3}(f_{1\times3}(F_{IFAM}^{t-1}) + f_{3\times1}(F_{IFAM}^{t-1}))\right) \tag{3}$$

结构感知注意块的局部特征信息函数如下：

$$F_{SAAB}^{t} = \alpha^t \cdot F_{gen}^{t} \tag{4}$$

$$F_{gen}^{t} = f_{3\times3}(f_{3\times3}(F_{IFAM}^{t-1})) \tag{5}$$

其中，所述其中，$\sigma(\cdot)$ 是 sigmoid 运算，$H(\cdot)$ 和 $f(\cdot)$ 是不同的卷积运算，其中下标表示卷积的大小。

Swin Transformer 块的输出函数如下：

$$\hat{F}_{SWTB}^{t} = W\text{-}MSA\left(LN\left(F_{IFAM}^{t-1}\right)\right) + F_{IFAM}^{t-1} \tag{6}$$

$$\tilde{F}_{SWTB}^{t} = MLP\left(LN\left(\hat{F}_{SWTB}^{t}\right)\right) + \hat{F}_{SWTB}^{t} \tag{7}$$

$$\bar{F}_{SWTB}^{t} = SW\text{-}MSA\left(LN\left(\tilde{F}_{SWTB}^{t}\right)\right) + \tilde{F}_{SWTB}^{t} \tag{8}$$

$$F_{SWTB}^{t} = MLP\left(LN\left(\bar{F}_{SWTB}^{t}\right)\right) + \bar{F}_{SWTB}^{t} \tag{9}$$

其中 $\hat{F}_{SWTB}^{t}$、$\bar{F}_{SWTB}^{t}$、$\tilde{F}_{SWTB}^{t}$ 和 F_{SWTB}^{t} 分别是第 t 个(S)W-MSA 单元和 MLP 的输出。

进一步地，所述训练过程 A3 中增强型空间自适应块的调制特征函数如下：

$$\hat{F}_{SAAB}^{t} = F_{SAAB}^{t} \cdot \sigma(\alpha_1) + \beta_1 \tag{10}$$

$$F_{ESAB}^{t} = \hat{F}_{SWTB}^{t} \cdot \sigma(\alpha_2) + \beta_2 \tag{11}$$

4、实验结果展示及分析：

本实施例中将本发明方法与主流 SR 方法进行实验结果对比，其包括以下两个方面 A1~A2：

A1：定量比较：为了更适合实际应用的轻量级比较，本发明选择网络参数量小于 2000K 的模型作为比较对象。为了增强比较的可理解性，本发明采用乘加运算量（Multi-Adds）来衡量深度神经网络的计算量，它是一种通过恢复 1280×720(720P)高分辨率图像进行计算。如表 1 中的定量结果所示，与主流的 SR 网络相比，本发明方法在不同规模上表现较好的 PSNR 和 SSIM 性能；与基于卷积神经网络方法（CNN-based）相比，本发明方法在相似的计算复杂度下表现出更好的单图像超分辨率重建性能；与 CFGN、Cross-SRN 和 FMFN 相比，在参数和计算量较小的情况下，本发明方法拥有相当的性能与结果；例如，在表 3 中，与 Ngswin 相比，本发明方法在 Urban100 上的 PSNR 高出 0.19dB，SSIM 高出 0.0016。此外，与基于 Transformer 的方法相比，本发明方法通过较低的网络参数量和 Multi-Adds 取得更好的重建结果。此外，由于低分辨率图像在大尺度下像素值较少，因此需要更丰富的特征来恢复高分辨率图像，而本发明方法在较大比例因子方面的重建精度更加优越。如图 5 所示，本发明方法在模型容量和重建性能方面具有显著的优越性，超过了主流的轻量级图像超分辨率重构方法，实现了高性能和网络容量之间的良好平衡。

为了进一步证明本发明方法的有效性和优越性，本发明在质量和空间分辨率相对较低的遥感图像上进行了测试。本发明使用两个来自加州大学默塞德分校的名为 RS-T1 和 RS-T2 的数据集进行测试，RS-1 和 RS-2 均包含 120 张图像并覆盖具有复杂图像图案的各种场景。如表 4 所示，本发明方法获得最高的 PSNR 和 SSIM，超越了 LGCNet、FeNet、DRAN 和 FDENet 等先进的遥感 SR 方法。例如，与轻量级 DRAN 相比，本发明方法获得 0.04−0.16 dB 的 PSNR

和 0.0004-0.0051 的 SSIM 增益，表现出很强的灵活性和稳定性。

为进一步检测本发明方法是否能在现实世界中实时应用，本发明在独立显卡硬件型号为 NVIDIA GeForce RTX 3060 GPU 的同一设备上对一些代表性 SR 方法进行时间测试，每个网络的时间消耗评估四次，然后计算平均成绩作为最终时间耗时。在表 5 中描述了 B100 数据集上的模型参、Multi-Adds、PSNR/SSIM 和时间消耗。与基于 CNN 的方法相比，本发明方法以更少的模型参数量和计算量获得了最高的 PSNR 和 SSIM。与基于 Transformer 的方法相比，本发明方法在计算上更加高效。具体来说，DRSAN-48m 和 Ngswin 的时间消耗分别是本发明方法的 8 倍和 2.5 倍。因此，本发明方法在模型复杂性、重建性能和时间消耗之间实现良好平衡，在现实世界中可以实时应用。

A2：定性比较：本发明对基准数据集的选定部分与现有的 SR 方法进行了视觉比较。如图 6~8 所示，本发明方法对条纹和线条图案具有出色的还原能力，能够展示出更精细、更准确的超分辨率图像。如图 6 所示，本发明方法能够产生更清晰的纹理细节，接近目标高分辨图像。在图 7 中，基于 ESRT、LBNet 和 CFGN 的方法可以重建出条纹特征，但具有可见的模糊，而本发明方法能够专注于微小的纹理并收集丰富的高频信息，从而获得更清晰、更准确的重建图像。如图 8 所示， 基于 SRCNN、CARN 和 ACNet 的方法难以获取纹理信息同时伴随着模糊伪影。相比之下，本发明方法可以有效缓解模糊，从而恢复更多细节。

本发明在质量和空间分辨率相对较低的遥感图像上现有的 SR 方法进行了测试并进行了直观的视觉对比。如图 9 所示，本发明方法在对象轮廓和纹理细节方面表现出比现有的 SR 方法更好的重建效果。在图 9（b）、（c）、（d）中，LGCNET、LESRCNN 和 FENet 无法恢复条纹信息，分别产生严重的模糊、失真和伪影。相比之下，如图 9（a）、（e）、（f）、（g）、(h) 所示，本发明方法可以更清晰、准确地重建图像细节，在视觉上与目标高分辨率图像一致。

说明书附图

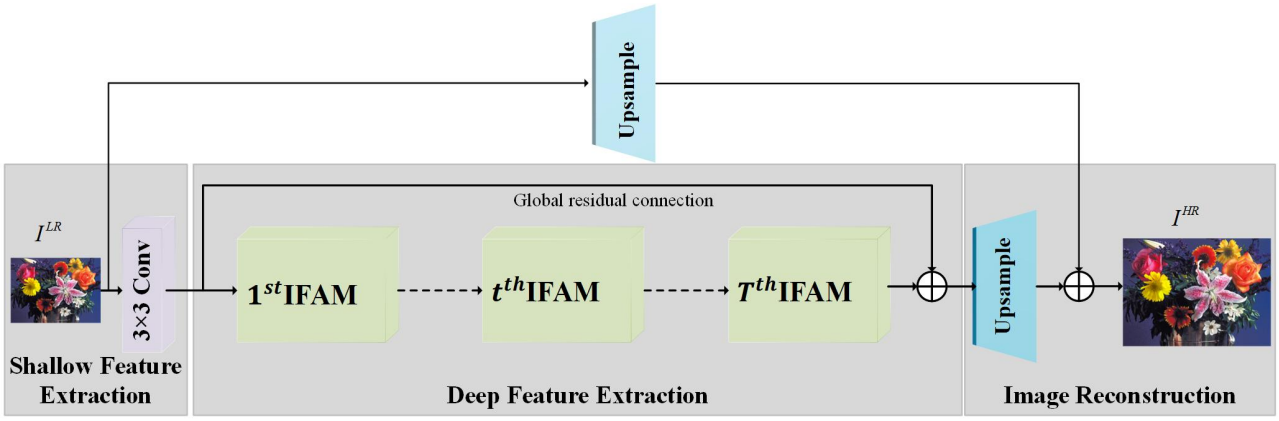

Upsample
Global residual connection
I^{LR}
3×3 Conv
1^{st}IFAM
t^{th}IFAM
T^{th}IFAM
Upsample
I^{HR}
Shallow Feature Extraction
Deep Feature Extraction
Image Reconstruction

图 1

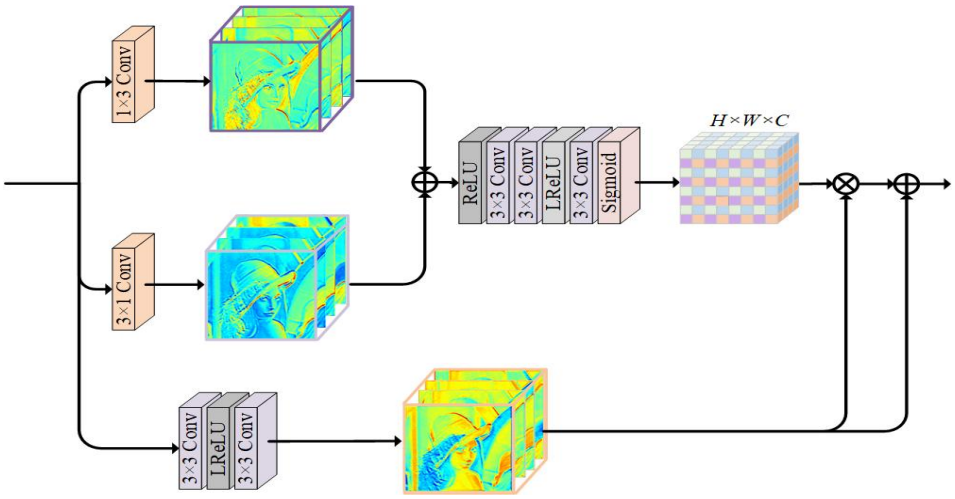

1×3 Conv
3×1 Conv
3×3 Conv
LReLU
3×3 Conv
ReLU
3×3 Conv
3×3 Conv
LReLU
3×3 Conv
Sigmoid
H×W×C

图 2

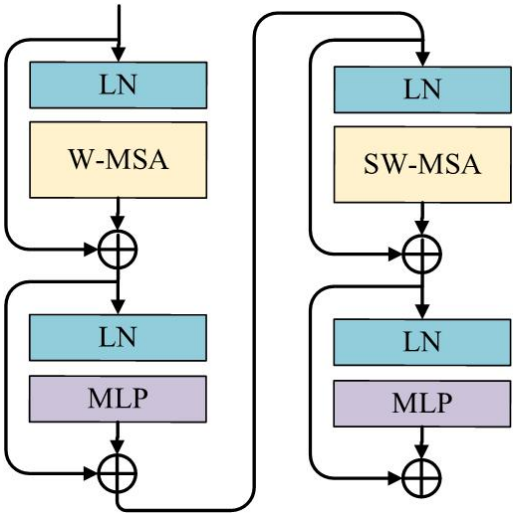

LN
W-MSA
LN
MLP
LN
SW-MSA
LN
MLP

图 3

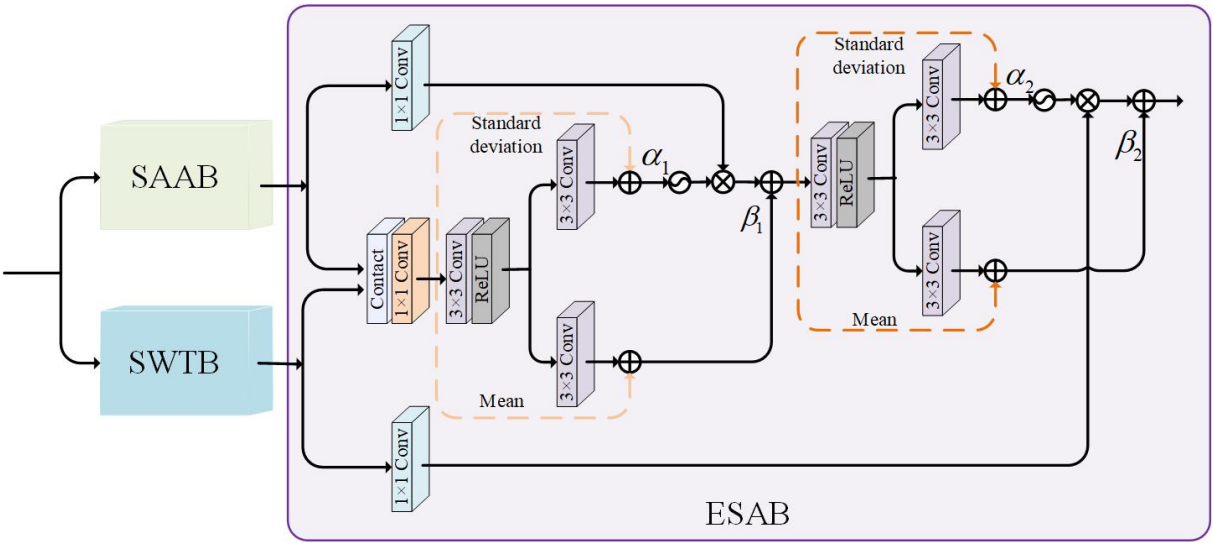

SAAB
SWTB
1×1 Conv
Contact
1×1 Conv
3×3 Conv
ReLU
Standard deviation
3×3 Conv
Mean
3×3 Conv
α_1
β_1
1×1 Conv
Standard deviation
3×3 Conv
3×3 Conv
ReLU
α_2
β_2
3×3 Conv
Mean
ESAB

图 4

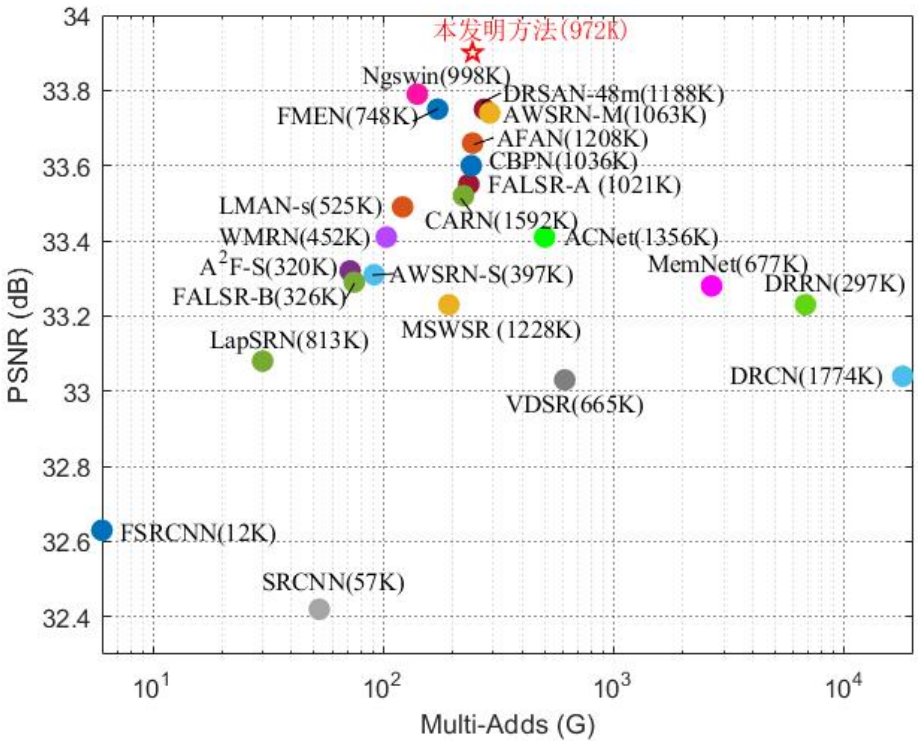
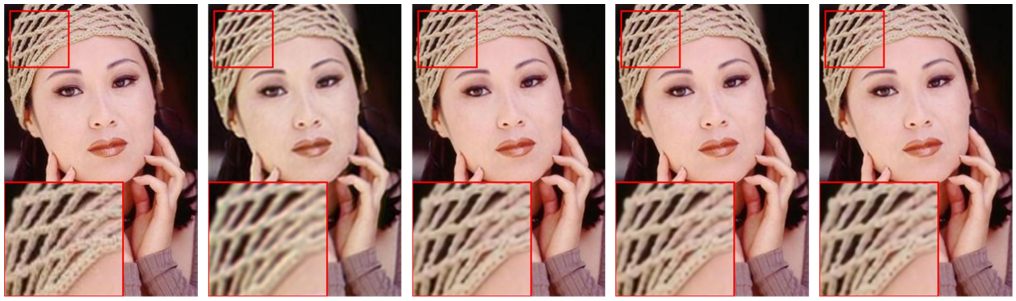
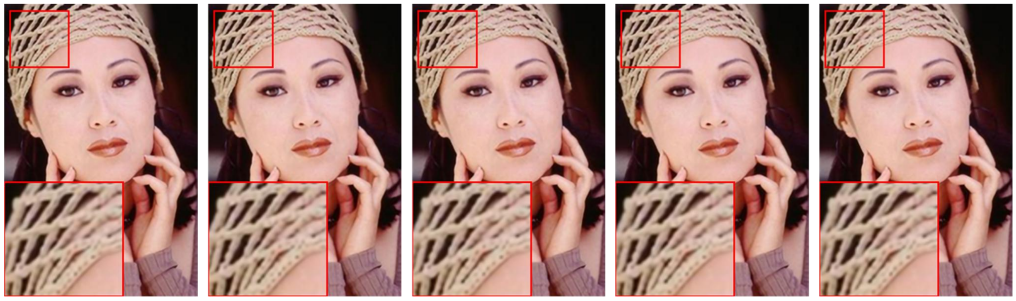

本发明方法(972K)
Ngswin(998K)
DRSAN-48m(1188K)
FMEN(748K)
AWSRN-M(1063K)
AFAN(1208K)
CBPN(1036K)
FALSR-A (1021K)
LMAN-s(525K)
CARN(1592K)
WMRN(452K)
ACNet(1356K)
A2F-S(320K)
AWSRN-S(397K)
MemNet(677K)
DRRN(297K)
FALSR-B(326K)
MSWSR (1228K)
LapSRN(813K)
DRCN(1774K)
VDSR(665K)
FSRCNN(12K)
SRCNN(57K)
PSNR (dB)
Multi-Adds (G)
34
33.8
33.6
33.4
33.2
33
32.8
32.6
32.4
10^1
10^2
10^3
10^4

图 5

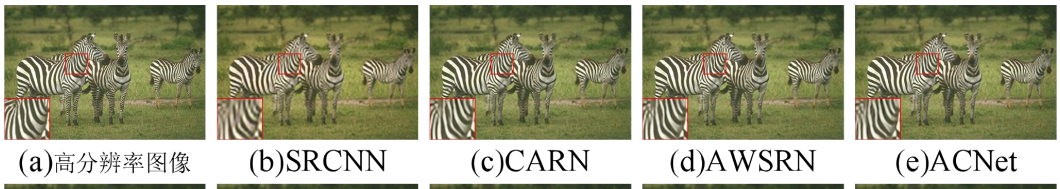


(a) 高分辨率图像 (b)SRCNN (c)CARN (d)AWSRN (e)ACNet

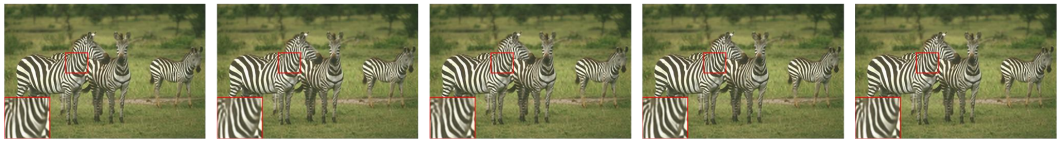


(f)DRSAN (g)ESRT (h)LBNet (i)CFGN (j)本发明方法

图 6



(a)高分辨率图像 (b)SRCNN (c)CARN (d)AWSRN (e)ACNet



(f)DRSAN (g)ESRT (h)LBNet (i)CFGN (j)本发明方法

图 7



(a)高分辨率图像 (b)SRCNN (c)CARN (d)AWSRN (e)ACNet



(f)DRSAN (g)ESRT (h)LBNet (i)CFGN (j)本发明方法

图 8



(a)目标高分辨率图像 (b)SRCNN (c)VDSR (d)LGCNET



(e)LESRCNN (f) FENet (g)DRAN (h)本发明方法

图 9

表 1

尺度	模型	参数量	Multi-Adds	Set5	Set14	B100	Urban100	Manga109
				PSNR(dB)/SSIM	PSNR(dB)/SSIM	PSNR(dB)/SSIM	PSNR(dB)/SSIM	PSNR(dB)/SSIM
×2	FSRCNN	12K	6G	37.00/0.9558	32.63/0.9088	31.53/0.8920	29.88/0.9020	36.67/0.9694
	SRCNN	57K	52.7G	36.66/0.9542	32.42/0.9063	31.36/0.8879	29.50/0.8946	35.74/0.9661
	VDSR	665K	612.6G	37.53/0.9587	33.03/0.9124	31.90/0.8960	30.76/0.9140	37.22/0.9729
	DRCN	1774K	17974G	37.63/0.9588	33.04/0.9118	31.85/0.8942	30.75/0.9133	37.63/0.9723
	LapSRN	813K	29.9G	37.52/0.9590	33.08/0.9130	31.80/0.8950	30.41/0.9100	37.27/0.9740
	DRRN	297K	6797G	37.74/0.9591	33.23/0.9136	32.05/0.8973	31.23/0.9188	37.92/0.9760
	CARN	1592K	222.8G	37.76/0.9590	33.52/0.9166	32.09/0.8978	31.92/0.9256	-
	CBPN	1036K	240.7G	37.90/0.9590	33.60/0.9171	32.17/0.8989	32.14/0.9279	-
	AWSRN-M	1063K	244.1G	38.04/0.9605	33.66/0.9181	32.21/0.9000	32.23/0.9294	38.66/0.9772
	OISR-RK2-s	1372 K	316.2G	37.98/0.9604	33.58/0.9172	32.18/0.8996	32.09/0.9281	-
	A2F-S	320K	71.7G	37.79/0.9597	33.32/0.9152	31.99/0.8972	31.44/0.9211	38.11/0.9757
	LESRCNN	516K	110.6G	37.65/0.9586	33.32/0.9148	31.95/0.8964	31.45/0.9206	-
	FALSR-A	1021K	234.7G	37.82/0.9595	33.55/0.9168	32.12/0.8987	31.93/0.9256	-

	LMAN-s	525K	121.2G	37.94/0.9603	33.49/0.9167	32.08/0.8984	31.85/0.9251	38.43/0.9765
	MSWSR	1228 K	192.5G	37.49/0.9583	33.23/0.9123	31.88/0.8929	31.14/0.9169	37.32/0.9733
	Cross-SRN	1276K	292.1G	38.03/0.9606	33.62/0.9180	32.19/0.8997	32.28/0.9290	38.75/0.9773
	FMEN	748K	172.0G	38.10/0.9609	33.75/0.9192	32.26/0.9007	32.41/0.9311	38.95/0.9778
	AFAN	1208K	289.5G	38.06/0.9608	33.74/0.9198	32.20/0.9001	32.38/0.9305	38.79/0.9773
	ACNet	1356K	501.5G	37.72/0.9588	33.41/0.9160	32.06/0.8978	31.79/0.9245	-
	CFGN	601K	130.9G	38.03/0.9607	33.74/0.9197	32.23/0.9004	32.47/0.9316	38.96/0.9777
	DRSAN-48m	1188K	274.6G	38.14/0.9611	33.75/0.9188	32.25/0.9010	32.46/0.9317	-
	ESRT	677K	271G	38.03/0.9600	33.75/0.9184	32.25/0.9001	32.58/0.9318	39.12/0.9774
	Ngswin	998K	140.4G	38.05/0.9610	33.79/0.9199	32.27/0.9008	32.53/0.9324	38.97/0.9777
	本发明方法	972K	243.8G	38.10/0.9610	33.90/0.9206	32.26/0.9007	32.45/0.9314	38.95/0.9777

表 2

尺度	模型	参数量	Multi-Adds	Set5	Set14	B100	Urban100	Manga109
				PSNR(dB)/SSIM	PSNR(dB)/SSIM	PSNR(dB)/SSIM	PSNR(dB)/SSIM	PSNR(dB)/SSIM
×3	FSRCNN	12K	5G	33.16/0.9140	29.43/0.8242	28.53/0.7910	26.43/0.8080	30.98/0.9212
	SRCNN	57K	52.7G	32.75/0.9090	29.28/0.8209	28.41/0.7863	26.24/0.7989	30.59/0.9107
	VDSR	665K	612.6G	33.66/0.9213	29.77/0.8314	28.82/0.7976	27.14/0.8279	32.01/0.9310
	DRCN	1774K	17974G	33.82/0.9226	29.76/0.8311	28.80/0.7963	27.15/0.8276	32.31/0.9328
	DRRN	297K	6797G	34.03/0.9244	29.96/0.8349	28.95/0.8004	27.53/0.8378	32.74/0.9390
	MemNet	677K	2662.4G	34.09/0.9248	30.00/0.8350	28.96/0.8001	27.56/0.8376	-
	CARN	1592K	118.8G	34.29/0.9255	30.29/0.8407	29.06/0.8034	28.06/0.8493	-
	AWSRN-S	477K	48.6G	34.02/0.9240	30.09/0.8376	28.92/0.8009	27.57/0.8391	32.82/0.9393
	AWSRN-M	1143K	116.6G	34.42/0.9275	30.32/0.8419	29.13/0.8059	28.26/0.8545	33.64/0.9450
	OISR-RK2-s	1557 K	160.1G	34.43/0.9273	30.33/0.8420	29.10/0.8053	28.20/0.8534	-
	A2F-S	324	32.3G	34.06/0.92	30.08/0.83	28.92/0.80	27.57/0.83	32.86/0.93

		k		41	70	06	92	94
	LESRCNN	516K	49.1G	33.93/0.9231	30.12/0.8380	28.91/0.8005	27.70/0.84152	-
	WMRN	556K	57G	34.11/0.9251	30.17/0.8390	28.98/0.8021	27.80/0.8448	33.07/0.9413
	LMAN-s	709K	73.5G	34.31/0.9265	30.24/0.8397	29.02/0.8030	28.02/0.8487	33.42/0.9433
	Cross-SRN	1285K	130.5G	34.43/0.9275	30.33/0.8417	29.09/0.8050	28.23/0.8535	33.65/0.9448
	ACNet	1541K	369G	34.14/0.9247	30.19/0.8398	28.98/0.8023	27.97/0.8482	-
	FMEN	757K	77.2G	34.45/0.9275	30.40/0.8435	29.17/0.8063	28.33/0.8562	33.86/0.9462
	AFAN	1208K	143.1G	34.46/0.9271	30.38/0.8436	29.11/0.8064	28.31/0.8556	33.61/0.9451
	CFGN	609K	59.0G	34.41/0.9274	30.44/0.8443	29.16/0.8066	28.37/0.8575	33.81/0.9459
	DRSAN-48m	1292K	133.4G	34.59/0.9286	30.42/0.8443	29.18/0.8079	28.52/0.8593	-
	ESRT	770K	135G	34.42/0.9268	30.43/0.8433	29.15/0.8063	28.46/0.8574	33.95/0.9455
	LBNet	736K	68.4G	34.47/0.9277	30.38/0.8417	29.13/0.8061	28.42/0.8559	33.82/0.9460
	Ngswin	1007K	66.6G	34.52/0.9282	30.53/0.8456	29.19/0.8078	28.52/0.8603	33.89/0.9470
	本发明方法	980K	107.0G	34.58/0.9287	30.55/0.8463	29.21/0.8082	28.57/0.8608	34.14/0.9479

表 3

规模	模型	参数量	Multi-Adds	Set5	Set14	B100	Urban100	Manga109
				PSNR(dB)/SSIM	PSNR(dB)/SSIM	PSNR(dB)/SSIM	PSNR(dB)/SSIM	PSNR(dB)/SSIM
×4	FSRCNN	12K	4.6G	30.71/0.8657	27.59/0.7535	26.98/0.7150	24.62/0.7280	27.90/0.8517
	SRCNN	57K	52.7G	30.48/0.8628	27.49/0.7503	26.90/0.7101	24.52/0.7221	27.66/0.8505
	VDSR	665K	612.6G	31.35/0.8838	28.01/0.7674	27.29/0.7251	25.18/0.7524	28.83/0.8809
	DRCN	1774K	17974G	31.53/0.8854	28.02/0.7670	27.23/0.7233	25.14/0.7510	28.98/0.8816
	LapSRN	813K	149.4G	31.54/0.8850	28.19/0.7720	27.32/0.7280	25.21/0.7560	29.09/0.8845
	DRRN	297K	6797G	31.68/0.8888	28.21/0.7720	27.38/0.7284	25.44/0.7638	29.46/0.8960
	MemNet	677K	2662.4G	31.74/0.8893	28.26/0.7723	27.40/0.7281	25.50/0.7630	-
	CARN	1592K	90.9G	32.13/0.8937	28.60/0.7806	27.58/0.7349	26.07/0.7837	-
	CBPN	119	97.9G	32.21/0.89	28.63/0.78	27.58/0.73	26.14/0.78	-

		7K		44	13	56	69	
	AWSRN-M	1254K	72.0G	32.21/0.8954	28.65/0.7832	27.60/0.7368	26.15/0.7884	30.56/0.9093
	OISR-RK2-s	1520 K	114.2G	32.21/0.8950	28.63/0.7822	27.58/0.7364	26.14/0.7874	-
	A2F-S	331k	18.6G	31.87/0.8900	28.36/0.7760	27.41/0.7305	25.58/0.7685	29.77/0.8987
	LESRCNN	516K	28.6G	31.88/0.8903	28.44/0.7772	27.45/0.7313	25.77/0.7732	-
	WMRN	536K	45.7G	32.00/0.8925	28.47/0.7786	27.49/0.7328	25.89/0.7789	30.11/0.9040
	LMAN-s	672K	65.5G	32.12/0.8939	28.53/0.7798	27.51/0.7340	25.96/0.7813	30.30/0.9062
	MSWSR	1228 K	101.7G	32.01/0.8914	28.47/0.7776	27.48/0.7311	25.78/0.7744	30.01/0.8999
	Cross-SRN	1296K	74.2G	32.24/0.8954	28.59/0.7817	27.58/0.7364	26.16/0.7881	30.53/0.9081
	ACNet	1784K	347.9G	31.83/0.8903	28.46/0.7788	27.48/0.7326	25.93/0.7798	-
	CRMBN	495K	-	32.07/0.8923	28.50/0.7783	27.50/0.7327	25.83/0.7771	-
	FMEN	769K	44.2G	32.24/0.8955	28.70/0.7839	27.63/0.7379	26.28/0.7908	30.70/0.9107
	AFAN	1226K	90.1G	32.30/0.8951	28.66/0.7838	27.61/0.7383	26.27/0.7913	30.63/0.9109
	CFGN	621K	33.9G	32.32/0.8957	28.67/0.7832	27.60/0.7377	26.22/0.7916	30.63/0.9101
	DRSAN-48m	1271K	88.7G	32.34/0.8960	28.65/0.7841	27.63/0.7390	26.33/0.7936	-

	ESRT	751K	67.7G	32.19/0.8947	28.69/0.7833	27.69/0.7379	26.39/0.7962	30.75/0.9100
	LBNet	742K	38.9G	32.29/0.8960	28.68/0.7832	27.62/0.7382	26.27/0.7906	30.76/0.9111
	Ngswin	1019K	36.4G	32.33/0.8963	28.78/0.7859	27.66/0.7396	26.45/0.7963	30.80/0.9128
	本发明方法	991K	64.6G	32.47/0.8988	28.80/0.7871	27.70/7414	26.64/0.7979	31.06/0.9156

表 4

方法	尺度	参数量	RS-T1	RS-T2
			PSNR(dB)/SSIM	PSNR(dB)/SSIM
Bicubic	×2	-	33.25/0.8934	30.64/0.8837
SRCNN		57K	35.18/0.9243	32.87/0.9209
VDSR		666K	35.85/0.9312	33.86/0.9312
LGCNet		193K	35.65/0.9298	33.47/0.9281
LapSRN		251K	35.69/0.9304	33.57/0.9286
IDN		553K	36.13/0.9339	34.07/0.9329
LESRCNN		626K	36.04/0.9328	34.00/0.9320
CARN-M		412K	35.77/0.9314	33.84/0.9315

FeNet		351K	36.23/0.9341	34.22/0.9337
FDENet		480K	36.26/0.9346	34.28/0.9338
DRAN		589K	36.38 /0.9348	34.42/0.9357
本发明方法		972K	36.42/0.9359	34.49/0.9361
Bicubic	×3	-	29.73/0.7818	27.23/0.7697
SRCNN		57K	30.95/0.8228	28.59/0.8180
VDSR		666K	31.55/0.8352	29.40/0.8391
LGCNet		193K	31.30/0.8314	29.03/0.8312
LapSRN		29 万	31.47/0.8338	29.22/0.8352
IDN		553K	31.73/0.8430	29.59/0.8450
LESRCNN		810K	31.68/0.8398	29.65/0.8444
CARN-M		412K	31.72/0.8426	29.62/0.8452
FeNet		357K	31.89/0.8432	29.80/0.8481
FDENet		488K	31.98/ 0.8488	29.88/0.8489
DRAN		589K	32.08 /0.8470	30.05/0.8537
本发明方法		991K	32.18/0.8506	32.18/0.8560
Bicubic	×4	-	27.91/0.6968	25.40/0.6770
SRCNN		57K	28.87/0.7382	26.46/0.7296
VDSR		666K	29.33/0.7546	27.03/0.7525
LGCNet		193K	29.13/0.7481	26.76/0.7426
LapSRN		543K	29.51/0.7614	27.24/0.7600
IDN		553K	29.56/0.7623	27.31/0.7627
LESRCNN		774K	29.62/0.7625	27.41/0.7646
CARN-M		412K	29.57/0.7624	27.37/0.7647
FeNet		366K	29.70/0.7688	27.45/0.7672
FDENet		501K	29.72/0.7658	27.54/0.7697
DRAN		589K	29.85 /0.7710	27.67/0.7758
本发明方法		991K	29.92/0.7736	27.83/0.7809

表 5

类型	模型	参数量	Multi-Adds	PSNR(dB)/SSIM	时间消耗(s)
基于 CNN 方法	CARN	1592K	118.8G	29.06/0.8034	0.4623
	AWSRN-S	477K	48.6G	28.92/0.8009	0.8807
	AWSRN-M	1143K	116.6G	29.13/0.8059	1.7432
	OISR-RK2-s	1557K	160.1G	29.10/0.8053	0.5304
	A2F-S	324k	32.3G	28.92/0.8006	0.6651
	LESRCNN	516K	49.1G	28.91/0.8005	0.2911
	LMAN-s	709K	73.5G	29.02/0.8030	1.6537
	Cross-SRN	1285K	130.5G	29.09/0.8050	2.2345
	ACNet	1541K	369G	28.98/0.8023	0.6436
	FMEN	757K	77.2G	29.17/0.8063	0.4598
	AFAN	1208K	143.1G	29.11/0.8064	2.9098
	CFGN	609K	59.0G	29.16/0.8066	2.1632
基于 Transformer 方法	DRSAN-48m	1292K	133.4G	29.18/ 0.8079	25.9941
	ESRT	770K	135G	29.15/0.8063	2.4120
	LBNet	736K	68.4G	29.13/0.8061	3.2489
	Ngswin	1007K	66.6G	29.19 /0.8078	8.0806
	本发明方法	980K	107.0G	29.21/0.8082	3.1728

申请材料分析说明

1.基础信息

专利名称：一种单幅图像超分辨率重建方法及其交互式推理网络

状态：审查中

2.交底材料

本案是以正式的专利文稿的形式提供的交底材料。交底材料内容相对较为充实，且提供了非常详细的测试内容说明、测试数据、测试图表、测试样张。

交底材料不用提供《权利要求书》，权利要求的编制是专利代理的核心工作，也是专利申请过程中所重点围绕开展的审查对象；权利要求是由代理师在经过充分理解技术方案的基础上，结合相关法律法规的要求，针对现有技术与本发明的创新点，通过合理的规划布局制定的。技术人员在交底材料中写好权利要求，不仅对专利申请没有帮助，反而会给专利代理工作制造障碍，因此交底材料中不要提供权利要求书。

对神经网络的结构表述稍显笼统，部分表述模糊不清，特别是存在一些自创表述，如“通过空间级别方式自适应地校准输入特征”不知所云。

交底材料中附图与文字内容存在不对应。

附图中涉及到真人照片，存在肖像权方面的法律风险。

3.权利要求书

给出了两项独立权利要求，分别保护“一种交互式推理网络”和“一种单幅图像超分辨率重建方法”。

对于第一项权利要求“一种交互式推理网络”，对其技术特征做了最大限度的提炼概括，并在下面设置了 8 条从属权利要求将概括的技术特征进行细化，为后期审查争取授权与较大保护范围提供支撑。

4.说明书

背景技术部分，技术问题交代明确——绝大多数超分辨率图像重构方法具有较大的模型参数量和较高的计算成本。

具体实施方式部分，结合附图采用总分形式对神经网络模型的结构进行讲解说明；针对交底材料中部分模糊性表述进行了重新整理，使得说明书做到清楚完整。

有益效果部分，针对 3 处创新点进行了逐条讲解，并给出了详细的测试验证说明，包括神经网络的训练参数设置，与多个现有神经网络的横向对比测试，自身网络性能的测试验证等。

申请稿

说明书摘要

本发明提供了一种单幅图像超分辨率重建方法及其交互式推理网络，其中网络包括浅层提取模块、深层提取模块和上采样重建模块，深层提取模块由若干链式堆叠的交互式聚合模块构成，根据浅层提取模块提取到的图像浅层特征提取出更深层特征，最后由上采样重建模块分别对初始图像和深层语义信息做上采样以及元素相加后，得到高分辨率的重建图像。本发明网络在模型容量和重建性能方面具有显著的优越性，超过了主流的轻量级图像超分辨率重构方法，实现了高性能和网络容量之间的良好平衡。

权利要求书

1.一种交互式推理网络，其特征在于：设有深层提取模块，根据输入的浅层特征 F_{IFAM}^{0} 提取图像的深层特征；所述深层提取模块中包括 T个交互式聚合模块， T个交互式聚合模块之间链式堆叠，其中前一个交互式聚合模块输出的特征作为后一个交互式聚合模块的输入，最后第 T个交互式聚合模块的输出特征 F_{IFAM}^{T}与浅层特征 F_{IFAM}^{0}做元素相加，得到所述深层特征。

2.根据权利要求 1 所述的交互式推理网络，其特征在于：用于图像超分辨率重建，包括：

浅层提取模块：用于提取初始图像的浅层特征 F_{IFAM}^{0}；

上采样重建模块：分别对初始图像和所述深层特征做上采样，之后再对两个上采样后的图像进行元素相加得到重建后的图像。

3.根据权利要求 2 所述的交互式推理网络，其特征在于：所述浅层提取模块中，对初始图像做 3×3 卷积得到浅层特征 F_{IFAM}^{0}。

4.根据权利要求 1 所述的交互式推理网络，其特征在于：所述交互式聚合模块包括：结构感知注意力块、Swin Transform 块、增强型空间自适应块；其中第 t个交互式聚合模块中：

结构感知注意力块：根据输入的特征 F_{IFAM}^{t-1}，提取图像的局部特征 F_{SAAB}^{t}；

Swin Transform 块：根据输入的特征 F_{IFAM}^{t-1}，提取图像的全局特征 F_{SWTB}^{t}；

增强型空间自适应块：根据所述局部特征和所述全局特征，输出全局深层特征 F_{IFAM}^{t}。

5.根据权利要求 4 所述的交互式推理网络，其特征在于：所述结构感知注意力块中，首先通过两个非对称卷积分别提取图像特征中的水平和垂直方向上的信息，之后再叠加多个卷积层对结构信息进行融合，并利用 Sigmoid 激活函数做归一化：

$$\alpha^{t}=\sigma\left(H_{3\times3}\left(f_{1\times3}\left(F_{IFAM}^{t-1}\right)+f_{3\times1}\left(F_{IFAM}^{t-1}\right)\right)\right)$$

其中， α^{t}为由 Sigmoid 函数生成的 3D 调制系数， $\sigma(\cdot)$表示 Sigmoid 运算， $H_{3\times3}(\cdot)$表示多个叠加的 3×3 卷积运算， $f(\cdot)$表示卷积运算，下标表示相应卷积核大小；

而后通过空间级别方式自适应地校准输入特征，得到局部特征 F_{SAAB}^{t}：

$$F_{SAAB}^{t} = \alpha^{t} \cdot F_{gen}^{t} + F_{gen}^{t}$$

$$F_{gen}^{t} = f_{3\times3}\left(f_{3\times3}\left(F_{IFAM}^{t-1}\right)\right)$$

其中，F_{gen}^{t}为第 t个块中利用两个连续的 3×3 卷积提取的广义特征，在上述两个 3×3 卷积之间设有一个 L-ReLU 层。

6.根据权利要求 5 所述的交互式推理网络，其特征在于：所述多个叠加的 3×3 卷积运算中，依次包括一个 ReLU、两个连续的 3×3 卷积、一个 L-ReLU、一个 3×3 卷积。

7.根据权利要求 4 所述的交互式推理网络，其特征在于：所述 Swin Transform 块中，全局特征 F_{SWTB}^{t}的获取过程为：

$$\widehat{F}_{SWTB}^{t} = W\text{-}MSA\left(LN\left(F_{IFAM}^{t-1}\right)\right) + F_{IFAM}^{t-1}$$

$$\widetilde{F}_{SWTB}^{t} = MLP\left(LN\left(\widehat{F}_{SWTB}^{t}\right)\right) + \widehat{F}_{SWTB}^{t}$$

$$\overline{F}_{SWTB}^{t} = SW\text{-}MSA\left(LN\left(\widetilde{F}_{SWTB}^{t}\right)\right) + \widetilde{F}_{SWTB}^{t}$$

$$F_{SWTB}^{t} = MLP\left(LN\left(\overline{F}_{SWTB}^{t}\right)\right) + \overline{F}_{SWTB}^{t}$$

其中，$W\text{-}MSA(\cdot)$表示 W-MSA 单元的输出，$SW\text{-}MSA(\cdot)$表示 SW-MSA 单元的输出，$MLP(\cdot)$表示 MLP 的输出，$LN(\cdot)$表示归一化操作。

8.根据权要求 4 所述的交互式推理网络，其特征在于：所述增强型空间自适应块中：

S1，对 F_{SAAB}^{t}和 F_{SWTB}^{t}做特征融合并由 1×1 卷积调整通道数得到融合特征，融合特征依次经 3×3 卷积和 ReLU 后，再由两路并行的 3×3 卷积分别得到调制参数 α_1^t和 β_1^t：

$$\alpha_1^t = f_{3\times3}\left(f_{3\times3}\left(f_{1\times1}\left(\left[F_{SAAB}^{t}, F_{SWTB}^{t}\right]\right)\right)\right) + f_{1\times1}\left(\left[F_{SAAB}^{t}, F_{SWTB}^{t}\right]\right)$$

$$\beta_1^t = f_{3\times3}\left(f_{3\times3}\left(f_{1\times1}\left(\left[F_{SAAB}^{t}, F_{SWTB}^{t}\right]\right)\right)\right) + f_{1\times1}\left(\left[F_{SAAB}^{t}, F_{SWTB}^{t}\right]\right)$$

其中，$[\cdot,\cdot]$表示级联操作，$f(\cdot)$表示卷积运算，下标表示相应卷积核大小；

S2，F_{SAAB}^{t}经 1×1 卷积调整后，利用所得到的 α_1^t和 β_1^t进行更新，得到空间调制特征 $\widehat{F}_{SAAB}^{t}$：

$$\widehat{F}_{SAAB}^{t} = f_{1\times1}(F_{SAAB}^{t}) \cdot \sigma(\alpha_1^t) + \beta_1^t$$

其中，$\sigma(\cdot)$表示 Sigmoid 运算；

S3，$\widehat{F}_{SAAB}^{t}$依次经 3×3 卷积和 ReLU 后，再由两路并行的 3×3 卷积分别得到另一组调制参数 α_2^t和 β_2^t：

$$\alpha_2^t = f_{3\times3}\left(f_{3\times3}\left(\widehat{F}_{SAAB}^{t}\right)\right) + \widehat{F}_{SAAB}^{t}$$

$$\beta_2^t = f_{3\times3}\left(f_{3\times3}\left(\widehat{F}_{SAAB}^{t}\right)\right) + \widehat{F}_{SAAB}^{t}$$

S4，全局特征 F_{SWTB}^{t}经 1×1 卷积调整后，利用所得到的 α_2^t和 β_2^t进行更新，得到全局深层次语义特征 F_{ESAB}^{t}：

$$F_{IFAM}^{t} = F_{ESAB}^{t} = f_{1\times1}(F_{SWTB}^{t}) \cdot \sigma(\alpha_2^t) + \beta_2^t$$

F_{ESAB}^{t}也即第 t个交互式聚合模块的输出 F_{IFAM}^{t}。

9.根据权利要求 2 所述的交互式推理网络，其特征在于：采用 L1 损失函数，训练时通过最小化损失函数来获得网络中的最佳权值和偏置：

$$L_1(\Theta) = \frac{1}{N}\sum_{i=1}^{N}\left\|I_i^{SR} - F\left(I_i^{LR}\right)\right\|_1$$

其中 $L_1(\cdot)$表示 L1 损失函数，Θ表示网络中需要训练优化的权值和偏置，N为训练集中的样本数，I_i^{LR}为训练集中第 i个输入的低分辨率图像，I_i^{SR}为对应的高分辨率图像，$F\left(I_i^{LR}\right)$表示网络重建出的高分辨率图像；

在网络训练前，使用 Kaiming 初始化来初始化所述网络，其中参数初始化值服从均值为 0、方差为 2/n 的高斯分布。

10.一种单幅图像超分辨率重建方法，其特征在于：采用如权利要求 1~9 任一项所述的交互式推理网络进行图像超分辨率重建。

说明书

技术领域

本发明属于数字图像技术领域，具体涉及一种单幅图像超分辨率重建方法及其交互式推理网络。

背景技术

图像超分辨率（Super-resolurion，SR）重建技术旨在从信息缺失严重的单张或多张低分辨率图像中重建出信息丰富的高分辨率图像。由于图像超分辨率重建过程中存在着诸多不确定的因素，因而是一个病态欠定问题（Ill-posed Problem），即一张低分辨率图像能够恢复出多个对应的高分辨率图像。深度学习的出现对 SR 任务产生了革命性的影响，从卷积神经网络的提出到 Transformer 的出现，网络深度、宽度和复杂度地不断增加，进一步提高网络的表征能力和重建性能。图像超分辨率重构是使用低分辨的单帧或多帧序列图像来重建一张高分辨率图像，高分辨率指图像的像素密度尽可能的高，并且尽可能多的包含图像高频信息。这样的图像可以更好的描述真实目标场景的细节信息，并给予人眼更良好的直观体验。由于计算机视觉发展也极大依赖于图像的采集和分析，因此对低分辨率图像进行超分辨率重构具有十分重要的理论意义和应用价值。

目前，绝大多数超分辨率图像重构方法具有较大的模型参数量和较高的计算成本，尽管研究者们已经做出了许多努力来减少参数和操作的数量，但大多数方法难以在模型规模和重建性能之间取得良好平衡。此外，一些方法没有关注到图像超分辨率重构的特殊性，即忽略图像固有结构信息如物体的外轮廓、线条和曲线等的探究，难以恢复出真实的高分辨率图像。

发明内容

针对现有技术中存在的不足，本发明提供了一种轻量级交互式推理网络以及基于该网络实现单幅图像超分辨率重建的方法，通过嵌入结构先验，提升细节信息重建的鲁棒性，同时在保持较低的计算需求基础上获得优异的图像超分辨率重构效果。

本发明通过以下技术手段实现上述技术目的。

一种交互式推理网络，设有深层提取模块，根据输入的浅层特征 F_{IFAM}^{0} 提取图像的深层特征；所述深层提取模块中包括 T 个交互式聚合模块，T 个交互式聚合模块之间链式堆叠，其中前一个交互式聚合模块输出的特征作为后一个交互式聚合模块的输入，最后第 T 个交互式聚合模块的输出特征 F_{IFAM}^{T} 与浅层特征 F_{IFAM}^{0} 做元素相加，得到所述深

层特征。

进一步地，所述网络用于图像超分辨率重建，包括：

浅层提取模块：用于提取初始图像的浅层特征 F_{IFAM}^{0}；

上采样重建模块：分别对初始图像和所述深层特征做上采样，之后再对两个上采样后的图像进行元素相加得到重建后的图像。

进一步地，所述浅层提取模块中，对初始图像做 3×3 卷积得到浅层特征 F_{IFAM}^{0}。

进一步地，所述交互式聚合模块包括：结构感知注意力块、Swin Transform 块、增强型空间自适应块；其中第 t个交互式聚合模块中：

结构感知注意力块：根据输入的特征 F_{IFAM}^{t-1}，提取图像的局部特征 F_{SAAB}^{t}；

Swin Transform 块：根据输入的特征 F_{IFAM}^{t-1}，提取图像的全局特征 F_{SWTB}^{t}；

增强型空间自适应块：根据所述局部特征和所述全局特征，输出全局深层特征 F_{IFAM}^{t}。

进一步地，所述结构感知注意力块中，首先通过两个非对称卷积分别提取图像特征中的水平和垂直方向上的信息，之后再叠加多个卷积层对结构信息进行融合，并利用 Sigmoid 激活函数做归一化：

$$\alpha^{t}=\sigma\left(H_{3\times3}\left(f_{1\times3}\left(F_{IFAM}^{t-1}\right)+f_{3\times1}\left(F_{IFAM}^{t-1}\right)\right)\right)$$

其中，α^{t}为由 Sigmoid 函数生成的 3D 调制系数，$\sigma(\cdot)$表示 Sigmoid 运算，$H_{3\times3}(\cdot)$表示多个叠加的 3×3 卷积运算，$f(\cdot)$表示卷积运算，下标表示相应卷积核大小；

而后通过空间级别方式自适应地校准输入特征，得到局部特征 F_{SAAB}^{t}：

$$F_{SAAB}^{t}=\alpha^{t}\cdot F_{gen}^{t}+F_{gen}^{t}$$

$$F_{gen}^{t}=f_{3\times3}\left(f_{3\times3}\left(F_{IFAM}^{t-1}\right)\right)$$

其中，F_{gen}^{t}为第 t个块中利用两个连续的 3×3 卷积提取广义特征，在上述两个 3×3 卷积之间设有一个 L-ReLU 层。

进一步地，所述多个叠加的 3×3 卷积运算中，依次包括一个 ReLU、两个连续的 3×3 卷积、一个 L-ReLU、一个 3×3 卷积。

进一步地，所述 Swin Transform 块中，全局特征 F_{SWTB}^{t}的获取过程为：

$$\widehat{F}_{SWTB}^{t} = W\text{-}MSA\left(LN\left(F_{IFAM}^{t-1}\right)\right) + F_{IFAM}^{t-1}$$

$$\widetilde{F}_{SWTB}^{t} = MLP\left(LN\left(\widehat{F}_{SWTB}^{t}\right)\right) + \widehat{F}_{SWTB}^{t}$$

$$\overline{F}_{SWTB}^{t} = SW\text{-}MSA\left(LN\left(\widetilde{F}_{SWTB}^{t}\right)\right) + \widetilde{F}_{SWTB}^{t}$$

$$F_{SWTB}^{t} = MLP\left(LN\left(\overline{F}_{SWTB}^{t}\right)\right) + \overline{F}_{SWTB}^{t}$$

其中，$W\text{-}MSA(\cdot)$表示 W-MSA 单元的输出，$SW\text{-}MSA(\cdot)$表示 SW-MSA 单元的输出，$MLP(\cdot)$表示 MLP 的输出，$LN(\cdot)$表示归一化操作。

进一步地，所述增强型空间自适应块中：

S1，对 F_{SAAB}^{t}和 F_{SWTB}^{t}做 contact 特征融合并由 1×1 卷积调整通道数得到融合特征，融合特征依次经 3×3 卷积和 ReLU 后，再由两路并行的 3×3 卷积分别得到调制参数 α_1^t和 β_1^t：

$$\alpha_1^t = f_{3\times3}\left(f_{3\times3}\left(f_{1\times1}([F_{SAAB}^{t}, F_{SWTB}^{t}])\right)\right) + f_{1\times1}([F_{SAAB}^{t}, F_{SWTB}^{t}])$$

$$\beta_1^t = f_{3\times3}\left(f_{3\times3}\left(f_{1\times1}([F_{SAAB}^{t}, F_{SWTB}^{t}])\right)\right) + f_{1\times1}([F_{SAAB}^{t}, F_{SWTB}^{t}])$$

其中，$[\cdot,\cdot]$表示级联操作，$f(\cdot)$表示卷积运算，下标表示相应卷积核大小；

S2，F_{SAAB}^{t}经 1×1 卷积调整后，利用所得到的 α_1^t和 β_1^t进行更新，得到空间调制特征 $\widehat{F}_{SAAB}^{t}$：

$$\widehat{F}_{SAAB}^{t} = f_{1\times1}(F_{SAAB}^{t}) \cdot \sigma(\alpha_1^t) + \beta_1^t$$

其中，$\sigma(\cdot)$表示 Sigmoid 运算；

S3，$\widehat{F}_{SAAB}^{t}$依次经 3×3 卷积和 ReLU 后，再由两路并行的 3×3 卷积分别得到另一组调制参数 α_2^t和 β_2^t：

$$\alpha_2^t = f_{3\times3}\left(f_{3\times3}\left(\widehat{F}_{SAAB}^{t}\right)\right) + \widehat{F}_{SAAB}^{t}$$

$$\beta_2^t = f_{3\times3}\left(f_{3\times3}\left(\widehat{F}_{SAAB}^{t}\right)\right) + \widehat{F}_{SAAB}^{t}$$

S4，全局特征 F_{SWTB}^{t}经 1×1 卷积调整后，利用所得到的 α_2^t和 β_2^t进行更新，得到全局深层次语义特征 F_{ESAB}^{t}：

$$F_{IFAM}^{t} = F_{ESAB}^{t} = f_{1\times1}(F_{SWTB}^{t}) \cdot \sigma(\alpha_2^t) + \beta_2^t$$

F_{ESAB}^{t}也即第 t个交互式聚合模块的输出 F_{IFAM}^{t}。

进一步地，采用 L1 损失函数，训练时通过最小化损失函数来获得网络中的最佳权值和偏置：

$$L_1(\Theta) = \frac{1}{N}\sum_{i=1}^{N} \left\| I_i^{SR} - F(I_i^{LR}) \right\|_1$$

其中 $L_1(\cdot)$表示 L1 损失函数，Θ表示网络中需要训练优化的权值和偏置，N为训练集中的样本数，I_i^{LR}为训练集中第 i个输入的低分辨率图像，I_i^{SR}为对应的高分辨率图像，$F(I_i^{LR})$表示网络重建出的高分辨率图像；

在网络训练前，使用 Kaiming 初始化来初始化所述网络，其中参数初始化值服从均值为 0、方差为 2/n 的高斯分布。

一种单幅图像超分辨率重建方法：采用上述交互式推理网络进行图像超分辨率重建。

本发明的有益效果为：

（1）本发明提供了一种单幅图像超分辨率重建方法及其交互式推理网络，通过嵌入结构先验，提升细节信息重建的鲁棒性，同时在保持较低的计算需求基础上获得优异的图像超分辨率重构效果。

（2）本发明网络表现出较好的 PSNR 和 SSIM 性能，特别是在较大比例因子方面的重建精度更加优越。

（3）本发明网络在模型容量和重建性能方面具有显著的优越性，超过了主流的轻量级图像超分辨率重构方法，实现了高性能和网络容量之间的良好平衡。

附图说明

图 1 为本发明轻量级交互式神经网络的总架构图；

图 2 为本发明中结构感知注意力块的网络架构图；

图 3 为本发明中 Swin Transformer 块的网络架构图；

图 4 为本发明中深层提取模块及其增强型空间自适应块部分的网络架构图；

图 5 为在基准数据集上本发明与其他各主流 SR 网络之间的性能差异分布图；

图 6 为在基准数据集 Set5 上比例因子×2 选取的图像超分辨率重建对比示例；

图 7 为在基准数据集 B100 上比例因子×3 选取的图像超分辨率重建对比示例；

图 8 为在基准数据集 Urban 上比例因子×4 选取的图像超分辨率重建对比示例；

图 9 为选取的卫星遥感图像超分辨率重建对比示例。

具体实施方式

下面详细描述本发明的实施例，所示实施例的示例在附图中示出，其中自始至终相通或类似的标号表示相同或类似的元件或具有相同或类似功能的元件。下面通过参考附图描述的实施例是示例性的，旨在用于解释本发明，而不能理解为对本发明的限制。

一、网络结构

如图 1 所示，本发明提出的轻量级交互式神经网络包括：①浅层提取模块、②深层提取模块、③上采样重建模块。对于输入的低分辨率图像，首先在浅层提取模块中利用 3×3 卷积层提取初始低分辨率图像中的浅层特征，如边缘、纹理等。深层提取模块则作为本发明轻量级交互式神经网络的主干，负责在浅层提取模块提取到的浅层特征基础上，提取出图像的深层特征。而上采样重建模块中，设有两个卷积大小不同的卷积层和亚像素卷积层；其中由所述卷积层上采样图像的初始信息（最初输入的低分辨率图像），由亚像素卷积层上采样图像的深层语义信息（深层提取模块提取到的深层特征），最后利用元素相加操作对上采样后的图像进行融合和集成，以此重建出细节丰富的高分辨率图像。

深层提取模块中包括具体由 T 个交互式聚合模块链式堆叠而成，其中前一个（第 $t-1$ 个）交互式聚合模块输出的特征 F_{IFAM}^{t-1} 作为后一个（第 t 个）交互式聚合模块的输入，而第 1 个交互式聚合模块的输入为浅层提取模块提取的浅层特征 F_{IFAM}^{0}。如图 4 所示，每个交互式聚合模块中包括①结构感知注意力块（图中标号“SAAB”）、②Swin Transformer 块（图中标号“SWTB”）、③增强型空间自适应块（图中标号“ESAB”）三部分。以下以第 t 个交互式聚合模块为例进行具体说明。

如图 2 所示为结构感知注意力块的网络架构图，其中首先通过两个非对称卷积分别提取图像特征中的水平和垂直两个方向上的信息；之后再叠加多个卷积层对结构信息进行融合，并利用 Sigmoid 激活函数归一化到 0 至 1 之间；最后通过空间级别方式自适应地校准输入特征，从而突出图像局部结构信息。

具体而言，对于输入的特征 F_{IFAM}^{t-1}：

1）一方面，首先利用 1×3 卷积和 3×1 卷积分别提取水平和垂直方向上的信息，再将两个方向上的特征信息进行元素相加：

$$f_{1\times3}\left(F_{IFAM}^{t-1}\right)+f_{3\times1}\left(F_{IFAM}^{t-1}\right)$$

其中，$f(\cdot)$表示卷积运算，下标表示相应卷积核大小；

上述元素相加后的特征再依次经过一个 ReLU（线性整流函数，一种常用的激活函数）、两个连续的 3×3 卷积、一个 L-ReLU（Leaky ReLU，带泄露线性整流函数）和一个 3×3 卷积对结构信息进行融合：

$$H_{3\times3}\left(f_{1\times3}\left(F_{IFAM}^{t-1}\right)+f_{3\times1}\left(F_{IFAM}^{t-1}\right)\right)$$

其中，$H_{3\times3}(\cdot)$表示上述连续三个 3×3 卷积运算；

上述经结构信息融合后的特征再经 Sigmoid 函数生成 3D 调制系数 α^t：

$$\alpha^t=\sigma\left(H_{3\times3}\left(f_{1\times3}\left(F_{IFAM}^{t-1}\right)+f_{3\times1}\left(F_{IFAM}^{t-1}\right)\right)\right)$$

其中 $\sigma(\cdot)$表示 Sigmoid 运算；

2）另一方面，利用两个连续的 3×3 卷积提取广义特征，其中在上述两个 3×3 卷积之间设有一个 L-ReLU 层：

$$F_{gen}^t=f_{3\times3}\left(f_{3\times3}\left(F_{IFAM}^{t-1}\right)\right)$$

3）最后，利用 3D 调制系数 α^t重新校准广义特征，从而输出丰富的局部特征 F_{SAAB}^t：

$$F_{SAAB}^t=\alpha^t\cdot F_{gen}^t+F_{gen}^t$$

如图 3 所示为 Swin Transformer 块的网络架构图，对输入特征张量，本发明采用两个连续的 Swin Transformer 块增强网络复原性能。其中第一个块提取图像的局部特征，并通过局部自注意力机制增强这些特征。第二个块则利用移位窗口机制，将第一个块输出的特征进行跨窗口的信息交互，从而捕获更丰富的全局上下文信息。

对于输入的特征 F_{IFAM}^{t-1}，首先在前一个块中由基于窗口的多头自注意（W-MSA）单元线性投影并重塑为 $\widehat{F}_{SWTB}^t$，而后由多层感知器（MLP）获得 $\widetilde{F}_{SWTB}^t$；之后传递进后

一个块中并由基于移位窗口的多头自注意（SW-MSA）单元得到 $\overline{F}^t_{SWTB}$，最后再由多层感知器（MLP）获得全局特征信息 F^t_{SWTB}：

$$\widehat{F}^t_{SWTB} = W\text{-}MSA\left(LN\left(F^{t-1}_{IFAM}\right)\right) + F^{t-1}_{IFAM}$$

$$\widetilde{F}^t_{SWTB} = MLP\left(LN\left(\widehat{F}^t_{SWTB}\right)\right) + \widehat{F}^t_{SWTB}$$

$$\overline{F}^t_{SWTB} = SW\text{-}MSA\left(LN\left(\widetilde{F}^t_{SWTB}\right)\right) + \widetilde{F}^t_{SWTB}$$

$$F^t_{SWTB} = MLP\left(LN\left(\overline{F}^t_{SWTB}\right)\right) + \overline{F}^t_{SWTB}$$

其中，$W\text{-}MSA(\cdot)$表示 W-MSA 单元的输出，$SW\text{-}MSA(\cdot)$表示 SW-MSA 单元的输出，$MLP(\cdot)$表示 MLP 的输出，$LN(\cdot)$表示归一化（Layer Normalization）操作。

如图 4 所示为增强型空间自适应块的网络架构图，其输入为结构感知注意力块输出的局部特征 F^t_{SAAB}和 Swin Transformer 块输出的全局特征 F^t_{SWTB}。

1）对 F^t_{SAAB}和 F^t_{SWTB}做特征融合并由 1×1 卷积调整通道数得到融合特征，融合特征依次经 3×3 卷积和 ReLU 后，再由两路并行的 3×3 卷积分别得到融合特征的标准差调制参数 α^t_1和均值调制参数 β^t_1：

$$\alpha^t_1 = f_{3\times3}\left(f_{3\times3}\left(f_{1\times1}([F^t_{SAAB}, F^t_{SWTB}])\right)\right) + f_{1\times1}([F^t_{SAAB}, F^t_{SWTB}])$$

$$\beta^t_1 = f_{3\times3}\left(f_{3\times3}\left(f_{1\times1}([F^t_{SAAB}, F^t_{SWTB}])\right)\right) + f_{1\times1}([F^t_{SAAB}, F^t_{SWTB}])$$

其中，$[\cdot,\cdot]$表示级联操作；

2） F^t_{SAAB}经 1×1 卷积调整后，利用所得到的 α^t_1和 β^t_1进行更新，得到空间调制特征 $\widehat{F}^t_{SAAB}$：

$$\widehat{F}^t_{SAAB} = f_{1\times1}(F^t_{SAAB}) \cdot \sigma(\alpha^t_1) + \beta^t_1$$

其中，$\sigma(\cdot)$表示 Sigmoid 运算；

3） $\widehat{F}^t_{SAAB}$依次经 3×3 卷积和 ReLU 后，再由两路并行的 3×3 卷积分别得到另一组调制参数 α^t_2和 β^t_2：

$$\alpha_2^t = f_{3\times3}\left(f_{3\times3}\left(\widehat{F}_{SAAB}^t\right)\right) + \widehat{F}_{SAAB}^t$$

$$\beta_2^t = f_{3\times3}\left(f_{3\times3}\left(\widehat{F}_{SAAB}^t\right)\right) + \widehat{F}_{SAAB}^t$$

4）全局特征 F_{SWTB}^t经 1×1 卷积调整后，利用所得到的 α_2^t和 β_2^t进行更新，得到全局深层次语义特征 F_{ESAB}^t：

$$F_{IFAM}^t = F_{ESAB}^t = f_{1\times1}(F_{SWTB}^t)\cdot\sigma(\alpha_2^t) + \beta_2^t$$

F_{ESAB}^t也即第 t个交互式聚合模块的输出 F_{IFAM}^t。

最终，如图 1 所示，最后一个（第 T个）交互式聚合模块的输出 F_{IFAM}^T，再与浅层特征 F_{IFAM}^0做元素相加（ $F_{IFAM}^0 + F_{IFAM}^T$），所得结果即为深层提取模块提取到的深层特征。所述深层特征输入进上采样重建模块中进行上采样，并与同样做上采样后的初始图像进行元素相加，得到高分辨率图像。

上述轻量级交互式神经网络，采用 L1 损失函数：

$$L_1(\Theta) = \frac{1}{N}\sum_{i=1}^{N}\left\|I_i^{SR} - F\left(I_i^{LR}\right)\right\|_1$$

其中 $L_1(\cdot)$表示 L1 损失函数，Θ表示网络中需要训练优化的权值和偏置，N为训练集中的样本数，I_i^{LR}为训练集中第 i个输入的低分辨率图像，I_i^{SR}为其对应的高分辨率图像，$F\left(I_i^{LR}\right)$表示网络重建出的高分辨率图像。

训练时通过最小化损失函数来获得网络中的最佳权值和偏置。

二、应用测试

1.网络训练

本实施例具体使用 Kaiming 初始化来初始化本发明提出的轻量级交互式神经网络，其中参数初始化值服从均值为 0、方差为 2/n 的高斯分布，n 为输入神经元的数量。

准备多张高分辨率图像并进行数据增强。之后使用 MATLAB 在缩放因子分别为×2、×3、×4 情况下，利用双三次插值下采样来获得各个对应的低分辨率图像。最后存储各高分辨率图像与各自对应的低分率图像作为训练集。最后基于训练集训练上述神经网络。

2.直观对比

对现有的多个主流 SR 网络模型与本发明做横向对比测试，包括 SRCNN、CARN、AWSRN、ACNet、DRSAN、ESRT、LBNet、CFGN。相应直观视觉对比如图 6 至图 9 所示，其中图 6 至图 8 为基准数据集中选取的样张图片，图 9 为遥感图像。相比于其他现有网络模型，本发明对图像中的条纹和线条都表现出更为出色的还原能力，能够重建出更加精细、准确的超分辨率图像。例如图 6 中，本发明能够还原出更清晰的纹理细节，更为接近原始稿分辨率图像。图 7 中，ESRT、LBNet 和 CFGN 虽然也都可以重建出条纹特性，但是图像中仍然具有肉眼可见的模糊；而本发明则能够专注于微小纹理并收集丰富的高频信息，从而获得更清晰、更准确的重建图像。图 8 中，SRCNN、CARN 和 ACNet 都难以获取纹理信息且出现模糊伪影；而本发明则有效缓解模糊问题。图 9 所示，对质量和空间分辨率都相对较低的遥感图像，本发明在对象轮廓和纹理细节方面也都表现出更加出色的重建能力；相比之下，图 9（b）、（c）、（d）中显示 LGCNET、LESRCNN 和 FENe 无法恢复条纹信息，分别产生了严重的模糊、失真和伪影。

3.性能对比

为了更适合实际应用的轻量级比较，本次测试选择网络参数量小于 2000K 的模型作为比较对象。为了增强比较的可理解性，采用乘加运算量（Multi-Adds）来衡量深度神经网络的计算量，它是一种通过恢复 1280×720(720P)高分辨率图像进行计算。相应对比结果如表 1 至表 3 所示。

综合表 1 至表 3 中的定量对比结果所示，与主流的 SR 网络相比，本发明方法在不同规模上表现出较好的 PSNR（峰值信噪比）和 SSIM（结构相似性）性能。其中与基于卷积神经网络方法（CNN-based）相比，本发明在相似的计算复杂度下表现出更好的单图像超分辨率重建性能；与 CFGN、Cross-SRN 和 FMFN 相比，在参数和计算量较小的情况下，本发明则拥有相当的性能与结果。例如，在表 3 中，与 Ngswin 相比，本发明在 Urban100 上的 PSNR 高出 0.19dB，SSIM 高出 0.0016。与基于 Transformer 的方法相比，本发明方法通过较低的网络参数量和 Multi-Adds 取得更好的重建结果。

此外，由于低分辨率图像在大尺度下像素值较少，因此更为需要提取出丰富的特征来恢复高分辨率图像，因而本发明方法在更大比例因子方面的重建精度更加优越。

如图 5 所示为在 Set14 数据上×2 比例尺度的相关性能数据所绘制的各网络性能分布图，图中横坐标为平均 Multi-Adds，纵坐标为平均 PSNR。相比而言，本发明方法在模型容量和重建性能方面具有显著的优越性，超过了主流的轻量级图像超分辨率重构方法，实现了高性能和网络容量之间的良好平衡。

表 1：×2 比例尺度的各网络性能对比

模型	参数量	Multi-Adds	Set5	Set14	B100	Urban100	Manga109
			PSNR(dB)/SSIM	PSNR(dB)/SSIM	PSNR(dB)/SSIM	PSNR(dB)/SSIM	PSNR(dB)/SSIM
FSRCNN	12K	6G	37.00/0.9558	32.63/0.9088	31.53/0.8920	29.88/0.9020	36.67/0.9694
SRCNN	57K	52.7G	36.66/0.9542	32.42/0.9063	31.36/0.8879	29.50/0.8946	35.74/0.9661
VDSR	665K	612.6G	37.53/0.9587	33.03/0.9124	31.90/0.8960	30.76/0.9140	37.22/0.9729
DRCN	1774K	17974G	37.63/0.9588	33.04/0.9118	31.85/0.8942	30.75/0.9133	37.63/0.9723
LapSRN	813K	29.9G	37.52/0.9590	33.08/0.9130	31.80/0.8950	30.41/0.9100	37.27/0.9740
DRRN	297K	6797G	37.74/0.9591	33.23/0.9136	32.05/0.8973	31.23/0.9188	37.92/0.9760
CARN	1592K	222.8G	37.76/0.9590	33.52/0.9166	32.09/0.8978	31.92/0.9256	-
CBPN	1036K	240.7G	37.90/0.9590	33.60/0.9171	32.17/0.8989	32.14/0.9279	-
AWSRN-M	1063K	244.1G	38.04/0.9605	33.66/0.9181	32.21/0.9000	32.23/0.9294	38.66/0.9772
OISR-RK2-s	1372K	316.2G	37.98/0.9604	33.58/0.9172	32.18/0.8996	32.09/0.9281	-
A2F-S	320K	71.7G	37.79/0.9597	33.32/0.9152	31.99/0.8972	31.44/0.9211	38.11/0.9757
LESRCNN	516K	110.6G	37.65/0.9586	33.32/0.9148	31.95/0.8964	31.45/0.9206	-
FALSR-	1021	234.7G	37.82/0.959	33.55/0.916	32.12/0.898	31.93/0.925	-

A	K		5	8	7	6	
LMAN-s	525 K	121.2G	37.94/0.9603	33.49/0.9167	32.08/0.8984	31.85/0.9251	38.43/0.9765
MSWSR	1228 K	192.5 G	37.49/0.9583	33.23/0.9123	31.88/0.8929	31.14/0.9169	37.32/0.9733
Cross-SRN	1276 K	292.1G	38.03/0.9606	33.62/0.9180	32.19/0.8997	32.28/0.9290	38.75/0.9773
FMEN	748 K	172.0G	38.10/0.9609	33.75/0.9192	32.26/0.9007	32.41/0.9311	38.95/0.9778
AFAN	1208 K	289.5G	38.06/0.9608	33.74/0.9198	32.20/0.9001	32.38/0.9305	38.79/0.9773
ACNet	1356 K	501.5G	37.72/0.9588	33.41/0.9160	32.06/0.8978	31.79/0.9245	-
CFGN	601 K	130.9G	38.03/0.9607	33.74/0.9197	32.23/0.9004	32.47/0.9316	38.96/0.9777
DRSAN-48m	1188 K	274.6G	38.14/0.9611	33.75/0.9188	32.25/0.9010	32.46/0.9317	-
ESRT	677 K	271G	38.03/0.9600	33.75/0.9184	32.25/0.9001	32.58/0.9318	39.12/0.9774
Ngswin	998 K	140.4G	38.05/0.9610	33.79/0.9199	32.27/0.9008	32.53/0.9324	38.97/0.9777
本发明	972 K	243.8G	38.10/0.9610	33.90/0.9206	32.26/0.9007	32.45/0.9314	38.95/0.9777

表 2：×3 比例尺度的各网络性能对比

模型	参数量	Multi-Adds	Set5	Set14	B100	Urban100	Manga109
			PSNR(dB)/SSIM	PSNR(dB)/SSIM	PSNR(dB)/SSIM	PSNR(dB)/SSIM	PSNR(dB)/SSIM
FSRCNN	12K	5G	33.16/0.9140	29.43/0.8242	28.53/0.7910	26.43/0.8080	30.98/0.9212

SRCNN	57K	52.7G	32.75/0.9090	29.28/0.8209	28.41/0.7863	26.24/0.7989	30.59/0.9107
VDSR	665K	612.6G	33.66/0.9213	29.77/0.8314	28.82/0.7976	27.14/0.8279	32.01/0.9310
DRCN	1774K	17974G	33.82/0.9226	29.76/0.8311	28.80/0.7963	27.15/0.8276	32.31/0.9328
DRRN	297K	6797G	34.03/0.9244	29.96/0.8349	28.95/0.8004	27.53/0.8378	32.74/0.9390
MemNet	677K	2662.4G	34.09/0.9248	30.00/0.8350	28.96/0.8001	27.56/0.8376	-
CARN	1592K	118.8G	34.29/0.9255	30.29/0.8407	29.06/0.8034	28.06/0.8493	-
AWSRN-S	477K	48.6G	34.02/0.9240	30.09/0.8376	28.92/0.8009	27.57/0.8391	32.82/0.9393
AWSRN-M	1143K	116.6G	34.42/0.9275	30.32/0.8419	29.13/0.8059	28.26/0.8545	33.64/0.9450
OISR-RK2-s	1557K	160.1 G	34.43/0.9273	30.33/0.8420	29.10/0.8053	28.20/0.8534	-
A2F-S	324k	32.3G	34.06/0.9241	30.08/0.8370	28.92/0.8006	27.57/0.8392	32.86/0.9394
LESRCNN	516K	49.1G	33.93/0.9231	30.12/0.8380	28.91/0.8005	27.70/0.84152	-
WMRN	556K	57G	34.11/0.9251	30.17/0.8390	28.98/0.8021	27.80/0.8448	33.07/0.9413
LMAN-s	709K	73.5G	34.31/0.9265	30.24/0.8397	29.02/0.8030	28.02/0.8487	33.42/0.9433
Cross-SRN	1285K	130.5G	34.43/0.9275	30.33/0.8417	29.09/0.8050	28.23/0.8535	33.65/0.9448
ACNet	1541	369G	34.14/0.924	30.19/0.839	28.98/0.802	27.97/0.848	-

	K		7	8	3	2	
FMEN	757 K	77.2G	34.45/0.927 5	30.40/0.843 5	29.17/0.806 3	28.33/0.856 2	33.86/0.946 2
AFAN	1208 K	143.1G	34.46/0.927 1	30.38/0.843 6	29.11/0.806 4	28.31/0.855 6	33.61/0.945 1
CFGN	609 K	59.0G	34.41/0.927 4	30.44/0.844 3	29.16/0.806 6	28.37/0.857 5	33.81/0.945 9
DRSAN-48m	1292 K	133.4G	34.59/0.928 6	30.42/0.844 3	29.18/0.807 9	28.52/0.859 3	-
ESRT	770 K	135G	34.42/0.926 8	30.43/0.843 3	29.15/0.806 3	28.46/0.857 4	33.95/0.945 5
LBNet	736 K	68.4G	34.47/0.927 7	30.38/0.841 7	29.13/0.806 1	28.42/0.855 9	33.82/0.946 0
Ngswin	1007 K	66.6G	34.52/0.928 2	30.53/ 0.8456	29.19/0.807 8	28.52/0.860 3	33.89/0.947 0
本发明	980 K	107.0G	34.58/0.928 7	30.55/0.846 3	29.21/0.808 2	28.57/0.860 8	34.14/0.947 9

表 3：×4 比例尺度的各网络性能对比

模型	参数量	Multi-Adds	Set5	Set14	B100	Urban100	Manga109
			PSNR(dB)/ SSIM	PSNR(dB)/ SSIM	PSNR(dB)/ SSIM	PSNR(dB)/ SSIM	PSNR(dB)/ SSIM
FSRCNN	12K	4.6G	30.71/0.865 7	27.59/0.753 5	26.98/0.715 0	24.62/0.728 0	27.90/0.851 7
SRCNN	57K	52.7G	30.48/0.862 8	27.49/0.750 3	26.90/0.710 1	24.52/0.722 1	27.66/0.850 5
VDSR	665 K	612.6G	31.35/0.883 8	28.01/0.767 4	27.29/0.725 1	25.18/0.752 4	28.83/0.880 9
DRCN	1774 K	17974G	31.53/0.885 4	28.02/0.767 0	27.23/0.723 3	25.14/0.751 0	28.98/0.881 6

LapSRN	813 K	149.4G	31.54/0.8850	28.19/0.7720	27.32/0.7280	25.21/0.7560	29.09/0.8845
DRRN	297 K	6797G	31.68/0.8888	28.21/0.7720	27.38/0.7284	25.44/0.7638	29.46/0.8960
MemNet	677 K	2662.4 G	31.74/0.8893	28.26/0.7723	27.40/0.7281	25.50/0.7630	-
CARN	1592 K	90.9G	32.13/0.8937	28.60/0.7806	27.58/0.7349	26.07/0.7837	-
CBPN	1197 K	97.9G	32.21/0.8944	28.63/0.7813	27.58/0.7356	26.14/0.7869	-
AWSRN-M	1254 K	72.0G	32.21/0.8954	28.65/0.7832	27.60/0.7368	26.15/0.7884	30.56/0.9093
OISR-RK2-s	1520 K	114.2 G	32.21/0.8950	28.63/0.7822	27.58/0.7364	26.14/0.7874	-
A2F-S	331k	18.6G	31.87/0.8900	28.36/0.7760	27.41/0.7305	25.58/0.7685	29.77/0.8987
LESRCNN	516 K	28.6G	31.88/0.8903	28.44/0.7772	27.45/0.7313	25.77/0.7732	-
WMRN	536 K	45.7G	32.00/0.8925	28.47/0.7786	27.49/0.7328	25.89/0.7789	30.11/0.9040
LMAN-s	672 K	65.5G	32.12/0.8939	28.53/0.7798	27.51/0.7340	25.96/0.7813	30.30/0.9062
MSWSR	1228 K	101.7G	32.01/0.8914	28.47/0.7776	27.48/0.7311	25.78/0.7744	30.01/0.8999
Cross-SRN	1296 K	74.2G	32.24/0.8954	28.59/0.7817	27.58/0.7364	26.16/0.7881	30.53/0.9081
ACNet	1784 K	347.9G	31.83/0.8903	28.46/0.7788	27.48/0.7326	25.93/0.7798	-
CRMBN	495	-	32.07/0.892	28.50/0.778	27.50/0.732	25.83/0.777	-

	K		3	3	7	1	
FMEN	769 K	44.2G	32.24/0.8955	28.70/0.7839	27.63/0.7379	26.28/0.7908	30.70/0.9107
AFAN	1226 K	90.1G	32.30/0.8951	28.66/0.7838	27.61/0.7383	26.27/0.7913	30.63/0.9109
CFGN	621 K	33.9G	32.32/0.8957	28.67/0.7832	27.60/0.7377	26.22/0.7916	30.63/0.9101
DRSAN-48m	1271 K	88.7G	32.34/0.8960	28.65/0.7841	27.63/0.7390	26.33/0.7936	-
ESRT	751 K	67.7G	32.19/0.8947	28.69/0.7833	27.69/0.7379	26.39/0.7962	30.75/0.9100
LBNet	742 K	38.9G	32.29/0.8960	28.68/0.7832	27.62/0.7382	26.27/0.7906	30.76/0.9111
Ngswin	1019 K	36.4G	32.33/0.8963	28.78/0.7859	27.66/0.7396	26.45/0.7963	30.80/0.9128
本发明	991 K	64.6G	32.47/0.8988	28.80/0.7871	27.70/7414	26.64/0.7979	31.06/0.9156

为了进一步证明本发明的有效性和优越性，在质量和空间分辨率相对较低的遥感图像上也进行了相关测试。本次测试使用两个来自加州大学默塞德分校的名为 RS-T1 和 RS-T2 的数据集，其中 RS-1 和 RS-2 均包含 120 张图像并覆盖具有复杂图像图案的各种场景。相应结果如表 4 所示。

如表 4 所示，本发明具有最高的 PSNR 和 SSIM，超越了 LGCNet、FeNet、DRAN 和 FDENet 等先进的遥感 SR 方法。例如，与轻量级 DRAN 相比，本发明方法获得 0.04−0.16 dB 的 PSNR 和 0.0004-0.0051 的 SSIM 增益，表现出很强的灵活性和稳定性。

表 4：针对遥感图像的各网络性能对比

方法	尺度	参数量	RS-T1	RS-T2
			PSNR(dB)/SSIM	PSNR(dB)/SSIM
Bicubic	×2	-	33.25/0.8934	30.64/0.8837
SRCNN		57K	35.18/0.9243	32.87/0.9209

VDSR		666K	35.85/0.9312	33.86/0.9312
LGCNet		193K	35.65/0.9298	33.47/0.9281
LapSRN		251K	35.69/0.9304	33.57/0.9286
IDN		553K	36.13/0.9339	34.07/0.9329
LESRCNN		626K	36.04/0.9328	34.00/0.9320
CARN-M		412K	35.77/0.9314	33.84/0.9315
FeNet		351K	36.23/0.9341	34.22/0.9337
FDENet		480K	36.26/0.9346	34.28/0.9338
DRAN		589K	36.38 /0.9348	34.42/0.9357
本发明		972K	36.42/0.9359	34.49/0.9361
Bicubic	×3	-	29.73/0.7818	27.23/0.7697
SRCNN		57K	30.95/0.8228	28.59/0.8180
VDSR		666K	31.55/0.8352	29.40/0.8391
LGCNet		193K	31.30/0.8314	29.03/0.8312
LapSRN		29 万	31.47/0.8338	29.22/0.8352
IDN		553K	31.73/0.8430	29.59/0.8450
LESRCNN		810K	31.68/0.8398	29.65/0.8444
CARN-M		412K	31.72/0.8426	29.62/0.8452
FeNet		357K	31.89/0.8432	29.80/0.8481
FDENet		488K	31.98/ 0.8488	29.88/0.8489
DRAN		589K	32.08 /0.8470	30.05/0.8537
本发明		991K	32.18/0.8506	32.18/0.8560
Bicubic	×4	-	27.91/0.6968	25.40/0.6770
SRCNN		57K	28.87/0.7382	26.46/0.7296
VDSR		666K	29.33/0.7546	27.03/0.7525
LGCNet		193K	29.13/0.7481	26.76/0.7426
LapSRN		543K	29.51/0.7614	27.24/0.7600
IDN		553K	29.56/0.7623	27.31/0.7627
LESRCNN		774K	29.62/0.7625	27.41/0.7646

CARN-M		412K	29.57/0.7624	27.37/0.7647
FeNet		366K	29.70/0.7688	27.45/0.7672
FDENet		501K	29.72/0.7658	27.54/0.7697
DRAN		589K	29.85 /0.7710	27.67/0.7758
本发明		991K	29.92/0.7736	27.83/0.7809

为检验本发明的实用性，选取部分有代表性的 SR 方法与本发明进行计算机耗时对比测试；本次测试中所采用的独立显卡硬件型号为 NVIDIA GeForce RTX 3060 GPU。具体测试时，每个网络模型的时间消耗分别进行四次评估，然后取平其均成绩。相应结果如表 5 所示。

在表 5 中描述了 B100 数据集上的模型参、Multi-Adds、PSNR/SSIM 和时间消耗。与基于 CNN 的方法相比，本发明方法以更少的模型参数量和计算量获得了最高的 PSNR 和 SSIM。而与其他同样基于 Transformer 的方法相比，本发明网络模型有着较为高效的运算效率，仅次于 ESRT 排在第二位；而其余的，如 DRSAN-48m 和 Ngswin 的时间消耗分别是本发明的 8 倍和 2.5 倍。

因此证明，本发明在模型复杂性、重建性能和时间消耗之间实现良好平衡，拥有者较高的实用价值。

类型	模型	参数量	Multi-Adds	PSNR(dB)/SSIM	时间消耗(s)
基于 CNN 方法	CARN	1592K	118.8G	29.06/0.8034	0.4623
	AWSRN-S	477K	48.6G	28.92/0.8009	0.8807
	AWSRN-M	1143K	116.6G	29.13/0.8059	1.7432
	OISR-RK2-s	1557K	160.1G	29.10/0.8053	0.5304
	A2F-S	324k	32.3G	28.92/0.8006	0.6651
	LESRCNN	516K	49.1G	28.91/0.8005	0.2911
	LMAN-s	709K	73.5G	29.02/0.8030	1.6537
	Cross-SRN	1285K	130.5G	29.09/0.8050	2.2345
	ACNet	1541K	369G	28.98/0.8023	0.6436
	FMEN	757K	77.2G	29.17/0.8063	0.4598
	AFAN	1208K	143.1G	29.11/0.8064	2.9098
	CFGN	609K	59.0G	29.16/0.8066	2.1632
基于 Transformer 方法	DRSAN-48m	1292K	133.4G	29.18/ 0.8079	25.9941

	ESRT	770K	135G	29.15/0.8063	2.4120
	LBNet	736K	68.4G	29.13/0.8061	3.2489
	Ngswin	1007K	66.6G	29.19 /0.8078	8.0806
	本发明	980K	107.0G	29.21/0.8082	3.1728

在本发明的描述中，需要理解的是，术语“上”、“下”、“前”、“后”、“左”、“右”、“竖直”、“水平”、“顶”、“底”、“内”、“外”等指示的方位或位置关系为基于附图所示的方位或位置关系，仅是为了便于描述本发明和简化描述，而不是指示或暗示所指的装置或元件必须具有特定的方位、以特定的方位构造和操作，因此不能理解为对本发明的限制。

本发明并不限于上述实施方式，在不背离本发明的实质内容的情况下，本领域技术人员能够做出的任何显而易见的改进、替换或变形均属于本发明的保护范围。

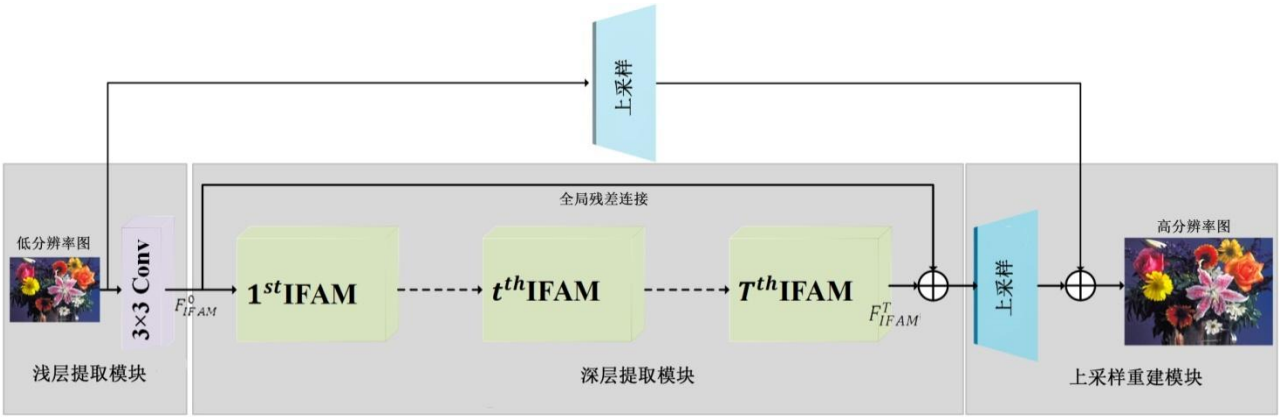

上采样
全局残差连接
低分辨率图
3×3 Conv
F_{IFAM}^{0}
1^{st}IFAM
t^{th}IFAM
T^{th}IFAM
F_{IFAM}^{T}
上采样
高分辨率图
浅层提取模块
深层提取模块
上采样重建模块

图 1

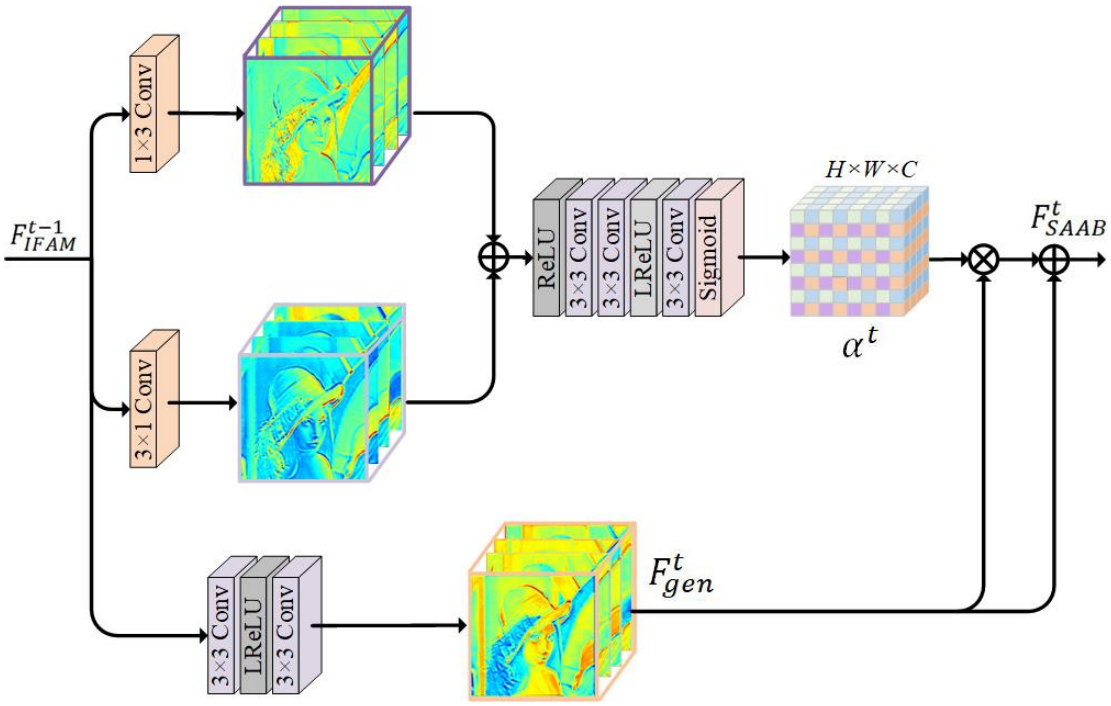

F_{IFAM}^{t-1}
1×3 Conv
3×1 Conv
3×3 Conv
LReLU
3×3 Conv
ReLU
3×3 Conv
LReLU
3×3 Conv
Sigmoid
$H\times W\times C$
α^t
F_{gen}^{t}
F_{SAAB}^{t}

图 2

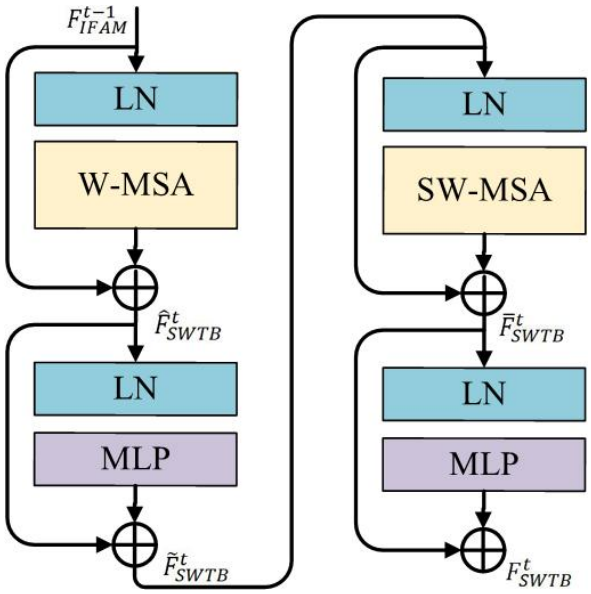

F_{IFAM}^{t-1}
LN
W-MSA
$\hat{F}_{SWTB}^{t}$
LN
MLP
$\tilde{F}_{SWTB}^{t}$
LN
SW-MSA
$\bar{F}_{SWTB}^{t}$
LN
MLP
F_{SWTB}^{t}

图 3

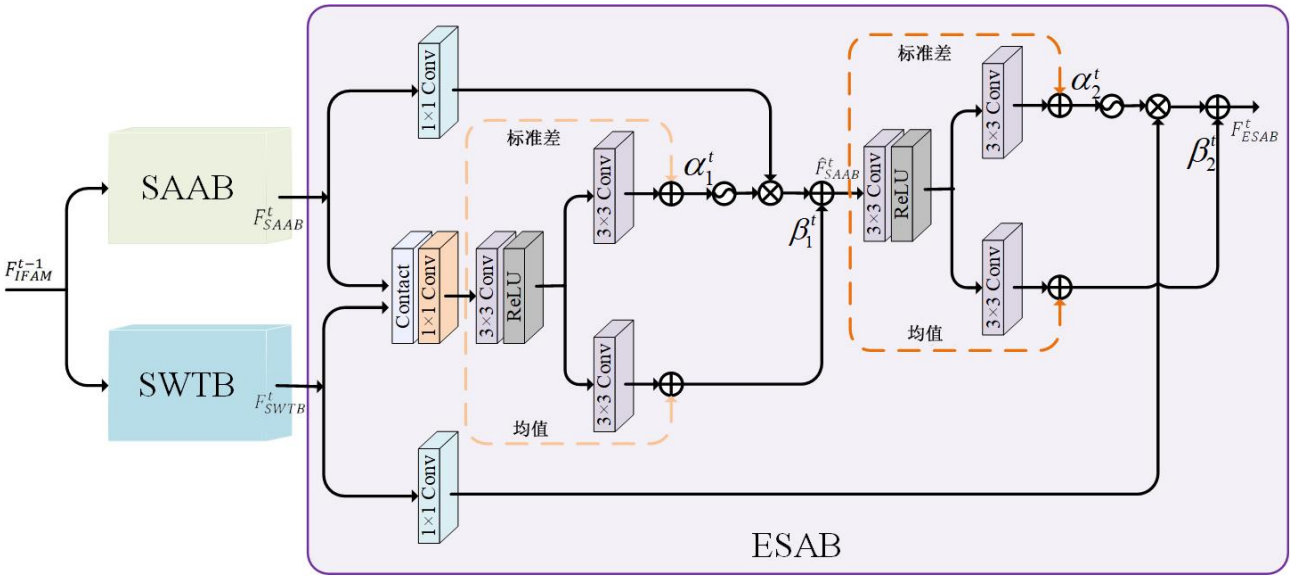

F_{IFAM}^{t-1}
SAAB
F_{SAAB}^{t}
SWTB
F_{SWTB}^{t}
1×1 Conv
Contact
1×1 Conv
1×1 Conv
标准差
3×3 Conv
ReLU
3×3 Conv
均值
α_1^t
β_1^t
$\hat{F}_{SAAB}^{t}$
标准差
3×3 Conv
ReLU
3×3 Conv
均值
α_2^t
β_2^t
F_{ESAB}^{t}
ESAB

图 4

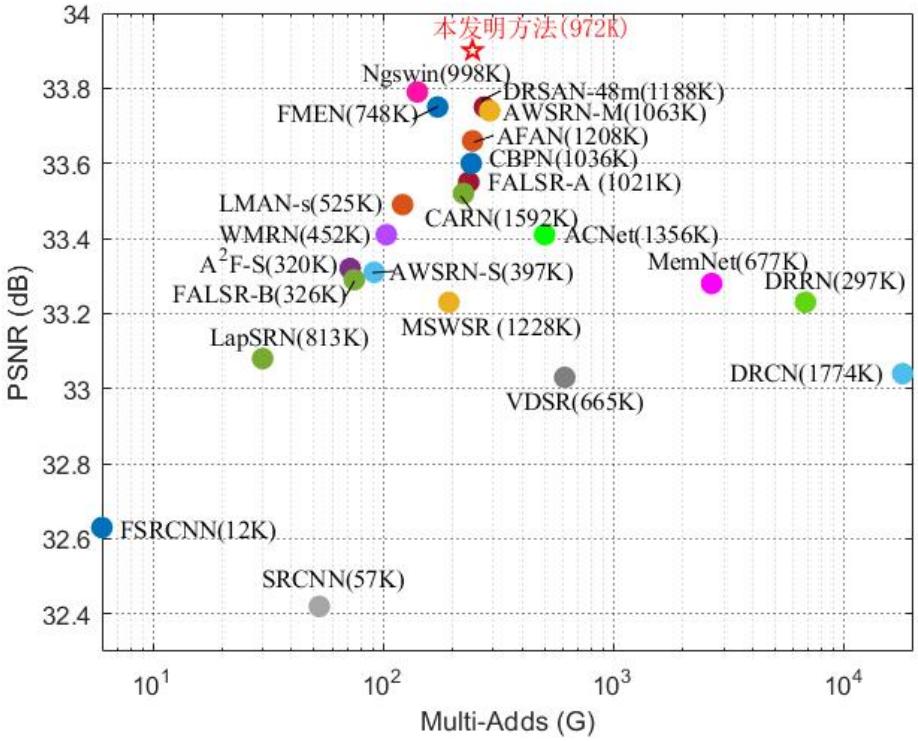

本发明方法(972K)
Ngswin(998K)
DRSAN-48m(1188K)
FMEN(748K)
AWSRN-M(1063K)
AFAN(1208K)
CBPN(1036K)
FALSR-A (1021K)
LMAN-s(525K)
CARN(1592K)
WMRN(452K)
ACNet(1356K)
A2F-S(320K)
AWSRN-S(397K)
MemNet(677K)
DRRN(297K)
FALSR-B(326K)
MSWSR (1228K)
LapSRN(813K)
DRCN(1774K)
VDSR(665K)
FSRCNN(12K)
SRCNN(57K)
PSNR (dB)
Multi-Adds (G)
34
33.8
33.6
33.4
33.2
33
32.8
32.6
32.4
10^1
10^2
10^3
10^4

图 5

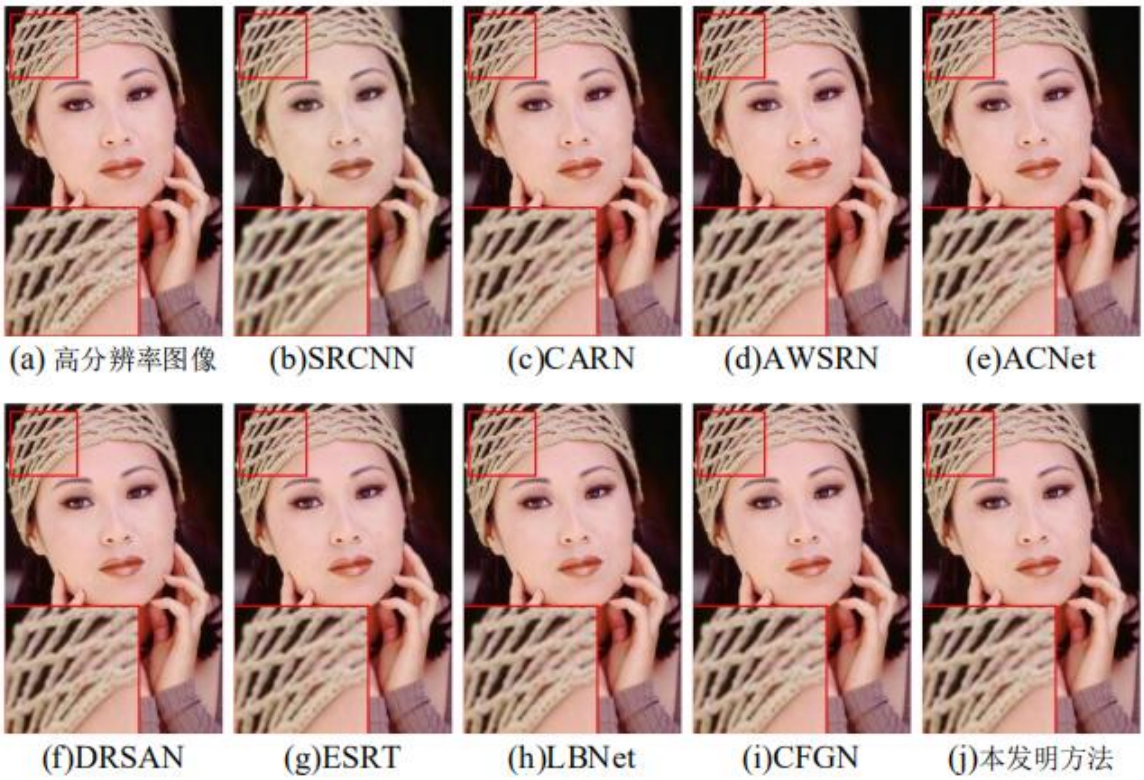

(a) 高分辨率图像
(b)SRCNN
(c)CARN
(d)AWSRN
(e)ACNet
(f)DRSAN
(g)ESRT
(h)LBNet
(i)CFGN
(j)本发明方法

图 6

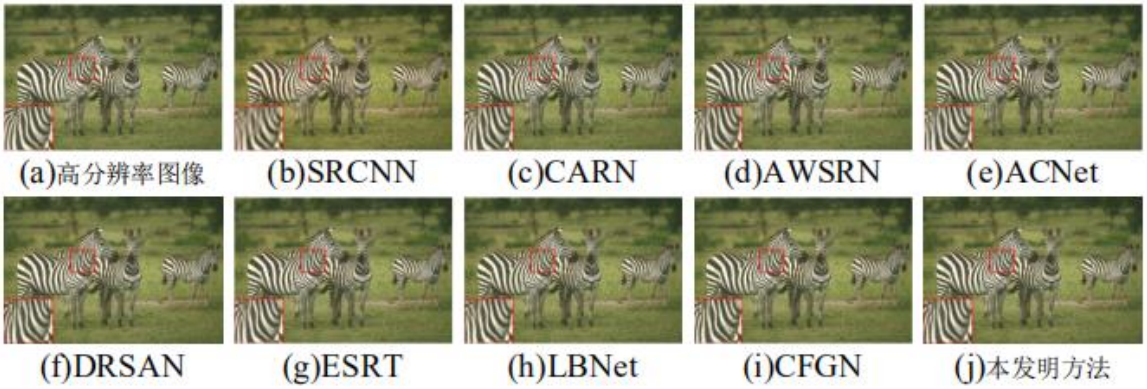

(a)高分辨率图像
(b)SRCNN
(c)CARN
(d)AWSRN
(e)ACNet
(f)DRSAN
(g)ESRT
(h)LBNet
(i)CFGN
(j)本发明方法

图 7

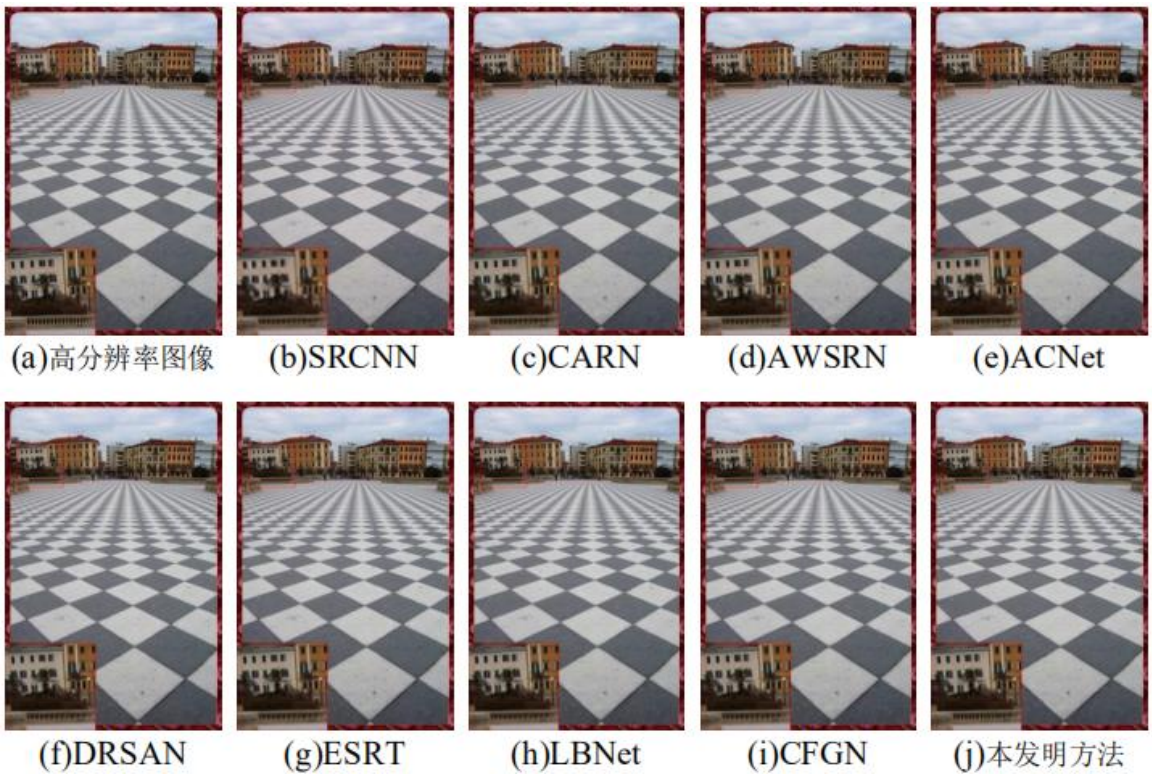

(a)高分辨率图像
(b)SRCNN
(c)CARN
(d)AWSRN
(e)ACNet
(f)DRSAN
(g)ESRT
(h)LBNet
(i)CFGN
(j)本发明方法

图 8

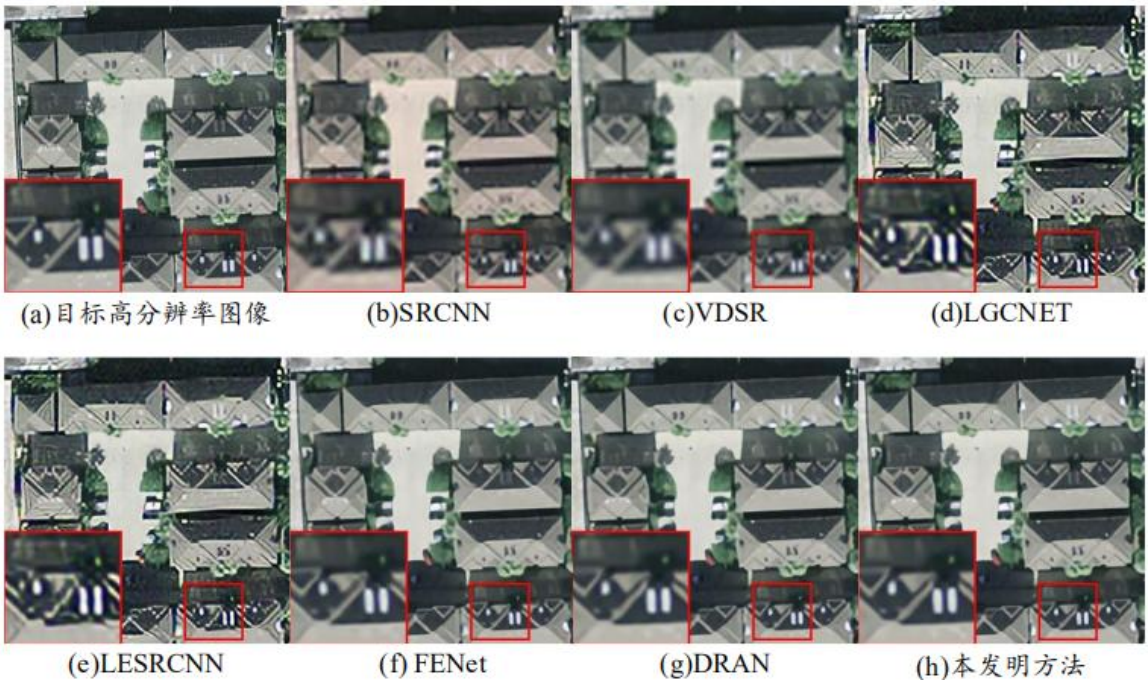

(a)目标高分辨率图像
(b)SRCNN
(c)VDSR
(d)LGCNET
(e)LESRCNN
(f) FENet
(g)DRAN
(h)本发明方法

图 9

一种基于Transformer架构的单碱基编辑结果预测方法（发明）技术交底书

技术领域

本发明属于生物技术领域，特别涉及一种基于 Transformer 架构的单碱基编辑结果预测方法。

背景技术

碱基编辑（Base Editor, BE）是自 2016 年起发展起来的一种基因编辑技术，其不依赖于 DNA 双链断裂，能够高效、精准地诱导 DNA 或 RNA 中单碱基的替换，具有高效、精准、特异性好等优点，在基因治疗、精准动植物育种和基因功能分析等领域具有广泛的应用。碱基编辑效率与编辑结果产物纯度是碱基编辑技术的两个最重要的指标，决定了碱基编辑技术是否能够最终走向临床应用。碱基编辑效率与编辑产物受编辑因素影响机理尚不明确，目前主要依靠经验和大量尝试来进行优化。基于深度学习的编辑结果预测可以在不需要生物实验的情况下指导碱基编辑工作和碱基编辑器的优化，有助于研究人员提高实验效率，节约实验成本。

BE 根据靶基因的不同，分为腺嘌呤碱基编辑（Adenine Base Editor, ABE）、胞嘧啶碱基编辑（Cytosine Base Editor，CBE）和胞嘧啶鸟嘌呤（Cytosine Guanine Base Editor，CGBE）三种，分别实现 A→G、T→C、C→G 的碱基转换。

发明内容

发明目的：本发明的目的是提供一种基于 Transformer 架构的碱基编辑结果预测方法，该模型能够预测 ABE、CBE 和 CGBE 在给定的靶序列下的碱基编辑结果，包括编辑效率与编辑产物概率分布。

技术方案：为实现上述发明目的，本发明提出以下技术方案。该技术方案主要步骤如下：

（1）数据集预处理。本发明收集当前已有碱基编辑结果数据，对原始数据清洗后，按照 8：1：1 的比例分别用于模型训练、模型测试与模型验证。采用十折交叉验证法以提高模型的预测精度。

（2）模型构建与训练。本发明包含两个深度学习模型，编辑效率预测模型和旁编辑预测模型。两个模型的区别是编辑效率预测模型以待编辑序列作为输入，以待编辑序列中的可编辑基因（即 CBE、CBGE 中的“C”和 ABE 中的“A”）的编辑概率作为输出；旁编辑预测模型是以待编辑序列作为输入，以该序列所有可能的编辑结果序列及其概率作为输出。

旁编辑是指在编辑窗口内存在多个可编辑碱基时可能出现的各种编辑情况，是碱基编辑

脱靶的重要类型。

本发明将输入序列中的每个碱基当作自然语言处理中的一个单词，运用 Transformer 架构对碱基序列进行处理。模型以包含邻近基序(Protospacer Adjacent Motif, PAM)的 23bp 待编辑碱基序列为输入，叠加每个碱基的位置特征，输入编码器。编码器的第一层是自注意力层，该层帮助编码器对每个碱基编码时关注其他碱基。自注意力层的输出会传递到前馈神经网络中，每个位置的碱基对应的前馈神经网络都完全一样。经过 N 个编码器后，再经过线性变换和 Softmax 激活函数后得到每个碱基的编辑概率。

旁编辑模型采用编码器-解码器构建，编码器与解码器对应，个数相同。解码器在编码器的模块基础上增加了掩码自注意力层和编码-解码注意力层。掩码自注意力层作为“自回归层”，确保在计算输出的概率时只使用过去的信息。编码-解码注意力层用于学习输入序列中的哪些碱基在表示输出碱基向量时是更重要的，从而使模型更精确地计算每个输出序列的概率。编辑效率预测模型的输出是一个二分类任务，将编辑概率高于或等于平均编辑概率的样本分类为已编辑，而将编辑效率低于平均编辑效率的样本分类为未编辑，最后输出是一个综合概率值，用于反映一个目标碱基被编辑的可能性（介于 0 和 1 之间）。旁编辑预测模型的输出并非是一个二分类任务，而是需要输出所有可编辑位点上的所有结果的概率。因此训练后的旁编辑模型可以预测每个目标序列的各种可能的编辑结果，包括多个碱基转换的组合。本发明针对两种模型单独训练，训练完成后分别用于单碱基编辑效率预测和编辑产物预测。

（3）模型评估。对于编辑效率预测模型，使用接收者操作特征曲线下面积（Area Under Curve，AUC）和精确率-召回率曲线下面积（Area Under the Precision-Recall curve，AUPR）评估其性能。即在模型训练过程中，记录模型在验证集上达到最佳 AUC 和 AUPR 的轮次，并保存截至该轮次的模型状态。然后，根据验证集确定的最佳模型在测试集上进行测试。对于不同的碱基编辑类型，本发明基于其在测试集上的平均性能对训练的模型进行评估。对于旁编辑模型，使用 Pearson 和 Spearman 相关系数评价其性能。在模型训练过程中，记录模型在验证集上在两个评估指标之间取得最佳值的轮次，并保存该轮次的模型状态。然后，根据验证集确定的最佳模型在测试集上进行测试。对于每种碱基编辑类型，本发明基于其在测试集上的平均性能对训练的模型进行评估。

（4）预测结果输出。为更好地展现预测结果，分别针对两种模型设计用户交互界面。交互界面提供参数输入和预测结果输出。参数输入简单方便，提供下拉清单。结果输出清晰明了，简洁美观。

有益效果：与现有技术相比，本发明具有以下优势：

本发明所提出的基于 Transformer 架构的碱基编辑结果预测方法，相比与传统的 CNN，

机器学习等方法具有创新。本方法采用的基于注意力机制的预测模型对不同位置的碱基生成不同的注意力分数，解决各碱基局部相关性问题，提升模型预测精度。

附图说明

图 1 是本发明用于编辑效率预测模型的数据集示例图

图 2 是本发明用于旁编辑预测模型的数据集示例图

图 3 是本发明所提出的单碱基编辑效率预测流程图

图 4 是本发明所提出的旁编辑预测流程图

图 5 是本发明预测 ABEmax 碱基编辑器编辑效率的 AUC 曲线

图 6 是本发明预测 ABE8 碱基编辑器预测准确度对比图

图 7 是本发明的单碱基编辑效率预测模块的超参数配置范围表

图 8 是本发明的旁编辑预测模块的超参数配置范围表

图 9 是本发明的单碱基编辑效率预测模型的预测结果显示界面

图 10 是本发明的旁编辑预测模型的预测结果显示界面

具体实施方式

下面结合附图对本发明作更进一步的说明。

（1）数据集预处理。对碱基编辑结果数据进行数据清洗与降维，分别得到编辑效率数据集与旁编练数据集，均按照 8:1:1 分为训练集、验证集和测试集。预处理后的编辑效率数据集示例如图 1 所示，包含序列 ID、序列作用、序列数量、序列内容、20 个碱基位置每个位置的编辑概率。预处理后的旁编练数据集如图 2 所示，包含序列 ID、序列数量、输入序列、输出序列，概率和序列作用。

（2）模型构建与训练

①碱基编辑效率预测模型

图 3 所示为本发明所提出的单碱基编辑效率预测流程图。该模型以包含 PAM 的 23 个碱基对的碱基序列作为输入，以每个可编辑碱基的编辑概率作为输出。该模型包含三个主要模块：①嵌入模块，将碱基及其对应位置从独热编码表示嵌入到紧凑向量表示中；②编码模块，主要包含多头自注意力层和前馈网络；③输出模块，主要包含位置注意力层和分类器层。

以 $\mathbf{S}=[\mathbf{x}_1,\mathbf{x}_2,\cdots,\mathbf{x}_T]$ $\mathbf{x}_t\in[0,1]^K$ 表示独热编码形式下输入序列，嵌入矩阵 $\mathbf{W}_e\in$ $^{d_e\times K}$ 用于将输入 $\mathbf{x}_t$ 映射成一个固定长度的向量 $\mathbf{e}_t\in$ ^{d_e}，即 $\mathbf{e}_t=\mathbf{W}_e\mathbf{x}_t$。类似的，以 $\mathbf{p}_t\in[0,1]^T$ 表示序列 $\mathbf{S}$ 中碱基 $\mathbf{x}_t$ 对应的位置，嵌入矩阵 $\mathbf{W}_{p}\in$ $^{d_{p}\times T}$ 用于将输入 $\mathbf{p}_t$ 转换成一个固定长度的向量

$\mathbf{p}_t^{'} \in$ $^{d_{p'}}$，即 $\mathbf{p}_t^{'} = \mathbf{W}_{p'}\mathbf{p}_t$。将两个嵌入向量 $\mathbf{e}_t$ 和 $\mathbf{p}_t$ 相加，$\mathbf{S}$ 中的每个元素得到一个统一的表示 $\mathbf{U} = [\mathbf{u}_1, \mathbf{u}_2, \cdots, \mathbf{u}_T]$，其中 $\mathbf{u}_t = \mathbf{e}_t + \mathbf{p}_t^{'}$，$\mathbf{u}_t \in$ ^{d}，$\forall t \in [1, \cdots, T]$。

自注意力层采用多头自注意力方法，即多个单头自注意力层同时并行处理每个输入向量 $\mathbf{u}_t$。每个单头层的输出通过仿射转换连接并转换成一个固定长度的向量。单头自注意力方法使用查询矩阵 $\mathbf{W}_{query}$，键矩阵 $\mathbf{W}_{key}$ 和值矩阵 $\mathbf{W}_{value}$ 对输入向量进行线性转换，每个 $\mathbf{U}$ 中的元素 $\mathbf{u}_t$ 分别通过这三个矩阵转换为三个新的向量，如下式所示：

$$\mathbf{q}_t = \mathbf{W}_{query}\mathbf{u}_t \tag{1}$$

$$\mathbf{k}_t = \mathbf{W}_{key}\mathbf{u}_t \tag{2}$$

$$\mathbf{v}_t = \mathbf{W}_{value}\mathbf{u}_t \tag{3}$$

其中 $\mathbf{W}_{query}$，$\mathbf{W}_{key}$，$\mathbf{W}_{value} \in$ $^{d' \times d}$，$\mathbf{q}_t$，$\mathbf{k}_t$，$\mathbf{v}_t \in$ $^{d'}$。

接下来，利用查询矩阵和键矩阵间的成对相似性为输入序列每个位置 t 计算注意力分数 α_{tl} 来表示 $\mathbf{q}_t$ 和向量 $\mathbf{k}_l$ $\forall l \in [1, \cdots, T]$ 之间的相似度，再使用 *softmax* 函数均衡，如下式所示：

$$\alpha_{tl} = \frac{\exp(score(\mathbf{q}_t, \mathbf{k}_l))}{\sum_{l=1}^{T} \exp(score(\mathbf{q}_t, \mathbf{k}_l))} \tag{4}$$

$$score(\mathbf{q}_t, \mathbf{k}_l) = \frac{\mathbf{q}_t^{\,T}\mathbf{k}_l}{\sqrt{d}} \tag{5}$$

然后基于注意力分数 α_{tl} 和 value 向量 $\mathbf{v}_l$ $\forall l \in [1, \cdots, T]$ 依据公式（6）加权求和得到一个新的向量序列 $\mathbf{Z} = [\mathbf{z}_1, \mathbf{z}_2, \cdots, \mathbf{z}_T]$。

$$\mathbf{z}_t = \sum_{l=1}^{T} \alpha_{tl}\mathbf{v}_l \tag{6}$$

在一个具有H头的多头设置中，查询矩阵，键矩阵和值矩阵以上标 h 索引（即 $\mathbf{W}_{query}^{h}$，$\mathbf{W}_{key}^{h}$，$\mathbf{W}_{value}^{h}$）并为每个单头自注意力层分别应用公式（6）生成新的向量表示 $\mathbf{z}_t^h$。每个单头层的输出连接成向量 $\mathbf{z}_t^{concat} = concat(\mathbf{z}_t^1, \mathbf{z}_t^2, \cdots, \mathbf{z}_t^H)$，$\mathbf{z}_t^{concat} \in$ $^{d'H}$ 然后进行仿射转换，转换公式为：

$$\tilde{\mathbf{z}}_t = \mathbf{W}_{unify}\mathbf{z}_t^{concat} + \mathbf{b}_{unify} \tag{7}$$

其中，$\mathbf{W}_{unify} \in$ $^{d' \times dH}$，$\mathbf{b}_{unify} \in$ $^{d'}$。$\mathbf{Z}$ 经上式转换后得到矩阵 $\tilde{\mathbf{Z}} = [\tilde{\mathbf{z}}_1, \tilde{\mathbf{z}}_2, \cdots, \tilde{\mathbf{z}}_T]$。

前馈网络用于进一步计算/嵌入从上层学习到的向量表示。首次转换（如公式 8 所示）使用 $\mathbf{W}_{MLP1} \in$ $^{\xi d' \times d'}$ 和 $\mathbf{b}_{MLP1} \in$ $^{\xi d'}$，将输入 $\tilde{z}_t$ 转换成一个新的向量 $\in$ $^{\xi d'}$，其中 $\xi \in$ ，为乘法因子。经非线性函数 *ReLU* 转换，再经过 $\mathbf{W}_{MLP2} \in$ $^{d' \times \xi d'}$ 和 $\mathbf{b}_{MLP2} \in$ $^{d'}$ 的另一个仿射转换获得向量 $\mathbf{r}_t \in$ $^{d'}$，再运用一个层均衡函数 LN（公式 9）得到序列 $\mathbf{R} = [\tilde{\mathbf{r}}_1, \tilde{\mathbf{r}}_2, \cdots, \tilde{\mathbf{r}}_T]$。

$$\mathbf{r}_t = \mathbf{W}_{MLP2} ReLU(\mathbf{W}_{MLP1} \tilde{\mathbf{z}}_t + \mathbf{b}_{MLP1}) + \mathbf{b}_{MLP2} \quad (8)$$

$$\tilde{\mathbf{r}}_t = \mathrm{LN}(\mathbf{r}_t) \quad (9)$$

位置注意力层由一组对应于输入序列中每个位置的全局上下文向量 $\mathbf{C} = [\mathbf{c}_1, \mathbf{c}_2, \cdots, \mathbf{c}_T]$ 参数化。注意力分数 $\varphi_t \ \forall t \in [1, \cdots, T]$ 由上下文向量 $\mathbf{c}_t \in$ $^{d'}$ 和上一层中计算的序列 $[\tilde{\mathbf{r}}_1, \tilde{\mathbf{r}}_2, \cdots, \tilde{\mathbf{r}}_T]$ 计算，公式如（10）（11）所示。这些分数继续用于与向量 $[\tilde{\mathbf{r}}_1, \tilde{\mathbf{r}}_2, \cdots, \tilde{\mathbf{r}}_T]$ 加权求和得到位置 *t* 处的一个新的向量 $\mathbf{O} = [\mathbf{o}_1, \mathbf{o}_2, \cdots, \mathbf{o}_T]$ 传递给输出分类器。

$$\varphi_t = \frac{\exp(score(\mathbf{c}_t, \tilde{\mathbf{r}}_t))}{\sum_{j=1}^{T} \exp(score(\mathbf{c}_t, \tilde{\mathbf{r}}_j))} \quad (10)$$

$$score(\mathbf{c}_t, \tilde{\mathbf{r}}_t) = \frac{\mathbf{c}_t^{\ T} \tilde{\mathbf{r}}_t}{\sqrt{d'}} \quad (11)$$

$$\mathbf{o}_t = \sum_{t=1}^{T} \varphi_t \tilde{\mathbf{r}}_t \quad (12)$$

输出分类器以自注意力层的 $\mathbf{O} = [\mathbf{o}_1, \mathbf{o}_2, \cdots, \mathbf{o}_T]$ 为输入，经仿射转换和 *softmax* 操作，得到各碱基编辑概率 $\mathbf{P}_{off} \in$ ^{T} 计算公式如下：

$$\mathbf{P}_{off} = \sigma(\mathbf{W}_o \mathbf{o}_t + \mathbf{b}_o) \quad (13)$$

其中 $\mathbf{W}_o \in$ $^{T \times d'}$ 和 $\mathbf{b}_o \in$ ^{T} 为仿射转换函数，σ 是 *softmax* 函数。

本发明通过使用交叉熵损失函数（公式 14）来定义在每个位置 t 处的第 i 个序列的损失。

$$l_t^{(i)} = -\sum_{c=1}^{|V_{\text{outcome}}|} y_{t,c}^{(i)} \times \log\left(\hat{y}_{t,c}^{(i)}\right) \quad (14)$$

第 i个序列的损失是通过序列长度 T上的平均损失（公式 15）来定义的。

$$L_i = \frac{1}{T}\sum_{t=1}^{T} l_t^{(i)} \tag{15}$$

由于本发明关注所有可编辑碱基，因此模型专注于所有可编辑碱基出现的位置。因此，本发明修改对第 i个序列的损失的定义，通过为目标碱基定义一个平均损失 L_i^{target}(公式 16)来计算损失。

$$L_i^{\text{target}} = \frac{1}{\sum^{T}\mathbb{1}\left[x_{t,\text{base}}^{(i)} \neq -1\right]}\sum_{t=1}^{T} l_t^{(i)}\,\mathbb{1}\left[x_{t,\text{base}}^{(i)} = 1\right] \tag{16}$$

其中，$\mathbb{1}\left[x_{t,base}^{(i)} = 1\right]$是一个指示函数，当第 i个序列中的位置 t上的碱基x_t^i为目标碱基，该函数的值为 1。最后，整个训练集D_{train}的目标函数由D_{train}中所有序列的平均损失加上应用于模型参数θ的权重正则化项（即l_2范数正则化）来定义，如公式（17）所示。

$$L(\boldsymbol{\theta}) = \frac{1}{N}\sum_{i=1}^{N} L_i^{\text{target}} + \frac{\lambda}{2}\|\boldsymbol{\theta}\|_2^2 \tag{17}$$

在实际训练中，使用小批量进行训练，即在处理完每个训练集的小批量之后，计算损失函数并更新参数/权重。

②旁编辑预测模型

图 4 所示为本发明所提出的旁编辑预测流程图。旁编辑模型以计算目标碱基与所有邻近碱基转换的所有可能组合的概率，也就是所有编辑结果的概率分布为目标。该模型采用嵌入模块和编码模块来处理输入序列，使用解码模块来计算所有编辑结果序列的概率。

该模型以碱基编辑系统、方法、过程及影响碱基编辑的因素及其权重数据为输入，经过数据预处理后，以独热形式编码为$\mathbf{S} = [\mathbf{x}_1, \mathbf{x}_2, \cdots, \mathbf{x}_T]$ $\mathbf{x}_t \in [0,1]^K$，其中T表示序列的长度，K表示独热编码的长度。序列输入到嵌入和编码模块产生一个新的向量，多个编码模块叠加产生新序列$\tilde{\mathbf{Z}} = [\tilde{\mathbf{z}}_1, \tilde{\mathbf{z}}_2, \cdots, \tilde{\mathbf{z}}_T]$。

以每个输入序列 **S** 实验观察到的目标碱基的组合作为解码模块的输入。编辑组合依据特定碱基编辑器的碱基转换，如 ABE 碱基编辑器对应的碱基转换为 A->G，CBE 碱基编辑器对应的碱基转换为 C->T。待编辑碱基序列的第 j 个碱基组合输出表示为 $\mathbf{O}_j=[\mathbf{o}_{j1},\mathbf{o}_{j2},\cdots,\mathbf{o}_{jT}]$，其中 $\mathbf{o}_{ji}\in[0,1]^{K'}$，$K'$ 为独热编码的长度。

所有输出序列 $\mathbf{O}_j$ 输入至嵌入层。该层将每一个碱基以及它们的对应位置从独热编码方式转换成一个紧凑向量表示方式，得到一个新的向量 $\mathbf{B}_j$。

随后，一个掩码自注意力层作为 “自回归层”，用于保证只在序列 $\mathbf{E}_j=[\mathbf{e}_{j1},\mathbf{e}_{j2},\cdots,\mathbf{e}_{jT}]$ 中每一次计算新的向量时使用过去的信息。层归一化和残差连接用于获得一个新的向量 $\mathbf{V}_j=[\mathbf{v}_{j1},\mathbf{v}_{j2},\cdots,\mathbf{v}_{jT}]$。

序列 $\mathbf{V}_j$ 随后输入给交叉注意力层。所以向量 $\mathbf{V}_j$ 用于查询，向量 $\mathbf{Z}$（编码模块计算的序列）作为键值以计算查询和键矩阵间的注意力分数。这些分数用于在计算新的序列表示 $\mathbf{D}_j=[\mathbf{d}_{j1},\mathbf{d}_{j2},\cdots,\mathbf{d}_{jT}]$ 时作为向量 $\mathbf{V}_j$ 的权重。然后经过一系列的层归一化，残差连接，伴随着前馈网络串行联接，得到序列 $\mathbf{H}_j=[\mathbf{h}_{j1},\mathbf{h}_{j2},\cdots,\mathbf{h}_{jT}]$。

输出模块以 $\mathbf{H}_j$ 作为输入，进行一个仿射转换，和*softmax*操作，计算第*j*个输出序列每个目标碱基所有转换的概率分布，如公式18所示：

$$\hat{\mathbf{P}}_{jt}=\sigma(\mathbf{W}\mathbf{h}_{jt}+\mathbf{b}_t) \tag{18}$$

其中，$\mathbf{W}\in\ ^{2\times d'}$，$\mathbf{b}_t\in\ ^{2}$，$\mathbf{h}_{jt}\in\ ^{d'}$，$\sigma$ 表示*softmax*函数。

整个输出序列 $\hat{\mathbf{P}}_j$（即第*j*个编辑组合）的概率计算公式如下：

$$\hat{\mathbf{P}}_j=\prod_{t=1}^{T}\hat{\mathbf{P}}_{jt} \tag{19}$$

Kullback-Leibler 散度（KL 散度）被用作第 i 个输入序列的损失函数。KL 散度表示模型对所有结果序列 y *j 的估计分布相对于真实分布（即观察到的编辑结果比例）y*j 的相对熵，其中 $j\in[1,\cdots,J]$，J 表示给定原始序列的编辑结果序列的数量，如公式 20 所示。

$$D_{KL-div}^{i}(y^i \parallel \hat{y}^i) = \sum_{j=1}^{J} y_j^i \log\left(\frac{y_j^i}{\hat{y}_j^i}\right) \quad (20)$$

最后，整个训练集的目标函数由所有输入原始序列的平均损失加上应用于模型参数 θ 的权重正则化项（即 l_2范数正则化）来定义。

$$L(\boldsymbol{\theta}) = \frac{1}{N}\sum_{i=1}^{N} D_{KL-div}^{i}(y^i \parallel \hat{y}^i) + \frac{\lambda}{2} \parallel \boldsymbol{\theta} \quad (21)$$

在实际训练中，使用小批量进行训练，即在处理完每个训练集的小批量之后，计算损失函数并更新参数/权重。

（3）模型评估

对于单碱基编辑效率预测模型，本发明使用 AUC 和 AUPR 评估模型的性能。在模型训练过程中，记录模型在验证集上达到最佳 AUC 和 AUPR 的轮次，并保存该轮次的模型状态。然后，根据验证集确定的最佳模型在测试集上进行测试。对于每种碱基编辑器类型，本发明基于其在测试集上的平均性能对训练的模型进行评估，并采用 10 折交叉验证法，综合 10 次运行的结果。图 5 是本发明针对 ABEmax 碱基编辑器编辑效率预测性能的 AUC 曲线。

为了更好地评估该模型的性能，本发明还构建了基于标准卷积神经网络（Convolutional Neural Network, CNN）的编辑效率预测模型作为比较基准。图 6 是本模型与基准模型在 ABE8e 碱基编辑器上的精确率对比图。从图中可以看出，本发明提出的基于 Transformer 架构的预测模型明显优于传统的基于标准 CNN 架构的预测模型。

对于旁编辑模型，本发明使用 Pearson 和 Spearman 相关系统评估其性能。在模型训练过程中，记录模型在验证集上两个评估指标之间取得最佳值的轮次，并保存该轮次的模型状态。然后，根据验证集确定的最佳模型在测试集上进行测试。

对于超参数优化，本发明采用一种均匀随机搜索策略，从所有可能的配置中随机选择一组超参数配置（例如嵌入维度、注意力头数、丢弃率等）。然后，本发明针对每个模型选择在验证集上表现最佳的配置作为最终的模型超参数配置。编辑效率预测模型和旁编辑预测模型的超参数配置范围表分别如图 7 和图 8 所示。

（4）预测结果输出

为更好地展现预测结果，本发明分别针对两种模型设计了不同的显示界面，如图 9 和图 10 所示。碱基编辑效率预测结果输出界面，采用 Flask 框架和 Ajax 实现前后端的交互。前端

用户输入编辑技术、预测编辑的序列位置、预测方式等数据被传送到后端。后端对这些数据进行预处理，并调用相应的模型进行计算。最终的计算结果为一张 PNG 图片，使用 Base64 编码将其嵌入到前端页面中进行展示，以便用户直观地查看编辑结果。

旁编辑预测结果输出界面同样通过 Flask 和 Ajax 实现了前后端数据的传输。前端将用户输入的编辑技术、预测编辑的序列位置、预测方式等数据发送到后端。后端对这些数据进行预处理，并调用相应的模型进行计算。计算结果经过 CSS 样式美化后，通过 Jinja2 模板引擎在前端进行渲染，以提供用户友好的展示效果。

权利要求书

1. 一种基于 Transformer 架构的单碱基编辑结果预测方法，其特征在于。所述方法包括以下步骤：

步骤 1，数据集预处理。收集碱基编辑结果数据，对原始数据清洗后，按照 8：1：1 的比例分别用于模型训练、模型测试与模型验证。采用十折交叉验证法以提高模型的预测精度。

步骤 2，碱基编辑效率预测模型的构建。预处理后的输入数据经过嵌入模块，编码器模块，输出模块，得到序列中每个可编辑碱基的编辑概率。

步骤 3，旁编辑预测模型的构建。预处理后的输入数据经过嵌入模块，编码器模块，解码器模块，输出模块，得到所有可能编辑产物及其概率。

步骤 4，模型交互界面的构建。针对两种模型设计不同的交互界面，界面中包含模型参数输入及预测结果输出。

2. 根据权利要求 1 所述的一种基于 Transformer 架构的单碱基编辑结果预测方法，其特征是，在步骤 2 中，所述的编码器模块，具体由多个单头自注意力层并行处理每个输入向量并通过缩放点积注意力来计算嵌入层输出的相似度，接着使用由两个仿射变换矩阵和非线性激活函数构成的前馈网络来计算先前层的向量表示，并通过验证集上使用超参数搜索确定所需的超参数。

3. 根据权利要求 1 所述的一种基于 Transformer 架构的单碱基编辑结果预测方法，其特征是，在步骤 2 中，编辑效率预测模型的损失函数关注于目标碱基出现的位置，因此编辑效率预测模型在 L2 交叉熵的基础上定义一个平均损失和指示函数计算序列的损失。

3. 根据权利要求 1 所述的一种基于 Transformer 架构的单碱基编辑结果预测方法，其特征是，在步骤 3 中，在解码器部分使用掩码自注意力层作为“自回归层”，再使用一系列的归一化层、残差连接和前馈网络来计算最终的序列表示。

4. 根据权利要求 1 所述的一种基于 Transformer 架构的单碱基编辑结果预测方法，其特征是，在步骤 3 中，在 L2 的 KL 散度基础上，整个训练集的目标函数由所有输入原始序列的平均损

失加上应用于模型参数的权重正则化项来构建。

说明书附图

ID	Purpose	Count	Sequence	Position_1	Position_2	Position_3	Position_4	Position_5	Position_6	Position_7	Position_8
CTRL_genomic_NM_000044	Validation/Test	4704	ACTGAAGATCAGCATGTGTC	0.00	0.00	0.00	0.00	4.66	4.02	0.00	4.76
CTRL_genomic_NM_000050	Validation/Test	2611	ACAGGTGTACATCCTCGGCC	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00
CTRL_genomic_NM_000059	Validation/Test	4683	ACTGCCACCTTCAGGGCCTC	0.15	0.00	0.00	0.00	0.00	0.00	7.09	0.00
CTRL_genomic_NM_000077	Validation/Test	8497	AAGCAGCAGCTCCGCCACTC	0.00	0.11	0.00	0.00	23.78	0.00	0.00	9.67
CTRL_genomic_NM_000090	Validation/Test	490	AGGAGAAAATGGAAAACCTG	0.00	0.00	0.00	1.63	0.00	6.33	0.00	0.00
CTRL_genomic_NM_000128	Validation/Test	1052	AGTATAAAATGGCAGAAAGC	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00
CTRL_genomic_NM_000179	Validation/Test	1013	AATACCCGGCTCCCAGTTTT	0.00	0.00	0.00	12.73	0.00	0.00	0.00	0.00
CTRL_genomic_NM_000182	Validation/Test	11485	ACCCTTATCCACGGAGACTT	0.00	0.00	0.00	0.00	0.00	0.00	91.49	0.00
CTRL_genomic_NM_000214	Validation/Test	359	ATGAGCAGCAGCTGGACTCT	0.00	0.00	0.00	6.96	0.00	0.00	1.67	0.00
CTRL_genomic_NM_000251	Validation/Test	3445	AAGTACTCATGGCCCAAATT	0.03	0.03	0.00	0.00	55.99	0.00	0.00	0.00
CTRL_genomic_NM_000251	Validation/Test	619	AGATGGATTTGGGTTAGCAT	0.00	0.00	0.00	0.00	0.00	0.00	13.73	0.00
CTRL_genomic_NM_000334	Validation/Test	650	ACTGGCGCGCCAGGGCTACT	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00
CTRL_genomic_NM_000430	Validation/Test	4981	ATAGTGACTGTGCAAGTTCC	0.00	0.00	0.50	0.00	0.00	0.00	68.24	0.00
CTRL_genomic_NM_000495	Validation/Test	1863	AGGCTGCCAGGACTTTGGCT	0.05	0.00	0.00	0.00	0.00	0.00	0.00	0.00

图 1

ID	Counts	Reference	Outcome	Proportion	Purpose
CTRL_genomic_NM_000044_	4704	ACTGAAGATCAGCATGTGTC	ACTGAAGATCAGCATGTGTC	0.865433673	Validation/Test
CTRL_genomic_NM_000044_	4704	ACTGAAGATCAGCATGTGTC	ACTGAAGGTCAGCATGTGTC	0.047619048	Validation/Test
CTRL_genomic_NM_000044_	4704	ACTGAAGATCAGCATGTGTC	ACTGGAGATCAGCATGTGTC	0.046556122	Validation/Test
CTRL_genomic_NM_000044_	4704	ACTGAAGATCAGCATGTGTC	ACTGAGGATCAGCATGTGTC	0.040178571	Validation/Test
CTRL_genomic_NM_000044_	4704	ACTGAAGATCAGCATGTGTC	ACTGAAGATCGGCATGTGTC	0.000212585	Validation/Test
CTRL_genomic_NM_000059_	4683	ACTGCCACCTTCAGGGCCTC	ACTGCCACCTTCAGGGCCTC	0.927396968	Validation/Test
CTRL_genomic_NM_000059_	4683	ACTGCCACCTTCAGGGCCTC	ACTGCCGCCTTCAGGGCCTC	0.070894726	Validation/Test
CTRL_genomic_NM_000059_	4683	ACTGCCACCTTCAGGGCCTC	GCTGCCACCTTCAGGGCCTC	0.001494768	Validation/Test
CTRL_genomic_NM_000059_	4683	ACTGCCACCTTCAGGGCCTC	ACTGCCACCTTCGGGGCCTC	0.000213538	Validation/Test
CTRL_genomic_NM_000077_	8497	AAGCAGCAGCTCCGCCACTC	AAGCAGCAGCTCCGCCACTC	0.664352124	Validation/Test
CTRL_genomic_NM_000077_	8497	AAGCAGCAGCTCCGCCACTC	AAGCGGCAGCTCCGCCACTC	0.237848652	Validation/Test
CTRL_genomic_NM_000077_	8497	AAGCAGCAGCTCCGCCACTC	AAGCAGCGGCTCCGCCACTC	0.096740026	Validation/Test
CTRL_genomic_NM_000077_	8497	AAGCAGCAGCTCCGCCACTC	AGGCAGCAGCTCCGCCACTC	0.001059197	Validation/Test
CTRL_genomic_NM_000090_	490	AGGAGAAAATGGAAAACCTG	AGGAGAAAATGGAAAACCTG	0.887755102	Validation/Test
CTRL_genomic_NM_000090_	490	AGGAGAAAATGGAAAACCTG	AGGAGGAAATGGAAAACCTG	0.063265306	Validation/Test

图 2

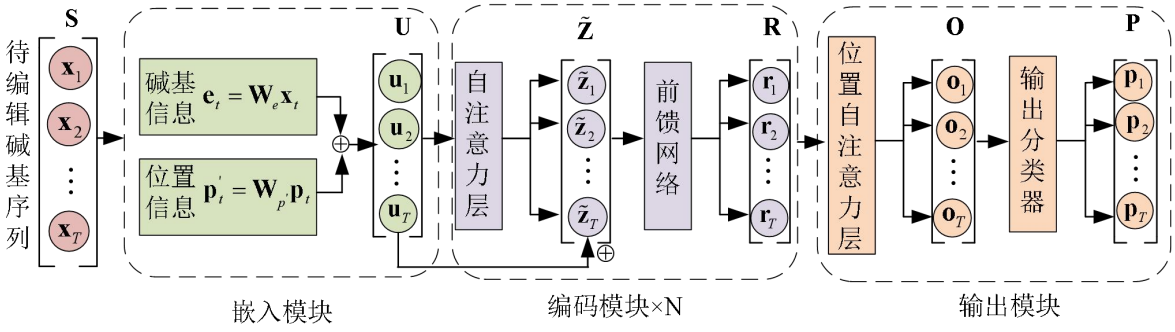


图 3

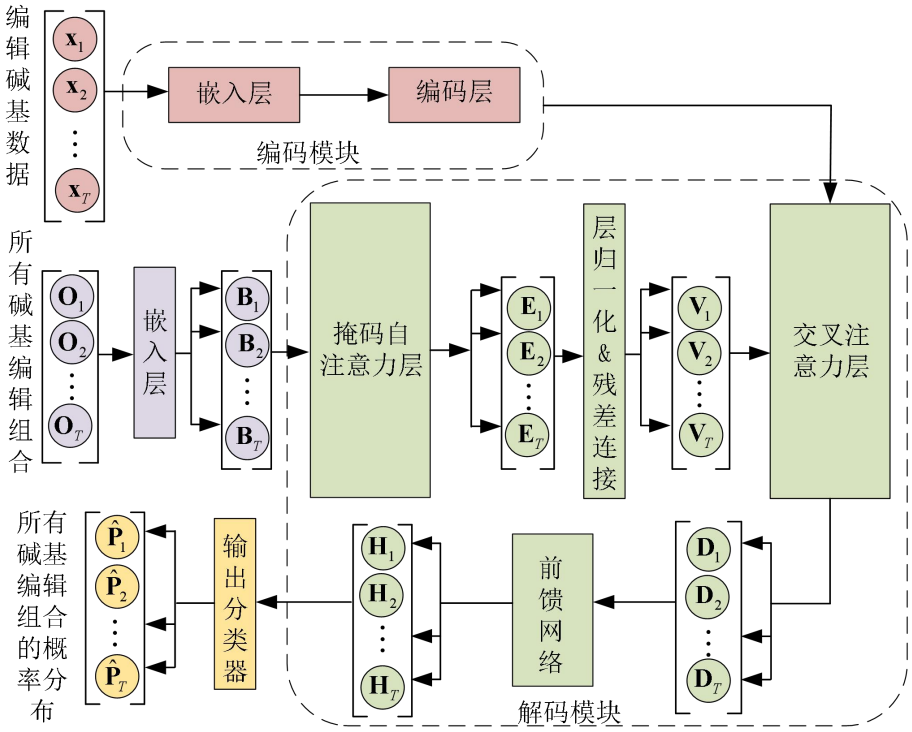

编辑碱基数据
嵌入层
编码层
编码模块
所有碱基编辑组合
嵌入层
掩码自注意力层
层归一化&残差连接
交叉注意力层
所有碱基编辑组合的概率分布
输出分类器
前馈网络
解码模块

图 4

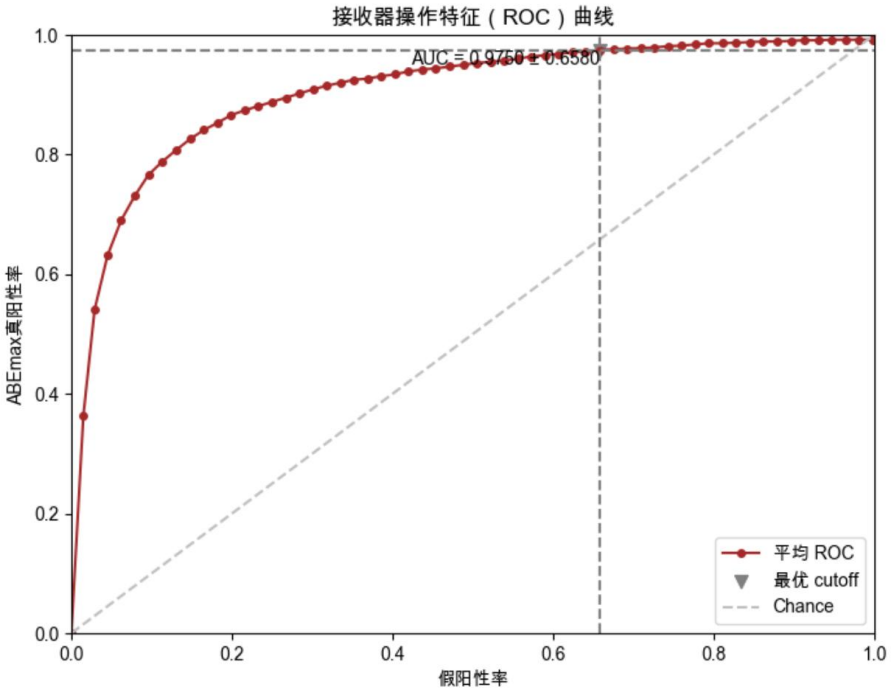

接收器操作特征（ROC）曲线
AUC = 0.9750 ± 0.6580
ABEmax真阳性率
假阳性率
平均 ROC
最优 cutoff
Chance

图 5

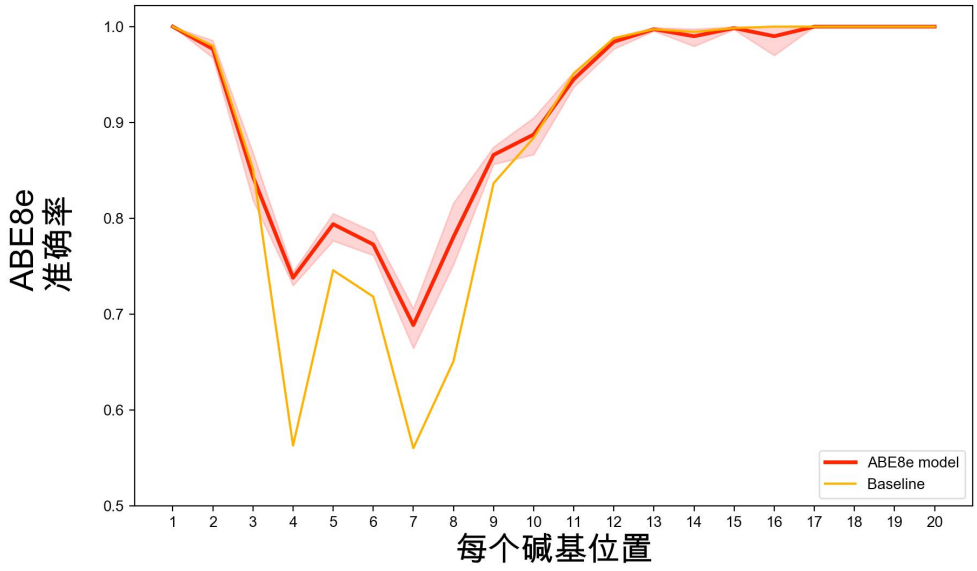


图 6

单碱基编辑模块的超参数配置范围

|-嵌入模块
|--核苷酸嵌入层嵌入维度d.....{16, 32, 64, 128}
|--位置嵌入层嵌入维度.....{16, 32, 64, 128}
|-编码器模块
|--自注意力层
|---注意力头数 .....{2, 4, 6, 8, 12}
|---注意力类型 .....{wide, Narrow}
|--Dropout .....{0.1, 0.25, 0.45}
|--前馈网络层
|---MLP嵌入因子(乘以ξ).....{2, 3}
|---非线性函数 .....{tanh, ELU, ReLU}
|--编码器块的重复次数..... {1, 2, 4}
|--L2范数正则化参数λ.....{10^-5, 10^-4, 10^-3, 10^-2, 10^-1}
|-训练期间的批次大小.....{300, 400, 500, 1000, 1500, 2000}
|--优化算法.....{Adam}

图 7

```
旁编辑模块的超参数配置范围
|-嵌入模块
|--核苷酸嵌入层嵌入维度d.....{16, 32, 64, 128}
|--位置嵌入层嵌入维度.....{16, 32, 64, 128}
|-编码器模块
|--自注意力层
|---注意力头数 .....{2, 4, 6, 8, 12}
|---注意力类型 .....{wide, Narrow}
|--Dropout .....{0.1, 0.25, 0.45}
|--前馈网络层
|---MLP嵌入因子(乘以ξ).....{2, 3}
|---非线性函数 .....{tanh, ELU, ReLU}
|--编码器块的重复次数..... {1, 2, 4}
|-解码器模块
|--掩码自注意力层
|---注意力头数.....{2, 4, 6, 8, 12}
|---注意力类型 .....{wide, Narrow}
|--交叉注意力层
|---注意力头数.....{2, 4, 6, 8, 12}
|---注意力类型.....{wide, Narrow}
|---Dropout.....{0.1, 0.25, 0.45}
|--前馈网络层MLP
|---嵌入因子(乘以ξ).....{2, 3}
|---非线性函数.....{tanh, ELU, ReLU}
|--解码器模块的重复次数.....{1, 2, 4}
|--L2范数正则化参数λ.....{10^-5, 10^-4, 10^-3, 10^-2, 10^-1}
|-训练期间的批次大小.....{300, 400, 500, 1000, 1500, 2000}
|--优化算法.....{Adam}
```

图 8

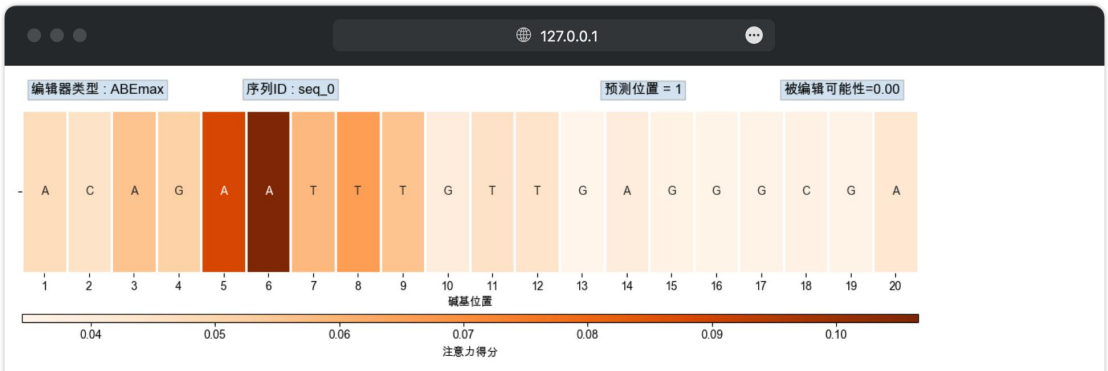


图 9

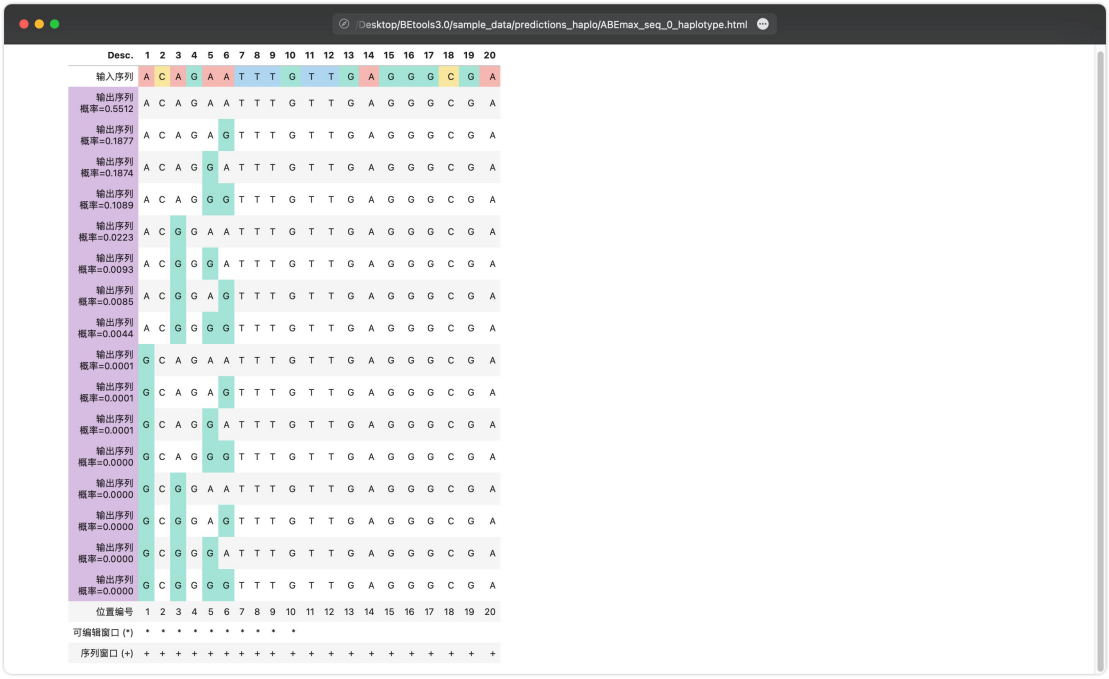
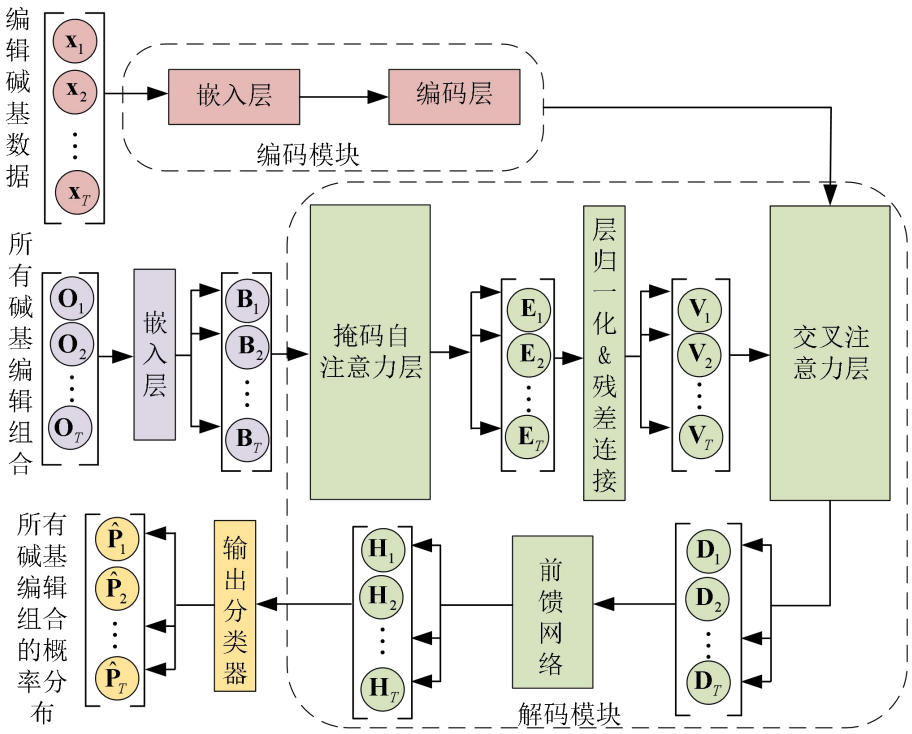


图 10

说明书摘要

本发明提供一种基于 Transformer 架构的单碱基编辑结果预测方法，所述方法包括数据集预处理、模型构建、模型评估、模型输出四个步骤。所涉及模型包含碱基编辑效率预测模型和旁编辑模型。碱基编辑效率模型结构为，预处理后的输入数据经过嵌入模块，编码器模块，输出模块，得到每个目标碱基的编辑概率，使用 L2 正则的交叉熵计算平均损失。旁编辑测测模型结构为，预处理后的输入数据经过嵌入模块，编码器模块，解码器模块，输出模块，得到输入序列所有可能编辑产物及其概率。旁编辑模型使用 L2 正则的 KL 散度计算平均损失。本发明能显著提高预测任何碱基编辑器在给定输入序列时的碱基编辑结果，包括碱基编辑效率和编辑产物，预测精度较已有的预测算法有所提高。本发明可以在不需要生物实验的情况下指导碱基编辑工作和碱基编辑器的优化，有助于研究人员提高实验效率，节约实验成本。

摘要附图


编辑碱基数据
嵌入层
编码层
编码模块
所有碱基编辑组合
嵌入层
掩码自注意力层
层归一化&残差连接
交叉注意力层
所有碱基编辑组合的概率分布
输出分类器
前馈网络
解码模块

申请材料分析说明

1.基础信息

专利名称：一种基于 Transformer 架构的碱基编辑结果预测模型

状态：审查中

2.交底材料

本案是以正式的专利文稿的形式提供的交底材料。交底材料内容相对较为充实，且提供了非常详细的测试数据。

交底材料中务必不要提供权利要求书。

背景技术部分仅仅只是讲解了本领域的技术现状，但缺乏对于技术问题的直接性表述。

技术方案的讲解稍显混乱，对于神经网络相关的专利，最好先单独讲解本案所提出（或改进）的神经网络的结构，之后在讲解基于本神经网络的相关应用。而当前交底材料则将模型结构的说明混杂在碱基编辑结果预测方法步骤之中，给他人阅读造成一定的障碍。

图 1 图 2 所示数据集示例，意义不大，如果要放进专利中，最好直接以 word 中的表格形式放出，而非插入在附图中展示；同样的，图 7 和图 8 也是。

在神经网络类的发明中，数据集的收集处理，模型构建过程，模型交互界面的构建，均为本领域的常规操作，因此最好不要作为方法的步骤来写出，而是直接写成采用某某神经网络执行某某操作即可。

3.权利要求书

直接以“预测模型”作为权利要求的主题进行保护，保护点相比交底材料中原定的某某方法，更加直接明了。

4.说明书

背景技术部分，技术问题交代明确——替代传统生物实验法，实现碱基编辑结果的虚拟仿真预测。

具体实施方式部分，首先给出了本发明最核心创新部分——即预测模型的讲解说明；之后基于该模型进行单碱基编辑效率预测的测试。

有益效果部分，一方面通过对模型结构的分析，以说理的方式论述有益效果，另一方面在测试例中，通过实际仿真测试获得的数据，验证本发明的效果。

申请稿

说明书摘要

本发明提供了一种基于 Transformer 架构的碱基编辑结果预测模型，包括①编辑效率预测模型和②旁编辑预测模型；其中编辑效率预测模型包括由嵌入层和编码层构成的编码模块和由分类器构成的输出模块，针对待编辑的碱基序列用以预测碱基编辑效率；所述旁编辑预测模型则包括编码模块、解码模块和输出分类器，针对待编辑的碱基序列及其所有可能的编辑结果，预测所有可能的编辑结果的概率分布。本发明基于 Transformer 架构的碱基编辑结果预测模型能够替代传统生物实验法，实现碱基编辑结果的虚拟仿真预测。

权利要求书

1.一种基于 Transformer 架构的碱基编辑结果预测模型，其特征在于：包括编辑效率预测模型，其中设有编码模块和输出模块，模型的输入为待编辑的碱基序列 $\mathrm{X} = [\mathrm{x}_1, \mathrm{x}_2, \cdots, \mathrm{x}_T]$；

所述编码模块中包括嵌入层和 N 个编码层；所述嵌入层负责将待编辑的碱基序列 X由独热编码形式转换为向量形式 $\mathrm{U} = [\mathrm{u}_1, \mathrm{u}_2, \cdots, \mathrm{u}_T]$，转换后的序列 U再经由 N 个编码层处理得到一个新序列 $\mathrm{R} = [\mathrm{r}_1, \mathrm{r}_2, \cdots, \mathrm{r}_T]$；

所述输出模块中，序列 R经分类器处理预测出各碱基的编辑效率 $\mathrm{S} = [\mathrm{s}_1, \mathrm{s}_2, \cdots, \mathrm{s}_T]$。

2.根据权利要求 1 所述的基于 Transformer 架构的碱基编辑结果预测模型，其特征在于：所述嵌入层的转换过程为：

$$\mathrm{e}_t = \mathrm{W}_e \mathrm{x}_t$$

$$\mathrm{p}_t^{'} = \mathrm{W}_p \mathrm{p}_t$$

$$\mathrm{u}_t = \mathrm{e}_t + \mathrm{p}_t^{'}$$

其中，x_t为独热编码形式序列中的第 t个元素，p_t为 x_t的对应位置，u_t为 x_t对应的转换结果，嵌入矩阵 $\mathrm{W}_e \in \mathbb{R}^{d_e \times K}$，$K$为独热编码的长度，向量 $\mathrm{e}_t \in \mathbb{R}^{d_e}$，嵌入矩阵 $\mathrm{W}_p \in \mathbb{R}^{d_p \times T}$，向量 $\mathrm{p}_t^{'} \in \mathbb{R}^{d_p}$，向量 $\mathrm{u}_t \in \mathbb{R}^{d}$，

$\forall t \in [1,\cdots,T]$，$d_e$、$d_p$、$d$为向量维度。

3.根据权利要求 1 所述的基于 Transformer 架构的碱基编辑结果预测模型，其特征在于：所述编码层中设有多头自注意力层和前馈网络，其中：

S1，编码层的输入序列先经由多头注意力层处理后得到序列 $\tilde{\mathrm{Z}} = [\tilde{\mathrm{z}}_1, \tilde{\mathrm{z}}_2, \cdots, \tilde{\mathrm{z}}_T]$：

$$\begin{cases} \mathrm{q}_t^h = \mathrm{W}_{query}^h \mathrm{u}_t \\ \mathrm{k}_t^h = \mathrm{W}_{key}^h \mathrm{u}_t \\ \mathrm{v}_t^h = \mathrm{W}_{value}^h \mathrm{u}_t \end{cases}$$

$$\begin{cases} \alpha_{t,l}^h = \dfrac{\exp\left(score\left(\mathrm{q}_t^h, \mathrm{k}_l^h\right)\right)}{\sum_{l'=1}^{T} \exp\left(score\left(\mathrm{q}_t^h, \mathrm{k}_{l'}^h\right)\right)} \\ score\left(\mathrm{q}_t^h, \mathrm{k}_l^h\right) = \dfrac{\left(\mathrm{q}_t^h\right)^{\mathrm{T}} \mathrm{k}_l^h}{\sqrt{d}} \end{cases}$$

$$\mathrm{z}_t^h = \sum_{l=1}^{T} \alpha_{t,l}^h \mathrm{v}_l^h$$

$$\mathrm{z}_t^{conact} = concat(\mathrm{z}_t^1, \mathrm{z}_t^2, \cdots, \mathrm{z}_t^H),\ \mathrm{z}_t^{conact} \in \mathbb{R}^{d' H}$$

$$\tilde{\mathrm{z}}_t = \mathrm{W}_{unify} \mathrm{z}_t^{conact} + \mathrm{b}_{unify}$$

其中，u_t为编码层输入序列中第 t个元素，$\tilde{\mathrm{z}}_t$为序列 $\tilde{\mathrm{Z}}$中第 t个元素，$\forall t \in [1,\cdots,T]$，查询矩阵$\mathrm{W}_{query}^h$、键矩阵$\mathrm{W}_{key}^h$、值矩阵$\mathrm{W}_{value}^h \in \mathbb{R}^{d' \times d}$，$d'$为向量维度，$\forall l \in [1,\cdots,T]$，$\mathrm{W}_{unify}$为线性变换矩阵，$\mathrm{b}_{unify}$为平移变换向量，$\mathrm{W}_{unify} \in \mathbb{R}^{d' \times dH}$，$\mathrm{b}_{unify} \in \mathbb{R}^{d'}$；

S2，序列 $\tilde{\mathrm{Z}}$与编码层的输入序列做求和与归一化处理得到序列 $\mathrm{Z} = [\mathrm{z}_1, \mathrm{z}_2, \cdots, \mathrm{z}_T]$：

$$\hat{\mathrm{z}}_t = \tilde{\mathrm{z}}_t + \mathrm{u}_t$$

$$\mathrm{z}_t = LN(\hat{\mathrm{z}}_t)$$

其中，$LN(\cdot)$为归一化操作，z_t为序列 Z中第 t个元素；

S3，序列 Z在前馈网络中嵌入从上层学习到的向量表示，得到序列

$\widetilde{\mathrm{R}} = [\tilde{\mathrm{r}}_1, \tilde{\mathrm{r}}_2, \cdots, \tilde{\mathrm{r}}_T]$：

$$\tilde{\mathrm{r}}_t = \mathrm{W}_{MLP2} ReLU(\mathrm{W}_{MLP1}\mathrm{z}_t + \mathrm{b}_{MLP1}) + \mathrm{b}_{MLP2}$$

其中 $ReLU(\cdot)$ 为线性整流函数，$\mathrm{W}_{MLP1} \in \mathbb{R}^{\xi d' \times d'}$，$\mathrm{b}_{MLP1} \in \mathbb{R}^{\xi d'}$，$\mathrm{W}_{MLP2} \in \mathbb{R}^{d' \times \xi d'}$，$\mathrm{b}_{MLP2} \in \mathbb{R}^{d'}$，$\xi \in \mathbb{N}$为乘法因子；

S4，序列 $\widetilde{\mathrm{R}}$与序列 Z进行求和与归一化处理，得到所述序列 R：

$$\hat{\mathrm{r}}_t = \tilde{\mathrm{r}}_t + \mathrm{z}_t$$

$$\mathrm{r}_t = LN(\hat{\mathrm{r}}_t)$$

其中，r_t为序列 R中第 t个元素；

所述 S2 和 S3 中归一化操作具体采用层均衡方法：

$$LN(\hat{\mathrm{z}}_t) = \gamma \times \frac{\hat{\mathrm{z}}_t - \mu_t}{\sqrt{\sigma_t^2 + \varepsilon}} + \beta$$

$$\mu_t = \frac{1}{d'}\sum_{j=1}^{d'} \hat{\mathrm{z}}_{t,j}$$

$$\sigma_t^2 = \frac{1}{d'}\sum_{j=1}^{d'} \left(\hat{\mathrm{z}}_{t,j} - \mu_t\right)^2$$

其中，下标 j用以表明 $\hat{\mathrm{z}}_t$是以 j维向量形式表示，μ_t和 σ_t^2分别为向量 $\hat{\mathrm{z}}_t$的均值和方差，γ为缩放参数，β为偏移参数，ε为极小数。

4.根据权利要求 3 所述的基于 Transformer 架构的碱基编辑结果预测模型，其特征在于：所述输出模块包括位置注意力层和分类器，其中：

位置注意力层中，对序列 R处理得到序列 $\mathrm{O} = [\mathrm{o}_1, \mathrm{o}_2, \cdots, \mathrm{o}_T]$：

$$\begin{cases} \varphi_{t,l} = \dfrac{\exp\left(score(\mathrm{c}_t, \mathrm{r}_l)\right)}{\sum_{l'=1}^{T} \exp\left(score\left(\mathrm{c}_t, \mathrm{r}_{l'}\right)\right)} \\ score(\mathrm{c}_t, \mathrm{r}_l) = \dfrac{(\mathrm{c}_t)^{\mathrm{T}}\mathrm{r}_l}{\sqrt{d'}} \end{cases}$$

$$\mathrm{o}_t = \sum_{l=1}^{T} \varphi_{t,l}\, \mathrm{r}_l$$

其中，$\varphi_{t,l}$为注意力分数，c_t为序列$C=[c_1,c_2,\cdots,c_T]$中第t个元素，序列C为对应于输入序列R中每个位置的全局上下文向量序列，o_t为序列O中第t个元素，$\forall t\in[1,\cdots,T]$，$\forall l\in[1,\cdots,T]$；

分类器中，序列O经仿射转换和 softmax 操作，得到编辑效率$S=[s_1,s_2,\cdots,s_T]$：

$$s_t=\sigma(W_o o_t+b_o)$$

其中s_t为位置t处的碱基编辑效率，W_o为线性变换矩阵，b_o为平移变换向量，$\sigma(\cdot)$表示 softmax 函数。

5.根据权利要求 1 所述的基于 Transformer 架构的碱基编辑结果预测模型，其特征在于：所述编辑效率预测模型的损失函数为：

$$L(\theta)=\frac{1}{N}\sum_{i=1}^{N}L_i^{\text{target}}+\frac{\lambda}{2}\|\theta\|_2^2$$

$$L_i^{\text{target}}=\frac{1}{\sum_{t=1}^{T}\mathbb{I}\left[x_{t,\text{base}}^{(i)}=1\right]}\sum_{t=1}^{T}l_t^{(i)}\mathbb{I}\left[x_{t,\text{base}}^{(i)}=1\right]$$

$$l_t^{(i)}=-\sum_{c=1}^{|Voutcome|}y_{t,c}^{(i)}\times\log\left(\hat{y}_{t,c}^{(i)}\right)$$

其中，N为训练集中的样本数，λ为l_2正则化系数，θ代表模型的参数或权重；$\mathbb{I}\left[x_{t,\text{base}}^{(i)}=1\right]$是一个指示函数，表示当$i$个样本序列中位置$t$处的碱基$x_t$为目标碱基时，该函数的值为 1；$l_{t,\text{base}}^{(i)}$为第$i$个样本序列中位置$t$处的碱基$x_t$为目标碱基时的交叉熵损失；$|Voutcome|$为第$i$个碱基样本序列位置$t$处编辑结果，$y_{t,c}^{(i)}$为该位置的实际编辑结果，$\hat{y}_{t,c}^{(i)}$为该位置的预测编辑结果。

6.一种基于 Transformer 架构的碱基编辑结果预测模型，其特征在于：包括旁编辑预测模型，其中设有编码模块和解码模块，模型的输入量为待编辑的碱基序列$X=[x_1,x_2,\cdots,x_T]$及其所有可能的编辑结果$A=[A_1,A_2,\cdots,A_F]$，$A_f=[a_{f,1},a_{f,2},\cdots,a_{f,T}]$，

$\forall f \in [1, \cdots, F]$;

编码模块：包括嵌入层和 N 个编码层；所述嵌入层负责将待编辑的碱基序列 X由独热编码形式转换为向量形式 $U = [u_1, u_2, \cdots, u_T]$, 转换后的序列 U再经由 N 个编码层处理得到序列 $R = [r_1, r_2, \cdots, r_T]$;

所有可能的编辑结果 $A_f = [a_{f,1}, a_{f,2}, \cdots, a_{f,T}]$分别经嵌入层转换对应的向量形式 $B_f = [b_{f,1}, b_{f,2}, \cdots, b_{f,T}]$;

解码模块：

T1，序列 B_f经掩码自注意力层处理得到序列 $F_f = [f_{f,1}, f_{f,2}, \cdots, f_{f,T}]$;

T2，序列 F_f与序列 B_f求和与归一化处理得到序列 $G_f = [g_{f,1}, g_{f,2}, \cdots, g_{f,T}]$;

T3，交叉注意力层中，序列 G_f用于查询，序列 R作为键值计算查询和键矩阵间的注意力分数，并基于所得注意力分数计算出一个新序列 $D_f = [d_{f,1}, d_{f,2}, \cdots, d_{f,T}]$;

T4，序列 D_f经前馈网络处理得到 $H_f = [h_{f,1}, h_{f,2}, \cdots, h_{f,T}]$;

模型输出：

序列 H_f经分类器处理得到对应第 f个可能编辑结果的出现概率 m_f，汇总得到与所有可能的编辑结果 $A = [A_1, A_2, \cdots, A_F]$相对应的概率分布 $M = [m_1, m_2, \cdots, m_F]$。

7.根据权利要求 6 所述的基于 Transformer 架构的碱基编辑结果预测模型，其特征在于：所述嵌入层的转换过程为：

$$e_t = W_e x_t$$

$$p_t^{'} = W_p p_t$$

$$u_t = e_t + p_t^{'}$$

其中，x_t为独热编码形式序列中的第t个元素，p_t为x_t的对应位置，u_t为x_t对应的转换结果，嵌入矩阵$W_e \in \mathbb{R}^{d_e \times K}$，$K$为独热编码的长度，向量$e_t \in \mathbb{R}^{d_e}$，嵌入矩阵$W_p \in \mathbb{R}^{d_p \times T}$，向量$p_t^{'} \in \mathbb{R}^{d_p}$，向量$u_t \in \mathbb{R}^{d}$，$\forall t \in [1,\cdots,T]$，$d_e$、$d_p$、$d$为向量维度。

8.根据权利要求 6 所述的基于 Transformer 架构的碱基编辑结果预测模型，其特征在于：所述编码层中设有多头自注意力层和前馈网络，其中：

S1，编码层的输入序列先经由多头注意力层处理后得到序列$\tilde{Z} = [\tilde{z}_1, \tilde{z}_2, \cdots, \tilde{z}_T]$：

$$\begin{cases} q_t^h = W_{query}^h u_t \\ k_t^h = W_{key}^h u_t \\ v_t^h = W_{value}^h u_t \end{cases}$$

$$\begin{cases} \alpha_{t,l}^h = \dfrac{\exp\left(score\left(q_t^h, k_l^h\right)\right)}{\sum_{l'=1}^{T} \exp\left(score\left(q_t^h, k_{l'}^h\right)\right)} \\ score\left(q_t^h, k_l^h\right) = \dfrac{\left(q_t^h\right)^{\mathrm{T}} k_l^h}{\sqrt{d}} \end{cases}$$

$$z_t^h = \sum_{l=1}^{T} \alpha_{t,l}^h v_l^h$$

$$z_t^{conact} = concat(z_t^1, z_t^2, \cdots, z_t^H),\ z_t^{conact} \in \mathbb{R}^{d^{'}H}$$

$$\tilde{z}_t = W_{unify} z_t^{conact} + b_{unify}$$

其中，u_t为编码层输入序列中第t个元素，$\tilde{z}_t$为序列$\tilde{Z}$中第t个元素，$\forall t \in [1,\cdots,T]$，查询矩阵$W_{query}^h$、键矩阵$W_{key}^h$、值矩阵$W_{value}^h \in \mathbb{R}^{d^{'} \times d}$，$d^{'}$为向量维度，$\forall l \in [1,\cdots,T]$，$W_{unify}$为线性变换矩阵，$b_{unify}$为平移变换向量，$W_{unify} \in \mathbb{R}^{d^{'} \times dH}$，$b_{unify} \in \mathbb{R}^{d^{'}}$；

S2，序列$\tilde{Z}$与编码层的输入序列做求和与归一化处理得到序列$Z = [z_1, z_2, \cdots, z_T]$：

$\hat{\mathrm{z}}_t = \tilde{\mathrm{z}}_t + \mathrm{u}_t$

$\mathrm{z}_t = LN(\hat{\mathrm{z}}_t)$

其中，$LN(\cdot)$为归一化操作，z_t为序列Z中第t个元素；

S3，序列Z在前馈网络中嵌入从上层学习到的向量表示，得到序列$\tilde{\mathrm{R}} = [\tilde{\mathrm{r}}_1, \tilde{\mathrm{r}}_2, \cdots, \tilde{\mathrm{r}}_T]$：

$\tilde{\mathrm{r}}_t = \mathrm{W}_{MLP2} ReLU(\mathrm{W}_{MLP1}\mathrm{z}_t + \mathrm{b}_{MLP1}) + \mathrm{b}_{MLP2}$

其中$ReLU(\cdot)$为线性整流函数，$\mathrm{W}_{MLP1} \in \mathbb{R}^{\xi d' \times d'}$，$\mathrm{b}_{MLP1} \in \mathbb{R}^{\xi d'}$，$\mathrm{W}_{MLP2} \in \mathbb{R}^{d' \times \xi d'}$，$\mathrm{b}_{MLP2} \in \mathbb{R}^{d'}$，$\xi \in \mathbb{N}$为乘法因子；

S4，序列$\tilde{\mathrm{R}}$与序列Z进行求和与归一化处理，得到所述序列R：

$\hat{\mathrm{r}}_t = \tilde{\mathrm{r}}_t + \mathrm{z}_t$

$\mathrm{r}_t = LN(\hat{\mathrm{r}}_t)$

其中，r_t为序列R中第t个元素；

所述归一化操作具体采用层均衡方法：

$$LN(\hat{\mathrm{z}}_t) = \gamma \times \frac{\hat{\mathrm{z}}_t - \mu_t}{\sqrt{\sigma_t^2 + \varepsilon}} + \beta$$

$$\mu_t = \frac{1}{d'}\sum_{j=1}^{d'} \hat{\mathrm{z}}_{t,j}$$

$$\sigma_t^2 = \frac{1}{d'}\sum_{j=1}^{d'} \left(\hat{\mathrm{z}}_{t,j} - \mu_t\right)^2$$

其中，下标j用以表明$\hat{\mathrm{z}}_t$是以j维向量形式表示，μ_t和σ_t^2分别为向量$\hat{\mathrm{z}}_t$的均值和方差，γ为缩放参数，β为偏移参数，ε为极小数。

9.根据权利要求 6 所述的基于 Transformer 架构的单碱基编辑结果预测模型，其特征在于：所述解码模块中 T4 前馈网络的处理过程为：

$\mathrm{h}_{f,t} = \mathrm{W}_{MLP2} ReLU\left(\mathrm{W}_{MLP1}\mathrm{d}_{f,t} + \mathrm{b}_{MLP1}\right) + \mathrm{b}_{MLP2}$

其中 $ReLU(\cdot)$ 为线性整流函数，$\mathrm{W}_{MLP1}\in\mathbb{R}^{\xi d^{'}\times d^{'}}$，$\mathrm{b}_{MLP1}\in\mathbb{R}^{\xi d^{'}}$，$\mathrm{W}_{MLP2}\in\mathbb{R}^{d^{'}\times\xi d^{'}}$，$\mathrm{b}_{MLP2}\in\mathbb{R}^{d^{'}}$，$\xi\in\mathbb{N}$为乘法因子；

所述分类器的处理过程为：

$$\mathrm{m}_f=\prod_{t=1}^{T}\mathrm{m}_{f,t}$$

$$\mathrm{m}_{f,t}=\sigma\left(\mathrm{W}_m\mathrm{h}_{f,t}+\mathrm{b}_m\right)$$

其中，W_m为线性变换矩阵，b_m为平移变换向量，$\sigma(\cdot)$表示 softmax 函数。

10.根据权利要求 6 所述的基于 Transformer 架构的碱基编辑结果预测模型，其特征在于：所述旁编辑预测模型的损失函数为：

$$L(\theta)=\frac{1}{N}\sum_{i=1}^{N}D_{KL-div}^{i}(y^i\|\hat{y}^i)+\frac{\lambda}{2}\|\theta\|_2^2$$

$$D_{KL-div}^{i}(y^i\|\hat{y}^i)=\sum_{f=1}^{F}y_f^i\log\left(\frac{y_f^i}{\hat{y}_f^i}\right)$$

其中，y^i代表实际的概率分布，$\hat{y}^i$代表本发明模型的估计分布，θ代表模型的参数或权重，λ为 l_2正则化系数，N为训练集中的样本数。

一种基于 Transformer 架构的碱基编辑结果预测模型

技术领域

本发明属于人工智能技术领域，具体涉及一种基于 Transformer 架构的碱基编辑结果预测模型。

背景技术

碱基编辑（Base Editing，BE）是自 2016 年起发展起来的一种基因编辑技术；其中依据靶基因的不同，可分为腺嘌呤碱基编辑（Adenine Base Editing，ABE）、胞嘧啶碱基编辑（Cytosin Base Editing，CBE）和胞嘧啶鸟嘌呤碱基编辑（Cytosine Guanine Base Editing，CGBE）三中，分别能够实现 A→G、T→C、C→G 的碱基转换。碱基编辑技术不依赖于 DNA 双链断裂，能够高效、精准地诱导 DNA 或 RNA 中单碱基的替换；具有高效、精准、特异性好等优点；因而在基因治疗、精准动植物育种和基因功能分析等领域具有广泛的应用。

碱基编辑效率（衡量基因编辑技术成功修改目标 DNA 碱基的比例）与编辑结果产物纯度是碱基编辑技术的两项最重要指标，用于评判某一碱基编辑技术能否最终走到临床应用。而当前碱基编辑效率与编辑产物受编辑因素影响机理尚不明确，因此目前主要还是依靠经验和大量尝试来进行优化相关碱基编辑技术。随着人工智能技术的发展，如若能基于深度学习技术进行编辑结果预测，则可以在不需要生物实验的情况下指导碱基编辑工作和碱基编辑器的优化，有助于研究人员提高实验效率，节约实验成本。

发明内容

针对现有技术中存在的不足，本发明提供了一种基于 Transformer 架构的碱基编辑结果预测模型，用以替代传统生物实验法，实现碱基编辑结果的虚拟仿真预测。

本发明通过以下技术手段实现上述技术目的。

一种基于 Transformer 架构的碱基编辑结果预测模型：包括编辑效率预测模型，其中设有编码模块和输出模块，模型的输入为待编辑的碱基序列 $X = [x_1, x_2, \cdots, x_T]$；

所述编码模块中包括嵌入层和 N 个编码层；所述嵌入层负责将待编辑的碱基序列 X 由独热编码形式转换为向量形式 $U = [u_1, u_2, \cdots, u_T]$，转换后的序列 U 再经由 N 个编码层处理得到一个新序列 $R = [r_1, r_2, \cdots, r_T]$；

所述输出模块中，序列 R 经分类器处理预测出各碱基的编辑效率

$S = [s_1, s_2, \cdots, s_T]$。

进一步地，所述嵌入层的转换过程为：

$$e_t = W_e x_t$$

$$p_t^{'} = W_p p_t$$

$$u_t = e_t + p_t^{'}$$

其中，x_t为独热编码形式序列中的第t个元素，p_t为x_t的对应位置，u_t为x_t对应的转换结果，嵌入矩阵$W_e \in \mathbb{R}^{d_e \times K}$，$K$为独热编码的长度，向量$e_t \in \mathbb{R}^{d_e}$，嵌入矩阵$W_p \in \mathbb{R}^{d_p \times T}$，向量$p_t^{'} \in \mathbb{R}^{d_p}$，向量$u_t \in \mathbb{R}^{d}$，$\forall t \in [1, \cdots, T]$，$d_e$、$d_p$、$d$为向量维度。

进一步地，所述编码层中设有多头自注意力层和前馈网络，其中：

S1，编码层的输入序列先经由多头注意力层处理后得到序列$\tilde{Z} = [\tilde{z}_1, \tilde{z}_2, \cdots, \tilde{z}_T]$：

$$\begin{cases} q_t^h = W_{query}^h u_t \\ k_t^h = W_{key}^h u_t \\ v_t^h = W_{value}^h u_t \end{cases}$$

$$\begin{cases} \alpha_{t,l}^h = \dfrac{\exp\left(score\left(q_t^h, k_l^h\right)\right)}{\sum_{l^{'}=1}^{T} \exp\left(score\left(q_t^h, k_{l^{'}}^h\right)\right)} \\ score\left(q_t^h, k_l^h\right) = \dfrac{\left(q_t^h\right)^{\mathrm{T}} k_l^h}{\sqrt{d}} \end{cases}$$

$$z_t^h = \sum_{l=1}^{T} \alpha_{t,l}^h v_l^h$$

$$z_t^{conact} = concat(z_t^1, z_t^2, \cdots, z_t^H), \quad z_t^{conact} \in \mathbb{R}^{d^{'}H}$$

$$\tilde{z}_t = W_{unify} z_t^{conact} + b_{unify}$$

其中，u_t为编码层输入序列中第t个元素，$\tilde{z}_t$为序列$\tilde{Z}$中第t个元素，$\forall t \in [1, \cdots, T]$，查询矩阵$W_{query}^h$、键矩阵$W_{key}^h$、值矩阵$W_{value}^h \in \mathbb{R}^{d^{'} \times d}$，$d^{'}$为向量

维度，$\forall l \in [1,\cdots,T]$，$\mathrm{W}_{unify}$为线性变换矩阵，$\mathrm{b}_{unify}$为平移变换向量，$\mathrm{W}_{unify} \in \mathbb{R}^{d^{'} \times dH}$，$\mathrm{b}_{unify} \in \mathbb{R}^{d^{'}}$；

S2，序列$\tilde{\mathrm{Z}}$与编码层的输入序列做求和与归一化处理得到序列$\mathrm{Z} = [\mathrm{z}_1, \mathrm{z}_2, \cdots, \mathrm{z}_T]$：

$$\hat{\mathrm{z}}_t = \tilde{\mathrm{z}}_t + \mathrm{u}_t$$

$$\mathrm{z}_t = LN(\hat{\mathrm{z}}_t)$$

其中，$LN(\cdot)$为归一化操作，z_t为序列Z中第t个元素；

S3，序列Z在前馈网络中嵌入从上层学习到的向量表示，得到序列$\tilde{\mathrm{R}} = [\tilde{\mathrm{r}}_1, \tilde{\mathrm{r}}_2, \cdots, \tilde{\mathrm{r}}_T]$：

$$\tilde{\mathrm{r}}_t = \mathrm{W}_{MLP2} ReLU(\mathrm{W}_{MLP1}\mathrm{z}_t + \mathrm{b}_{MLP1}) + \mathrm{b}_{MLP2}$$

其中$ReLU(\cdot)$为线性整流函数，$\mathrm{W}_{MLP1} \in \mathbb{R}^{\xi d^{'} \times d^{'}}$，$\mathrm{b}_{MLP1} \in \mathbb{R}^{\xi d^{'}}$，$\mathrm{W}_{MLP2} \in \mathbb{R}^{d^{'} \times \xi d^{'}}$，$\mathrm{b}_{MLP2} \in \mathbb{R}^{d^{'}}$，$\xi \in \mathbb{N}$为乘法因子；

S4，序列$\tilde{\mathrm{R}}$与序列Z进行求和与归一化处理，得到所述序列R：

$$\hat{\mathrm{r}}_t = \tilde{\mathrm{r}}_t + \mathrm{z}_t$$

$$\mathrm{r}_t = LN(\hat{\mathrm{r}}_t)$$

其中，r_t为序列R中第t个元素；

所述 S2 和 S3 中归一化操作具体采用层均衡方法：

$$LN(\hat{\mathrm{z}}_t) = \gamma \times \frac{\hat{\mathrm{z}}_t - \mu_t}{\sqrt{\sigma_t^2 + \varepsilon}} + \beta$$

$$\mu_t = \frac{1}{d^{'}} \sum_{j=1}^{d^{'}} \hat{\mathrm{z}}_{t,j}$$

$$\sigma_t^2 = \frac{1}{d^{'}} \sum_{j=1}^{d^{'}} \left(\hat{\mathrm{z}}_{t,j} - \mu_t\right)^2$$

其中，下标j用以表明$\hat{\mathrm{z}}_t$是以j维向量形式表示，μ_t和σ_t^2分别为向量

$\hat{z}_t$的均值和方差，γ为缩放参数，β为偏移参数，ε为极小数。

进一步地，所述输出模块包括位置注意力层和分类器，其中：

位置注意力层中，对序列 R处理得到序列 $O=[o_1,o_2,\cdots,o_T]$：

$$\begin{cases}\varphi_{t,l}=\dfrac{\exp\left(score(c_t,r_l)\right)}{\sum_{l'=1}^{T}\exp\left(score\left(c_t,r_{l'}\right)\right)}\\ score(c_t,r_l)=\dfrac{(c_t)^{\mathrm{T}}r_l}{\sqrt{d}}\end{cases}$$

$$o_t=\sum_{l=1}^{T}\varphi_{t,l}\,r_l$$

其中，$\varphi_{t,l}$为注意力分数，c_t为序列 $C=[c_1,c_2,\cdots,c_T]$中第 t个元素，序列 C为对应于输入序列 R中每个位置的全局上下文向量序列，o_t为序列 O中第 t个元素，$\forall t\in[1,\cdots,T]$，$\forall l\in[1,\cdots,T]$；

分类器中，序列 O经仿射转换和 softmax 操作，得到编辑效率 $S=[s_1,s_2,\cdots,s_T]$：

$$s_t=\sigma(W_o o_t+b_o)$$

其中 s_t为位置 t处的碱基编辑效率，W_o为线性变换矩阵，b_o为平移变换向量，$\sigma(\cdot)$表示 softmax 函数。

进一步地， 所述编辑效率预测模型的损失函数为：

$$L(\theta)=\frac{1}{N}\sum_{i=1}^{N}L_i^{\text{target}}+\frac{\lambda}{2}\|\theta\|_2^2$$

$$L_i^{\text{target}}=\frac{1}{\sum_{t=1}^{T}\mathbb{I}\left[x_{t,\text{base}}^{(i)}=1\right]}\sum_{t=1}^{T}l_t^{(i)}\mathbb{I}\left[x_{t,\text{base}}^{(i)}=1\right]$$

$$l_t^{(i)}=-\sum_{c=1}^{|Voutcome|}y_{t,c}^{(i)}\times\log\left(\hat{y}_{t,c}^{(i)}\right)$$

其中，N为训练集中的样本数，λ为 l_2正则化系数，θ代表模型的参数或权重；$\mathbb{I}\left[x_{t,\text{base}}^{(i)}=1\right]$是一个指示函数，表示当 i个样本序列中位置 t处的碱基 x_t为目标碱基时，该函数的值为 1；$l_{t,\text{base}}^{(i)}$为第 i个样本序列中位置 t处的碱基 x_t

为目标碱基时的交叉熵损失；$|Voutcome|$为第i个碱基样本序列位置t处编辑结果，$y_{t,c}^{(i)}$为该位置的实际编辑结果，$\hat{y}_{t,c}^{(i)}$为该位置的预测编辑结果。

上述基于 Transformer 架构的单碱基编辑结果预测模型，还包括旁编辑预测模型，其中设有编码模块和解码模块，模型的输入量为待编辑的碱基序列$\mathrm{X}=[\mathrm{x}_1,\mathrm{x}_2,\cdots,\mathrm{x}_T]$及其所有可能的编辑结果$\mathrm{A}=[\mathrm{A}_1,\mathrm{A}_2,\cdots,\mathrm{A}_F]$，$\mathrm{A}_f=[\mathrm{a}_{f,1},\mathrm{a}_{f,2},\cdots,\mathrm{a}_{f,T}]$，$\forall f\in[1,\cdots,F]$；

编码模块：包括嵌入层和 N 个编码层；所述嵌入层负责将待编辑的碱基序列X由独热编码形式转换为向量形式$\mathrm{U}=[\mathrm{u}_1,\mathrm{u}_2,\cdots,\mathrm{u}_T]$，转换后的序列$\mathrm{U}$再经由 N 个编码层处理得到序列$\mathrm{R}=[\mathrm{r}_1,\mathrm{r}_2,\cdots,\mathrm{r}_T]$；

所有可能的编辑结果$\mathrm{A}_f=[\mathrm{a}_{f,1},\mathrm{a}_{f,2},\cdots,\mathrm{a}_{f,T}]$分别经嵌入层转换对应的向量形式$\mathrm{B}_f=[\mathrm{b}_{f,1},\mathrm{b}_{f,2},\cdots,\mathrm{b}_{f,T}]$；

解码模块：

T1，序列B_f经掩码自注意力层处理得到序列$\mathrm{F}_f=[\mathrm{f}_{f,1},\mathrm{f}_{f,2},\cdots,\mathrm{f}_{f,T}]$；

T2，序列F_f与序列B_f求和与归一化处理得到序列$\mathrm{G}_f=[\mathrm{g}_{f,1},\mathrm{g}_{f,2},\cdots,\mathrm{g}_{f,T}]$；

T3，交叉注意力层中，序列G_f用于查询，序列R作为键值计算查询和键矩阵间的注意力分数，并基于所得注意力分数计算出一个新序列$\mathrm{D}_f=[\mathrm{d}_{f,1},\mathrm{d}_{f,2},\cdots,\mathrm{d}_{f,T}]$；

T4，序列D_f经前馈网络处理得到$\mathrm{H}_f=[\mathrm{h}_{f,1},\mathrm{h}_{f,2},\cdots,\mathrm{h}_{f,T}]$；

模型输出：

序列H_f经分类器处理得到对应第f个可能编辑结果的出现概率m_f，汇总得到与所有可能的编辑结果$\mathrm{A}=[\mathrm{A}_1,\mathrm{A}_2,\cdots,\mathrm{A}_F]$相对应的概率分布$\mathrm{M}=[\mathrm{m}_1,\mathrm{m}_2,\cdots,\mathrm{m}_F]$。

进一步地，所述嵌入层的转换过程为：

$$\mathrm{e}_t = \mathrm{W}_e \mathrm{x}_t$$

$$\mathrm{p}_t^{'} = \mathrm{W}_p \mathrm{p}_t$$

$$\mathrm{u}_t = \mathrm{e}_t + \mathrm{p}_t^{'}$$

其中，x_t为独热编码形式序列中的第t个元素，p_t为x_t的对应位置，u_t为x_t对应的转换结果，嵌入矩阵$\mathrm{W}_e \in \mathbb{R}^{d_e \times K}$，$K$为独热编码的长度，向量$\mathrm{e}_t \in \mathbb{R}^{d_e}$，嵌入矩阵$\mathrm{W}_p \in \mathbb{R}^{d_p \times T}$，向量$\mathrm{p}_t^{'} \in \mathbb{R}^{d_p}$，向量$\mathrm{u}_t \in \mathbb{R}^{d}$，$\forall t \in [1, \cdots, T]$，$d_e$、$d_p$、$d$为向量维度。

进一步地，所述编码层中设有多头自注意力层和前馈网络，其中：

S1，编码层的输入序列先经由多头注意力层处理后得到序列$\tilde{\mathrm{Z}} = [\tilde{\mathrm{z}}_1, \tilde{\mathrm{z}}_2, \cdots, \tilde{\mathrm{z}}_T]$：

$$\begin{cases} \mathrm{q}_t^h = \mathrm{W}_{query}^h \mathrm{u}_t \\ \mathrm{k}_t^h = \mathrm{W}_{key}^h \mathrm{u}_t \\ \mathrm{v}_t^h = \mathrm{W}_{value}^h \mathrm{u}_t \end{cases}$$

$$\begin{cases} \alpha_{t,l}^h = \dfrac{\exp\left(score\left(\mathrm{q}_t^h, \mathrm{k}_l^h\right)\right)}{\sum_{l'=1}^{T} \exp\left(score\left(\mathrm{q}_t^h, \mathrm{k}_{l'}^h\right)\right)} \\ score\left(\mathrm{q}_t^h, \mathrm{k}_l^h\right) = \dfrac{\left(\mathrm{q}_t^h\right)^{\mathrm{T}} \mathrm{k}_l^h}{\sqrt{d}} \end{cases}$$

$$\mathrm{z}_t^h = \sum_{l=1}^{T} \alpha_{t,l}^h \mathrm{v}_l^h$$

$$\mathrm{z}_t^{conact} = concat(\mathrm{z}_t^1, \mathrm{z}_t^2, \cdots, \mathrm{z}_t^H), \quad \mathrm{z}_t^{conact} \in \mathbb{R}^{d^{'}H}$$

$$\tilde{\mathrm{z}}_t = \mathrm{W}_{unify} \mathrm{z}_t^{conact} + \mathrm{b}_{unify}$$

其中，u_t为编码层输入序列中第t个元素，$\tilde{\mathrm{z}}_t$为序列$\tilde{\mathrm{Z}}$中第t个元素，$\forall t \in [1, \cdots, T]$，查询矩阵$\mathrm{W}_{query}^h$、键矩阵$\mathrm{W}_{key}^h$、值矩阵$\mathrm{W}_{value}^h \in \mathbb{R}^{d^{'} \times d}$，$d^{'}$为向量维度，$\forall l \in [1, \cdots, T]$，$\mathrm{W}_{unify}$为线性变换矩阵，$\mathrm{b}_{unify}$为平移变换向量，

$\mathrm{W}_{unify} \in \mathbb{R}^{d' \times dH}$，$\mathrm{b}_{unify} \in \mathbb{R}^{d'}$；

S2，序列 $\tilde{\mathrm{Z}}$与编码层的输入序列做求和与归一化处理得到序列 $\mathrm{Z} = [\mathrm{z}_1, \mathrm{z}_2, \cdots, \mathrm{z}_T]$：

$$\hat{\mathrm{z}}_t = \tilde{\mathrm{z}}_t + \mathrm{u}_t$$

$$\mathrm{z}_t = LN(\hat{\mathrm{z}}_t)$$

其中，$LN(\cdot)$为归一化操作，z_t为序列 Z中第 t个元素；

S3，序列 Z在前馈网络中嵌入从上层学习到的向量表示，得到序列 $\tilde{\mathrm{R}} = [\tilde{\mathrm{r}}_1, \tilde{\mathrm{r}}_2, \cdots, \tilde{\mathrm{r}}_T]$：

$$\tilde{\mathrm{r}}_t = \mathrm{W}_{MLP2} ReLU(\mathrm{W}_{MLP1}\mathrm{z}_t + \mathrm{b}_{MLP1}) + \mathrm{b}_{MLP2}$$

其中 $ReLU(\cdot)$为线性整流函数，$\mathrm{W}_{MLP1} \in \mathbb{R}^{\xi d' \times d'}$，$\mathrm{b}_{MLP1} \in \mathbb{R}^{\xi d'}$，$\mathrm{W}_{MLP2} \in \mathbb{R}^{d' \times \xi d'}$，$\mathrm{b}_{MLP2} \in \mathbb{R}^{d'}$，$\xi \in \mathbb{N}$为乘法因子；

S4，序列 $\tilde{\mathrm{R}}$与序列 Z进行求和与归一化处理，得到所述序列 R：

$$\hat{\mathrm{r}}_t = \tilde{\mathrm{r}}_t + \mathrm{z}_t$$

$$\mathrm{r}_t = LN(\hat{\mathrm{r}}_t)$$

其中，r_t为序列 R中第 t个元素；

所述归一化操作具体采用层均衡方法：

$$LN(\hat{\mathrm{z}}_t) = \gamma \times \frac{\hat{\mathrm{z}}_t - \mu_t}{\sqrt{\sigma_t^2 + \varepsilon}} + \beta$$

$$\mu_t = \frac{1}{d'} \sum_{j=1}^{d'} \hat{\mathrm{z}}_{t,j}$$

$$\sigma_t^2 = \frac{1}{d'} \sum_{j=1}^{d'} \left(\hat{\mathrm{z}}_{t,j} - \mu_t\right)^2$$

其中，下标 j用以表明 $\hat{\mathrm{z}}_t$是以 j维向量形式表示，μ_t和 σ_t^2分别为向量 $\hat{\mathrm{z}}_t$的均值和方差，γ为缩放参数，β为偏移参数，ε为极小数。

进一步地，所述解码模块中 T4 前馈网络的处理过程为：

$$\mathrm{h}_{f,t} = \mathrm{W}_{MLP2} ReLU\left(\mathrm{W}_{MLP1}\mathrm{d}_{f,t} + \mathrm{b}_{MLP1}\right) + \mathrm{b}_{MLP2}$$

其中 $ReLU(\cdot)$ 为线性整流函数，$\mathrm{W}_{MLP1} \in \mathbb{R}^{\xi d' \times d'}$，$\mathrm{b}_{MLP1} \in \mathbb{R}^{\xi d'}$，$\mathrm{W}_{MLP2} \in \mathbb{R}^{d' \times \xi d'}$，$\mathrm{b}_{MLP2} \in \mathbb{R}^{d'}$，$\xi \in \mathbb{N}$为乘法因子；

所述分类器的处理过程为：

$$\mathrm{m}_f = \prod_{t=1}^{T} \mathrm{m}_{f,t}$$

$$\mathrm{m}_{f,t} = \sigma\left(\mathrm{W}_m \mathrm{h}_{f,t} + \mathrm{b}_m\right)$$

其中，W_m为线性变换矩阵，b_m为平移变换向量，$\sigma(\cdot)$表示 softmax 函数。

进一步地，所述旁编辑预测模型的损失函数为：

$$L(\theta) = \frac{1}{N}\sum_{i=1}^{N} D_{KL-div}^{i}(y^i \| \hat{y}^i) + \frac{\lambda}{2}\|\theta\|_2^2$$

$$D_{KL-div}^{i}(y^i \| \hat{y}^i) = \sum_{f=1}^{F} y_f^i \log\left(\frac{y_f^i}{\hat{y}_f^i}\right)$$

其中，y^i代表实际的概率分布，$\hat{y}^i$代表本发明模型的估计分布，θ代表模型的参数或权重，λ为 l_2正则化系数，N为训练集中的样本数。

本发明的有益效果为：

本发明提供了一种基于 Transformer 架构的碱基编辑结果预测模型，包括编辑效率预测模型和旁编辑预测模型，能够有效预测出碱基编辑操作的编辑效率和各种可能出现的编辑结果概率分布。其中基于注意力机制对不同位置的碱基生成相应的注意力分数，解决各碱基局部相关性问题；因而相比于传统的 CNN、机器学习等方法，预测精度更高。

附图说明

图 1 为本发明中编辑效率预测模型的网络架构图；

图 2 为本发明中旁编辑预测模型的网络架构图；

图 3 为本发明预测 ABEmax 碱基编辑器编辑效率的 AUC 曲线；

图 4 为本发明预测 ABE8 碱基编辑器的预测准确度对比图。

具体实施方式

下面详细描述本发明的实施例，所示实施例的示例在附图中示出，其中自始至终相通或类似的标号表示相同或类似的元件或具有相同或类似功能的元件。下面通过参考附图描述的实施例是示例性的，旨在用于解释本发明，而不能理解为对本发明的限制。

一、方案

本发明提出的基于 Transformer 架构的碱基编辑结果预测模型包括两个深度学习模型，分别是①编辑效率预测模型、②旁编辑预测模型。其中编辑效率预测模型用于预测碱基编辑效率，即待编辑序列中可编辑基因的占比；旁编辑预测模型用于预测所有可能的编辑结果以及各个编辑结果出现的概率。

1.编辑效率预测模型

如图 1 所示为本发明中编辑效率预测模型的网络架构图，所示模型中包括嵌入层、编码层、输出模块；上述模型的输入为（包含 PAM 的 23 个碱基对的）待编辑碱基序列 X，输出为每个可编辑碱基的编辑效率（组成序列 S）。

（1）嵌入层

用于将碱基及其对应位置信息，从独热编码表示嵌入到紧凑向量表示中：

对于以独热编码形式表示的碱基序列 $\mathrm{X} = [\mathrm{x}_1, \mathrm{x}_2, \cdots, \mathrm{x}_T]$，嵌入层中分别使用两个嵌入矩阵将碱基序列中的元素 $\mathrm{x}_t \in [0,1]^K$及其对应的位置 $\mathrm{p}_t \in [0,1]^T$转换为固定长度的向量形式，并将两者相加得到一个统一的向量表示 $\mathrm{U} = [\mathrm{u}_1, \mathrm{u}_2, \cdots, \mathrm{u}_T]$：

$$\mathrm{e}_t = \mathrm{W}_e \mathrm{x}_t$$

$$\mathrm{p}_t^{'} = \mathrm{W}_p \mathrm{p}_t$$

$$\mathrm{u}_t = \mathrm{e}_t + \mathrm{p}_t^{'}$$

其中 T为序列长度， K为独热编码的长度， U为以向量形式表示的碱基序列，嵌入矩阵 $\mathrm{W}_e \in \mathbb{R}^{d_e \times K}$，向量 $\mathrm{e}_t \in \mathbb{R}^{d_e}$，嵌入矩阵 $\mathrm{W}_p \in \mathbb{R}^{d_p \times T}$，向量 $\mathrm{p}_t^{'} \in \mathbb{R}^{d_p}$，$\mathrm{u}_t \in \mathbb{R}^d$， $\forall t \in [1, \cdots, T]$， d_e为向量 e_t的维度， d_p为向量 $\mathrm{p}_t^{'}$的维度，实际中 d_e与 d_p相等，故统一记为 d。

之后，嵌入层将序列 $\mathrm{U}=[\mathrm{u}_1,\mathrm{u}_2,\cdots,\mathrm{u}_T]$输出至编码层。

（2）编码层

共设有 N 个以链式堆叠的编码层，初始第一个编码层的输入为序列 U，往后的编码层的输入序列为前一个编码层的输出序列 R。每个编码层分别包括多头自注意力层和前馈网络，其中以第一个编码层为例：

1）多头自注意力层共具有 H头，其中每个单头自注意力层同时并行处理输入向量 u_t（往后的编码模块则对应的是 r_t）。对于其中第 h（ $\forall h\in[1,\cdots,H]$）个单头自注意力层：

1.1）先分别使用查询矩阵 W_{query}^{h}、键矩阵 W_{key}^{h}、值矩阵 W_{value}^{h}对输入向量 u_t进行线性转换：

$$\mathrm{q}_t^h=\mathrm{W}_{query}^{h}\mathrm{u}_t$$

$$\mathrm{k}_t^h=\mathrm{W}_{key}^{h}\mathrm{u}_t$$

$$\mathrm{v}_t^h=\mathrm{W}_{value}^{h}\mathrm{u}_t$$

其中 $\mathrm{W}_{query}^{h}、\mathrm{W}_{key}^{h}、\mathrm{W}_{value}^{h}\in\mathbb{R}^{d^{'}\times d}$，$\mathrm{q}_t^h、\mathrm{k}_t^h、\mathrm{v}_t^h\in\mathbb{R}^{d^{'}}$，$d^{'}$为向量维度。

1.2）利用查询矩阵 W_{query}^{h}和键矩阵 W_{key}^{h}之间的成对相似性，为序列 U中每个位置 t计算注意力分数 $\alpha_{t,l}^{h}$，以此来表示向量 q_t^h与向量 $\mathrm{k}_l^h,\ \forall l\in[1,\cdots,T]$之间的相似度：

$$\alpha_{t,l}^{h}=\frac{\exp\left(score\left(\mathrm{q}_t^h,\mathrm{k}_l^h\right)\right)}{\sum_{l^{'}=1}^{T}\exp\left(score\left(\mathrm{q}_t^h,\mathrm{k}_{l^{'}}^h\right)\right)}$$

$$score\left(\mathrm{q}_t^h,\mathrm{k}_l^h\right)=\frac{\left(\mathrm{q}_t^h\right)^{\mathrm{T}}\mathrm{k}_l^h}{\sqrt{d}}$$

其中 $\left(\mathrm{q}_t^h\right)^{\mathrm{T}}$表示 q_t^h的转置。

1.3）基于注意力分数 $\alpha_{t,l}^{h}$ 和向量 v_{l}^{h} 进行加权求和得到一个新的向量序列 $\mathrm{Z}^{h}=\left[\mathrm{z}_{1}^{h},\mathrm{z}_{2}^{h},\cdots,\mathrm{z}_{T}^{h}\right]$：

$$\mathrm{z}_{t}^{h}=\sum_{l=1}^{T}\alpha_{t,l}^{h}\,\mathrm{v}_{l}^{h}$$

2）对总共 H 个单头自注意力层输出的向量 z_{t}^{h} 进行连接：

$$\mathrm{z}_{t}^{conact}=concat(\mathrm{z}_{t}^{1},\mathrm{z}_{t}^{2},\cdots,\mathrm{z}_{t}^{H}),\ \ \mathrm{z}_{t}^{conact}\in\mathbb{R}^{d^{'}H}$$

之后再对 z_{t}^{conact} 进行仿射转换：

$$\tilde{\mathrm{z}}_{t}=\mathrm{W}_{unify}\mathrm{z}_{t}^{conact}+\mathrm{b}_{unify}$$

其中，W_{unify} 为线性变换矩阵，b_{unify} 为平移变换向量，$\mathrm{W}_{unify}\in\mathbb{R}^{d^{'}\times dH}$，$\mathrm{b}_{unify}\in\mathbb{R}^{d^{'}}$；从而通过上述转换得到序列 $\tilde{\mathrm{Z}}=[\tilde{\mathrm{z}}_{1},\tilde{\mathrm{z}}_{2},\cdots,\tilde{\mathrm{z}}_{T}]$。

3）求和与归一化

3.1）序列 $\tilde{\mathrm{Z}}$ 再与其所在编码层的输入序列（第一个编码模块的输入序列为 U，往后编码模块的输入序列为前一编码模块的输出序列 R）求和：

$$\hat{\mathrm{z}}_{t}=\tilde{\mathrm{z}}_{t}+\mathrm{u}_{t}$$

得到序列 $\hat{\mathrm{Z}}=[\hat{\mathrm{z}}_{1},\hat{\mathrm{z}}_{2},\cdots,\hat{\mathrm{z}}_{T}]$。

3.2）采用层均衡方法对序列 $\hat{\mathrm{Z}}$ 做归一化，得到归一化后的序列 $\mathrm{Z}=[\mathrm{z}_{1},\mathrm{z}_{2},\cdots,\mathrm{z}_{T}]$；具体如下：

$$\mathrm{z}_{t}=LN(\hat{\mathrm{z}}_{t})=\gamma\times\frac{\hat{\mathrm{z}}_{t}-\mu_{t}}{\sqrt{\sigma_{t}^{2}+\varepsilon}}+\beta$$

$$\mu_{t}=\frac{1}{d^{'}}\sum_{j=1}^{d^{'}}\hat{\mathrm{z}}_{t,j}$$

$$\sigma_{t}^{2}=\frac{1}{d^{'}}\sum_{j=1}^{d^{'}}\left(\hat{\mathrm{z}}_{t,j}-\mu_{t}\right)^{2}$$

其中，$LN(\cdot)$为归一化操作，$\hat{z}_{t,j}$中第二个下标j用以表明此碱基$\hat{z}_t$是以j维向量形式表示，μ_t和σ_t^2分别为向量$\hat{z}_t$的均值和方差，γ为缩放参数，β为偏移参数，ε表示一个极小数，其值在具体操作中由人为设定，用以保持数值的稳定性。

最后将归一化后的序列$Z = [z_1, z_2, \cdots, z_T]$输出至前馈网络。

4）所述前馈网络用于进一步计算/嵌入从上层学习到的向量表示。前馈网络中的具体处理过程如下

4.1）先将z_t仿射转换成一个属于$\mathbb{R}^{\xi d'}$的向量，之后经 ReLU 操作后再做一次仿射转换为向量$\tilde{r}_t \in \mathbb{R}^{d'}$：

$$\tilde{r}_t = W_{MLP2} ReLU(W_{MLP1} z_t + b_{MLP1}) + b_{MLP2}$$

其中$ReLU(\cdot)$为线性整流函数，$W_{MLP1} \in \mathbb{R}^{\xi d' \times d'}$，$b_{MLP1} \in \mathbb{R}^{\xi d'}$，$W_{MLP2} \in \mathbb{R}^{d' \times \xi d'}$，$b_{MLP2} \in \mathbb{R}^{d'}$，$\xi \in \mathbb{N}$为乘法因子。通过上述操作得到序列$\tilde{R} = [\tilde{r}_1, \tilde{r}_2, \cdots, \tilde{r}_T]$。

4.2）序列$\tilde{R}$与输入序列Z求和：

$$\hat{r}_t = \tilde{r}_t + z_t$$

得到序列$\hat{R} = [\hat{r}_1, \hat{r}_2, \cdots, \hat{r}_T]$。

4.3）参照 3.2）对序列$\hat{R}$做归一化：

$$r_t = LN(\hat{r}_t)$$

从而通过上述操作得到序列$R = [r_1, r_2, \cdots, r_T]$。

序列$R = [r_1, r_2, \cdots, r_T]$即为当前所在编码层的最终输出量。往后，前一个编码层的输出序列R作为后一个编码层的输入，直至最后第 N 个编码层的输出序列R给到模型的

输出模块。

（3）输出模块

输出模块主要包括位置注意力层和分类器。其中：

1）位置注意力层由一组对应于输入序列 R中每个位置的全局上下文向量序列 $\mathrm{C}=[\mathrm{c}_1,\mathrm{c}_2,\cdots,\mathrm{c}_T]$进行参数化。其中：

1.1）计算注意力分数 $\varphi_{t,l}$：

$$\varphi_{t,l}=\frac{\exp\left(score(\mathrm{c}_t,\mathrm{r}_l)\right)}{\sum_{l'=1}^{T}\exp\left(score\left(\mathrm{c}_t,\mathrm{r}_{l'}\right)\right)}$$

$$score(\mathrm{c}_t,\mathrm{r}_l)=\frac{(\mathrm{c}_t)^{\mathrm{T}}\mathrm{r}_l}{\sqrt{d}}$$

1.2）基于注意力分数 $\varphi_{t,l}$和向量 r_l进行加权求和得到一个新的向量序列 $\mathrm{O}=[\mathrm{o}_1,\mathrm{o}_2,\cdots,\mathrm{o}_T]$：

$$\mathrm{o}_t=\sum_{l=1}^{T}\varphi_{t,l}\,\mathrm{r}_l$$

2）最后，序列 $\mathrm{O}=[\mathrm{o}_1,\mathrm{o}_2,\cdots,\mathrm{o}_T]$在分类器中，经仿射转换和 softmax 操作，得到各碱基的编辑效率 $\mathrm{S}=[\mathrm{s}_1,\mathrm{s}_2,\cdots,\mathrm{s}_T]$：

$$\mathrm{s}_t=\sigma(\mathrm{W}_o\mathrm{o}_t+\mathrm{b}_o)$$

其中 s_t为位置 t处的碱基编辑效率，W_o为线性变换矩阵，b_o为平移变换向量，$\sigma(\cdot)$表示 softmax 函数。

2. 编辑效率预测模型的损失函数

采用交叉熵损失函数来定义每次训练样本各个位置处的损失：

$$l_t^{(i)}=-\sum_{c=1}^{|Voutcome|}y_{t,c}^{(i)}\times\log\left(\hat{y}_{t,c}^{(i)}\right)$$

其中，$l_t^{(i)}$表示训练集中第 i个碱基样本序列位置 t处的损失，$|Voutcome|$为第 i个碱基样本序列位置 t处编辑结果种类，具体在本发明分为“已编辑”和“未编辑”

两种，$y_{t,c}^{(i)}$为该位置的实际编辑结果，$\hat{y}_{t,c}^{(i)}$为该位置的预测编辑结果。

由于本发明关注所有可编辑碱基，因此模型专注于所有可编辑碱基出现的位置，故本发明将第i个样本序列的损失定义为：

$$L_i^{\text{target}} = \frac{1}{\sum_{t=1}^{T} \mathbb{I}\left[\mathrm{x}_{t,\text{base}}^{(i)} = 1\right]} \sum_{t=1}^{T} l_t^{(i)} \mathbb{I}\left[\mathrm{x}_{t,\text{base}}^{(i)} = 1\right]$$

其中，$\mathbb{I}\left[\mathrm{x}_{t,\text{base}}^{(i)} = 1\right]$是一个指示函数，表示当$i$个样本序列中位置$t$处的碱基$\mathrm{x}_t$为目标碱基时，该函数的值为1。

最终，整个训练集的目标函数由训练集中所有样本序列的平均损失以及模型参数θ的权重正则化项（即l_2范数正则化）来定义：

$$L(\theta) = \frac{1}{N} \sum_{i=1}^{N} L_i^{\text{target}} + \frac{\lambda}{2} \|\theta\|_2^2$$

其中，N为训练集中的样本数，λ为l_2正则化系数。在模型训练时，通过最小化上述损失函数$L(\theta)$来优化更新模型的参数或权重。

3.旁编辑预测模型

如图2所示为本发明中旁编辑预测模型的网络架构图，主要包括编码模块和解码模块。模型的输入为待编辑碱基序列X、以及序列X所有可能的编辑结果A；模型的输出为所有可能的编辑结果A所对应出现的概率分布情况M。

（1）编码模块

编码模块依次包括嵌入层和N个编码层，嵌入层与编码层的具体网络架构与前文编辑效率预测模型中的一致，故在此不再做额外赘述。输入的碱基序列$\mathrm{X} = [\mathrm{x}_1, \mathrm{x}_2, \cdots, \mathrm{x}_T]$经编码模块处理得到序列$\mathrm{R} = [\mathrm{r}_1, \mathrm{r}_2, \cdots, \mathrm{r}_T]$发送给解码模块。

（2）解码模块

解码模块中包括掩码自注意力层、交叉注意力层、前馈网络，其中前馈网络具体网络架构同前文编辑效率预测模型，掩码自注意力层与交叉注意力层也均为现有通用网络层结构，因此其具体网络结构设置在此不多做赘述。

对于给定的输入序列 $X=[x_1,x_2,\cdots,x_T]$，其所有可能的编辑结果所组成的集合为 $A=[A_1,A_2,\cdots,A_F]$，记其中任一可能的编辑结果为序列 $A_f=[a_{f,1},a_{f,2},\cdots,a_{f,T}]$，$\forall f\in[1,\cdots,F]$。集合 A中各序列 A_f分别经嵌入层转换得到对应的序列 $B_f=[b_{f,1},b_{f,2},\cdots,b_{f,T}]$。

1）所述掩码自注意力层作为“自回归层”，序列 $B_f=[b_{f,1},b_{f,2},\cdots,b_{f,T}]$经所述掩码自注意力层处理得到序列 $F_f=[f_{f,1},f_{f,2},\cdots,f_{f,T}]$；之后序列 F_f在于其对应的序列 B_f经求和与归一化处理（具体处理过程参照前文编辑效率预测模型）后，得到序列 $G_f=[g_{f,1},g_{f,2},\cdots,g_{f,T}]$。

2）所述交叉注意力层中，序列 G_f用于查询，序列 R则作为键值以计算查询矩阵和键矩阵间的注意力分数，并基于所得注意力分数计算出一个新序列 $D_f=[d_{f,1},d_{f,2},\cdots,d_{f,T}]$。

3）序列 D_f在前馈网络中经一系列的层归一化与残差连接等操作（具体参照前文编辑效率预测模型）：

$$h_{f,t}=W_{MLP2}ReLU\left(W_{MLP1}d_{f,t}+b_{MLP1}\right)+b_{MLP2}$$

得到序列 $H_f=[h_{f,1},h_{f,2},\cdots,h_{f,T}]$；与所有可能的编辑结果 A相对应的，由序列 H_1~H_F组成的集合为 $H=[H_1,H_2,\cdots,H_F]$。

（3）模型输出

集合 H输入至分类器经以下处理，得到各编辑结果的概率分布 $M=[m_1,m_2,\cdots,m_F]$：

$$\mathrm{m}_f = \prod_{t=1}^{T} \mathrm{m}_{f,t}$$

$$\mathrm{m}_{f,t} = \sigma\left(\mathrm{W}_m \mathrm{h}_{f,t} + \mathrm{b}_m\right)$$

其中，m_f为第 f个可能编辑结果的出现概率，W_m为线性变换矩阵，b_m为平移变换向量。

4. 旁编辑预测模型的损失函数

（1）采用 KL 散度（Kullback-Leibler 散度）作为训练集中第 i个样本序列的损失函数：

$$D^i_{KL-div}(y^i \| \hat{y}^i) = \sum_{f=1}^{F} y^i_f \log\left(\frac{y^i_f}{\hat{y}^i_f}\right)$$

其中 y^i代表实际的概率分布，$\hat{y}^i$代表本发明模型的估计分布。

（2）整个训练集的目标函数由所有输入原始序列的平均损失加上应用于模型参数 θ的权重正则化项（即 l_2范数正则化）来定义：

$$L(\theta) = \frac{1}{N}\sum_{i=1}^{N} D^i_{KL-div}(y^i \| \hat{y}^i) + \frac{\lambda}{2}\|\theta\|_2^2$$

在模型训练时，通过最小化上述损失函数 $L(\theta)$来优化更新模型的参数或权重。

二、测试

1.对于单碱基编辑效率预测模型，本发明使用 AUC 和 AUPR 评估模型的性能。在模型训练过程中，记录模型在验证集上达到最佳 AUC 和 AUPR 的轮次，并保存该轮次的模型状态。然后，根据验证集确定的最佳模型在测试集上进行测试。对于每种碱基编辑器类型，本发明基于其在测试集上的平均性能对训练的模型进行评估，并采用 10 折交叉验证法，综合 10 次运行的结果。图 3 是本发明针对 ABEmax 碱基编辑器编辑效率预测性能的 AUC 曲线。

为了更好地评估该模型的性能，本发明还构建了基于标准卷积神经网络（Convolutional Neural Network，CNN）的编辑效率预测模型作为比较基准。图 4 是本模型与基准模型在 ABE8e 碱基编辑器上的精确率对比图。从图中可以看出，本发明提出的基于 Transformer 架构的预测模型明显优于传统的基于标准 CNN 架构的预测模型。

2.对于旁编辑模型，本发明使用 Pearson 和 Spearman 相关系统评估其性能。在模型训练过程中，记录模型在验证集上两个评估指标之间取得最佳值的轮次，并保存该轮次的模型状

态。然后，根据验证集确定的最佳模型在测试集上进行测试。最终实测结果，Pearson 相关系数为 0.76，Spearman 相关系数为 0.68；验证本发明提出的旁编辑模型拥有较高的性能。

在本发明的描述中，需要理解的是，术语“上”、“下”、“前”、“后”、“左”、“右”、“竖直”、“水平”、“顶”、“底”、“内”、“外”等指示的方位或位置关系为基于附图所示的方位或位置关系，仅是为了便于描述本发明和简化描述，而不是指示或暗示所指的装置或元件必须具有特定的方位、以特定的方位构造和操作，因此不能理解为对本发明的限制。

本发明并不限于上述实施方式，在不背离本发明的实质内容的情况下，本领域技术人员能够做出的任何显而易见的改进、替换或变形均属于本发明的保护范围。

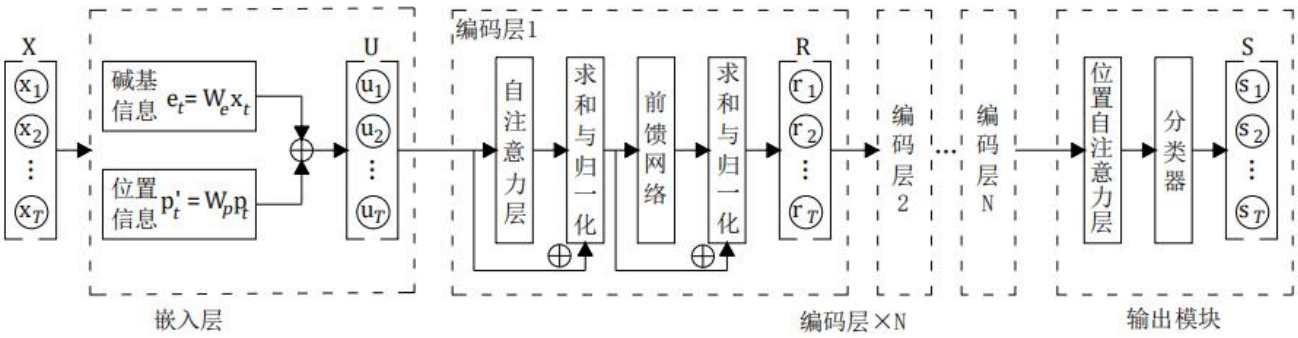

X
碱基信息 $e_t = W_e x_t$
位置信息 $p'_t = W_p p_t$
U
编码层1
自注意力层
求和与归一化
前馈网络
求和与归一化
R
编码层2
编码层N
位置自注意力层
分类器
S
嵌入层
编码层×N
输出模块

图 1

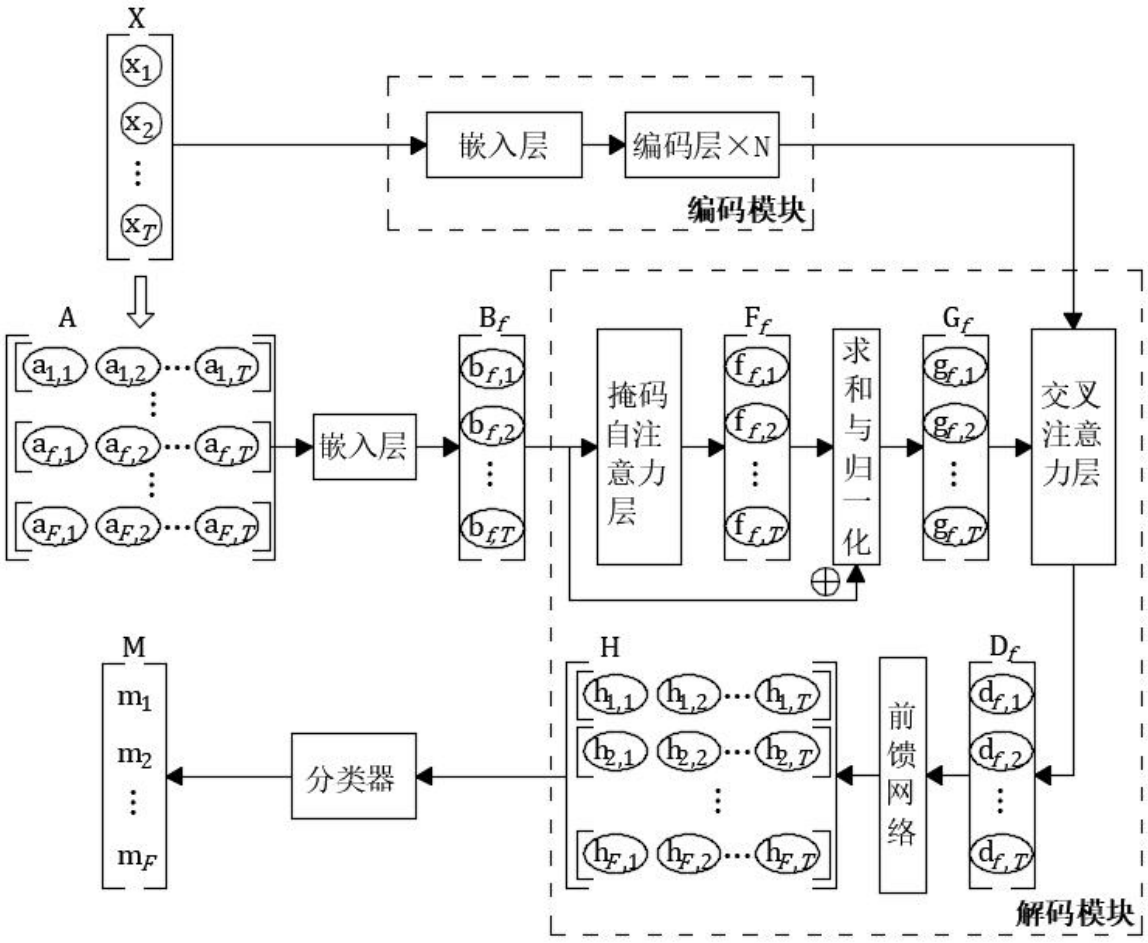

X
嵌入层
编码层×N
编码模块
A
嵌入层
B_f
掩码自注意力层
F_f
求和与归一化
G_f
交叉注意力层
M
分类器
H
前馈网络
D_f
解码模块

图 2

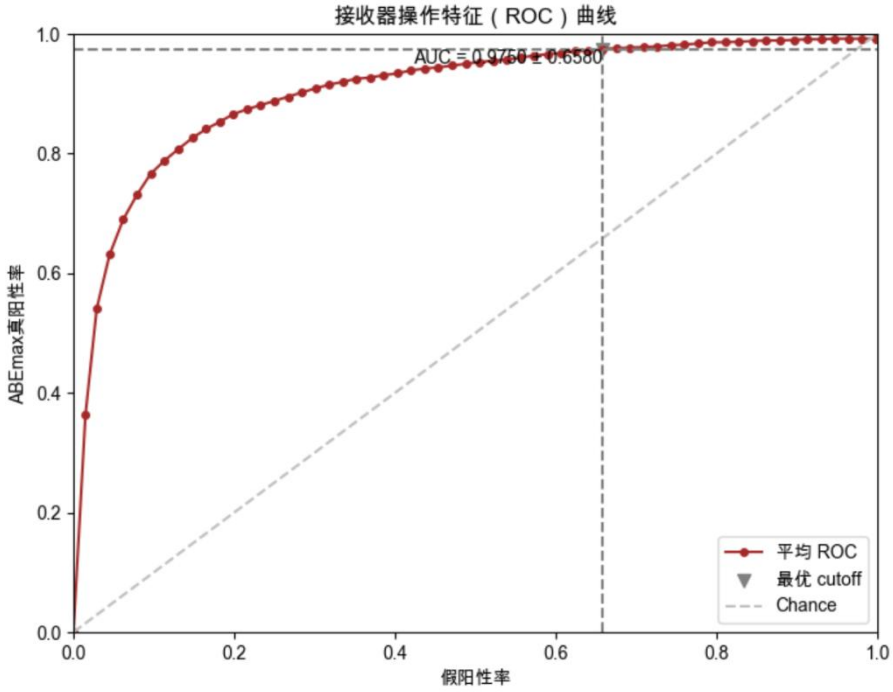

接收器操作特征（ROC）曲线
AUC = 0.9758 ± 0.6580
ABEmax真阳性率
假阳性率
平均 ROC
最优 cutoff
Chance

图 3

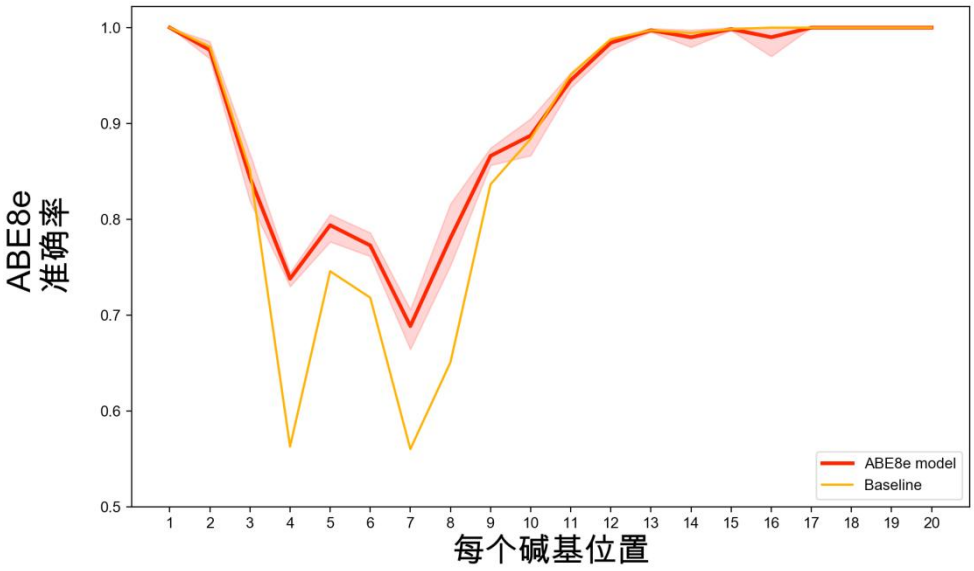

ABE8e
准确率
每个碱基位置
ABE8e model
Baseline

图 4

一种基于表面激子极化子增强光子自旋霍尔效应的方法（发明）技术交底书

说明书摘要

本发明公开了一种基于表面激子极化增强光子自旋霍尔效应的方法，可应用在光传感系统中，特别是气体和液体的检测等传感应用领域。本方法应用在由有机半导体[5,6-二氯-2-[3-[5,6-二氯-1-乙基-3-(4-磺基丁基)- 苯并咪唑-2-亚烯]- 前戊基]-1-乙基-3-(4-磺基丁基)- 苯并咪唑氢氧化钠 (TDBC)]构成的Kretschmann-Raether结构上，该结构由棱镜、玻璃平板和TDBC涂层构成。在室温条件下激发表面激子极化，实现大的反射光光子自旋霍尔效应横向偏移量。

权利要求书

1．一种基于表面激子极化增强光子自旋霍尔效应的方法，其特征在于：包括棱镜、玻璃平板和有机半导体材料——TDBC 涂层的三层结构；该结构可以在室温下激发表面激子激化波，并诱导其沿 TDBC 涂层和环境介质的界面传播；工作光源选取高斯光束的线偏振光，并以一定的入射角度照射该结构，反射光束分裂为左旋和右旋圆偏振光，所述左旋和右旋的圆偏振光在线偏振光和法线构成的入射面的垂直方向上发生横向位移，即为反射光光子自旋霍尔效应；通过选取 TDBC 涂层最佳的厚度，结合入射光线入射角的调控，实现反射光光子自旋霍尔效应的增强。

2. 根据权利要求 1 所述的一种基于表面激子极化增强光子自旋霍尔效应的方法，其特征在于：TDBC 作为一种有机半导体材料，其光学折射率随入射光波长改变，且具有复数形式，在一定波长的入射光（463 - 589 nm）的激励下，可以在室温条件下激发表面激子激化波，是本发明中利用表面激子极化增强光子自旋霍尔效应的核心部分。

3. 根据权利要求 1 所述的一种基于表面激子极化增强光子自旋霍尔效应的方法，其特征在于：TDBC 作为一种折射率随波长变化的有机半导体材料，与棱镜和玻璃平板构成 Kretschmann – Raether 结构。采用高斯光束的线偏振光以一定的入射角度入射时，其反射光的左旋和右旋圆偏振光分量会发生横向位移，产生光子自旋霍尔效应。

4. 根据权利要求 1 所述的一种基于表面激子极化增强光子自旋霍尔效应的方法，其特征在于：TDBC 涂层的折射率与入射光的波长相关，通过选取合适的入射光波长和涂层厚度，结

合入射光线入射角的调控，可以借助 TDBC 激发的表面激子激化波实现强烈的反射光光子自旋霍尔效应。

5. 一种基于表面激子极化增强光子自旋霍尔效应的方法，其特征在于，采用权利要求 1~4 中所述棱镜、玻璃平板和 TDBC 涂层的 Kretschmann – Raether 结构；选取合适的入射光波长和 TDBC 涂层厚度，在室温条件下激发表面激子激化，从而实现反射光光子自旋霍尔效应的增强。

6. 一种基于表面激子极化增强光子自旋霍尔效应的方法，其特征在于，采用权利要求 1~4 中所述棱镜、玻璃平板和 TDBC 涂层的 Kretschmann – Raether 结构；选取合适的入射光波长和 TDBC 涂层厚度，依托反射光显著的光子自旋霍尔效应以及其对折射率变化的高度灵敏性，可以设计光学折射率传感器，该传感器具有优异的传感性能。

一种基于表面激子极化子增强光子自旋霍尔效应的方法

技术领域

本发明涉及应用光学和光学工程领域，具体为一种基于表面激子极化增强光子自旋霍尔效应的方法。通过构造由棱镜、玻璃平板和 TDBC 涂层的 Kretschmann – Raether 结构，可以在室温条件下激发表面激子极化子，进而实现室温条件下利用表面激子极化增强反射光光子自旋霍尔效应，并用于光传感领域的新型光子器件的研发。

背景技术

近年来光自旋霍尔效应已经成为光子学领域的研究热点，当一束线偏振光经过不同介质构成的界面时，反射光和透射光中，自旋方向相反的光子会在垂直于入射面的方向发生横向偏离，从而分裂成左旋和右旋两束圆偏振光，这种现象就是光子自旋霍尔效应（PSHE）。反射光在垂直于入射面的方向发生横向偏离称为反射光光子自旋霍尔效应；透射光在垂直于入射面的方向发生横向偏离称为透射光光子自旋霍尔效应。PSHE 与折射率梯度密切关联，它将在精密计量、新型传感、量子信息处理等领域发挥巨大的潜在应用。PSHE 是光子自旋-轨道相互作用引起的微弱光学效应，产生的自旋相关位移通常仅为纳米级。为了能够实现其工程应用，对其进行灵活的调控并有效地增强这种效应是十分必要的。到目前为止，已经提出了基于布儒斯特角、宇称时间对称结构、石墨烯光泵浦、光子诱导载流子注入等多种方法来获得巨型 PSHE。值得强调的是，共振方法在增强 PSHE 中起着重要作用，包括表面等离子体共振(SPR)、长程 SPR 和导波 SPR。与金属中的表面等离子体极化子(SPP)类似，表面激子极化子(SEP)也是一种表面波，由电磁波和半导体中存在的激子(电子-空穴对)相互作用而产生。然而，成功观测无机半导体中的 SEPs 需要极低的温度，因为这些介质中的激子是 Wannier-Mott 激子，其结合能(~ 0.01 eV)

低于室温下的热能(0.25 eV)。幸运的是，有机材料中的激子是 Frenkel 激子，具有更高的结合能(0.1-1 eV)，这使得在室温下可以观察到 SEPs。与 SPP 相比，SEP 是光子与流动性较差的激子耦合的结果，支持更强的场约束。因此，室温下有机介质中的 SEPs 为新型传感器和下一代光子器件的实际应用提供了机会。

在这里，考虑到 SEP 和 SPP 之间的显著相似性，自然会产生一个问题:是否有可能通过有机半导体室温条件下的 SEP 来增强光子自旋霍尔效应?

发明内容

本发明所要解决的技术问题：本发明公开了一种基于表面激子极化增强光子自旋霍尔效应的方法。这一方法可以在室温条件下利用表面激子极化增强光子自旋霍尔效应，其在光传感系统中，特别是气体和液体的检测等传感领域有着很大的应用潜力。

本发明提供以下技术方案：

一种基于表面激子极化增强光子自旋霍尔效应的方法，其特征在于：包括棱镜、玻璃平板和有机半导体材料——TDBC 涂层的 Kretschmann – Raether 结构；该结构可以在室温下激发表面激子激化波，并诱导其沿 TDBC 涂层和空气的界面传播；工作光源选取高斯光束的线偏振光，并以一定的入射角度照射该结构，反射光束分裂为左旋和右旋圆偏振光，所述左旋和右旋的圆偏振光在线偏振光和法线构成的入射面的垂直方向上发生横向位移，即为反射光光子自旋霍尔效应；通过选取最佳的 TDBC 涂层厚度，并结合入射光线入射角的调控，实现反射光光子自旋霍尔效应的增强。依托增强的反射光光子自旋霍尔效应，有助于高敏的光学折射率传感器的制作。

优选地，采用 TDBC 这一有机半导体材料作为 PSHE 器件的核心部分，其光学折射率随入射光波长改变，且具有复数形式，可以在室温下激发表面激子激化。

优选地，TDBC 与棱镜和玻璃平板构成 Kretschmann–Raether 结构，采用高斯光束的线偏振光入射时，其反射光的左旋和右旋圆偏振光分量会发生分裂，产生横向位移，即光子自旋霍尔效应。

优选地，通过选取合适的入射光波长和 TDBC 涂层厚度，结合入射光线入射角的调控，可以通过室温下激发的表面激子极化实现光子自旋霍尔效应的增强，具体增强对象为 H 偏振光入射的反射光光子自旋霍尔效应。

优选地，依托 TDBC 与棱镜和玻璃平板构成 Kretschmann–Raether 结构的显著的反射光光

子自旋霍尔效应，结合光子自旋霍尔效应对检测物质折射率变化的高度敏感性，可助力于高敏的光学折射率传感器的设计。

本发明获得的有益效果：

本发明提出了一种基于表面激子极化增强光子自旋霍尔效应的方法，其中由棱镜、玻璃平板和有机半导体材料——TDBC 涂层构成的 Kretschmann–Raether 结构，可以在室温条件下激发表面激子极化，进而通过表面激子极化增强 H 偏振光下反射光的光子自旋霍尔效应。该方法具有器件结构简单，增强效果明显的特点。

附图说明

图 1 为具体实施例中采用棱镜、玻璃平板和 TDBC 涂层构成的 Kretschmann–Raether 结构和 TDBC 有机半导体的分子结构，高斯线偏振光从棱镜上方入射至该结构，反射光出现明显的光子自旋霍尔效应。

图 2 为本发明采用高斯线偏振光从棱镜上方入射至由棱镜、玻璃平板和 TDBC 涂层构成的 Kretschmann–Raether 结构，H 偏振光入射时，反射光展现出非常明显的光子自旋霍尔效应。

图 3 为本发明采用高斯线偏振光从棱镜上方入射至由棱镜、玻璃平板和 TDBC 涂层构成的 Kretschmann–Raether 结构，以此来检测不同折射率的气体。

具体实施方式

下面通过对实施例的描述，对本发明的具体实施方式作进一步详细的说明，以帮助本领域的技术人员对本发明的发明构思、技术方案有更完整、准确和深入的理解。

实施例 1：一种基于表面激子极化增强光子自旋霍尔效应的方法。其结构如图 1 所示，为棱镜、玻璃平板和 TDBC 涂层构成的 Kretschmann 克莱切曼–Raether 结构（棱镜选择 BK7 玻璃材质，折射率为 1.7，玻璃平板折射率为 1.52）和 TDBC 分子的化学式。TDBC 是一种 j-聚类菁染料，以薄膜旋涂在薄玻璃基板，玻璃基板则附着在 BK7 玻璃棱镜上。

考虑入射线偏振光束为高斯形式且具有有限的角谱宽度，可表示为

$\widetilde{\boldsymbol{E}}_i(k_{ix},k_{iy}) = \frac{w_0}{\sqrt{2\pi}}\exp\left[-\frac{(k_{ix}^2+k_{iy}^2)w_0^2}{4}\right]$，$w_0$为入射光束的束腰宽度。该入射线偏振光可看成同频率的左、右旋圆偏振光的叠加，即水平（简记为 H）和垂直（简记为 V）偏振光可表示为 $\widetilde{\boldsymbol{E}}_a^H = \frac{1}{\sqrt{2}}(\widetilde{\boldsymbol{E}}_{a+} + \widetilde{\boldsymbol{E}}_{a-})$和 $\widetilde{\boldsymbol{E}}_a^V = \frac{1}{\sqrt{2}}i(\widetilde{\boldsymbol{E}}_{a-} - \widetilde{\boldsymbol{E}}_{a+})$，符号“+”和“-”分别表示左、右旋圆

偏振分量。反射光角谱和入射光角谱的关系为：

$$\begin{bmatrix}\widetilde{E}_r^H\\ \widetilde{E}_r^V\end{bmatrix}=\begin{bmatrix}r_p & \frac{k_{ry}cot\theta_i(r_p+r_s)}{k_0}\\ -\frac{k_{ry}cot\theta_i(r_p+r_s)}{k_0} & r_s\end{bmatrix}\begin{bmatrix}\widetilde{E}_i^H\\ \widetilde{E}_i^V\end{bmatrix}$$，其中，θ_i为入射角，r_p和r_s分别为p和s偏振光的菲涅尔反射系数。棱镜、玻璃平板和TDBC涂层构成的Kretschmann–Raether结构在空气中的菲涅尔反射系数r_p和r_s可依托转移矩阵法求得。反射光光子自旋霍尔效应的自旋偏移量可表示为$\delta_{H,V}^{\pm}=\frac{\iint y|E_{H,V}^{+}|^2dxdy}{\iint|E_{H,V}^{+}|^2dxdy}$。

入射光的波长设置为510nm，该波长下TDBC的介电常数为-1.76 + 0.08i，玻璃平板的厚度选定为d_{glass} =26.6nm，入射光的束腰为0.5mm，工作背景选择空气环境（折射率为1）。此时，为了实现较为明显的H偏振光的光子自旋霍尔效应横向偏移量，通过优化模型，分别选择d_{TDBC} =63.9nm、64.0nm和64.1nm实现H偏振光的反射光光子自旋霍尔效应（图2所示）。实施例显示，设定不同的TDBC涂层厚度，反射光光子自旋霍尔效应横向偏移峰出现的角度和峰值均有明显变化；且在d_{TDBC} =64.0nm时，该结构出现明显增强的反射光光子自旋霍尔效应，最大偏移量达到了12.15 μm，该数值分别是SPR结构和长程SPR结构的4倍和1.5倍。

实施例2：采用实施例1所述的三层Kretschmann–Raether结构设计一款光学折射率传感器，并进行气体检测。

将待测气体置于装置下方，气体层可视为衬底与三层Kretschmann–Raether结构构成一个光学系统。不同类型或组分的待测气体的折射率不同，这会导致整个系统的光子自旋霍尔效应产生明显变化。当采用高斯光束的线偏振光入射时，可通过观测光子自旋霍尔效应的横向偏移量的值检测气体类型。

所述的待测气体选取折射率分别为1、1.0001、1.0002三种差异很小的类型，入射光参数和三层Kretschmann–Raether结构各层参数与实施例1相同，TDBC涂层厚度选用最佳厚度d_{TDBC} =64.0nm。因为光子自旋霍尔效应对折射率的微小差异非常敏感，其反射光的自旋霍尔效应将差别较大，相应的自旋偏移改变量记为Δδ。基于光子自旋霍尔效应的折射率传感器，固定入射光线工作角度时，其强度灵敏度定义为$S_\delta=\frac{\Delta\delta}{\Delta n}$（单位μm/RIU），这为气体类型的检测

提供了一种有效的途径。如图 3 所示，当入射角固定为 70.17 º时，三种待测气体对应的光子自旋霍尔效应横向偏移量分别为 12.15μm、7.95μm、4.51μm。通过强度灵敏度的定义公式，可以得到相应的强度灵敏度，取平均值可得到平均强度灵敏度为 4.805×10^4μm/RIU，这一值明显优于双金属 SPR 的强度灵敏度（6602μm/RIU）。

以上实施例仅为说明本发明的技术思想，不能以此限定本发明的保护范围，凡是按照本发明提出的技术思想，在技术方案基础上所做的任何改动，均落入本发明保护范围之内；本发明未涉及的技术均可通过现有技术加以实现。

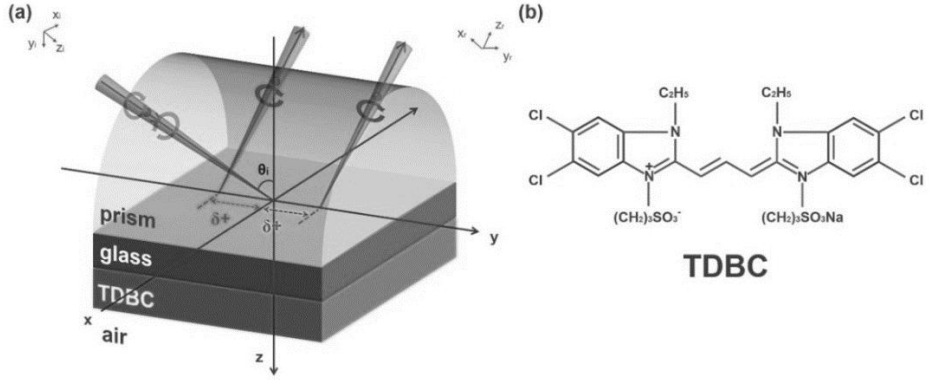


图 1

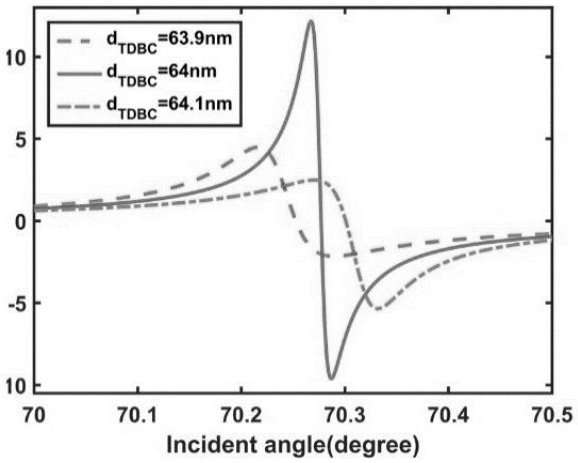


图 2

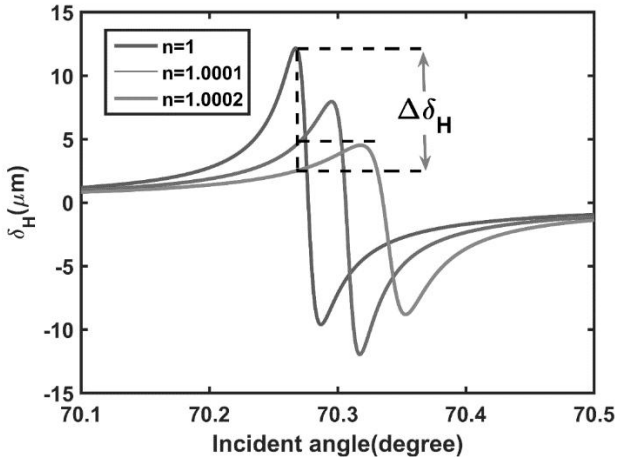

n=1
n=1.0001
n=1.0002
$\Delta\delta_H$
$\delta_H(\mu m)$
15
10
5
0
-5
-10
-15
70.1
70.2
70.3
70.4
70.5
Incident angle(degree)

图 3

申请材料分析说明

1.基础信息

专利名称：一种增强光自旋霍尔效应的光学器件及其应用

代理师：戴羽丰（南京智造力知识产权代理有限公司）

状态：审查中

2.交底材料

本案是以正式的专利文稿的形式提供的交底材料。交底材料内容相对较为充实，且提供了非常详细的测试数据。

交底材料中务必不要提供权利要求书。

主题确立不够准确，本发明实质上是提出了一种光学器件，并采用该光学器件实现增强光子自旋霍尔效应；故交底材料中将主题列为“一种基于表面激子极化增强光子自旋霍尔效应的方法”，对于实际要保护的技术创新不够准确。

背景技术部分为表达出当下的技术问题，反而“室温下有机介质中的 SEPs 为新型传感器和下一代光子器件的实际应用提供了机会”这样的内容会给审查员认为当下现有技术对本发明具有技术启示，从而否定本发明的创造性。

技术方案部分内容表述不清，如“将待测气体置于装置下方”中的“装置”是什么前文缺乏交代。

交底材料中附图的文字不能为外文，专利稿中应当全部使用中文，包括附图中出现的文字。

3.权利要求书

给出了两项独立权利要求，分别是“一种增强光子自旋霍尔效应的光学器件”和“一种光学折射率传感器”。

从专利维权角度看，相比于产品类的专利，方法类的专利由于取证困难等因素难以维权保护。而本案将交底材料的主题由“方法”改为“光学器件”和“传感器”这两项产品，使得本专利权能够更容易地行使。

4.说明书

背景技术部分，技术问题交代明确——现有方法对于 PSHE 的增强能力仍然有限。

具体实施方式部分，分为“结构说明”和“应用”两部分，对本发明技术方案进行说明。并将

附图中原本的外文修改为中文。

有益效果部分，结合试验测试数据，论证本发明光学器件，增强光子自旋霍尔效应的能力是现有其他手段的 1.5 倍到 4 倍。

上述问题、手段、效果三者相统一。

申请稿

说明书摘要

本发明提供了一种增强光自旋霍尔效应的光学器件及其应用，其中光学器件为Kretschmann-Raether结构，依次包括棱镜、玻璃平板和TDBC涂层，入射光由棱镜射入；上述光学器件具有增强光子自旋霍尔效应的效果，其增强能力是现有其他手段的1.5倍到4倍；且能够在室温条件实现。基于上述光学器件提出了一种光学折射率传感器，应用时，所述光学器件用于置于待测气体中，高斯线偏振光入射所述光学器件，测量反射光的横向偏移量，根据气体折射率与反射光横向偏移量的对应关系，得到待测气体折射率，并进而由折射率反推出相应的气体种类。

权利要求书

1.一种增强光子自旋霍尔效应的光学器件，其特征在于：为Kretschmann-Raether结构，依次包括棱镜、玻璃平板和TDBC涂层，入射光由棱镜射入。

2.根据权利要求1所述的增强光子自旋霍尔效应的光学器件，其特征在于：所述棱镜的折射率为1.7，所述玻璃平板折射率为1.52。

3.根据权利要求1所述的增强光子自旋霍尔效应的光学器件，其特征在于：所述入射光为高斯线偏振光。

4.根据权利要求3所述的增强光子自旋霍尔效应的光学器件，其特征在于：所述入射光的波长为510nm，所述玻璃平板的厚度为26.6nm，所述TDBC涂层的厚度为63.9~64.1nm。

5.根据权利要求4所述的增强光子自旋霍尔效应的光学器件，其特征在于：所述TDBC涂层的厚度为64nm。

6.根据权利要求4所述的增强光子自旋霍尔效应的光学器件，其特征在于：所述入射光的入射角为70.27°。

7.一种光学折射率传感器，其特征在于：包括如权利要求1~6任一项所述的光学器件，所述光学器件用于置于待测气体中，高斯线偏振光入射所述光学器件，测量反射光的横向偏移量，根据气体折射率与反射光横向偏移量的对应关系，得到待测气体折射率。

8.根据权利要求7所述的光学折射率传感器，其特征在于：用于检测气体种类，根据气体种类与各自折射率的对应关系，通过测得的气体折射率得到待测气体种类。

技术领域

本发明属于光学技术领域，具体涉及一种增强光自旋霍尔效应的光学器件及其应用。

背景技术

光子自旋霍尔效应（PSHE）表现为：当一束线偏振光经过不同介质构成的界面时，在所产生的反射光和透射光中，自旋方向相反的光子会在垂直于入射面的方向发生横向偏离，从而分裂成左旋和右旋两束圆偏振光。上述这一现象称为光子自旋霍尔效应，其中反射光在垂直于入射面的方向发生横向偏离称为反射光光子自旋霍尔效应；透射光在垂直于入射面的方向发生横向偏离称为透射光光子自旋霍尔效应。

PSHE 与折射率梯度密切相关，从而使得这一现象能够在精密计量、新型传感、量子信息处理等领域发挥巨大的潜在应用。但是由于 PSHE 是光子自旋-轨道相互作用引起的微弱光学效应，产生的自旋相关位移通常仅为纳米级，因此这也是 PSHE 难以得到工程应用的难点所在。目前共振方法在增强 PSHE 中起着重要作用，包括表面等离子体共振（SPR）、长程 SPR、导波 SPR，但这些现有方法对于 PSHE 的增强能力仍然有限。

发明内容

针对现有技术中存在的不足，本发明提供了一种光学器件，用以增强光子自旋霍尔效应，并基于此提供了一种用于检测气体类别的应用。

本发明通过以下技术手段实现上述技术目的。

一种增强光子自旋霍尔效应的光学器件，为 Kretschmann-Raether 结构，依次包括棱镜、玻璃平板和 TDBC 涂层，入射光由棱镜射入。

进一步地，所述棱镜的折射率为 1.7，所述玻璃平板折射率为 1.52。

进一步地，所述入射光为高斯线偏振光。

进一步地，所述入射光的波长为 510nm，所述玻璃平板的厚度为 26.6nm，所述 TDBC 涂层的厚度为 63.9~64.1nm。

进一步地，所述 TDBC 涂层的厚度为 64nm。

进一步地，所述入射光的入射角为 70.27°。

一种光学折射率传感器，包括上述光学器件，所述光学器件用于置于待测气体中，高斯线偏振光入射所述光学器件，测量反射光的横向偏移量，根据气体折射率与反射光横向偏移量的对应关系，得到待测气体折射率。

进一步地，用于检测气体种类，根据气体种类与各自折射率的对应关系，通过测得的气体折射率得到待测气体种类。

本发明的有益效果为：

（1）本发明提供了一种光学器件，具有增强光子自旋霍尔效应的效果，其增强能力是现有其他手段的 1.5 倍到 4 倍；并且能够在室温条件实现。

（2）基于本发明提出的增强光自旋霍尔效应的光学器件，进一步给出了一种光学折射率传感器，其对气体折射率的变化具有极强的灵敏度，通过测量反射光的横向偏移量可得出对应的待测气体折射率，并进而由折射率反推出相应的气体种类。

附图说明

图 1 为本发明光学器件的结构图；

图 2 为 TDBC 分子化学式；

图 3 为不同 TDBC 涂层厚度下反射光光子自旋霍尔效应的横向偏移图；

图 4 为不同折射率下反射光光子自旋霍尔效应的横向偏移图。

具体实施方式

下面详细描述本发明的实施例，所示实施例的示例在附图中示出，其中自始至终相通或类似的标号表示相同或类似的元件或具有相同或类似功能的元件。下面通过参考附图描述的实施例是示例性的，旨在用于解释本发明，而不能理解为对本发明的限制。

1.结构说明

与金属中的表面等离子体极化子（SPP）类似，表面激子极化子（SEP）也是一种表面波。SEP 是由电磁波和半导体中存在的激子（电子-空穴对）相互作用而产生。考虑到 SEP 与 SPP 之间的显著相似性，本发明提出通过 SEP 来增强光子自旋霍尔效应，为此设计如下结构：

如图 1 所示的光学器件为 Kretschmann-Raether 结构，由上至下依次包括棱镜、玻璃平板和 TDBC 涂层。其中棱镜选用 BK7 玻璃材质，折射率为 1.7。玻璃平板折射率为 1.52。TDBC 是一种 j-聚类菁燃料，TDBC 分子化学式如图 2 所示。上述光学器件由高斯线偏振光从棱镜处入射，相应的反射光由于光子自旋霍尔效应产生横向偏移。

针对上述结构说明：一般而言，要成功观测到无机半导体中的 SEPs 需要极地的温度，因为这些介质中的激子是 Wannier-Mott 激子，其结合能（~0.01eV）低于室温下的热能（0.25eV）。而有机材料中的激子是 Frenkel 激子，具有更高的结合能（0.1~1eV），因此本发明采用有机半导体，实现能够在室温条件下观察到 SEPs。并且与 SPP 相比，SEP 是光子与流动性较差的激子耦合的结果，这使得本发明支持更强的场约束。

针对上述光学器件，可做如下理论推导：

1）该光学器件的入射光采用高斯线偏振光，高斯线偏振光具有有限的角谱宽度，因此入

射线偏振光束可表示为：

$$\widetilde{E}_i(k_{ix}, k_{iy}) = \frac{w_0}{\sqrt{2\pi}} \exp\left[-\frac{(k_{ix}^2 + k_{iy}^2)w_0^2}{4}\right]$$

其中 w_0为入射光束的束腰宽度，$\widetilde{E}_i$为入射光的角谱，k_{ix}为入射光束的波矢在 x 轴方向上的分量，k_{iy}为入射光束的波矢在 y 轴方向上的分量，exp 表示以自然常数 e 为底的指数函数。

2）上述入射线偏振光束可看成同频率的左旋圆偏振光和右旋圆偏振光的叠加，即水平（以标号 *H* 表示）偏振光可表示为：

$$\widetilde{E}_a^H = \frac{1}{\sqrt{2}}(\widetilde{E}_{a+} + \widetilde{E}_{a-})$$

垂直（以标号 *V* 表示）偏振光刻表示为：

$$\widetilde{E}_a^V = \frac{1}{\sqrt{2}} i(\widetilde{E}_{a-} - \widetilde{E}_{a+})$$

其中符号“+”和“-”分别表示左旋和右旋圆偏振分量，$\widetilde{E}_a^H$为水平偏振光的角谱，$\widetilde{E}_a^V$为垂直偏振光的角谱，$\widetilde{E}_{a+}$为左旋圆偏振光的角谱，$\widetilde{E}_{a-}$为左旋圆偏振光的角谱，i 为虚数。

3）反射光角谱和入射光角谱的关系为：

$$\begin{bmatrix} \widetilde{E}_r^H \\ \widetilde{E}_r^V \end{bmatrix} = \begin{bmatrix} r_p & \frac{k_{ry} cot\theta_i (r_p + r_s)}{k_0} \\ -\frac{k_{ry} cot\theta_i (r_p + r_s)}{k_0} & r_s \end{bmatrix} \begin{bmatrix} \widetilde{E}_i^H \\ \widetilde{E}_i^V \end{bmatrix}$$

其中θ_i为入射角，r_p和r_s分别为p和s偏振光的菲涅尔反射系数，$\widetilde{E}_r^H$为反射光水平分量的角谱，$\widetilde{E}_r^V$为反射光垂直分量的角谱，k_{ry}为反射光在 y 轴方向上的空间波数分量，k_0为自由空间波数，其数值是$2\pi/\lambda$，$\widetilde{E}_i^H$为入射光水平分量的角谱，$\widetilde{E}_i^V$为入射光垂直分量的角谱。

4）本发明所设计的光学器件在空气中的菲涅尔反射系数 r_p和 r_s可依托转移矩阵法求得。本发明光学结构的反射光光子自旋霍尔效应的自旋偏移量可表示为：

$$\delta_{H,V}^{\pm} = \frac{\iint y\left|\boldsymbol{E}_{H,V}^{\pm}\right|^2 dxdy}{\iint \left|\boldsymbol{E}_{H,V}^{\pm}\right|^2 dxdy}$$

其中 $\delta_{H,V}^{\pm}$ 分别为反射光左、右旋圆偏振光的横向位移，$\boldsymbol{E}_{H,V}^{\pm}$ 为左、右旋圆偏振光的电场分布，x 是反射路径上建立坐标系的 x 轴分量，y 是反射路径上建立坐标系的 y 轴分量。

针对上述光学器件，入射光的波长设置为 510nm，在该波长下 TDBC 的介电常数为 -1.76+0.08i，入射光的束腰宽度 w_0 为 0.5mm；玻璃平板的厚度定为 d_{glass}=26.6nm；工作背景选择为空气（折射率为 1）。TDBC 涂层厚度 d_{TDBC} 分别取 63.9nm、64.0nm、64.1nm 进行测试，结果如图 3 所示。不同的 TDBC 涂层厚度，反射光光子自旋霍尔效应的横向偏移峰出现的角度和峰值均有明显变化，其中在 d_{TDBC} 为 64.0nm 时出现明显增强的反射光光子自旋霍尔效应，其最大偏移量达到了 12.15μm，该数值分别是 SPR 结构和长程 SPR 结构的 4 倍和 1.5 倍。

2.应用

基于本发明提出的增强光自旋霍尔效应的光学器件，给出一种光学折射率传感器，用以进行气体检测。

所述传感器中包括本发明的光学器件以及发射高斯线偏振光的光源。使用时，将该光学器件置于待测气体内。由于不同类型或组分的待测气体的折射率不同，会导致上述光学器件的光子自旋霍尔效应产生明显变化，因此使用高斯光束的线偏振光入射上述光学结构时，通过测量光子自旋霍尔效应的横向偏移量值的方式，可以实现对气体种类的检测。

例如选取折射率分别为 1、1.0001、1.0002 的三种差异很小的气体，使用上述基于本发明光学器件的光学折射率传感器进行检测。保持入射高斯线偏振光的入射角 θ_i 在 70.27°，如图 4 所示，可直观看出这三种折射率相差不大的气体之间有着很大的光子自旋霍尔效应横向偏移量很。进一步根据强度灵敏度公式计算出上述传感器的平均强度灵敏度为 $4.805*10^4$μm/RIU，而这一数值明显优于当前双金属 SPR 的强度灵敏度（6602μm/RIU）。

在本发明的描述中，需要理解的是，术语“上”、“下”、“前”、“后”、“左”、“右”、“竖直”、“水平”、“顶”、“底”、“内”、“外”等指示的方位或位置关系为基于附图所示的方位或位置关系，仅是为了便于描述本发明和简化描述，而不是指示或暗示所指的装置或元件必须具有特定的

方位、以特定的方位构造和操作，因此不能理解为对本发明的限制。

本发明并不限于上述实施方式，在不背离本发明的实质内容的情况下，本领域技术人员能够做出的任何显而易见的改进、替换或变形均属于本发明的保护范围。

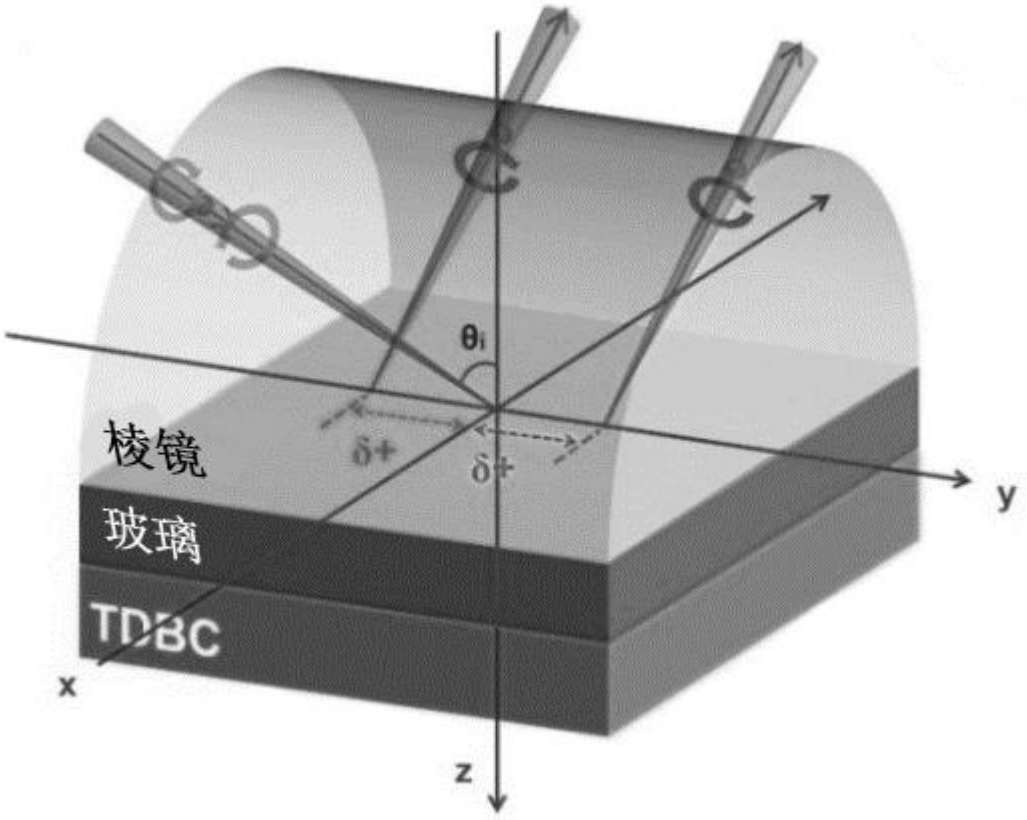


图 1

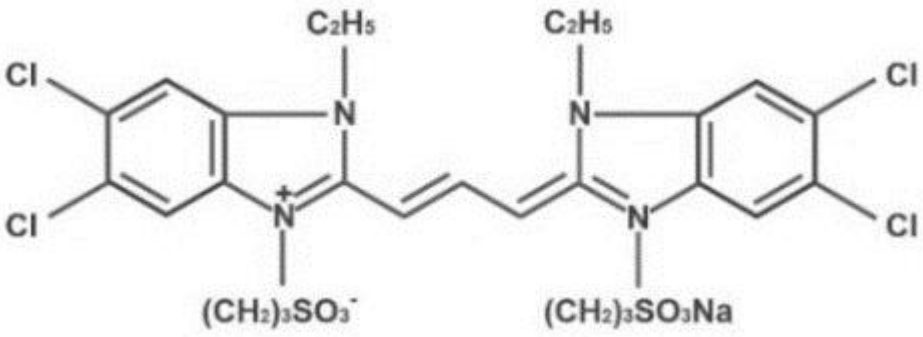


图 2

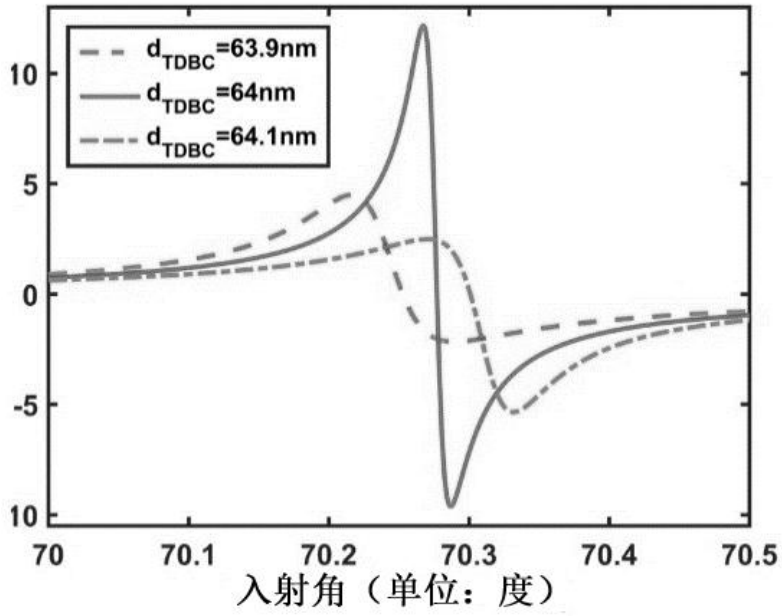

d_TDBC=63.9nm
d_TDBC=64nm
d_TDBC=64.1nm
10
5
0
-5
10
70
70.1
70.2
70.3
70.4
70.5
入射角（单位：度）

图 3

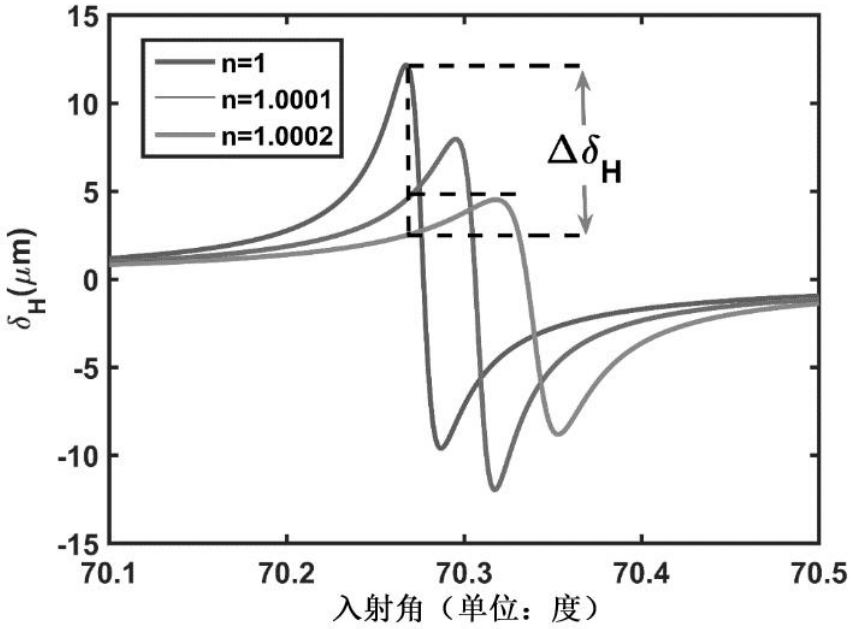

n=1
n=1.0001
n=1.0002
Δδ_H
δ_H(μm)
15
10
5
0
-5
-10
-15
70.1
70.2
70.3
70.4
70.5
入射角（单位：度）

图 4

一种非参数化表示学习的大规模点云语义分割方法（发明）

技术交底书

一、发明名称

一种非参数化表示学习的大规模点云语义分割方法

二、技术领域

本公开涉及人工智能技术领域，尤其涉及计算机视觉、深度学习等技术领域，可以应用于自动驾驶、智能汽车等场景。具体涉及一种非参数化表示学习的大规模点云语义分割方法。

三、现有技术的技术方案

背景/公知技术：目前 3D 点云分割方法主要可分为基于分割的方法（partition-based methods）和基于整体的方法（whole-based methods）。基于分割的方法，如 PointNet、PointNet++、PointWeb、PointConv、DGCNN 和 KPConv，将点云划分为小块（block），然后从每个小块中采样点作为输入，通过分块来处理大规模点云。基于整体的方法，如 SPGraph 和 SuperPoint Transformer 将点云表示为一组超点，并使用超点图来捕获点云的结构和上下文。此外，RandLA-Net 及其后续工作，如 SCF-Net 和 BAAF-Net，将整个点云直接输入，并使用随机采样进行下采样。

最接近的技术方案：专利 CN 114758129 A 一种基于局部特征增强的 RandLA-Net 室外场景语义分割方法：首先通过使用 MLP 对中心点与邻近点的坐标、相对位置和法向量方向变化进行编码来提取点云的空间几何特征，通过将中心点特征与邻域点特征进行堆叠得到提取语义特征，不对语义特征进行编码，而是直接对几何特征和语义特征进行连接得到增强后的特征。其次，通过注意力机制学习每个特征的权重，将权重与特征相乘并对加权后的特征求和得到聚合后的特征。然后，通过扩张残差块来增大每个点的感受野。最后，使用编码层-解码层的网络结构实现室外场景语义分割。

四、现有技术的缺点及本申请提案要解决的技术问题

现有技术的缺点:

1、对于基于分割的方法，点云被划分为小块（block）时场景中对象的几何结构被破坏，导致该方法无法捕获大范围的上下文信息，这可能会影响整体的语义分割结果；

2、对于基于整体的方法，将点云划分为超点的预处理方法可能非常耗时；

3、对于基于整体的方法，部分将整体点云作为输入的模型在面对复杂场景、复杂任务时性能相对较差。

本发明所要解决的技术问题:

1、大规模点云数据的高效处理：传统点云语义分割方法在处理大规模点云数据时往往需要预处理步骤，或者在提取点云特征方面能力不足。由于数据量庞大，传统方法在计算复杂性和存储需求上存在不足，难以满足实时处理和资源受限的嵌入式系统的需求；

2、增强模型在大规模 3D 点云语义分割任务中的特征提取能力：现有的点云语义分割方法在处理复杂和大规模场景时，特征提取往往存在不足。传统方法通常使用较单一的编码方式对点云坐标特征和语义特征进行相同的处理，难以充分捕捉点云数据中的丰富细节和复杂语义信息。因此，增强模型在大规模 3D 点云语义分割任务中的特征提取能力成为一项重要的技术问题。

3、模型性能与计算效率、存储效率的平衡：传统的高性能模型往往伴随着大量的参数和高昂的计算成本，导致在实际应用中难以实现实时处理和部署。此外，存储资源的消耗也成为限制模型应用的一个重要因素。因此，在保证模型性能的前提下，减少参数量，使得模型在计算效率和存储效率方面更具优势，成为一个亟待解决的问题。

五、本申请提案的技术方案的详细阐述

本发明提出了一种非参数化表示学习的大规模点云语义分割方法 TriEn-Net，架构如图 1 所示。它由多个编码层和解码层堆叠而成，为了提高计算效率和减少存储需求，我们引入了两个非参数模块，分别用于提取局部几何特征丰富的语义特征。我们将点云划分为坐标特征和语义特征分别进行编码。具体来说，我们利用三角函数来探索坐标特征的空间结构，同时利用能量函数来捕捉语义特征的细粒度特征。随后，我们利用注意力池化来聚合拼接的特征。

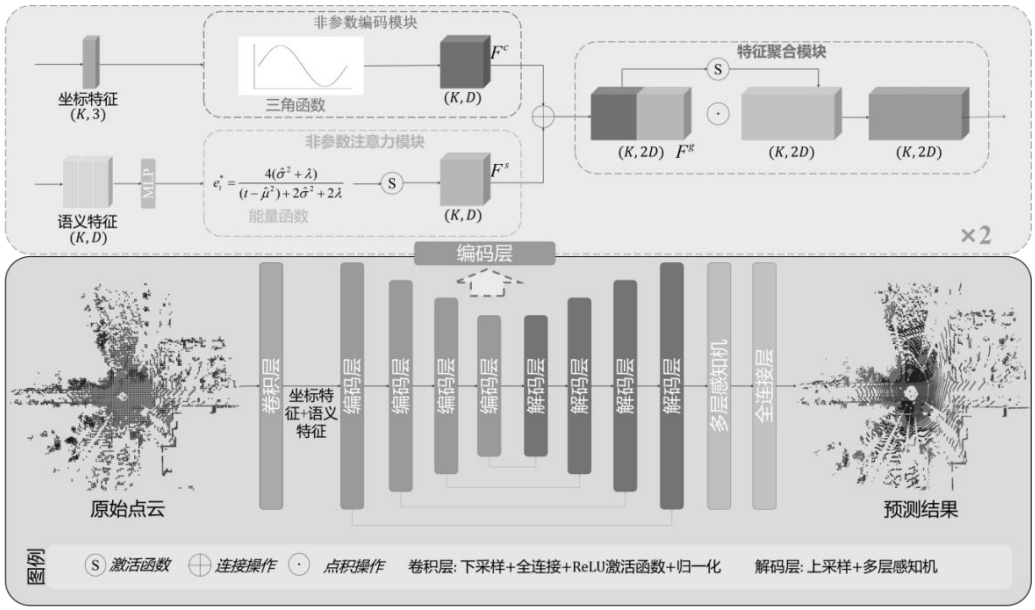


图 1 架构图

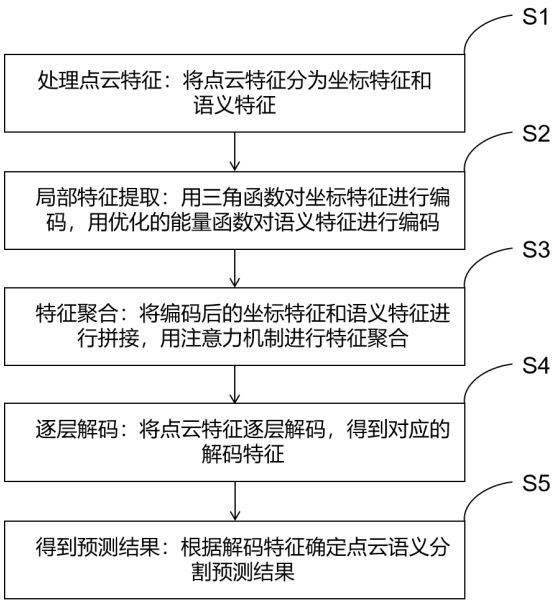


图 2 流程图

步骤 S1：处理点云特征

TriEn-Net 以整个原始点云为输入，并利用随机采样将点云集从 N 个点下采样到 N′个点。采用 K-最近邻（KNN）算法来收集每个中心点的相邻点。使用卷积层将点云特征分为坐标特征和语义特征。

步骤 S2：局部特征提取

该步骤包含两个模块，分别是无参数编码模块和无参数注意力模块，分别用来提取点云的位置特征和语义特征。

在非参数编码模块中，利用三角函数对点坐标进行编码，有效提取局部几何特征。三角函数实现了坐标从三维空间到高维空间的映射，有效地保留了点之间的局部几何结构和全局拓扑信息。由于三角函数的周期性，编码特征具有稳定性和鲁棒性，使其能够更好地处理点云数据中的噪声。

对于每个点，我们首先计算点在其邻域中相对于 的相对位置。以 p_i的邻域内点 p_j为例， Δp_{ij}表示相对位置：

$$\Delta p_{ij}^{x} = p_i^{x} - p_j^{x}$$

$$\Delta p_{ij} = \mathrm{Concat}(\Delta p_{ij}^{x}, \Delta p_{ij}^{y}, \Delta p_{ij}^{z})$$

其中 p_i^x 和 p_j^x 分别表示点 i 和点 j 的 x 坐标。

然后，我们使用三角函数将相对位置嵌入到高维向量 f_{ij} 中。嵌入向量是通过连接 $d/6$ 组 6 维向量形成的，其中 d 表示输出维数。我们将正弦和余弦函数应用于相对位置 Δp_{ij}：

$$f_{ij} = (\sin\frac{\partial \Delta p_{ij}}{\beta^{\frac{6m}{d}}}, \cos\frac{\partial \Delta p_{ij}}{\beta^{\frac{6m}{d}}})$$

其中 α 和 β 控制三角函数的振幅和波长，在我们的模型中，α 取 100，β 取 1000。

利用三角函数对空间坐标进行编码，可以捕获具有周期特征的结构特征。此外，深度网络中倾向于低频函数的学习偏差，其表现为频率依赖的学习速度，随着流形复杂性的增加，学习更高频率变得更容易。同时，通过正弦映射变换低维输入有助于 MLP 在训练过程中学习高频内容。因此，使用三角函数可以帮助 MLP 更好地捕获点云的高频特征，在不同模块之间形成优势互补。

在非参数注意力模块中，我们通过计算点之间的线性可分性来分配权重。因此，我们采用优化的能量函数进行特征编码。

我们采用了一种采用二元标签和正则化的能量函数:

$$e_t(w_t, b_t, y, x_i) = \frac{1}{M-1}\sum_{i=1}^{M-1}(-1-(w_t x_i + b_t))^2 + (1-(w_t + b_t))^2 + \lambda w_t^2$$

其中 和 x_i 为目标点及其邻域点，M 为每个通道中能量函数的个数，y 为二值标号，取值为 1 或-1。w_t 和 b_t 由下式可得:

$$w_t = -\frac{2(t-\mu_t)}{(t-\mu_t)^2 + 2\sigma_t^2 + 2\lambda}$$

$$b_t = -\frac{1}{2}(t+\mu_t)w_t$$

其中 $\mu_t = \frac{1}{M-1}\sum_{i=1}^{M-1} x_i$ ， $\sigma_t^2 = \frac{1}{M-1}\sum_{i=1}^{M-1}(x_i-\mu_t)^2$ 是除 t 外通道中所有点的均值和方差。

假设单个通道内的所有特征都遵循相同的分布是合理的。基于这一假设，我们得到如下闭型解:

$$e_t^* = \frac{4(\hat{\sigma}^2+\lambda)}{(t-\hat{\mu}^2)+2\hat{\sigma}^2+2\lambda}$$

其中， $\hat{\mu}$ 为输入特征的均值， $\hat{\sigma}^2$ 为输入特征的方差。每个点的重要性程度可由 $\frac{1}{e_t^*}$ 求得。

然后，我们使用 Sigmoid 函数映射到(0,1)得到最终输出:

$$Y = Sigmoid(\frac{1}{E}) \bullet X$$

其中 E 将所有 e_t^* 在通道和空间维度上分组。

能量函数基于神经科学理论来确定每个点的重要性，并通过闭式解形式的解决方案快速选择算子，而无需引入额外的参数。同时，能量函数与三角函数的结合可以实现优势互补。三角函数将点的位置信息转化为周期特征，可以很好地描述点的几何特征点云。能量函数基于神经科学原理，优先捕获点云中与相邻点显示不同模式或结构的特征。这两种特征提取方法的结合丰富了 TriEn-Net 的特征表示能力，提高了模型的整体性能。

步骤 S3：特征聚合

通过非参数方法提取特征后，可能会有一些冗余或不太重要的信息。我们选择在非参数编码模块和非参数注意力模块之后使用注意力池化来有效地聚合特征，可以选择性地关注重要的特征，减少对不重要信息的考虑。

我们使用注意机制进行特征聚合。首先用 MLP 学习每个特征的注意分数，再用 Softmax 激活，然后将特征的加权和表示为:

$$s_i^k = Soft\max(MLP(\hat{f}_i^k, W))$$
$$\widetilde{f}_i = \sum_{k=1}^{K}(\hat{f}_i^k \cdot s_i^k)$$

其中 s_i^k 为各特征 $\hat{f}_i^k$ 的注意分数,W 为 MLP 的可学习权值，$\widetilde{f}_i$ 为加权求和特征。与 Transformer 中使用的注意力机制相比，这种注意力机制的实现可以用更少的参数有效地学习局部特征。

步骤 S4：逐层解码

每个解码层都包含上采样和多层感知机，使其与原始输入点云的维度相匹配，以便进行后续的下游任务。

步骤 S5：得到预测结果

用多层感知机对解码后的特征进行提取和调整，再用全连接层将每个点的特征向量映射到最终的语义分割标签空间，得到每个点属于各个类别的概率分布，进而得到，从而完成整个点云的语义分割任务。

六、本申请提案的关键点和欲保护点

6.1 非参数的特征提取方案

与 PointNet 及其后续研究中常见的使用复杂的可学习算子提取特征的方式不同，TriEn-Net 分别用非参数编码模块和非参数注意力模块以无参的形式提取位置信息和高维语义信息，在保证语义分割高精度的同时提高了整体计算效率和存储效率，具有良好的实际应用能力。

具体来说，TriEn-Net 引入非参数编码模块用于点的空间坐标编码。非参数编码模块利用三角函数对点的空间坐标进行编码，无需额外参数即可有效提取坐标信息和结构特征。与现有技术中常见的使用 MLP 捕获点云位置信息的方法相比，这种设计不仅增强了特征表示能力，而且避免了引入额外参数，从而在保证模型性能的同时，保持了模型的简洁性和计算效率。

TriEn-Net 还采用了非参数注意力模块用于对特征进行编码。非参数注意力模块通过优化的能量函数作为非参数注意力机制，通过计算点之间的线性可分性来分配权重，并用闭式解计算得到的注意力分数对特征进行加权，高效地提取重要的语义信息。与传统参数化注意力机制相比，非参数注意力模块在使用注意力机制提取特征时无需引入额外的参数，简化了模型训练。

6.2 整体点云处理

本申请提案中，TriEn-Net 采用了整体点云直接输入的方式，而非传统的分块处理方法。现有

技术如 PointNet 及其后续研究，通过将大规模点云划分为小块进行处理，破坏了场景中的几何结构，限制了大范围上下文信息的捕捉能力，进而损失了部分局部语义分割的性能。TriEn-Net 摒弃了分块处理，直接对整体点云进行操作，从而避免了上述问题，能够更全面地捕捉点云数据中的大范围上下文信息，提高了语义分割的整体效果和精度。

6.3 点云坐标、高维语义特征分开编码

本申请提案中，TriEn-Net 采用了一种创新的方法，将点云坐标特征与高维语义特征分开编码。这一设计显著区别于现有点云语义分割模型的常规方法。传统模型通常将点云的所有特征统一进行编码和特征提取，未能充分考虑不同特征的性质和需求。这种单一编码方式虽然实现简单，但在处理复杂点云数据时，可能无法有效捕捉到点云的空间几何信息和高维语义信息之间的细微差异。

在 TriEn-Net 中，点云坐标特征通过非参数编码模块进行处理，高维语义特征则通过非参数注意力模块进行编码。通过将点云坐标特征和高维语义特征分开编码，TriEn-Net 模型能够更加精确地处理和表示不同类型的特征信息，避免了传统方法中统一编码可能导致的信息混淆和特征提取不充分的问题，提升了特征提取的精度。

七、与第三条中最接近的现有技术相比，本申请提案有何技术优点

本申请提案提出的 TriEn-Net 模型与第三条中的现有技术专利 CN 114758129 A 一种基于局部特征增强的 RandLA-Net 室外场景语义分割方法最接近，以下将详细罗列与 CN 114758129 A 相比 TriEn-Net 模型的技术优点。

7.1 特征提取能力更好

技术优点：专利 CN 114758129 A 在处理真实场景数据集时的性能有所不足，分割精度相对较低，TriEn-Net 在特征提取能力上优于 RandLA-Net，特别是在处理复杂几何结构和语义信息丰富的场景时表现突出，能够更精细地捕捉点云的结构特征和语义特征，从而在语义分割任务中取得更高的精度。

技术手段：相较于专利 CN 114758129 A 只对坐标信息进行单独编码，并在模型中使用单一的 MLP 进行编码，TriEn-Net 将点云坐标特征和高维语义特征分别编码并使用了丰富且互补的编码方式。通过将点云坐标特征和高维语义特征分开编码，TriEn-Net 能够分别处理空间坐标和语义信息。这种方式使得模型能够更好地利用点云数据的不同维度特性，从而增强整体特征表示能力。与此同时，TriEn-Net 引入了丰富的特征提取方法，即两种非参数特征提取方法三角函数编码和能量函数编码，以及参数化特征提取方法常规注意力机制和 MLP，不同特征提取方法之间存在优势互补作用，因此组合使用进一步提高了特征提取的精度。

7.2 计算效率更高

技术优点：TriEn-Net 相较于专利 CN 114758129 A 提高了计算效率，能够更高效的处理大规模的点云数据而无需进行预处理或分块。这使得 TriEn-Net 模型具有更好的实际应用能力，尤其是在资源有限的嵌入式系统上。

技术手段：相较于专利 CN 114758129 A 使用参数化的 MLP 进行编码，TriEn-Net 通过引入非参数化编码模块和非参数化注意力模块，分别用无参的方法编码点云的空间坐标和语义特征。通过这种方式，模型在不增加额外参数的情况下，能够更有效地提取点云特征，同时避免了传统方法中对点云进行复杂预处理和分块所需的高计算开销。

综上所述，TriEn-Net 在特征提取能力、计算效率等方面均优于专利 CN 114758129 A，使其在大规模点云语义分割任务中具有更显著的技术优势和实际应用潜力。

八、本发明是否经过实验、模拟、使用而证明可行，结果如何？

【展示实验结果/效果】

为了验证 TriEn-Net 模型的有效性，我们在两个广泛使用的基准数据集 SemanticKITTI 和 S3DIS 上进行了全面的实验。所有实验均基于 Python 3.7 和 Tensorflow 1.13.0 进行，使用了配备 24GB 内存的 Nvidia 3090 GPU。训练过程中使用 Adam 优化器，学习率设为 1e-2，权重衰减率为 0.95。训练批次大小设置为 6，训练周期为 100。

8.1 在 SemanticKITTI 数据集上的评估

SemanticKITTI 是一个大型数据集，该数据集为 KITTI 视觉基准的里程计基准中的 22 个序列提供了详细的扫描级注释。原始的里程计数据集包含 22 个序列，其中序列 00 到 10 被指定为训练集，序列 11 到 21 作为测试集。数据集为训练提供了 23201 个完整的 3D 扫描，为测试提供了 20351 个 3D 扫描。为了保持与原始基准的一致性，我们在序列 00 到 10 上进行训练，但序列 08 被用作验证集，序列 11 到 21 用于在线测试。平均交并比（mIoU）分数作为标准指标。

SemanticKITTI 数据集上的语义分割结果如表 1 所示，TriEn-Net 模型取得了 57.8%的 mIoU 值，超过了所有比较方法。本模型在小物体类别和大物体类别（如地形类别中达到 68.7%的 IoU 值）上均表现出色，展示了模型在处理复杂实际场景时的出色泛化能力和鲁棒性。

表 1 在 SemanticiKITTI 数据集上的语义分割结果

方法 类型	参数量 M	平均交并	道路	人行道	停车场	其他地面	建筑物	汽车	卡车	自行车	摩托车	其他车辆	植被	树干	地形	人	骑自行车	骑摩托车	围栏	杆	交通标志

		比%																的人	的人					
基于分割的方法	PointNet	14.6	3	61.6	35.7	15.8	1.4	41.4	46.3	0.1	1.3	0.3	0.8	31	4.6	17.6	0.2	0.2	0	12.9	2.4	3.7
	PointNet++	20.1	6	72.0	41.8	18.7	5.6	62.3	53.7	0.9	1.9	0.2	0.2	46.5	13.8	30	0.9	1.0	0	16.9	6.0	8.9
	SPLATNet	18.4	0.8	64.6	39.1	0.4	0	58.3	58.2	0	0	0	0	71.1	9.9	19.3	0	0	0	23.1	5.6	0
	SqueezeSeg	29.5	1	85.4	54.3	26.9	4.5	57.4	68.8	3.3	16	4.1	3.6	60.0	24.3	53.7	12.9	13.1	0.9	29.0	17.5	24.5
	SqueezeSegV2	39.7	1	88.6	67.6	45.8	17.7	73.7	81.8	13.4	18.5	17.9	14.0	71.8	35.8	60.2	20.1	25.1	3.9	41.1	20.2	36.3
	TangentConv	40.9	0.4	83.9	63.9	33.4	15.4	83.4	90.8	15.2	2.7	16.5	12.1	79.5	49.3	58.1	23.0	28.4	8.1	49.0	35.8	28.5
	DarkNet21Seg	47.4	25	91.4	74.0	57.0	26.4	81.9	85.4	18.6	26.2	26.5	15.6	77.6	48.4	63.6	31.8	33.6	4.0	52.3	36.0	50.0
	DarkNet53Seg	49.9	50	91.8	74.6	64.8	27.9	84.1	86.4	25.5	24.5	32.7	22.6	78.3	50.1	64.0	36.2	33.6	4.7	55.0	38.9	52.2
	RangeNet++	52.2	50	91.8	75.2	65	27.8	87.4	91.4	25.7	25.7	34.4	23	80.5	55.1	64.6	38.3	38.8	4.8	58.6	47.9	55.9
基于整体的方法	SPGraph	17.4	0.25	45.0	28.5	0.6	0.6	64.3	49.3	0.1	0.2	0.2	0.8	48.9	27.2	24.6	0.3	2.7	0.1	20.8	15.9	0.8
	RandLA-Net	53.9	1.24	90.7	73.7	60.3	20.4	86.9	94.2	40.1	26	25.8	38.9	81.4	61.3	66.8	49.2	48.2	7.2	56.3	49.2	47.7
	TriEn-Net	57.8	1.57	91.0	74.6	62.7	26.2	89.5	98.4	61.9	36.7	38.6	38.7	83.6	41.1	68.7	54.3	50.6	21.4	60.4	52.6	51.8

8.2 在 S3DIS 数据集上的评估

S3DIS 数据集包含来自三栋建筑的五个室内区域，总覆盖面积约为 6020 平方米。这些区域包含各种场景，包括办公空间、教育区域、会议室等。数据集涵盖了 271 个独立的房间，并

对墙壁、地板、家具、门等语义类别进行了细致的标注。S3DIS 数据集中的点云数据是经过采样的，每个点包含 XYZ 坐标和 RGB 颜色信息，以及一个指示其类别的语义标签。我们使用 Area-5 作为测试场景，并以平均交并比（mIoU）作为评估指标。

在 S3DIS 数据集上，如表 2 所示，TriEn-Net 模型取得了卓越的 mIoU 值 66.0%。与现有方法相比，TriEn-Net 在大多数类别上表现优异，尤其是在墙壁、窗户和板等类别中分别获得了 83.0%、62.3%和 68.8%的交并比值。通过定性结果展示，我们的模型在处理大规模点云语义分割任务时，预测结果与真实值高度一致，显示了优异的分割性能。

表 2 在 S3DIS 数据集上的语义分割结果

类型	方法	平均交并比%	参数量M	天花板	地板	墙	梁	柱子	窗户	门	桌子	椅子	沙发	书架	黑板	杂物
基于分割的方法	PointNet	41.1	1.7	88.8	97.3	69.8	0.1	3.9	46.3	10.8	58.9	52.6	5.9	40.3	26.4	33.2
	PointCNN	57.3	-	92.3	98.2	79.4	0	17.6	22.8	62.1	74.4	80.6	31.7	66.7	62.1	56.7
	PointWeb	60.3	-	92.0	98.5	79.4	0	21.1	59.7	34.8	76.3	88.3	46.9	69.3	64.9	52.5
	KPConv	67.1	14.1	92.8	97.3	82.4	0	23.9	58.0	69.0	91.0	81.5	75.3	75.4	66.7	58.9
基于整体的方法	SPGraph	58.0	0.28	89.4	96.9	78.1	0	42.8	48.9	61.6	84.7	75.4	69.8	52.6	2.1	52.2
	RandLA-Net	62.4	0.5	91.8	97.7	79.9	0	17.7	61.4	36.1	75.2	87.1	75.5	70.2	66.6	51.6
	SCF-Net	63.7	12.0	90.8	97.0	80.9	0	19.9	60.7	44.6	79.4	87.9	76.1	71.5	68.8	50.4
	TriEn-Net	66.0	0.63	92.8	97.6	83.0	0.2	34.0	62.3	53.0	80.5	85.8	74.6	72.3	68.8	53.7

8.3 消融实验

我们进行了一系列消融实验，以证明我们的非参数编码模块和非参数注意力模块的有效性，所有消融实验都在 S3DIS 数据集上进行，并在 Area-5 上进行测试。如表 3 所示，我们使用不含非参数编码模块和非参数注意力模块的 TriEn-Net 模型作为基线。首先，我们在基线模型上添加了非参数编码模块。在这种情况下，非参数编码模块使用三角函数对点坐标特征进行编码，然后将编码后的点坐标特征与未编码的高维语义特征拼接起来，并通过注意力池化进行聚合。仅添加非参数编码模块后，平均交并比相比基线提高了 16%，达到了 65.0%，这表明非参数编码模块在捕捉位置特征方面的重要性。在此基础上，我们进一步添加了非参数注意力模块，非参数注意力模块使用优化的能量函数对高维语义特征进行编码，从而形成完整的 TriEn-Net 模型。添加非参数注意力模块后，平均交并比增加了 1%，达到了 66.0%，这表明特征编码对提升整体模型性能的有效性。

表 3 消融实验结果

方法	平均交并比%
基线	49.0
基线+非参数编码模块	65.0
基线+非参数编码模块+非参数注意力模块	66.0

九、其他有助于理解本申请提案的技术资料

本模块中将介绍相关术语点云数据和点云语义分割任务。

1、点云数据

点云数据是三维空间中物体的集合，每个点在点云中都具有三维坐标（X, Y, Z）以及可能的颜色信息（RGB）。点云数据通常由激光扫描仪或深度相机采集，能够有效地表示物体的几何形状和空间分布。在计算机视觉和机器人领域，点云数据被广泛应用于物体识别、环境建模和导航等任务。

2、点云语义分割任务

点云语义分割任务旨在将点云数据中的每个点分配到预定义的语义类别中。该任务的目标是对点云数据进行详细的标注，以识别和分类不同的物体或场景组件。与图像分割任务类似，点云语义分割需要处理高维、不规则的数据，并且需要考虑点之间的空间关系和上下文信息。此任务在自动驾驶、增强现实和室内导航等应用中具有重要意义。

申请材料分析说明

1.基础信息

专利名称：一种非参数化表示学习的大规模点云语义分割网络

状态：审查中

2.交底材料

交底材料内容相对较为充实，且提供了非常详细的测试数据。

详细列举并分析了几个现有技术的缺陷，在此基础上明确了本发明所要解决的技术问题。

技术方案的表述上，部分表达由于简写而导致他人阅读理解障碍。一些不同含义的内容采用了相同的字符，而又有同一个含义在不同的公式中采用不同的字符，这是专利撰写中应当避免的。对于神经网络结构的说明存在疏漏，导致撰写不够清楚完整。

3.权利要求书

主题名称由交底材料的“方法”改为了“点云语义分割网络”，使方法类专利转变为产品类专利的表达形式，为后期专利权的有效使用提升便利性。

4.说明书

背景技术部分，技术问题交代明确——现有基于分割的方法无法捕获大范围的上下文信息；基于整体的方法非常耗时，且在面对复杂场景、复杂任务时性能相对较差。

具体实施方式部分，首先对本发明提出的神经网络结构进行讲解说明，之后给出了对此网络与现有方案的横向对比测试，使之与专利法中“创造性”条款的评判定义（相比于现有技术，具有突出的实质性特点和显著的进步）相对应。

有益效果部分，针对各条技术创新点所能带来的技术效果，分别进行了充分的展开说明。

申请稿

说明书摘要

本发明提供了一种非参数化表示学习的大规模点云语义分割网络：包括多个堆叠的编码层和多个堆叠的解码层；所述编码层中，输入的点云先经下采样，并收集各采样点的相邻点；之后分别使用非参数编码模块和非参数注意力模块，提取各采样点及其相邻点的位置特征和语义特征；各点的位置特征与语义特征做连接操作后，再通过特征聚合模块将各相邻点的特征融合到各自对应的采样点中；所述解码层中，包括上采样和多层感知机。本发明中分别用非参数编码模块和非参数注意力模块以无参的形式提取位置信息和高维语义信息，在保证语义分割高精度的同时提高了整体计算效率和存储效率，具有良好的实际应用能力。

权利要求书

1.一种非参数化表示学习的大规模点云语义分割网络，其特征在于：包括多个堆叠的编码层和多个堆叠的解码层；

所述编码层中，输入的点云先经下采样，并收集各采样点的相邻点；之后分别使用非参数编码模块和非参数注意力模块，提取各采样点及其相邻点的位置特征和语义特征；各点的位置特征与语义特征做连接操作后，再通过特征聚合模块将各相邻点的特征融合到各自对应的采样点中；

所述解码层中，包括上采样和多层感知机。

2.根据权利要求 1 所述的非参数化表示学习的大规模点云语义分割网络，其特征在于：以随机采样方式做下采样。

3.根据权利要求 1 所述的非参数化表示学习的大规模点云语义分割网络，其特征在于：所述非参数编码模块中，利用三角函数对各点的坐标进行编码，包括：

A1，计算各采样点距离各自相邻点的距离：

$$\Delta p_{i,k} = \mathrm{Concat}\left(\Delta p_{i,k}^{x}, \Delta p_{i,k}^{y}, \Delta p_{i,k}^{z}\right)$$

$$\begin{cases} \Delta p_{i,k}^{x} = p_{i}^{x} - p_{i,k}^{x} \\ \Delta p_{i,k}^{y} = p_{i}^{y} - p_{i,k}^{y} \\ \Delta p_{i,k}^{z} = p_{i}^{z} - p_{i,k}^{z} \end{cases}$$

其中 $\left(p_i^x, p_i^y, p_i^z\right)$ 为采样点 p_i 的三维坐标，$\left(p_{i,k}^x, p_{i,k}^y, p_{i,k}^z\right)$ 为相邻点 $p_{i,k}$ 的三维坐标，$i \in [1, N']$，$k \in [0, K]$；

A2，将相对位置嵌入到高维向量中：

$$f_{i,k}^{c}=\left(\sin\frac{\alpha\Delta p_{i,k}}{\beta^{\frac{6m}{d}}},\cos\frac{\alpha\Delta p_{i,k}}{\beta^{\frac{6m}{d}}}\right)$$

其中 $f_{i,k}^{c}$为所述非参数编码模块提取的位置特征，α和 β为控制三角函数的振幅和波长，d为输出维数，m为通道索引，$m\in\left[0,\frac{d}{6}\right]$。

4.根据权利要求 3 所述的非参数化表示学习的大规模点云语义分割网络，其特征在于：

$\alpha=100$，$\beta=1000$。

5.根据权利要求 3 所述的非参数化表示学习的大规模点云语义分割网络，其特征在于：所述非参数注意力模块中，包括：

B1，通过以下能量函数进行特征编码：

$$e_{i,k}^{*}=\frac{4\left(\hat{\sigma}_{i}^{2}+\lambda\right)}{\left(f_{i,k}-\hat{\mu}_{i}^{2}\right)+2\hat{\sigma}_{i}^{2}+2\lambda}$$

其中，$\hat{\mu}_{i}$和 $\hat{\sigma}_{i}^{2}$分别为点 p_{i}及其相邻点语义特征之间的均值和方差，$f_{i,k}$为点 $p_{i,k}$初始输入本级编码层时的语义特征，$i\in[1,N']$，$k\in[0,K]$，λ为偏移量；

B2，通过以下函数对各点的语义特征 $f_{i,k}$进行加权编码：

$$f_{i,k}^{s}=\mathrm{Sigmoid}\left(\frac{1}{e_{i,k}^{*}}\right)\cdot f_{i,k}$$

其中，$f_{i,k}^{s}$为所述非参数注意力模块编码后的语义特征。

6.根据权利要求 5 所述的非参数化表示学习的大规模点云语义分割网络，其特征在于：所述特征聚合模块中通过以下方式进行特征聚合：

$$s_{i,k}=\mathrm{Softmax}\left(\mathrm{MLP}\left(f_{i,k}^{g},W\right)\right)$$

$$\tilde{f}_{i}=\sum_{k=0}^{K}\left(f_{i,k}^{g}\cdot s_{i,k}\right)$$

其中，$f_{i,k}^{g}=f_{i,k}^{c}+f_{i,k}^{s}$，$s_{i,k}$为特征 $f_{i,k}^{g}$的注意分数，W为 MLP 的可学习

权值，$\tilde{f}_i$为采样点p_i经本级编码层更新后的语义特征。

7.根据权利要求 1 所述的非参数化表示学习的大规模点云语义分割网络，其特征在于：网络的输入为整个原始点云；在所述多个堆叠的编码层之前设有卷积层，用于提取原始点云的语义特征；

所述卷积层中包括下采样、全连接、ReLU 激活函数、归一化操作。

8.根据权利要求 1 所述的非参数化表示学习的大规模点云语义分割网络，其特征在于：在所述多个堆叠的解码层之后设多层感知机和全连接层；其中：

所述多层感知机用于对解码后的特征进行提取和调整；

所述全连接层用于将每个点的特征向量映射到语义分割标签空间，得到每个点属于各个类别的概率分布。

9.根据权利要求 1 所述的非参数化表示学习的大规模点云语义分割网络，其特征在于：所述解码层的数量与编码层相同。

10.根据权利要求 1 所述的非参数化表示学习的大规模点云语义分割网络，其特征在于：采用 K-NN 算法收集相邻点。

一种非参数化表示学习的大规模点云语义分割网络

技术领域

本发明属于计算机视觉、深度学习技术领域，具体涉及一种非参数化表示学习的大规模点云语义分割网络。

背景技术

目前 3D 点云分割方法主要可分为基于分割的方法（partition-based methods）和基于整体的方法（whole-based methods）。基于分割的方法，如 PointNet、PointNet++、PointWeb、PointConv、DGCNN 和 KPConv，将点云划分为小块（block），然后从每个小块中采样点作为输入，通过分块来处理大规模点云。基于整体的方法，如 SPGraph 和 SuperPoint Transformer 将点云表示为一组超点，并使用超点图来捕获点云的结构和上下文。此外，RandLA-Net 及其后续工作，如 SCF-Net 和 BAAF-Net，将整个点云直接输入，并使用随机采样进行下采样。

但是，对于基于分割的方法，点云被划分为小块（block）时场景中对象的几何结构被破坏，导致该方法无法捕获大范围的上下文信息，这可能会影响整体的语义分割结果；而对于基于整体的方法，将点云划分为超点的预处理方法可能非常耗时，并且部分将整体点云作为输入的模型在面对复杂场景、复杂任务时性能相对较差。

发明内容

针对现有技术中存在的不足，本发明提供了一种非参数化表示学习的大规模点云语义分割网络，用以解决大规模点云数据的高效处理。

本发明通过以下技术手段实现上述技术目的。

一种非参数化表示学习的大规模点云语义分割网络：包括多个堆叠的编码层和多个堆叠的解码层；

所述编码层中，输入的点云先经下采样，并收集各采样点的相邻点；之后分别使用非参数编码模块和非参数注意力模块，提取各采样点及其相邻点的位置特征和语义特征；各点的位置特征与语义特征做连接操作后，再通过特征聚合模块将各相邻点的特征融合到各自对应的采样点中；

所述解码层中，包括上采样和多层感知机。

进一步地，以随机采样方式做下采样。

进一步地，所述非参数编码模块中，利用三角函数对各点的坐标进行编码，包括：

A1，计算各采样点距离各自相邻点的距离：

$$\Delta p_{i,k} = \mathrm{Concat}\left(\Delta p_{i,k}^{x}, \Delta p_{i,k}^{y}, \Delta p_{i,k}^{z}\right)$$

$$\begin{cases} \Delta p_{i,k}^{x} = p_i^{x} - p_{i,k}^{x} \\ \Delta p_{i,k}^{y} = p_i^{y} - p_{i,k}^{y} \\ \Delta p_{i,k}^{z} = p_i^{z} - p_{i,k}^{z} \end{cases}$$

其中 $\left(p_i^{x}, p_i^{y}, p_i^{z}\right)$ 为采样点 p_i 的三维坐标，$\left(p_{i,k}^{x}, p_{i,k}^{y}, p_{i,k}^{z}\right)$ 为相邻点 $p_{i,k}$ 的三维坐标，$i \in [1, N']$，$k \in [0, K]$；

A2，将相对位置嵌入到高维向量中：

$$f_{i,k}^{c} = \left(\sin \frac{\alpha \Delta p_{i,k}}{\beta^{\frac{6m}{d}}}, \cos \frac{\alpha \Delta p_{i,k}}{\beta^{\frac{6m}{d}}} \right)$$

其中 $f_{i,k}^{c}$ 为所述非参数编码模块提取的位置特征，α 和 β 为控制三角函数的振幅和波长，d 为输出维数，m 为通道索引，$m \in \left[0, \frac{d}{6}\right]$。

进一步地，$\alpha = 100$，$\beta = 1000$。

进一步地，所述非参数注意力模块中，包括：

B1，通过以下能量函数进行特征编码：

$$e^{*}_{i,k}=\frac{4\left(\widehat{\sigma}^{2}_{i}+\lambda\right)}{\left(f_{i,k}-\hat{\mu}^{2}_{i}\right)+2\widehat{\sigma}^{2}_{i}+2\lambda}$$

其中，$\hat{\mu}_i$和$\widehat{\sigma}^{2}_{i}$分别为点p_i及其相邻点语义特征之间的均值和方差，$f_{i,k}$为点$p_{i,k}$初始输入本级编码层时的语义特征，$i\in[1,N']$，$k\in[0,K]$，λ为偏移量；

B2，通过以下函数对各点的语义特征$f_{i,k}$进行加权编码：

$$f^{s}_{i,k}=\text{Sigmoid}\left(\frac{1}{e^{*}_{i,k}}\right)\cdot f_{i,k}$$

其中，$f^{s}_{i,k}$为所述非参数注意力模块编码后的语义特征。

进一步地，所述特征聚合模块中通过以下方式进行特征聚合：

$$s_{i,k}=\text{Softmax}\left(\text{MLP}\left(f^{g}_{i,k},W\right)\right)$$

$$\tilde{f}_{i}=\sum_{k=0}^{K}\left(f^{g}_{i,k}\cdot s_{i,k}\right)$$

其中，$f^{g}_{i,k}=f^{c}_{i,k}+f^{s}_{i,k}$，$s_{i,k}$为特征$f^{g}_{i,k}$的注意分数，$W$为 MLP 的可学习权值，$\tilde{f}_i$为采样点$p_i$经本级编码层更新后的语义特征。

进一步地，网络的输入为整个原始点云；在所述多个堆叠的编码层之前设有卷积层，用于提取原始点云的语义特征；

所述卷积层中包括下采样、全连接、ReLU 激活函数、归一化操作。

进一步地，在所述多个堆叠的解码层之后设多层感知机和全连接层；其中：

所述多层感知机用于对解码后的特征进行提取和调整；

所述全连接层用于将每个点的特征向量映射到语义分割标签空间，得到每个点属于各个类别的概率分布。

进一步地，所述解码层的数量与编码层相同。

进一步地，采用 K-NN 算法收集相邻点。

本发明的有益效果为：

（1）本发明提供了一种非参数化表示学习的大规模点云语义分割网络。与 PointNet 及其后续研究中常见的使用复杂的可学习算子提取特征的方式不同，本发明中分别用非参数编码模块和非参数注意力模块以无参的形式提取位置信息和高维语义信息，在保证语义分割高精

度的同时提高了整体计算效率和存储效率，具有良好的实际应用能力。

（2）本发明中引入非参数编码模块用于点的空间坐标编码。非参数编码模块利用三角函数对点的空间坐标进行编码，无需额外参数即可有效提取坐标信息和结构特征。与现有技术中常见的使用 MLP 捕获点云位置信息的方法相比，这种设计不仅增强了特征表示能力，而且避免了引入额外参数，从而在保证模型性能的同时，保持了模型的简洁性和计算效率。

（3）本发明中还采用了非参数注意力模块用于对特征进行编码。非参数注意力模块通过优化的能量函数作为非参数注意力机制，通过计算点之间的线性可分性来分配权重，并用闭式解计算得到的注意力分数对特征进行加权，高效地提取重要的语义信息。与传统参数化注意力机制相比，非参数注意力模块在使用注意力机制提取特征时无需引入额外的参数，简化了模型训练。

（4）本发明采用了整体点云直接输入的方式，而非传统的分块处理方法。现有技术如 PointNet 及其后续研究，通过将大规模点云划分为小块进行处理，破坏了场景中的几何结构，限制了大范围上下文信息的捕捉能力，进而损失了部分局部语义分割的性能。本发明摒弃了分块处理，直接对整体点云进行操作，从而避免了上述问题，能够更全面地捕捉点云数据中的大范围上下文信息，提高了语义分割的整体效果和精度。

（5）本发明中将点云坐标特征与高维语义特征分开编码，这一设计显著区别于现有点云语义分割模型的常规方法。传统模型通常将点云的所有特征统一进行编码和特征提取，未能充分考虑不同特征的性质和需求。这种单一编码方式虽然实现简单，但在处理复杂点云数据时，可能无法有效捕捉到点云的空间几何信息和高维语义信息之间的细微差异。而在本发明中，点云坐标特征通过非参数编码模块进行处理，高维语义特征则通过非参数注意力模块进行编码。通过将点云坐标特征和高维语义特征分开编码，本发明语义分割网络能够更加精确地处理和表示不同类型的特征信息，避免了传统方法中统一编码可能导致的信息混淆和特征提取不充分的问题，提升了特征提取的精度。

附图说明

图 1 为本发明非参数化表示学习的大规模点云语义分割网络的架构图；

图 2 为本发明中编码层的结构示意图。

具体实施方式

下面详细描述本发明的实施例，所示实施例的示例在附图中示出，其中自始至终相通或类似的标号表示相同或类似的元件或具有相同或类似功能的元件。下面通过参考附图描述的实施例是示例性的，旨在用于解释本发明，而不能理解为对本发明的限制。

一、方案

如图 1 所示为本发明非参数化表示学习的大规模点云语义分割网络的架构图，其由多个编码层和多个解码层堆叠而成。为提高计算效率并减少存储需求，在所述编码层中引入了两个非参数模块，分别用于提取局部几何特征丰富的语义特征。本发明中将点云划分为坐标特征和语义特征分别进行编码；具体而言，采用三角函数来探索坐标特征的空间结构，同时利用能量函数来捕捉语义特征的细粒度特征。最后，利用注意力池化来聚合拼接的特征。

结合图 1，本发明大规模点云语义分割方法包括如下部分：

S1，点云特征处理

所述分割网络以整个原始点云作为输入。输入的原始点云经卷积层处理得到语义特征；所述卷积层中包括有下采样、全连接、ReLU 激活函数、归一化操作。所得语义特征与点云原本的坐标特征（即每个点的空间坐标）一同送入编码层进行局部特征提取。

S2，编码层

所述编码层设有多个，前一个编码层的输出作为后一个编码层的输入；在每个编码层中，先通过随机采样方式进行下采样，将输入的点云由 N 个点下采样 N'个点，之后采用 K-最近邻（K-NN）算法，收集每个采样点（N'个点）的相邻点（每个点收集 K 个相邻点）。

参照图 2 所示，每个编码层中还包括非参数编码模块、非参数注意力模块和特征聚合模块。其中：

1）非参数编码模块

利用三角函数对每个点（下采样后的 N'个点及其 K 个相邻点）的坐标进行编码，用以提取局部几何特征。三角函数实现了坐标从三维空间到高维空间的映射，有效地保留了点之间的局部几何结构和全局拓扑信息。由于三角函数的周期性，编码特征具有稳定性和鲁棒性，使其能够更好地处理点云数据中的噪声。

首先，计算每个采样点距离各自（K 个）相邻点的距离：

$$\Delta p_{i,k} = \mathrm{Concat}\left(\Delta p_{i,k}^{x}, \Delta p_{i,k}^{y}, \Delta p_{i,k}^{z}\right)$$

$$\begin{cases} \Delta p_{i,k}^{x} = p_i^{x} - p_{i,k}^{x} \\ \Delta p_{i,k}^{y} = p_i^{y} - p_{i,k}^{y} \\ \Delta p_{i,k}^{z} = p_i^{z} - p_{i,k}^{z} \end{cases}$$

其中 $\left(p_i^{x}, p_i^{y}, p_i^{z}\right)$为采样点 p_i的三维坐标，$\left(p_{i,k}^{x}, p_{i,k}^{y}, p_{i,k}^{z}\right)$为相邻点 $p_{i,k}$的三维坐标，$i \in [1, N']$，$k \in [0, K]$；其中 $k = 0$表示点 p_i自己，$k = 1 \sim K$表

示 p_i的 K 个相邻点。

之后，使用三角函数将上述计算获得的相对位置（ $\Delta p_{i,k}$）嵌入到高维向量（ $f_{i,k}^c$）中：

$$f_{i,k}^c = \left(\sin\frac{\alpha \Delta p_{i,k}}{\beta^{\frac{6m}{d}}}, \cos\frac{\alpha \Delta p_{i,k}}{\beta^{\frac{6m}{d}}} \right)$$

其中 α和 β为控制三角函数的振幅和波长，本实施例中 $\alpha = 100$，$\beta = 1000$；d为输出维数，m为通道索引，$m \in \left[0, \frac{d}{6}\right]$。上述嵌入向量通过连接 $d/6$组 6 维向量组成，将正弦和余弦函数应用于相对位置。

本发明中利用三角函数对空间坐标进行编码，可以捕获具有周期特征的结构特征。此外，深度网络中倾向于低频函数的学习偏差，其表现为频率依赖的学习速度，随着流形复杂性的增加，学习更高频率变得更容易。同时，通过正弦映射变换低维输入有助于 MLP（多层感知机）在训练过程中学习高频内容。因此，使用三角函数可以帮助 MLP 更好地捕获点云的高频特征，在不同模块之间形成优势互补。

2）非参数注意力模块

通过计算点之间的线性可分性来分配权重。因此，本实施例采用优化的能量函数进行特征编码。

本实施例中采用了一种二元标签和正则化的能量函数，其原始函数表达式为：

$$e_t(w_t, b_t, y, x_i) = \frac{1}{M-1} \sum_{i=1}^{M-1} \left(-1 - (w_t x_i + b_t)\right)^2 + \left(1 - (w_t + b_t)\right)^2 + \lambda w_t^2$$

其中，下标 t表示目标点，x_i为目标点的邻域点（相邻点），M为每个通道中能量函数的个数，y为二值标号，取 1 或-1，w_t和 b_t由下式求得：

$$w_t = -\frac{2(t - \mu_t)}{(f_t - \mu_t)^2 + 2\sigma_t^2 + 2\lambda}$$

$$b_t = -\frac{1}{2}(f_t + \mu_t) w_t$$

其中，$\mu_t = \frac{1}{M-1}\sum_{i=1}^{M-1} x_i$、$\sigma_t^2 = \frac{1}{M-1}\sum_{i=1}^{M-1}(x_i - \mu_t)^2$，分别是除点 t外通道中所有点的均值和方差。

基于上述能量函数，假设单个通道中的所有特征都遵循相同的分布是合理的，由此可得

到如下闭型解：

$$e_t^* = \frac{4(\hat{\sigma}^2 + \lambda)}{(f_t - \hat{\mu}^2) + 2\hat{\sigma}^2 + 2\lambda}$$

其中，$\hat{\mu}$和$\hat{\sigma}^2$分别为输入特征的均值和方差，f_t为输入的第t个特征，λ为偏移量。

应用到本发明中，上述公式可以写为：

$$e_{i,k}^* = \frac{4(\hat{\sigma}_i^2 + \lambda)}{(f_{i,k} - \hat{\mu}_i^2) + 2\hat{\sigma}_i^2 + 2\lambda}$$

其中，$\hat{\mu}_i$和$\hat{\sigma}_i^2$分别为点p_i及其相邻点语义特征之间的均值和方差，$f_{i,k}$为点$p_{i,k}$初始输入本级编码层时的语义特征，$i \in [1, N']$，$k \in [0, K]$，λ为偏移量，本实施例中$\lambda = \mathrm{e}^{-4}$。

每个点的重要性程度可由$\frac{1}{e_i^*}$求得；之后，使用 Sigmoid 函数将各点的重要性映射到（0，1）中，用以作为权重对原语义特征进行加权，得到本模块的最终输出：

$$f_{i,k}^s = Y = \mathrm{Sigmoid}\left(\frac{1}{E}\right) \cdot X$$
$$= \mathrm{Sigmoid}\left(\frac{1}{e_{i,k}^*}\right) \cdot f_{i,k}$$

其中，$f_{i,k}^s$为原输入语义特征$f_{i,k}$经非参数注意力模块加权得到编码后的新特征。

本发明中，能量函数基于神经科学理论来确定每个点的重要性，并通过闭式解形式的解决方案快速选择算子，而无需引入额外的参数。同时，能量函数与三角函数的结合可以实现优势互补。三角函数将点的位置信息转化为周期特征，可以很好地描述点的几何特征点云。能量函数基于神经科学原理，优先捕获点云中与相邻点显示不同模式或结构的特征。这两种特征提取方法的结合丰富了本发明语义分割网络的特征表示能力，提高了网络的整体性能。

3）特征聚合模块

将非参数编码模块输出的特征$f_{i,k}^c$与非参数注意力模块输出的特征$f_{i,k}^s$相连接，作为本模块的输入$f_{i,k}^g = f_{i,k}^c + f_{i,k}^s$。

通过非参数方法提取特征后，可能会有一些冗余或不太重要的信息。因此本实施例选择在非参数编码模块和非参数注意力模块之后使用注意力池化来有效地聚合特征，可以选择性

地关注重要的特征，减少对不重要信息的考虑。

具体使用注意机制进行特征聚合。首先用 MLP 学习每个特征的注意分数，再用 Softmax 激活，然后将特征的加权和表示为：

$$s_{i,k} = \mathrm{Softmax}\left(\mathrm{MLP}\left(f_{i,k}^{g}, W\right)\right)$$

$$\tilde{f}_i = \sum_{k=0}^{K}\left(f_{i,k}^{g} \cdot s_{i,k}\right)$$

其中，$s_{i,k}$为特征$f_{i,k}^{g}$的注意分数，W为 MLP 的可学习权值，$\tilde{f}_i$为加权求和后的特征，用于作为采样点p_i经本级编码层更新后的语义特征；也即通过上述方式，将各相邻点（p_{i1}~p_{iK}）的特征融合进对应的采样点（p_i）中。与 Transformer 中使用的注意力机制相比，本实施例中注意力机制的实现可以用更少的参数有效地学习局部特征。

最终本级编码层将下采样后的点云（*N'*个点）及各点的坐标特征（三维坐标）和语义特征（$\tilde{f}_i$，$i \in [1, N']$）输出给下一级编码层。

S3，解码层

所述解码层设有多个，数量与编码层相同，前一个解码层的输出作为后一个解码层的输入。利用多个相堆叠的解码层进行逐层解码，每个解码层都包含有上采样和多层感知机，用以使与原始输入点云的维度相匹配，以便进行后续的下游任务。

S4，输出预测结果

在解码层之后，采用多层感知机对解码后的特征进行提取和调整，再用全连接层将每个点的特征向量映射到最终的语义分割标签空间，得到每个点属于各个类别的概率分布，从而完成整个点云的语义分割任务。

二、测试

为了验证本发明语义分割网络的有效性，本次测试中在两个广泛使用的基准数据集 SemanticKITTI 和 S3DIS 上进行了全面的实验。所有实验均基于 Python 3.7 和 Tensorflow 1.13.0 进行，使用了配备 24GB 内存的 Nvidia 3090 GPU。训练过程中使用 Adam 优化器，学习率设为 1e-2，权重衰减率为 0.95。训练批次大小设置为 6，训练周期为 100。

1.在 SemanticKITTI 数据集上的评估

SemanticKITTI 是一个大型数据集，该数据集为 KITTI 视觉基准的里程计基准中的 22 个

序列提供了详细的扫描级注释。原始的里程计数据集包含 22 个序列，其中序列 00 到 10 被指定为训练集，序列 11 到 21 作为测试集。数据集为训练提供了 23201 个完整的 3D 扫描，为测试提供了 20351 个 3D 扫描。为了保持与原始基准的一致性，本次测试在序列 00 到 10 上进行训练，但序列 08 被用作验证集，序列 11 到 21 用于在线测试。平均交并比（mIoU）分数作为标准指标。

SemanticKITTI 数据集上的语义分割结果下如表 1 所示，本发明语义分割网络取得了 57.8%的 mIoU 值，超过了所有比较方法。本发明语义分割网络在小物体类别和大物体类别（如地形类别中达到 68.7%的 IoU 值）上均表现出色，展示了模型在处理复杂实际场景时的出色泛化能力和鲁棒性。

表 1：SemanticKITTI 数据集上性能评估

类型	方法	平均交并比 %	参数量 M	道路	人行道	停车场	其他地面	建筑物	汽车	卡车	自行车	摩托车	其他车辆
基于分割的方法	PointNet	14.6	3	61.6	35.7	15.8	1.4	41.4	46.3	0.1	1.3	0.3	0.8
	PointNet++	20.1	6	72.0	41.8	18.7	5.6	62.3	53.7	0.9	1.9	0.2	0.2
	SPLATNet	18.4	0.8	64.6	39.1	0.4	0	58.3	58.2	0	0	0	0
	SqueezeSeg	29.5	1	85.4	54.3	26.9	4.5	57.4	68.8	3.3	16	4.1	3.6
	SqueezeSegV2	39.7	1	88.6	67.6	45.8	17.7	73.7	81.8	13.4	18.5	17.9	14.0
	TangentConv	40.9	0.4	83.9	63.9	33.4	15.4	83.4	90.8	15.2	2.7	16.5	12.1
	DarkNet21Seg	47.4	25	91.4	74.0	57.0	26.4	81.9	85.4	18.6	26.2	26.5	15.6
	DarkNet53Seg	49.9	50	**91.8**	74.6	64.8	**27.9**	84.1	86.4	25.5	24.5	32.7	22.6

	RangeNet++	52.2	50	**91.8**	**75.2**	**65**	27.8	87.4	91.4	25.7	25.7	34.4	23
基于整体的方法	SPGraph	17.4	0.25	45.0	28.5	0.6	0.6	64.3	49.3	0.1	0.2	0.2	0.8
	RandLA-Net	53.9	1.24	90.7	73.7	60.3	20.4	86.9	94.2	40.1	26	25.8	**38.9**
	本发明	**57.8**	1.57	91.0	74.6	62.7	26.2	**89.5**	**98.4**	**61.9**	**36.7**	**38.6**	38.7
类型	方法	植被	树干	地形	人	骑自行车的人	骑摩托车的人	围栏	杆	交通标志			
基于分割的方法	PointNet	31	4.6	17.6	0.2	0.2	0	12.9	2.4	3.7			
	PointNet++	46.5	13.8	30	0.9	1.0	0	16.9	6.0	8.9			
	SPLATNet	71.1	9.9	19.3	0	0	0	23.1	5.6	0			
	SqueezeSeg	60.0	24.3	53.7	12.9	13.1	0.9	29.0	17.5	24.5			
	SqueezeSegV2	71.8	35.8	60.2	20.1	25.1	3.9	41.1	20.2	36.3			
	TangentConv	79.5	49.3	58.1	23.0	28.4	8.1	49.0	35.8	28.5			
	DarkNet21Seg	77.6	48.4	63.6	31.8	33.6	4.0	52.3	36.0	50.0			
	DarkNet53Seg	78.3	50.1	64.0	36.2	33.6	4.7	55.0	38.9	52.2			

	RangeNet++	80.5	55.1	64.6	38.3	38.8	4.8	58.6	47.9	**55.9**
基于整体的方法	SPGraph	48.9	27.2	24.6	0.3	2.7	0.1	20.8	15.9	0.8
	RandLA-Net	81.4	**61.3**	66.8	49.2	48.2	7.2	56.3	49.2	47.7
	本发明	**83.6**	41.1	**68.7**	**54.3**	**50.6**	**21.4**	**60.4**	**52.6**	51.8

2.在 S3DIS 数据集上的评估

S3DIS 数据集包含来自三栋建筑的五个室内区域，总覆盖面积约为 6020 平方米。这些区域包含各种场景，包括办公空间、教育区域、会议室等。数据集涵盖了 271 个独立的房间，并对墙壁、地板、家具、门等语义类别进行了细致的标注。S3DIS 数据集中的点云数据是经过采样的，每个点包含 XYZ 坐标和 RGB 颜色信息，以及一个指示其类别的语义标签。我们使用 Area-5 作为测试场景，并以平均交并比（mIoU）作为评估指标。

在 S3DIS 数据集上，如表 2 所示，本发明语义分割网络取得了卓越的 mIoU 值 66.0%。与现有方法相比，本发明在大多数类别上表现优异，尤其是在墙壁、窗户和板等类别中分别获得了 83.0%、62.3%和 68.8%的交并比值。通过定性结果展示，我们的模型在处理大规模点云语义分割任务时，预测结果与真实值高度一致，显示了优异的分割性能。

表 2：S3DIS 数据集上性能评估

类型	**方法**	**平均交并比%**	**参数量M**	**天花板**	**地板**	**墙**	**梁**	**柱子**	**窗户**	**门**	**桌子**	**椅子**	**沙发**	**书架**	**黑板**	**杂物**
基于分割的	PointNet	41.1	1.7	88.8	97.3	69.8	0.1	3.9	46.3	10.8	58.9	52.6	5.9	40.3	26.4	33.2
	PointCNN	57.3	-	92.3	98.2	79.4	0	17.6	22.8	62.1	74.4	80.6	31.7	66.7	62.1	56.7
	PointWe	60.3	-	92	**98**	79	0	21	59	34	76	**88**	46	69	64	52

方法	b			.0	**.5**	.4		.1	.7	.8	.3	**.3**	.9	.3	.9	.5
	KPConv	**67.1**	14.1	**92.8**	97.3	82.4	0	23.9	58.0	**69.0**	**91.0**	81.5	75.3	**75.4**	66.7	**58.9**
基于整体的方法	SPGraph	58.0	0.28	89.4	96.9	78.1	0	**42.8**	48.9	61.6	84.7	75.4	69.8	52.6	2.1	52.2
	RandLA-Net	62.4	0.5	91.8	97.7	79.9	0	17.7	61.4	36.1	75.2	87.1	75.5	70.2	66.6	51.6
	SCF-Net	63.7	12.0	90.8	97.0	80.9	0	19.9	60.7	44.6	79.4	87.9	**76.1**	71.5	**68.8**	50.4
	本发明	66.0	0.63	**92.8**	97.6	**83.0**	**0.2**	34.0	**62.3**	53.0	80.5	85.8	74.6	72.3	**68.8**	53.7

本发明并不限于上述实施方式，在不背离本发明的实质内容的情况下，本领域技术人员能够做出的任何显而易见的改进、替换或变形均属于本发明的保护范围。

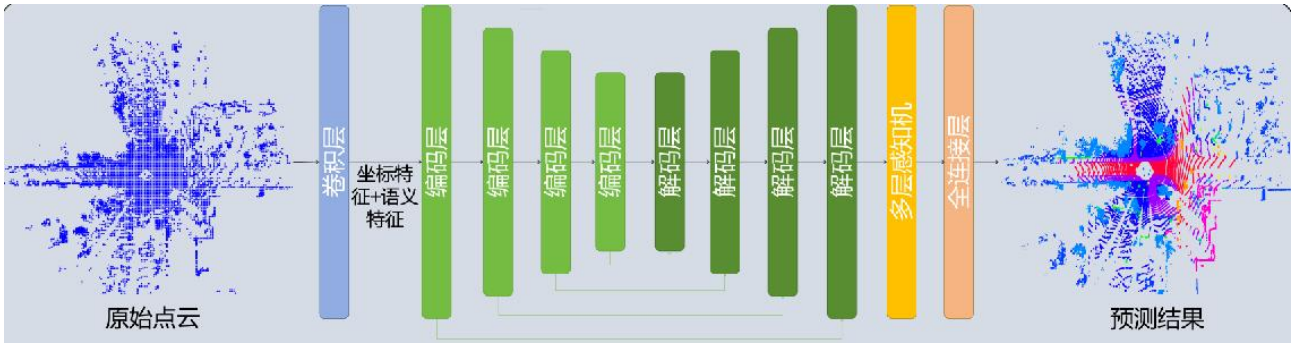


图 1

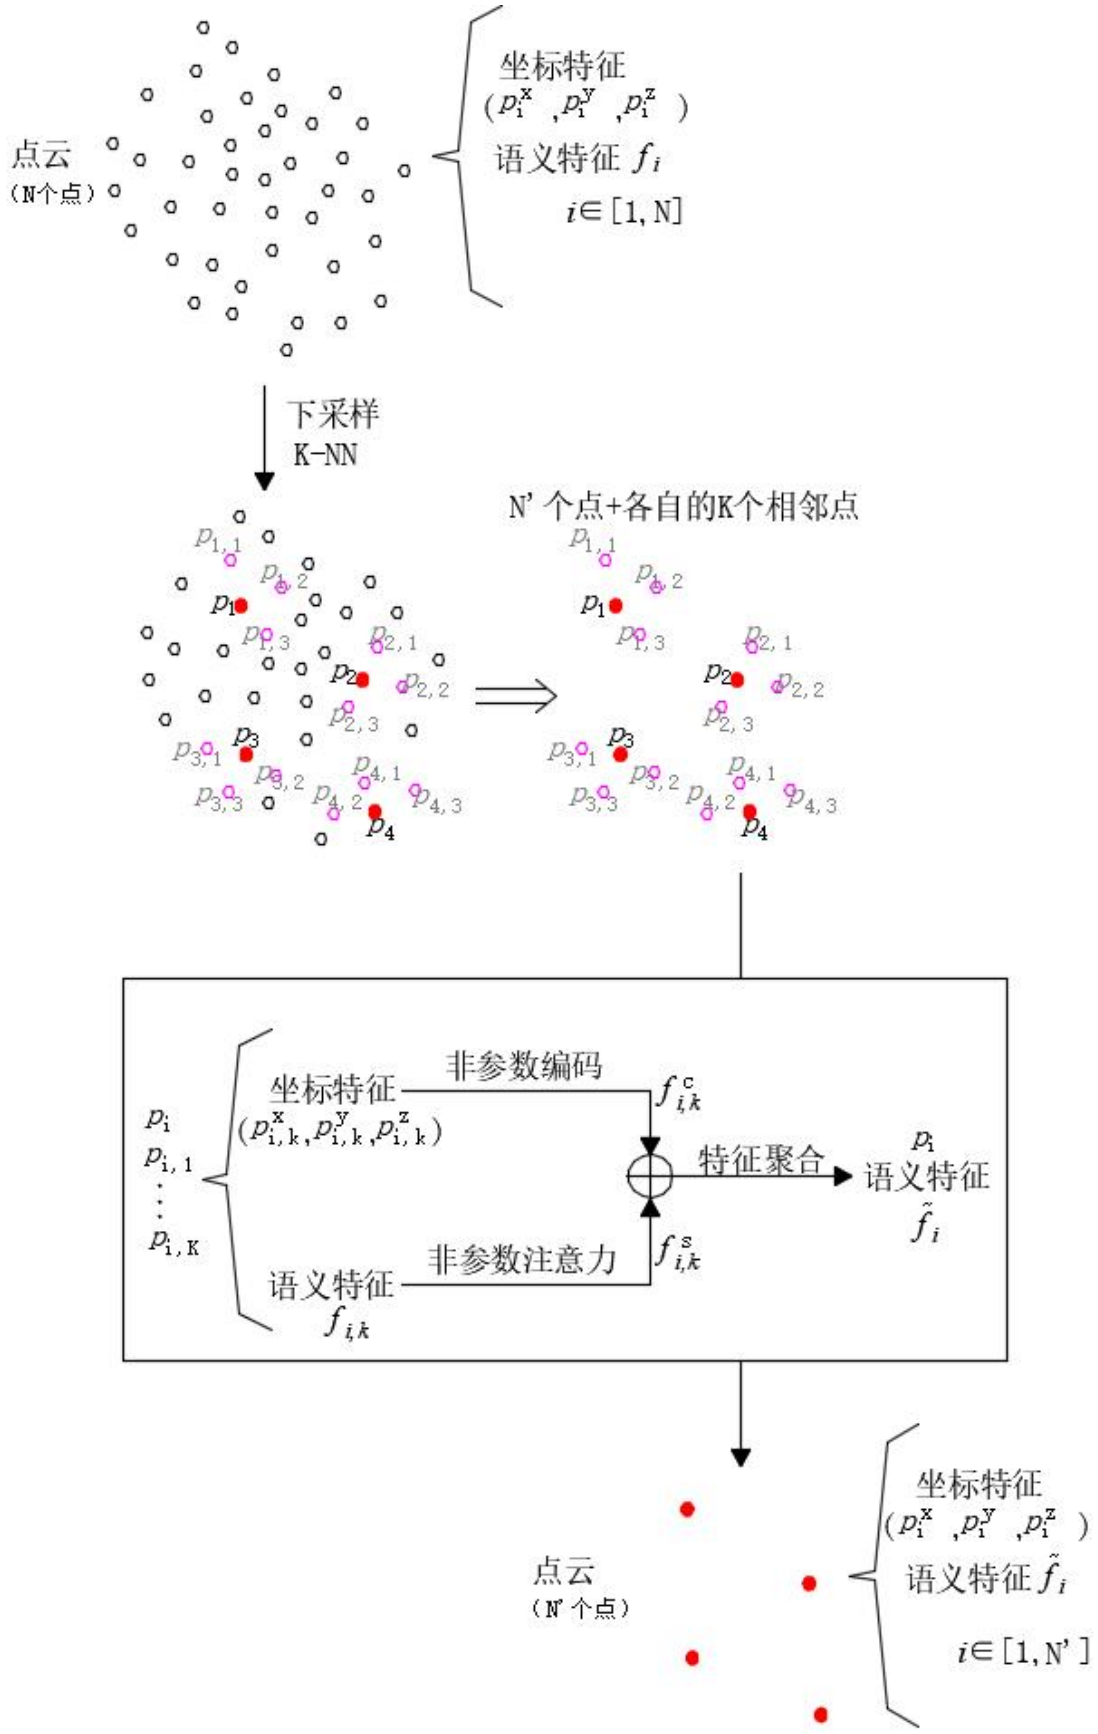

点云
（N个点）
坐标特征
(p_i^x, p_i^y, p_i^z)
语义特征 f_i
$i \in [1, N]$
下采样
K-NN
N' 个点+各自的K个相邻点
p_i
$p_{i,1}$
$p_{i,K}$
坐标特征
$(p_{i,k}^x, p_{i,k}^y, p_{i,k}^z)$
非参数编码
$f_{i,k}^c$
特征聚合
$\tilde{p}_i$
语义特征
$\tilde{f}_i$
非参数注意力
$f_{i,k}^s$
语义特征
$f_{i,k}$
点云
（N' 个点）
坐标特征
(p_i^x, p_i^y, p_i^z)
语义特征 $\tilde{f}_i$
$i \in [1, N']$

图 2

一种雷达通信一体化控制方法、装置、介质、程序产品（发明）技术交底书

1. 相关背景技术及现有技术发展情况：

1.1 背景技术

（简介该技术领域的发展状况，解释关键技术）

该技术领域的发展状况

在固定式雷达系统中，障碍物可能会阻挡雷达与目标的视线路径，导致探测性能的下降。为解决此问题，文献[1-2]提出机载雷达，包括预警机、无人机（Unmanned Aerial Vehicle, UAV）。通过机载计算机的自主控制，机载雷达可以实现灵活飞行，减少信号阻挡，进而取得更广的覆盖范围。此外，机载雷达具有高度可控的机动性，为性能优化引入了轨迹自由度。上述优势在目标跟踪中尤其显著[4]。因此，机载雷达广泛应用于军用和民用领域，比如战争、紧急救援、空中成像、监视监测等[5]。

上述应用场景对通信的需求越来越高，比如战场中的雷达在跟踪目标的同时，需向目标传输作战指挥信息，来避开障碍物或潜在攻击。因此，机载雷达需要具备通信能力。然而，额外安装通信系统会给机载雷达带来沉重的负荷，导致机动性下降和能耗增加。雷达通信一体化技术，可实现雷达与通信共享射频硬件和无线基础设施，为机载雷达实现通信功能提供了有效的解决方案。文献[6,7,8]提出了机载一体化系统，利用轨迹自由度来提高雷达和通信性能。其中文献[6]研究了时分复用模式下的机载一体化系统的时间资源分配、功率资源分配和运行轨迹的联合优化问题；文献[7]通过设计 UAV 的轨迹，在最小化目标定位 CRLB 的同时，实现下行通信速率的最大化；文献[8]提出联合优化机载雷达位置、用户关联和发射功率控制，在定位精度限制下，实现最大化网络总效用。

[1] Albert A, Imsland L. Performance bounds for tracking multiple objects using a single UAV[C]. 2017 International Conference on Unmanned Aircraft Systems (ICUAS), 2017: 1539-1546.

[2] Lu X, Yi W, Kong L. Joint online route planning and resource optimization for multitarget tracking in airborne radar systems[J]. IEEE Systems Journal, 2021, 16(3): 4198-4209.

[3] Guerra A, Dardari D, Djurić P M. Dynamic radar network of UAVs: A joint navigation and tracking approach[J]. IEEE Access, 2020, 8: 116454-116469.

[4] Alhafnawi M, Salameh H B, Masadeh A E, et al. A survey of indoor and outdoor uav-based target tracking systems: Current status, challenges, technologies, and future directions[J]. IEEE Access, 2023, 11: 68324–68339.

[5] Guerra A, Dardari D, Djuric P M. Dynamic radar networks of UAVs: A tutorial overview and tracking performance comparison with terrestrial radar networks[J]. IEEE Vehicular Technology Magazine, 2020, 15(2): 113-120.

[6] 范绍帅, 王煜菲, 田辉, et al. 面向无人机雷达通信一体化系统的轨迹与资源联合优化[J]. 通信学报, 2021, 42(11): 182-192.

[7] Jing X, Liu F, Masouros C, et al. ISAC from the sky: UAV trajectory design for joint communication and target localization[J]. arXiv preprint arXiv:2207.02904, 2022.

[8] Wang X, Fei Z, Zhang J A, et al. Constrained utility maximization in dual-functional radar-communication multi-UAV networks[J]. IEEE Transactions on Communications, 2020, 69(4): 2660-2672.

关键技术

本专利提出了面向目标跟踪的机载一体化系统，通过联合设计一体化波形和系统轨迹，提升跟踪和通信性能。首先，基于目标预估状态，分别推导得出目标跟踪误差和一体化波形、目标跟踪误差和系统运行轨迹、误码率和系统运行轨迹之间的数学关系。然后，基于矩形网格搜索算法和梯度下降法，求解得出最优的一体化波形和运行轨迹。最后，通过仿真验证了所提出方案的有效性。

1.2 与本发明创造相关的现有技术

1.2.1 现有技术的技术方案

（提供相关现有技术、结合附图，用文字对现有技术进行详细描述，以不需要去看文献即可领会该技术内容为准，如果现有技术出自专利、期刊、书籍，则请提供出处。）

在固定式雷达系统中，障碍物可能会阻挡雷达与目标的视线路径，导致探测性能的下降。为解决此问题，文献[1-2]提出机载雷达，包括预警机、无人机（Unmanned Aerial Vehicle, UAV）。通过机载计算机的自主控制，机载雷达可以实现灵活飞行，减少信号阻挡，进而取得更广的覆盖范围。此外，机载雷达具有高度可控的机动性，为性能优化引入了轨迹自由度。上述优势在目标跟踪中尤其显著[4]。因此，机载雷达广泛应用于军用和民用领域，比如战争、紧急救援、空中成像、监视监测等[5]。

上述应用场景对通信的需求越来越高，比如战场中的雷达在跟踪目标的同时，需向目标传输作战指挥信息，来避开障碍物或潜在攻击。因此，机载雷达需要具备通信能力。然而，额外安装通信系统会给机载雷达带来沉重的负荷，导致机动性下降和能耗增加。雷达通信一体化技术，可实现雷达与通信共享射频硬件和无线基础设施，为机载雷达实现通信功能提供了有效的解决方案。文献[6,7,8]提出了机载一体化系统，利用轨迹自由度来提高雷达和通信

性能。其中文献[6]研究了时分复用模式下的机载一体化系统的时间资源分配、功率资源分配和运行轨迹的联合优化问题；文献[7]通过设计 UAV 的轨迹，在最小化目标定位 CRLB 的同时，实现下行通信速率的最大化；文献[8]提出联合优化机载雷达位置、用户关联和发射功率控制，在定位精度限制下，实现最大化网络总效用。

[1] Albert A, Imsland L. Performance bounds for tracking multiple objects using a single UAV[C]. 2017 International Conference on Unmanned Aircraft Systems (ICUAS), 2017: 1539-1546.

[2] Lu X, Yi W, Kong L. Joint online route planning and resource optimization for multitarget tracking in airborne radar systems[J]. IEEE Systems Journal, 2021, 16(3): 4198-4209.

[3] Guerra A, Dardari D, Djurić P M. Dynamic radar network of UAVs: A joint navigation and tracking approach[J]. IEEE Access, 2020, 8: 116454-116469.

[4] Alhafnawi M, Salameh H B, Masadeh A E, et al. A survey of indoor and outdoor uav-based target tracking systems: Current status, challenges, technologies, and future directions[J]. IEEE Access, 2023, 11: 68324–68339.

[5] Guerra A, Dardari D, Djuric P M. Dynamic radar networks of UAVs: A tutorial overview and tracking performance comparison with terrestrial radar networks[J]. IEEE Vehicular Technology Magazine, 2020, 15(2): 113-120.

[6] 范绍帅, 王煜菲, 田辉, et al. 面向无人机雷达通信一体化系统的轨迹与资源联合优化[J]. 通信学报, 2021, 42(11): 182-192.

[7] Jing X, Liu F, Masouros C, et al. ISAC from the sky: UAV trajectory design for joint communication and target localization[J]. arXiv preprint arXiv:2207.02904, 2022.

[8] Wang X, Fei Z, Zhang J A, et al. Constrained utility maximization in dual-functional radar-communication multi-UAV networks[J]. IEEE Transactions on Communications, 2020, 69(4): 2660-2672.

1.2.2 现有技术的缺点

（结合现有技术，客观评价，推导出现有技术存在的缺陷、缺点、不足之处，且所提出的不足之处需要是本发明创造能够解决的问题。本发明不能解决的缺点不必写；如果找不出对比技术方案及其缺点，可用反推法，根据本发明的优点来找对应的缺点；缺点可以是成本高、处理时间慢等类似问题）

首先，目前的相关研究主要关注目标定位，缺乏对目标跟踪场景的考虑。其次，现有研

究主要考虑轨迹设计和资源分配，未能挖掘一体化波形对性能的优化潜力。

2．本发明创造技术方案详细阐述：

(a.交底书一定要使代理人能够看懂为准，尤其是背景技术和详细技术方该部分，要写的清楚，专利必须充分公开；其中，发明人认为需要保密不想公开的内容，可以标注出，但是对代理人不必隐瞒。**b.**材料中有英文缩写的一定要提供中文译文，最好能清楚的解释说明。**c.**全文中对同一事物的称呼请统一，避免前后不一致。)

2.1 本发明创造所要解决的技术问题

（针对现有技术的缺陷、缺点、不足之处，证明描述本技术方案所要解决的技术问题；用正面的、尽可能简洁的语言客观而有根据地反映发明要解决的技术问题，本发明解决不了的，不必写。）

相比于固定式雷达，机载雷达系统凭借平台的高机动性，可以获取更广的探测范围和更优的目标跟踪性能，常用于战场、救灾场景中。为了满足应用场景对通信的需求，本发明把一体化技术引入机载雷达系统中，提出机载雷达与通信一体化系统。然而，高机动性带来轨迹自由度的同时，也给一体化系统和波形设计带来了新的挑战。如何联合发挥一体化波形和系统运行轨迹对跟踪和通信性能的提升作用，成为值得研究的问题。

目前的相关研究主要关注目标定位，缺乏对目标跟踪场景的考虑。其次，现有研究主要考虑轨迹设计和资源分配，未能挖掘一体化波形对性能的优化潜力。因此，本专利围绕一体化波形和系统轨迹优化，研究面向目标跟踪的机载雷达与通信一体化系统方案。

2.2 本发明创造完整的技术方案阐述

（**备注 1：a．**本部分为专利申请中最重要的部分，请提供详细描述，越详细越好，最好结合附图进行说明，附图可以是流程图、电路图、时序图等。**b.** 专利必须是一个完成的技术方案，应该说明发明目的是通过什么技术方案来实现的，不能只有原理，也不能只做功能介绍。**c.** 在这一部分中如果涉及到创新点的技术参数，那么可以写成一个范围形式的，比如是某部件长度 5-10 米的形式，并且在实施例中至少要有 3 个实施例支撑，这 3 个实施例必须是范围的两个端点值和一个任意中间值，如 5、10、和 5-10 之间任意一个值的实施例）

（**备注 2：a. 如果是装置或系统**，应结合附图，阐述装置或系统的组成部分以及各组成部分之间的连接关系，对个组成部分零部件的名称、相互组装及位置关系作出清楚、完整的描述，并说明工作原理、结构特征、工作过程。

b.如果是涉及计算机程序的发明专利，应提供清楚、完成的描述该计算机程序的设计构思及其技术特征以及达到其技术效果的实施方式，最好结合具体实施例对方案进行描述，以本领域技术人员能够根据描述实现方案为准。

c.如果是工艺方法类发明，应给出解决所述技术问题所有必要的工艺流程、所涉及的必要的工艺参数和原料用量，同时客观说明该发明的创新点及该创新点所带来的技术效果。对于优选的工艺流程、参数、原料选取和用量另起一段描述，同时介绍优选方案的技术效果。

d.如果是产品类发明：组合物请给出各组分及各组分的含量，组合物的产品与现有产品相比的有益效果（提供实验数据来支撑）。同时给出优选的组分含量及进一步的有益效果。化合物请给出化合物的化学名称、化学式（包括结构式和/或分子式）、物理化学参数（包括表征的实验数据）。

e.如果是用途或应用类发明：请详细描述用途及应用方法，有益效果。）

发明内容

为解决上述问题，本发明提出一种雷达通信一体化系统设计方法，通过发射单一波形实现目标跟踪和通信功能。

本发明采用的技术方案为：一种雷达通信一体化系统设计方法，包括：

S1、建立面向目标跟踪的机载雷达通信一体化系统模型；

S2、以步骤 S1 建立模型的雷达通信一体化系统的发射波形和运行轨迹为联合优化变量，以跟踪性能和通信性能为目标函数，建立优化模型；

S3、基于网格搜索算法和梯度下降算法交替求解优化模型，得到设计好的雷达通信一体化系统。

步骤 S1 所述的雷达通信一体化系统模型具体为：雷达通信一体化系统包括一个雷达通信一体化 UAV 和 L 个运动目标，雷达通信一体化 UAV 循环执行发射一体化信号、接收目标回波和自适应发射方案调整，目标用来接收通信信号。

为了提升频谱效率，将一体化信号设置为 LFM-CPM 信号，所述的一体化发射信号的表达式为：

$$\tilde{s}_k(t) = s_k(t)\exp(-j2\pi f_c t)$$

其中，f_c 为载频，$s_k(t)$ 表示传输信号的归一化复包络。设发射信号为 LFM-CPM 信号，因此，$s_k(t)$ 数学表示为：

$$s_k(t) = \sum_{n=0}^{N-1} \mathrm{rect}\left(\frac{t-nT_{s,k}}{T_{s,k}}\right)\exp\left(j\pi\mu_k t^2 + j\pi h\left(b_n \frac{t-nT_{s,k}}{T_{s,k}} + \sum_{i=0}^{n-1} b_i\right)\right)$$

其中，$\mathrm{rect}(\cdot)$ 表示矩形函数，N 表示符号数量，μ_k 表示 LFM 的调频率，h 表示调制指数，$T_{s,k}$ 表示符号持续时间，$b_i \in \{\pm 1, \pm 3\}$ 表示传输的信息序列。

设目标距离一体化系统为$R_{l,k}$，相对速度为$v_{l,k}$，目标回波的基带表示为：

$$r_k(t)=\sum_{l=1}^{L}\xi_{l,k}s_k(t-\tau_{l,k})e^{-j2\pi fd_{l,k}t}+n_{l,k}(t)$$

其中，$\xi_{l,k}$表示第l个目标在第k个时间间隔的雷达截面积（Radar Cross Section, RCS），$\tau_{l,k}=2R_{l,k}/c$表示时延，$fd_{l,k}=2v_{l,k}f_c/c$表示多普勒频移，$n_{l,k}(t)$表示均值为0，实谱密度为$N_0/2$的复高斯白噪声。

附图说明

图1为雷达通信一体化系统示意图

图2为雷达通信一体化工作时序图

图3为雷达通信一体化系统工作图

图4为通信误码率性能对比图（线性机动目标）

图5为目标轨迹估计性能对比图（线性机动目标）

图6为目标估计性能对比图（线性机动目标）

图7为通信误码率性能对比图（非线性机动目标）

图8为目标轨迹估计性能对比图（非线性机动目标）

图9为目标估计性能对比图（非线性机动目标）

具体实施方式

本发明主要采用数值仿真实验的方法进行验证，所有步骤、结论均在Matlab2020上验证正确。下面结合附图1-9对本发明内容作进一步说明。

实施例1

本实施例以图1所示的典型雷达通信一体化系统为例，对本发明的内容进行说明，本发明的实施过程包括以下步骤：

步骤1：建立雷达通信一体化场景图和相应的工作时序图，初始化系统参数

如图1，一个典型的雷达通信一体化系统包含雷达通信一体化UAV和目标。机载雷达向目标传输一体化信号以跟踪和传输指挥信息，并通过跟踪滤波算法预估目标状态。根据目标预估位置，调整运行轨迹和发射波形，以提升跟踪精度和通信准确率。

该系统包含一个机载雷达和$L=2$个运动目标。在第k个脉冲间，第l个目标的状态定义为$\boldsymbol{X}_{l,k}=[x_{l,k},y_{l,k},\dot{x}_{l,k},\dot{y}_{l,k},\ddot{x}_{l,k},\ddot{y}_{l,k}]^{\mathrm{T}}$，其中$[\cdot]^{\mathrm{T}}$表示矩阵的转置，$x_{l,k}$和$y_{l,k}$分别表示目标在$x$轴与$y$

轴的位置，$\dot{x}_{l,k}$ 和 $\dot{y}_{l,k}$ 分别表示目标在 x 轴与 y 轴的速度，$\ddot{x}_{l,k}$ 和 $\ddot{y}_{l,k}$ 分别表示目标在 x 轴与 y 轴的加速度。雷达的位置定义为 $\boldsymbol{X}_k=[x_k,y_k]^{\mathrm{T}}$，速度定义为 $\boldsymbol{v}_k=[v_{k,x},v_{k,y}]^{\mathrm{T}}$。

系统的工作方式是循环执行发射一体化信号、接收目标回波和自适应发射方案调整。t_{cycle} 表示一个循环时间周期，其中包含三个重要的时间段：第一个时间段用来探测目标并与之通信，标记为 t_{trans}，表示一体化信号从系统到目标、再反射回来所用的时间；第二个时间段用来对目标回波执行匹配滤波获得目标测量信息后，根据跟踪滤波算法预估目标状态，标记为 t_{rece}；第三个时间段用来根据目标预估状态调整发射波形与系统轨迹，标记为 t_{move}。综上所述，一个时间周期满足 $t_{cycle}=t_{trans}+t_{rece}+t_{move}$，并且小于一体化信号脉冲的重复周期。假设一个脉冲重复周期内只发生一次循环，整个一体化系统工作时序图如图 2 所示。

步骤 2：雷达通信一体化信号模型建立

2.1 根据探测与通信任务需求，选择 LFM-CPM 为发射信号，发射信号的载频 f_c=35GHz，调制指数 $h=1/4$，传输的信息序列 $b_i\in\{\pm1,\pm3\}$，通信符号数量 $N=100$。一体化系统在第 k 个脉冲发送的单脉冲信号为：

$$\tilde{s}_k(t)=s_k(t)\exp(-j2\pi f_c t)$$

其中，$s_k(t)$ 表示传输信号的归一化复包络，数学表示为：

$$s_k(t)=\sum_{n=0}^{N-1}\mathrm{rect}\left(\frac{t-nT_{s,k}}{T_{s,k}}\right)\exp\left(j\pi\mu_k t^2+j\pi h\left(b_n\frac{t-nT_{s,k}}{T_{s,k}}+\sum_{i=0}^{n-1}b_i\right)\right)$$

其中，$\mathrm{rect}(\cdot)$ 表示矩形函数，μ_k 表示 LFM 的调频率，$T_{s,k}$ 表示符号持续时间。

2.2 设目标距离一体化系统为 $R_{l,k}$，相对速度为 $v_{l,k}$，目标回波的基带表示为：

$$r_k(t)=\sum_{l=1}^{L}\xi_{l,k}s_k(t-\tau_{l,k})e^{-j2\pi fd_{l,k}t}+n_{l,k}(t)$$

其中，$\xi_{l,k}$ 表示第 l 个目标在第 k 个时间间隔的雷达截面积（Radar Cross Section, RCS），$\tau_{l,k}=2R_{l,k}/c$ 表示时延，$fd_{l,k}=2v_{l,k}f_c/c$ 表示多普勒频移，$n_{l,k}(t)$ 表示均值为 0，实谱密度为 $N_0/2$ 的复高斯白噪声。值得注意的是，在对目标进行通信和探测的时间段以及对信号接收

处理的时间段中，雷达保持悬停状态。

步骤 3：目标运动和测量模型建立

目前跟踪中常考虑的目标运动模型主要有匀速运动（Constant Velocity, CV）模型、匀加速（Constant Acceleration, CA）运动模型和长转弯（Coordinated Turn, CT）模型。目标运动模型的数学表示为：

$$\boldsymbol{X}_{l,k+1} = \boldsymbol{F}\boldsymbol{X}_{l,k} + \boldsymbol{G}\boldsymbol{\omega}_{l,k}$$

其中，$\boldsymbol{F} \in {}^{6\times6}$ 表示状态转换矩阵，$\boldsymbol{G} \in {}^{6\times2}$ 表示过程噪声分布矩阵，$\boldsymbol{\omega}_{l,k} \in {}^{2\times1}$ 表示均值为$\mathbf{0}$、协方差矩阵为$\boldsymbol{Q}_k$的高斯白噪声向量。对于 CV 模型来说，$\boldsymbol{F}$和$\boldsymbol{G}$分别定义为：

$$\boldsymbol{F}_{CV} = \begin{bmatrix} \begin{bmatrix} 1 & \Delta T \\ 0 & 1 \end{bmatrix} \otimes \boldsymbol{I}_2 & \mathbf{0}_{4\times2} \\ \mathbf{0}_{2\times4} & \mathbf{0}_{2\times2} \end{bmatrix}, \quad \boldsymbol{G}_{CV} = \begin{bmatrix} \frac{\Delta T^2}{2} \\ \Delta T \\ 0 \end{bmatrix} \otimes \boldsymbol{I}_2$$

对于 CA 模型来说，$\boldsymbol{F}$和$\boldsymbol{G}$分别定义为：

$$\boldsymbol{F}_{CA} = \begin{bmatrix} 1 & \Delta T & \frac{\Delta T^2}{2} \\ 0 & 1 & \Delta T \\ 0 & 0 & 1 \end{bmatrix} \otimes \boldsymbol{I}_2, \quad \boldsymbol{G}_{CA} = \begin{bmatrix} \frac{\Delta T^3}{6} \\ \frac{\Delta T^2}{2} \\ \Delta T \end{bmatrix} \otimes \boldsymbol{I}_2$$

对于 CT 模型来说，$\boldsymbol{F}$和$\boldsymbol{G}$分别定义为：

$$\boldsymbol{F}_{CT} = \begin{bmatrix} \begin{bmatrix} 1 & \frac{\sin(\tilde{\omega}\Delta T)}{\tilde{\omega}} & 0 & \frac{\cos(\tilde{\omega}\Delta T)-1}{\tilde{\omega}} \\ 0 & \frac{1-\cos(\tilde{\omega}\Delta T)}{\tilde{\omega}} & 1 & \frac{\sin(\tilde{\omega}\Delta T)}{\tilde{\omega}} \\ 0 & \cos(\tilde{\omega}\Delta T) & 0 & -\sin(\tilde{\omega}\Delta T) \\ 0 & \sin(\tilde{\omega}\Delta T) & 0 & \cos(\tilde{\omega}\Delta T) \end{bmatrix} & \mathbf{0}_{4\times2} \\ \mathbf{0}_{2\times4} & \mathbf{0}_{2\times2} \end{bmatrix}, \quad \boldsymbol{G}_{CT} = \begin{bmatrix} \frac{\Delta T^2}{2} \\ \Delta T \\ 0 \end{bmatrix} \otimes \boldsymbol{I}_2$$

其中$\tilde{\omega}$表示旋转角速度，⊗表示克罗内克积。

第k时刻第l个目标的测量值为：

$$\boldsymbol{z}_{l,k} = \boldsymbol{h}(\boldsymbol{X}_{l,k}, \boldsymbol{X}_k) + \delta_{l,k}$$

其中，$\boldsymbol{h}(\boldsymbol{X}_{l,k}, \boldsymbol{X}_k) = [R_{l,k}, v_{l,k}]^{\mathrm{T}}$为测量函数，$\delta_{l,k}$表示测量误差。测量函数表征了目标距离$R_{l,k}$、

速度$v_{l,k}$和状态$\boldsymbol{X}_{l,k}$之间的非线性关系，具体表示为：

$$R_{l,k}=\sqrt{(x_{l,k}-x_k)^2+(y_{l,k}-y_k)^2}$$
$$v_{l,k}=\frac{\dot{x}_{l,k}(x_{l,k}-x_k)+\dot{y}_{l,k}(y_{l,k}-y_k)}{\sqrt{(x_{l,k}-x_k)^2+(y_{l,k}-y_k)^2}}$$

测量误差$\delta_{l,k}$受到测量距离和波形分辨特性的影响，而测量距离与运行轨迹、波形分辨特性与发射波形紧密相关。测量误差的协方差矩阵$\boldsymbol{U}_{l,k}\in\ ^{2\times2}$，可以较好地表征运行轨迹和发射波形对测量误差的影响。测量误差的协方差矩阵$\boldsymbol{U}_{l,k}$的数学表示为：

$$\boldsymbol{U}_{l,k}=\boldsymbol{\Gamma}\boldsymbol{C}_{l,k}\boldsymbol{\Gamma}$$

其中$\boldsymbol{\Gamma}=\mathrm{diag}[c/2,c/(2f_c)]$表示从时延和多普勒频移到距离和速度的转换矩阵，$c$表示光速。$\boldsymbol{C}_{l,k}$表示在第$k$个周期对第$l$个目标时延和多普勒频移估计的 CRLB，而 CRLB 可以通过计算参数估计的 Fisher 信息矩阵$\boldsymbol{J}_{l,k}$的逆获得，数学表示为：

$$\boldsymbol{C}_{l,k}=\boldsymbol{J}_{l,k}^{-1}$$

为了分别分析雷达运行轨迹和发射波形对性能的影响，将$\boldsymbol{J}_{l,k}$表示为$\boldsymbol{J}_{l,k}=\eta_{l,k}\tilde{\boldsymbol{J}}_k$，其中$\eta_{l,k}$表示信噪比，只受雷达运行轨迹的影响。$\tilde{\boldsymbol{J}}_k$表示 Fisher 信息矩阵$\boldsymbol{J}_{l,k}$中受到波形影响的部分。下面将信噪比$\eta_{l,k}$和只受波形影响的矩阵分开讨论。

首先，$\eta_{l,k}$表示第l个目标信道在第k个跟踪时隙时的信噪比（Signal-to-Noise Ratio, SNR）。$\eta_{l,k}$的数学表示为$\eta_{l,k}=\dfrac{P_{t,l,k}T_{d,l,k}G_{t,l}G_{r,l}\lambda^2\sigma_l}{64\pi^3T_rR_{l,k}^4N_0}$，其中$P_{t,l,k}$表示发射功率，$T_{d,l,k}$表示信号停留时间，$G_{t,l}$表示发射增益，$G_{r,l}$表示目标的接收增益，$\sigma_l$表示第$l$个目标的雷达截面积，$T_r$表示脉冲重复频率，$N_0$表示噪声功率密度。

$\tilde{\boldsymbol{J}}_k$只受波形的影响，其定义为发射波形模糊函数$\chi(\tau,f_d)$在目标时延τ和多普勒频移f_d处的 Hessian 矩阵：

$$\tilde{\boldsymbol{J}}_k=\begin{bmatrix} -\left.\frac{\partial\chi(\tau,f_d)}{\partial\tau\partial\tau}\right|_{\substack{\tau=0\\f_d=0}} & -\left.\frac{\partial\chi(\tau,f_d)}{\partial\tau\partial f_d}\right|_{\substack{\tau=0\\f_d=0}} \\ -\left.\frac{\partial\chi(\tau,f_d)}{\partial\tau\partial f_d}\right|_{\substack{\tau=0\\f_d=0}} & -\left.\frac{\partial\chi(\tau,f_d)}{\partial f_d\partial f_d}\right|_{\substack{\tau=0\\f_d=0}} \end{bmatrix} \quad \begin{bmatrix} \tilde{J}_{k,\tau\tau} & \tilde{J}_{k,\tau f_d} \\ \tilde{J}_{k,\tau f_d} & \tilde{J}_{k,f_d f_d} \end{bmatrix}$$

对称矩阵 $\tilde{\boldsymbol{J}}_k$ 中的 $\tilde{J}_{k,\tau\tau}$ 数学推导结果为：

$$\tilde{J}_{k,\tau\tau}=\sum_{i=-1}^{6}\overline{J}_{k,\tau\tau}^{(i)}T_{s,k}^{i}$$

其中 $\overline{J}_{k,\tau\tau}^{(-1)}=h^2\sum_{n=0}^{N-1}b_n^2$，$\overline{J}_{k,\tau\tau}^{(0)}=-(\frac{h}{2\mu_k}\sum_{n=0}^{N-1}b_n)^2$，$\overline{J}_{k,\tau\tau}^{(1)}=4h\mu_k\sum_{n=0}^{N-1}nb_n+2h\mu_k\sum_{n=0}^{N-1}b_n$，$\overline{J}_{k,\tau\tau}^{(2)}=-\frac{hN}{2\mu_k}\sum_{n=0}^{N-1}b_n$，

$\overline{J}_{k,\tau\tau}^{(3)}=\frac{4\mu_k^2}{3}(N-1)(N^2+N)+\frac{4}{3}N\mu_k^2-\frac{h(N-1)N}{2\mu_k}\sum_{n=0}^{N-1}b_n$ ，$\overline{J}_{k,\tau\tau}^{(4)}=-\frac{N^2}{4}$ ，$\overline{J}_{k,\tau\tau}^{(5)}=-(N-1)N^2$ ，

$\overline{J}_{k,\tau\tau}^{(6)}=-\frac{(N-1)^2N^2}{4}$。

矩阵 $\tilde{\boldsymbol{J}}_k$ 中的 $\tilde{J}_{k,f_df_d}$ 数学表示为：

$$\tilde{J}_{k,f_df_d}=\sum_{i=3}^{4}\overline{J}_{k,f_df_d}^{(i)}T_{s,k}^{i}$$

其中 $\overline{J}_{k,f_df_d}^{(3)}=\frac{N^3}{3}$，$\overline{J}_{k,f_df_d}^{(4)}=-\frac{N^4}{4}$。

矩阵 $\tilde{\boldsymbol{J}}_k$ 中的 $\tilde{J}_{k,\tau f_d}$ 数学表示为：

$$\tilde{J}_{k,\tau f_d}=\tilde{J}_{k,f_d\tau}=\sum_{i=1}^{4}\overline{J}_{k,\tau f_d}^{(i)}T_{s,k}^{i}$$

其中 $\overline{J}_{k,\tau f_d}^{(1)}=\pi h\sum_{n=0}^{N-1}nb_n+\frac{\pi h}{2}\sum_{n=0}^{N-1}b_n$ ，$\overline{J}_{k,\tau f_d}^{(2)}=-\frac{hN^2}{4\mu_k}\sum_{n=0}^{N-1}b_n$ ，

$\overline{J}_{k,\tau f_d}^{(3)}=\frac{2\pi\mu_k}{3}(\frac{(N-1)N(2N-1)}{2}+(N-1)(\frac{3N}{2}+1))-\frac{(N-1)N^3}{4}$，$\overline{J}_{k,\tau f_d}^{(4)}=\frac{N^3}{4}$。

步骤 4：跟踪滤波模型建立

跟踪滤波旨在根据目标运动模型与测量数据预估下一时刻的目标状态。本发明使用扩展

Kalman 滤波实现目标跟踪。首先，已知$k-1$时刻的第l个目标状态估计值为$\boldsymbol{X}_{l,k-1|k-1}$，以及估计协方差为$\boldsymbol{P}_{l,k-1|k-1}$，使用运动模型式对目标在$k$时刻的状态进行预测：

$$\boldsymbol{X}_{l,k|k-1}=\boldsymbol{F}_k\boldsymbol{X}_{l,k-1|k-1}$$

状态预测协方差为：

$$\boldsymbol{P}_{l,k|k-1}=\boldsymbol{F}_k\boldsymbol{P}_{l,k-1|k-1}\boldsymbol{F}_k^T+\boldsymbol{G}\boldsymbol{Q}_{k-1}\boldsymbol{G}^T$$

经过一体化发射信号在k时刻的探测，获得相应的测量值$z_{l,k}$。目标状态估计值以及协方差矩阵更新为：

$$\boldsymbol{X}_{l,k|k}=\boldsymbol{X}_{l,k|k-1}+\boldsymbol{K}_{l,k}(\boldsymbol{z}_{l,k}-\boldsymbol{h}(\boldsymbol{X}_{l,k|k-1},\boldsymbol{X}_k))$$

$$\boldsymbol{P}_{l,k|k}=\boldsymbol{P}_{l,k|k-1}-\boldsymbol{K}_{l,k}\boldsymbol{S}_{l,k}\boldsymbol{K}_{l,k}^T$$

其中$\boldsymbol{S}_{l,k}$和$\boldsymbol{K}_{l,k}$分别为新增协方差和卡尔曼增益，数学表示为：

$$\boldsymbol{S}_{l,k}=\boldsymbol{H}_{l,k}\boldsymbol{P}_{l,k|k-1}\boldsymbol{H}_{l,k}^T+\boldsymbol{U}_{l,k}$$

$$\boldsymbol{K}_{l,k}=\boldsymbol{P}_{l,k|k-1}\boldsymbol{H}_{l,k}^T\boldsymbol{S}_{l,k}^{-1}$$

其中$\boldsymbol{H}_{l,k}$表示测量函数$\boldsymbol{h}(\boldsymbol{X}_{l,k|k-1},\boldsymbol{X}_k)$在预测目标状态$\boldsymbol{X}_{l,k|k-1}$处的雅可比矩阵。

步骤 5：建立自适应一体化系统

设已知$k-1$时刻的目标状态为$\boldsymbol{X}_{l,k-1|k-1}$，相应的状态预测协方差为$\boldsymbol{P}_{l,k-1|k-1}$。使用目标运动模型，可以预测第$k$时刻的目标状态为$\boldsymbol{X}_{l,k|k-1}$。一体化系统根据目标预估状态$\boldsymbol{X}_{l,k|k-1}$来调整运行轨迹和发射波形。

5.1 计算雷达与通信性能指标。目标估计协方差可以作为雷达跟踪性能的衡量指标。预估目标估计协方差$\hat{\boldsymbol{P}}_{l,k|k}$的迹数学表示为：

$$\text{è}_{l,k}(\boldsymbol{X}_{l,k|k-1},\mu_k,T_{s,k},v_{k,x},v_{k,y})=\mathrm{Tr}(\hat{\boldsymbol{P}}_{l,k|k}(\boldsymbol{X}_{l,k|k-1},\mu_k,T_{s,k},v_{k,x},v_{k,y}))$$
$$=\mathrm{Tr}(\boldsymbol{P}_{l,k|k-1}-\boldsymbol{P}_{l,k|k-1}\boldsymbol{H}_{l,k}^{T}(\boldsymbol{H}_{l,k}\boldsymbol{P}_{l,k|k-1}\boldsymbol{H}_{l,k}^{T}+$$
$$\hat{\boldsymbol{U}}_{l,k}(\boldsymbol{X}_{l,k|k-1},\mu_k,T_{s,k},v_{k,x},v_{k,y}))^{-1}\boldsymbol{H}_{l,k}\boldsymbol{P}_{l,k|k-1})$$

其中，$\hat{\boldsymbol{U}}_{l,k}(\boldsymbol{X}_{l,k|k-1},\mu_k,T_{s,k},v_{k,x},v_{k,y})$ 表示预估测量误差协方差，数学表示为：

$$\hat{\boldsymbol{U}}_{l,k}(\boldsymbol{X}_{l,k|k-1},\mu_k,T_{s,k},v_{k,x},v_{k,y})=\Gamma(\hat{\eta}_{lk}\tilde{\boldsymbol{J}}_k)^{-1}\Gamma$$

其中，$\hat{\eta}_{l,k}$ 表示预估测量信噪比，数学表示为 $\hat{\eta}_{l,k}=\dfrac{P_{t,l,k}T_{d,l,k}G_{t,l}G_{r,l}\lambda^2\sigma_l}{64\pi^3T_r\hat{R}_{l,k}^4N_0}$。由于实际的探测距离 $R_{l,k}$ 是未知目标参数 $\boldsymbol{X}_{l,k}$ 的函数，使用预估目标状态 $\boldsymbol{X}_{l,k|k-1}$ 计算预估距离 $\hat{R}_{l,k}$ 以代替实际探测距离 $R_{l,k}$：

$$\hat{R}_{l,k}=\sqrt{(x_{l,k|k-1}-x_k)^2+(y_{l,k|k-1}-y_k)^2}$$

把一体化系统第 k 时刻的速度代入上式，进一步得到：

$$\hat{R}_{l,k}=\sqrt{(x_{l,k|k-1}-(x_{k-1}+v_{k,x}))^2+(y_{l,k|k-1}-(y_{k-1}+v_{k,y}))^2}$$

在通信领域中，误码率是衡量通信有效性的重要指标。与跟踪指标同理，本文使用预估误码率作为通信性能衡量指标。系统的预估误码率为：

$$\bar{\text{y}}_{l,k}(\boldsymbol{X}_{l,k|k-1},v_{k,x},v_{k,y})=Q(\sqrt{d_{\min}^2SNR_{l,k}})$$

其中，$Q(x)=\int_x^{\infty}\dfrac{1}{\sqrt{2\pi}}e^{-\frac{t^2}{2}dt}$ 表示 Q 函数，$d_{\min}$ 表示归一化最小欧氏距离。$SNR_{l,k}$ 表示通信信道的预估信噪比，数学表示为 $SNR_{l,k}=P_{t,l,k}h_{l,k}/N_0$，其中 $h_{l,k}$ 表示预估通信信道增益，数学表示为：

$$h_{l,k}=\frac{G_{t,l}G_{c,l}\lambda^2}{16\pi^2\hat{R}_{l,k}^2}$$

其中，$G_{c,l}$ 表示目标接收天线增益。

5.2 建立优化模型。为了进一步提升目标跟踪精度与通信准确率，本发明设计了一种联合调节系统运行轨迹与发射波形的优化方案。鉴于雷达性能指标与通信性能指标具有不同的量

纲，在此对雷达性能指标 $\grave{\text{e}}_{l,k}$ 和通信性能指标 $\bar{\text{y}}_{l,k}$ 进行归一化处理。基于上述描述，该优化问题的目标是最小化预估目标状态估计误差和预估通信误码率之和：

$$
\begin{aligned}
\mathrm{P}_0:\min_{\mu_k,T_{s,k},v_{k,x},v_{k,y}} \quad & \Phi\Big(\sum_{l=1}^{L}\grave{\text{e}}_{l,k}\left(\boldsymbol{X}_{l,k|k-1},\mu_k,T_{s,k},v_{k,x},v_{k,y}\right)\Big) \\
& +\Phi\Big(\sum_{l=1}^{L}\bar{\text{y}}_{l,k}\left(\boldsymbol{X}_{l,k|k-1},v_{k,x},v_{k,y}\right)\Big) \\
s.t.\ \ & \mu_{\min}\le\mu_k\le\mu_{\max} \\
& T_{s,\min}\le T_{s,k}\le T_{s,\max} \\
& \left|v_{k,x}\right|\le Cons_x \\
& \left|v_{k,y}\right|\le Cons_y
\end{aligned}
$$

其中，Φ 表示归一化操作，$\mu_{\min}$ 和 $\mu_{\max}$ 分别表示 LFM-SO8PSK 调频率 μ_k 的最小值和最大值，$T_{s,\min}$ 和 $T_{s,\max}$ 分别表示通信符号持续时间 $T_{s,k}$ 的最小值和最大值，$Cons_x$ 和 $Cons_y$ 分别表示一体化系统在 x 和 y 方向上每时刻运行距离的限制。为了方便表示，标记 P_0 的目标函数为 $\mathrm{L}\left(\boldsymbol{X}_{l,k|k-1},\mu_k,T_{s,k},v_{k,x},v_{k,y}\right)$。

5.3 优化问题求解。优化问题 P_0 涉及四个相关参数，包括 LFM-SO8PSK 的调频率 μ_k、符号持续时间 $T_{s,k}$、系统在 x 轴的速度 $v_{k,x}$ 和系统在 y 轴上的速度 $v_{k,y}$。从数学角度来看，优化问题 P_0 是一个非线性和非凸的优化问题，其目标函数是非线性和非凸的。同时，调频率、符号持续时间和系统速度是耦合的。综上所述，问题 P_0 难以直接求得最优解，因此，下面提出一个三步法来解决该优化问题。

（1） 问题分解

根据目标估计协方差和通信误码率的表达式，可以观察到前者与发射波形、系统运行轨迹相关，而后者仅与系统运行轨迹相关。因此，本发明将参数分为发射波形相关和运行轨迹相关两部分。随之，原始优化问题 P_0 可以分解为发射波形优化子问题和系统轨迹优化子问题，这两个优化子问题的数学表示分别为：

$$\mathrm{P}_{1.1}:\min_{\mu_k,T_{s,k}} \quad \Phi(\sum_{l=1}^{L} \text{è}_{l,k}(\boldsymbol{X}_{l,k|k-1},\mu_k,T_{s,k}))$$
$$s.t. \quad \mu_{\min}\le\mu_k\le\mu_{\max}$$
$$T_{s,\min}\le T_{s,k}\le T_{s,\max}$$

和

$$\mathrm{P}_{1.2}:\min_{v_{k,x},v_{k,y}} \quad \Phi(\sum_{l=1}^{L} \text{è}_{l,k}(\boldsymbol{X}_{l,k|k-1},\mu_k^*,T_{s,k}^*,v_{k,x},v_{k,y}))+\Phi(\sum_{l=1}^{L} \text{ÿ}_{l,k}(\boldsymbol{X}_{l,k|k-1},v_{k,x},v_{k,y}))$$
$$s.t. \quad |v_{k,x}|\le Cons_x$$
$$|v_{k,y}|\le Cons_y$$

在将原问题P_0分解为发射波形优化和系统轨迹优化两个子问题之后，下面将依次求解并进行迭代优化。

（2） 发射波形优化

首先，固定一体化系统探测位置，将原问题P_0转化为仅关于发射波形的优化问题$\mathrm{P}_{1.1}$。问题$\mathrm{P}_{1.1}$依旧是一个非凸非线性的优化问题，难以直接得到最优解。鉴于 RGS 算法在波形参数优化问题中的计算便捷性和有效性，本专利采用 RGS 算法求解波形优化问题。通过对波形空间进行迭代搜索，RGS 方法可以找到最小化目标函数的波形。

具体而言，在第t轮迭代搜索中，设定待搜索矩形区域的μ_k和$T_{s,k}$两个维度的区间分别为$[\mu_{k,low}^t,\mu_{k,high}^t]$和$[T_{s,k,low}^t,T_{s,k,high}^t]$。在该矩形搜索区域中，参数$\mu_k$维度上一共有$N_\mu$个格点，参数$T_{s,k}$维度上一共有$N_{T_s}$个格点。因此，对于参数$\mu_k$的维度，格点为$\{\mu_{k,1}^t,\mu_{k,2}^t,\cdots,\mu_{k,N_\mu}^t\}$，对于参数$T_s$维度，格点为$\{T_{s,k,1}^t,T_{s,k,2}^t,\cdots,T_{s,k,N_{T_s}}^t\}$，这些点分别均匀分布于$[\mu_{k,low}^t,\mu_{k,high}^t]$和$[T_{s,k,low}^t,T_{s,k,high}^t]$中。RGS 算法搜索得出最优的参数$\mu_{k,N_\mu^*}^t$和$T_{s,k,N_{T_s}^*}^t$，即：

$$(\mu_{k,N_\mu^*}^t,T_{s,k,N_{T_s}^*}^t)=\arg\min_{\mu_k,T_{s,k}} \Phi(\sum_{l=1}^{L} \text{è}_{l,k}(\boldsymbol{X}_{l,k|k-1},\mu_k,T_{s,k}))) \tag{0.1}$$

在第$t+1$轮迭代搜索中，第t轮得出的最优格点$(\mu_{k,N_\mu^*}^t,T_{s,k,N_{T_s}^*}^t)$成为新的搜索区域的中心，其周围的点$[\mu_{k,N_\mu^*-1}^t,\mu_{k,N_\mu^*+1}^t]$以及$[T_{s,k,N_{T_s}^*-1}^t,T_{s,k,N_{T_s}^*+1}^t]$形成新的矩形边界$[\mu_{k,low}^{t+1},\mu_{k,high}^{t+1}]$和$[T_{s,k,low}^{t+1},T_{s,k,high}^{t+1}]$。经过预设轮数的迭代，可以得到最优的波形参数结果$\mu_k^*$和$T_{s,k}^*$。

（3） 系统轨迹优化

得出最优发射波形参数后，将最优信号参数 μ_k^* 和 $T_{s,k}^*$ 代入轨迹优化问题 $\mathrm{P}_{1.2}$ 中，数学表示为：

$$\begin{aligned}\mathrm{P}_{1.2}:\min_{v_{k,x},v_{k,y}}\quad & \Phi(\sum_{l=1}^{L}\text{ə}_{l,k}(\boldsymbol{X}_{l,k|k-1},\mu_k^*,T_{s,k}^*,v_{k,x},v_{k,y}))+\Phi(\sum_{l=1}^{L}\bar{\text{y}}_{l,k}(\boldsymbol{X}_{l,k|k-1},v_{k,x},v_{k,y}))\\ s.t.\quad & |v_{k,x}|\le Cons_x\\ & |v_{k,y}|\le Cons_y\end{aligned}$$

为了方便表示，记 $\mathrm{P}_{1.2}$ 的目标函数为 $\mathrm{L}(v_{k,x},v_{k,y})$。目标函数 $\mathrm{L}(v_{k,x},v_{k,y})$ 具有非凸性，因此使用梯度下降法进行解决。设在第 m 轮迭代中，为了拟合目标函数，对 $\mathrm{L}(v_{k,x},v_{k,y})$ 在给定点 $v_{k,x}^{(m-1)}$ 和 $v_{k,y}^{(m-1)}$ 实施一阶泰勒展开：

$$\begin{aligned}&\mathrm{L}(v_{k,x},v_{k,y})\approx \mathrm{L}(v_{k,x}^{(m-1)},v_{k,y}^{(m-1)})+\nabla\mathrm{L}_{v_{k,x}}(v_{k,x}^{(m-1)},v_{k,y}^{(m-1)})(v_{k,x}-v_{k,x}^{(m-1)})\\ &+\nabla\mathrm{L}_{v_{k,y}}(v_{k,x}^{(m-1)},v_{k,y}^{(m-1)})(v_{k,y}-v_{k,y}^{(m-1)})\end{aligned}$$

其中，$\nabla\mathrm{L}_{v_{k,x}}$ 和 $\nabla\mathrm{L}_{v_{k,y}}$ 分别表示函数 $\mathrm{L}(v_{k,x},v_{k,y})$ 关于 $v_{k,x}$ 和 $v_{k,y}$ 的梯度。将该式右侧的后两项记为 $G(v_{k,x},v_{k,y})$。由此，优化问题 $\mathrm{P}_{1.2}$ 转化为问题 $\mathrm{P}_{1.3}$：

$$\begin{aligned}\mathrm{P}_{1.3}:\min_{v_{k,x},v_{k,y}}\ & G(v_{k,x},v_{k,y})\\ s.t.\quad & |v_{k,x}|\le Cons_x\\ & |v_{k,y}|\le Cons_y\end{aligned}$$

使用搜索法求得问题 $\mathrm{P}_{1.3}$ 的最优解，并标记为 $v_{k,x}^*$ 和 $v_{k,y}^*$。由于优化问题是最小化问题，$v_{k,x}^*-v_{k,x}^{(m-1)}$ 和 $v_{k,y}^*-v_{k,y}^{(m-1)}$ 表示参数 $v_{k,x}$ 和 $v_{k,y}$ 的下降方向。接着，通过搜索得到可以最小化函数 $\mathrm{L}(v_{k,x},v_{k,y})$ 的步长值 ω^*，其取值区间为 $\omega\in[0,1]$。最终，问题 $\mathrm{P}_{1.2}$ 的局部最优解 $v_{k,x}$ 和 $v_{k,y}$ 由下式给出：

$$\begin{aligned}v_{k,x}^{(m)}&=v_{k,x}^{(m-1)}+\omega^*(v_{k,x}^*-v_{k,x}^{(m-1)})\\ v_{k,y}^{(m)}&=v_{k,y}^{(m-1)}+\omega^*(v_{k,y}^*-v_{k,y}^{(m-1)})\end{aligned}$$

5.4 一体化系统工作流程描述。面向目标跟踪与通信一体化系统的工作流程如图所示，其中基本步骤如下：

(1) 在第 $k-1$ 时刻，雷达处于位置 $\boldsymbol{X}_{k-1}$ 处，其向目标发送一体化信号用于探测和数据传输。一体化信号的调频率为 μ_{k-1}，符号持续时间为 $T_{s,k-1}$。接收到目标回波后，雷达接收系统使

用最大似然方法获得目标距离和速度的估计值。

(2) 雷达接收系统把目标距离和速度估计值作为目标状态的测量值 $\boldsymbol{z}_{l,k\text{-}1}$。系统基于目标预估状态 $\boldsymbol{X}_{l,k-1|k-2}$ 和测量值 $\boldsymbol{z}_{l,k\text{-}1}$，使用扩展 Kalman 滤波算法推导出目标状态估计值 $\boldsymbol{X}_{l,k-1|k-1}$ 和状态估计协方差 $\boldsymbol{P}_{l,k-1|k-1}$。

(3) 根据目标运动模型，推导出第 k 时刻的目标状态预估值 $\boldsymbol{X}_{l,k|k-1}$ 和预测协方差 $\boldsymbol{P}_{l,k|k-1}$。

(4) 根据提出的一体化发射波形和系统轨迹联合优化算法，求出第 k 时刻的最优发射信号参数 $\mu_k, T_{s,k}$ 以及探测位置 $\boldsymbol{X}_k$。

2.3 本发明创造技术方案带来的有益效果

（结合技术方案，以因果关系推理的方式推导出本发明能够达到的有益技术效果，可以对应 1.2.2 中现有技术的缺点来描述。）

在固定式雷达系统中，障碍物可能会阻挡雷达与目标的视线路径，导致探测性能的下降。相比于固定式雷达，机载雷达可以实现灵活飞行，减少信号阻挡，进而取得更广的覆盖范围。此外，机载雷达具有高度可控的机动性，为性能优化引入了轨迹自由度。上述优势在目标跟踪中尤其显著。目前机载一体化系统研究主要关注目标定位，缺乏对目标跟踪场景的考虑。其次，现有研究主要考虑轨迹设计和资源分配，未能挖掘一体化波形对性能的优化潜力。

本发明提出了一种雷达通信一体化系统设计方法，解决了现有雷达通信一体化技术中未能挖掘一体化波形对目标跟踪性能优化的问题。首先，基于 UAV 建立了雷达通信一体化系统模型；其次，以所设计的一体化信号波形和系统运行轨迹为优化变量，以跟踪性能和通信性能为目标函数，建立了优化模型；最后利用本发明提出的基于网格搜索和梯度下降交替求解了优化模型，获取设计好的一体化波形和系统运行轨迹。本发明的优点是能较大程度的提升目标跟踪和通信性能。

3．本发明创造的技术关键点和拟保护点：

（简单点明，提炼出本发明创造的技术创新点，以便代理人更清楚的了解技术方案，可以根据前一部分带来有益效果的关键技术点来写，如果包含多个拟保护点，按照重要次序逐条列出）

1. 一体化技术引入机载雷达系统中，提出了面向目标跟踪的机载雷达与通信一体化波形及系统方案。
2. 为了提升目标跟踪精度和通信准确率，提出一种联合一体化波形与系统运行轨迹设计

方案。首先，基于目标的预估状态，分别推导得出目标跟踪误差和一体化波形、目标跟踪误差和系统运行轨迹、误码率和系统运行轨迹之间的数学关系。建立了波形与系统轨迹联合优化问题，以提升目标状态估计精度和通信准确率。鉴于优化函数的非凸性，将优化问题解耦为两个独立的子问题，分别通过矩形网格搜索算法和梯度下降法进行迭代优化，求解得出最优的一体化波形与运行轨迹方案。仿真结果表明，所提出的机载一体化系统方案可以高效地实现多目标跟踪与通信。

4.本发明创造的替代方案：

（如果有其他的方案同样能达到发明目的，请尽量写明，内容的提供可以扩大专利的保护范围；可用其他方式替代的产品形状、构造、方法的执行步骤；包括部分结构、器件、方法步骤的替代，以及完整技术方案的替代。）

5．具体实施例及附图：

（实施例是实施发明内容的具体例子，可有多个实施例；对实施例的描述应当详细，有附图的，应当对照附图。如有附图的，请提供；附图应该是清晰的线条图，黑白方式，且最好是可编辑的。）

本发明主要采用数值仿真实验的方法进行验证，所有步骤，结论均在 Matlab2020 上验证正确。下面结合附图 1-9 对本发明内容作进一步说明。

实施例 1

本实施例以图 1 所示的典型雷达通信一体化系统为例，对本发明的内容进行说明，本发明的实施过程包括以下步骤：

步骤 1：建立雷达通信一体化场景图和相应的工作时序图，初始化系统参数

如图 1，一个典型的雷达通信一体化系统包含雷达通信一体化 UAV 和目标。机载雷达向目标传输一体化信号以跟踪和传输指挥信息，并通过跟踪滤波算法预估目标状态。根据目标预估位置，调整运行轨迹和发射波形，以提升跟踪精度和通信准确率。

该系统包含一个机载雷达和 $L=2$ 个运动目标。在第 k 个脉冲间，第 l 个目标的状态定义为 $\boldsymbol{X}_{l,k}=[x_{l,k},y_{l,k},\dot{x}_{l,k},\dot{y}_{l,k},\ddot{x}_{l,k},\ddot{y}_{l,k}]^{\mathrm{T}}$，其中 $[\cdot]^{\mathrm{T}}$ 表示矩阵的转置，$x_{l,k}$ 和 $y_{l,k}$ 分别表示目标在 x 轴与 y 轴的位置，$\dot{x}_{l,k}$ 和 $\dot{y}_{l,k}$ 分别表示目标在 x 轴与 y 轴的速度，$\ddot{x}_{l,k}$ 和 $\ddot{y}_{l,k}$ 分别表示目标在 x 轴与 y 轴的加速度。雷达的位置定义为 $\boldsymbol{X}_k=[x_k,y_k]^{\mathrm{T}}$，速度定义为 $\boldsymbol{v}_k=[v_{k,x},v_{k,y}]^{\mathrm{T}}$。

系统的工作方式是循环执行发射一体化信号、接收目标回波和自适应发射方案调整。t_{cycle} 表示一个循环时间周期，其中包含三个重要的时间段：第一个时间段用来探测目标并与之通信，

标记为t_{trans}，表示一体化信号从系统到目标、再反射回来所用的时间；第二个时间段用来对目标回波执行匹配滤波获得目标测量信息后，根据跟踪滤波算法预估目标状态，标记为t_{rece}；第三个时间段用来根据目标预估状态调整发射波形与系统轨迹，标记为t_{move}。综上所述，一个时间周期满足$t_{cycle}=t_{trans}+t_{rece}+t_{move}$，并且小于一体化信号脉冲的重复周期。假设一个脉冲重复周期内只发生一次循环，整个一体化系统工作时序图如图 2 所示。

步骤 2：雷达通信一体化信号模型建立

2.1 根据探测与通信任务需求，选择 LFM-CPM 为发射信号，发射信号的载频f_c=35GHz，调制指数$h=1/4$，传输的信息序列$b_i\in\{\pm1,\pm3\}$，通信符号数量$N=100$。一体化系统在第k个脉冲发送的单脉冲信号为：

$$\tilde{s}_k(t)=s_k(t)\exp(-j2\pi f_c t)$$

其中，$s_k(t)$表示传输信号的归一化复包络，数学表示为：

$$s_k(t)=\sum_{n=0}^{N-1}\mathrm{rect}(\frac{t-nT_{s,k}}{T_{s,k}})\exp(j\pi\mu_k t^2+j\pi h(b_n\frac{t-nT_{s,k}}{T_{s,k}}+\sum_{i=0}^{n-1}b_i))$$

其中，rect(·)表示矩形函数，μ_k表示 LFM 的调频率，$T_{s,k}$表示符号持续时间。

2.2 设目标距离一体化系统为$R_{l,k}$，相对速度为$v_{l,k}$，目标回波的基带表示为：

$$r_k(t)=\sum_{l=1}^{L}\xi_{l,k}s_k(t-\tau_{l,k})e^{-j2\pi fd_{l,k}t}+n_{l,k}(t)$$

其中，$\xi_{l,k}$表示第l个目标在第k个时间间隔的雷达截面积（Radar Cross Section, RCS），$\tau_{l,k}=2R_{l,k}/c$表示时延，$fd_{l,k}=2v_{l,k}f_c/c$表示多普勒频移，$n_{l,k}(t)$表示均值为 0，实谱密度为$N_0/2$的复高斯白噪声。值得注意的是，在对目标进行通信和探测的时间段以及对信号接收处理的时间段中，雷达保持悬停状态。

步骤 3：目标运动和测量模型建立

目前跟踪中常考虑的目标运动模型主要有匀速运动（Constant Velocity, CV）模型、匀加速（Constant Acceleration, CA）运动模型和长转弯（Coordinated Turn, CT）模型。目标运动模型的数学表示为：

$$\boldsymbol{X}_{l,k+1}=\boldsymbol{F}\boldsymbol{X}_{l,k}+\boldsymbol{G}\boldsymbol{\omega}_{l,k}$$

其中，$\boldsymbol{F}\in{}^{6\times6}$表示状态转换矩阵，$\boldsymbol{G}\in{}^{6\times2}$表示过程噪声分布矩阵，$\boldsymbol{\omega}_{l,k}\in{}^{2\times1}$表示均值为$\boldsymbol{0}$、协方差矩阵为$\boldsymbol{Q}_k$的高斯白噪声向量。对于 CV 模型来说，$\boldsymbol{F}$和$\boldsymbol{G}$分别定义为：

$$\boldsymbol{F}_{CV}=\begin{bmatrix}\begin{bmatrix}1 & \Delta T\\ 0 & 1\end{bmatrix}\otimes\boldsymbol{I}_2 & \boldsymbol{0}_{4\times2}\\ \boldsymbol{0}_{2\times4} & \boldsymbol{0}_{2\times2}\end{bmatrix},\ \boldsymbol{G}_{CV}=\begin{bmatrix}\frac{\Delta T^2}{2}\\ \Delta T\\ 0\end{bmatrix}\otimes\boldsymbol{I}_2$$

对于 CA 模型来说，$\boldsymbol{F}$和$\boldsymbol{G}$分别定义为：

$$\boldsymbol{F}_{CA}=\begin{bmatrix}1 & \Delta T & \frac{\Delta T^2}{2}\\ 0 & 1 & \Delta T\\ 0 & 0 & 1\end{bmatrix}\otimes\boldsymbol{I}_2,\quad \boldsymbol{G}_{CA}=\begin{bmatrix}\frac{\Delta T^3}{6}\\ \frac{\Delta T^2}{2}\\ \Delta T\end{bmatrix}\otimes\boldsymbol{I}_2$$

对于 CT 模型来说，$\boldsymbol{F}$和$\boldsymbol{G}$分别定义为：

$$\boldsymbol{F}_{CT}=\begin{bmatrix}\begin{bmatrix}1 & \frac{\sin(\tilde{\omega}\Delta T)}{\tilde{\omega}} & 0 & \frac{\cos(\tilde{\omega}\Delta T)-1}{\tilde{\omega}}\\ 0 & \frac{1-\cos(\tilde{\omega}\Delta T)}{\tilde{\omega}} & 1 & \frac{\sin(\tilde{\omega}\Delta T)}{\tilde{\omega}}\\ 0 & \cos(\tilde{\omega}\Delta T) & 0 & -\sin(\tilde{\omega}\Delta T)\\ 0 & \sin(\tilde{\omega}\Delta T) & 0 & \cos(\tilde{\omega}\Delta T)\end{bmatrix} & \boldsymbol{0}_{4\times2}\\ \boldsymbol{0}_{2\times4} & \boldsymbol{0}_{2\times2}\end{bmatrix},\quad \boldsymbol{G}_{CT}=\begin{bmatrix}\frac{\Delta T^2}{2}\\ \Delta T\\ 0\end{bmatrix}\otimes\boldsymbol{I}_2$$

其中$\tilde{\omega}$表示旋转角速度，⊗表示克罗内克积。

第k时刻第l个目标的测量值为：

$$\boldsymbol{z}_{l,k}=\boldsymbol{h}(\boldsymbol{X}_{l,k},\boldsymbol{X}_k)+\ \delta_{l,k}$$

其中，$\boldsymbol{h}(\boldsymbol{X}_{l,k},\boldsymbol{X}_k)=[R_{l,k},v_{l,k}]^{\mathrm{T}}$为测量函数，$\delta_{l,k}$表示测量误差。测量函数表征了目标距离$R_{l,k}$、速度$v_{l,k}$和状态$\boldsymbol{X}_{l,k}$之间的非线性关系，具体表示为：

$$R_{l,k}=\sqrt{(x_{l,k}-x_k)^2+(y_{l,k}-y_k)^2}$$
$$v_{l,k}=\frac{\dot{x}_{l,k}(x_{l,k}-x_k)+\dot{y}_{l,k}(y_{l,k}-y_k)}{\sqrt{(x_{l,k}-x_k)^2+(y_{l,k}-y_k)^2}}$$

测量误差$\delta_{l,k}$受到测量距离和波形分辨特性的影响，而测量距离与运行轨迹、波形分辨特性与发射波形紧密相关。测量误差的协方差矩阵$\boldsymbol{U}_{l,k}\in{}^{2\times2}$，可以较好地表征运行轨迹和发射波形

对测量误差的影响。测量误差的协方差矩阵$\boldsymbol{U}_{l,k}$的数学表示为：

$$\boldsymbol{U}_{l,k}=\boldsymbol{\Gamma}\boldsymbol{C}_{l,k}\boldsymbol{\Gamma}$$

其中$\boldsymbol{\Gamma}=\mathrm{diag}[c/2,c/(2f_c)]$表示从时延和多普勒频移到距离和速度的转换矩阵，$c$表示光速。$\boldsymbol{C}_{l,k}$表示在第$k$个周期对第$l$个目标时延和多普勒频移估计的 CRLB，而 CRLB 可以通过计算参数估计的 Fisher 信息矩阵$\boldsymbol{J}_{l,k}$的逆获得，数学表示为：

$$\boldsymbol{C}_{l,k}=\boldsymbol{J}_{l,k}^{-1}$$

为了分别分析雷达运行轨迹和发射波形对性能的影响，将$\boldsymbol{J}_{l,k}$表示为$\boldsymbol{J}_{l,k}=\eta_{l,k}\tilde{\boldsymbol{J}}_k$，其中$\eta_{l,k}$表示信噪比，只受雷达运行轨迹的影响。$\tilde{\boldsymbol{J}}_k$表示 Fisher 信息矩阵$\boldsymbol{J}_{l,k}$中受到波形影响的部分。下面将信噪比$\eta_{l,k}$和只受波形影响的矩阵分开讨论。

首先，$\eta_{l,k}$表示第l个目标信道在第k个跟踪时隙时的信噪比（Signal-to-Noise Ratio, SNR）。$\eta_{l,k}$的数学表示为$\eta_{l,k}=\dfrac{P_{t,l,k}T_{d,l,k}G_{t,l}G_{r,l}\lambda^2\sigma_l}{64\pi^3T_rR_{l,k}^4N_0}$，其中$P_{t,l,k}$表示发射功率，$T_{d,l,k}$表示信号停留时间，$G_{t,l}$表示发射增益，$G_{r,l}$表示目标的接收增益，$\sigma_l$表示第$l$个目标的雷达截面积，$T_r$表示脉冲重复频率，$N_0$表示噪声功率密度。

$\tilde{\boldsymbol{J}}_k$只受波形的影响，其定义为发射波形模糊函数$\chi(\tau,f_d)$在目标时延τ和多普勒频移f_d处的 Hessian 矩阵：

$$\tilde{\boldsymbol{J}}_k=\begin{bmatrix}-\left.\dfrac{\partial\chi(\tau,f_d)}{\partial\tau\partial\tau}\right|_{\substack{\tau=0\\f_d=0}} & -\left.\dfrac{\partial\chi(\tau,f_d)}{\partial\tau\partial f_d}\right|_{\substack{\tau=0\\f_d=0}}\\ -\left.\dfrac{\partial\chi(\tau,f_d)}{\partial\tau\partial f_d}\right|_{\substack{\tau=0\\f_d=0}} & -\left.\dfrac{\partial\chi(\tau,f_d)}{\partial f_d\partial f_d}\right|_{\substack{\tau=0\\f_d=0}}\end{bmatrix}\quad\begin{bmatrix}\tilde{J}_{k,\tau\tau} & \tilde{J}_{k,\tau f_d}\\ \tilde{J}_{k,\tau f_d} & \tilde{J}_{k,f_df_d}\end{bmatrix}$$

对称矩阵$\tilde{\boldsymbol{J}}_k$中的$\tilde{J}_{k,\tau\tau}$数学推导结果为：

$$\tilde{J}_{k,\tau\tau}=\sum_{i=-1}^{6}\bar{J}_{k,\tau\tau}^{(i)}T_{s,k}^i$$

其中$\bar{J}_{k,\tau\tau}^{(-1)}=h^2\sum_{n=0}^{N-1}b_n^2$，$\bar{J}_{k,\tau\tau}^{(0)}=-(\dfrac{h}{2\mu_k}\sum_{n=0}^{N-1}b_n)^2$，$\bar{J}_{k,\tau\tau}^{(1)}=4h\mu_k\sum_{n=0}^{N-1}nb_n+2h\mu_k\sum_{n=0}^{N-1}b_n$，$\bar{J}_{k,\tau\tau}^{(2)}=-\dfrac{hN}{2\mu_k}\sum_{n=0}^{N-1}b_n$，

$\bar{J}_{k,\tau\tau}^{(3)}=\frac{4\mu_k^2}{3}(N-1)(N^2+N)+\frac{4}{3}N\mu_k^2-\frac{h(N-1)N}{2\mu_k}\sum_{n=0}^{N-1}b_n$ ， $\bar{J}_{k,\tau\tau}^{(4)}=-\frac{N^2}{4}$ ， $\bar{J}_{k,\tau\tau}^{(5)}=-(N-1)N^2$ ，

$\bar{J}_{k,\tau\tau}^{(6)}=-\frac{(N-1)^2N^2}{4}$。

矩阵 $\tilde{\boldsymbol{J}}_k$ 中的 $\tilde{J}_{k,f_df_d}$ 数学表示为：

$$\tilde{J}_{k,f_df_d}=\sum_{i=3}^{4}\bar{J}_{k,f_df_d}^{(i)}T_{s,k}^{i}$$

其中 $\bar{J}_{k,f_df_d}^{(3)}=\frac{N^3}{3}$， $\bar{J}_{k,f_df_d}^{(4)}=-\frac{N^4}{4}$。

矩阵 $\tilde{\boldsymbol{J}}_k$ 中的 $\tilde{J}_{k,\tau f_d}$ 数学表示为：

$$\tilde{J}_{k,\tau f_d}=\tilde{J}_{k,f_d\tau}=\sum_{i=1}^{4}\bar{J}_{k,\tau f_d}^{(i)}T_{s,k}^{i}$$

其 中 $\bar{J}_{k,\tau f_d}^{(1)}=\pi h\sum_{n=0}^{N-1}nb_n+\frac{\pi h}{2}\sum_{n=0}^{N-1}b_n$ ， $\bar{J}_{k,\tau f_d}^{(2)}=-\frac{hN^2}{4\mu_k}\sum_{n=0}^{N-1}b_n$ ，

$\bar{J}_{k,\tau f_d}^{(3)}=\frac{2\pi\mu_k}{3}(\frac{(N-1)N(2N-1)}{2}+(N-1)(\frac{3N}{2}+1))-\frac{(N-1)N^3}{4}$， $\bar{J}_{k,\tau f_d}^{(4)}=\frac{N^3}{4}$。

步骤 4：跟踪滤波模型建立

跟踪滤波旨在根据目标运动模型与测量数据预估下一时刻的目标状态。本发明使用扩展 Kalman 滤波实现目标跟踪。首先，已知 $k-1$ 时刻的第 l 个目标状态估计值为 $\boldsymbol{X}_{l,k-1|k-1}$，以及估计协方差为 $\boldsymbol{P}_{l,k-1|k-1}$，使用运动模型式对目标在 k 时刻的状态进行预测：

$$\boldsymbol{X}_{l,k|k-1}=\boldsymbol{F}_k\boldsymbol{X}_{l,k-1|k-1}$$

状态预测协方差为：

$$\boldsymbol{P}_{l,k|k-1}=\boldsymbol{F}_k\boldsymbol{P}_{l,k-1|k-1}\boldsymbol{F}_k^T+\boldsymbol{G}\boldsymbol{Q}_{k-1}\boldsymbol{G}^T$$

经过一体化发射信号在 k 时刻的探测，获得相应的测量值 $\boldsymbol{z}_{l,k}$。目标状态估计值以及协方差矩阵更新为：

$$\boldsymbol{X}_{l,k|k}=\boldsymbol{X}_{l,k|k-1}+\boldsymbol{K}_{l,k}(\boldsymbol{z}_{l,k}-\boldsymbol{h}(\boldsymbol{X}_{l,k|k-1},\boldsymbol{X}_k))$$

$$\boldsymbol{P}_{l,k|k}=\boldsymbol{P}_{l,k|k-1}-\boldsymbol{K}_{l,k}\boldsymbol{S}_{l,k}\boldsymbol{K}_{l,k}^T$$

其中 $\boldsymbol{S}_{l,k}$ 和 $\boldsymbol{K}_{l,k}$ 分别为新增协方差和卡尔曼增益，数学表示为：

$$\boldsymbol{S}_{l,k}=\boldsymbol{H}_{l,k}\boldsymbol{P}_{l,k|k-1}\boldsymbol{H}_{l,k}^{T}+\boldsymbol{U}_{l,k}$$

$$\boldsymbol{K}_{l,k}=\boldsymbol{P}_{l,k|k-1}\boldsymbol{H}_{l,k}^{T}\boldsymbol{S}_{l,k}^{-1}$$

其中 $\boldsymbol{H}_{l,k}$ 表示测量函数 $\boldsymbol{h}(\boldsymbol{X}_{l,k|k-1},\boldsymbol{X}_{k})$ 在预测目标状态 $\boldsymbol{X}_{l,k|k-1}$ 处的雅可比矩阵。

步骤 5：建立自适应一体化系统

设已知 $k-1$ 时刻的目标状态为 $\boldsymbol{X}_{l,k-1|k-1}$，相应的状态预测协方差为 $\boldsymbol{P}_{l,k-1|k-1}$。使用目标运动模型，可以预测第 k 时刻的目标状态为 $\boldsymbol{X}_{l,k|k-1}$。一体化系统根据目标预估状态 $\boldsymbol{X}_{l,k|k-1}$ 来调整运行轨迹和发射波形。

5.1 计算雷达与通信性能指标。目标估计协方差可以作为雷达跟踪性能的衡量指标。预估目标估计协方差 $\hat{\boldsymbol{P}}_{l,k|k}$ 的迹数学表示为：

$$\begin{aligned}&\text{ə}_{l,k}(\boldsymbol{X}_{l,k|k-1},\mu_k,T_{s,k},v_{k,x},v_{k,y})=\mathrm{Tr}(\hat{\boldsymbol{P}}_{l,k|k}(\boldsymbol{X}_{l,k|k-1},\mu_k,T_{s,k},v_{k,x},v_{k,y}))\\&=\mathrm{Tr}(\boldsymbol{P}_{l,k|k-1}-\boldsymbol{P}_{l,k|k-1}\boldsymbol{H}_{l,k}^{T}(\boldsymbol{H}_{l,k}\boldsymbol{P}_{l,k|k-1}\boldsymbol{H}_{l,k}^{T}+\\&\hat{\boldsymbol{U}}_{l,k}(\boldsymbol{X}_{l,k|k-1},\mu_k,T_{s,k},v_{k,x},v_{k,y}))^{-1}\boldsymbol{H}_{l,k}\boldsymbol{P}_{l,k|k-1})\end{aligned}$$

其中，$\hat{\boldsymbol{U}}_{l,k}(\boldsymbol{X}_{l,k|k-1},\mu_k,T_{s,k},v_{k,x},v_{k,y})$ 表示预估测量误差协方差，数学表示为：

$$\hat{\boldsymbol{U}}_{l,k}(\boldsymbol{X}_{l,k|k-1},\mu_k,T_{s,k},v_{k,x},v_{k,y})=\Gamma(\hat{\eta}_{lk}\tilde{\boldsymbol{J}}_{k})^{-1}\Gamma$$

其中，$\hat{\eta}_{l,k}$ 表示预估测量信噪比，数学表示为 $\hat{\eta}_{l,k}=\dfrac{P_{t,l,k}T_{d,l,k}G_{t,l}G_{r,l}\lambda^{2}\sigma_{l}}{64\pi^{3}T_{r}\hat{R}_{l,k}^{4}N_{0}}$。由于实际的探测距离 $R_{l,k}$ 是未知目标参数 $\boldsymbol{X}_{l,k}$ 的函数，使用预估目标状态 $\boldsymbol{X}_{l,k|k-1}$ 计算预估距离 $\hat{R}_{l,k}$ 以代替实际探测距离 $R_{l,k}$：

$$\hat{R}_{l,k}=\sqrt{(x_{l,k|k-1}-x_{k})^{2}+(y_{l,k|k-1}-y_{k})^{2}}$$

把一体化系统第 k 时刻的速度代入上式，进一步得到：

$$\hat{R}_{l,k}=\sqrt{(x_{l,k|k-1}-(x_{k-1}+v_{k,x}))^{2}+(y_{l,k|k-1}-(y_{k-1}+v_{k,y}))^{2}}$$

在通信领域中，误码率是衡量通信有效性的重要指标。与跟踪指标同理，本文使用预估误码率作为通信性能衡量指标。系统的预估误码率为：

$$\bar{\text{y}}_{l,k}(\boldsymbol{X}_{l,k|k-1},v_{k,x},v_{k,y})=Q(\sqrt{d_{\min}^{2}SNR_{l,k}})$$

其中，$Q(x)=\int_{x}^{\infty}\dfrac{1}{\sqrt{2\pi}}e^{-\frac{t^{2}}{2}dt}$ 表示 Q 函数，$d_{\min}$ 表示归一化最小欧氏距离。$SNR_{l,k}$ 表示通信信道

的预估信噪比，数学表示为 $SNR_{l,k}=P_{t,l,k}h_{l,k}/N_0$，其中 $h_{l,k}$ 表示预估通信信道增益，数学表示为：

$$h_{l,k}=\frac{G_{t,l}G_{c,l}\lambda^2}{16\pi^2\hat{R}_{l,k}^2}$$

其中，$G_{c,l}$ 表示目标接收天线增益。

5.2 建立优化模型。为了进一步提升目标跟踪精度与通信准确率，本发明设计了一种联合调节系统运行轨迹与发射波形的优化方案。鉴于雷达性能指标与通信性能指标具有不同的量纲，在此对雷达性能指标 $\grave{\partial}_{l,k}$ 和通信性能指标 $\bar{\gamma}_{l,k}$ 进行归一化处理。基于上述描述，该优化问题的目标是最小化预估目标状态估计误差和预估通信误码率之和：

$$\begin{aligned}\mathrm{P}_0:\min_{\mu_k,T_{s,k},v_{k,x},v_{k,y}}\quad & \Phi\Big(\sum_{l=1}^{L}\grave{\partial}_{l,k}(\boldsymbol{X}_{l,k|k-1},\mu_k,T_{s,k},v_{k,x},v_{k,y})\Big)\\ &+\Phi\Big(\sum_{l=1}^{L}\bar{\gamma}_{l,k}(\boldsymbol{X}_{l,k|k-1},v_{k,x},v_{k,y})\Big)\\ s.t.\quad & \mu_{\min}\le\mu_k\le\mu_{\max}\\ & T_{s,\min}\le T_{s,k}\le T_{s,\max}\\ & |v_{k,x}|\le Cons_x\\ & |v_{k,y}|\le Cons_y\end{aligned}$$

其中，Φ 表示归一化操作，$\mu_{\min}$ 和 $\mu_{\max}$ 分别表示 LFM-SO8PSK 调频率 μ_k 的最小值和最大值，$T_{s,\min}$ 和 $T_{s,\max}$ 分别表示通信符号持续时间 $T_{s,k}$ 的最小值和最大值，$Cons_x$ 和 $Cons_y$ 分别表示一体化系统在 x 和 y 方向上每时刻运行距离的限制。为了方便表示，标记 P_0 的目标函数为 $\mathrm{L}(\boldsymbol{X}_{l,k|k-1},\mu_k,T_{s,k},v_{k,x},v_{k,y})$。

5.3 优化问题求解。优化问题 P_0 涉及四个相关参数，包括 LFM-SO8PSK 的调频率 μ_k、符号持续时间 $T_{s,k}$、系统在 x 轴的速度 $v_{k,x}$ 和系统在 y 轴上的速度 $v_{k,y}$。从数学角度来看，优化问题 P_0 是一个非线性和非凸的优化问题，其目标函数是非线性和非凸的。同时，调频率、符号持续时间和系统速度是耦合的。综上所述，问题 P_0 难以直接求得最优解，因此，下面提出一个三步法来解决该优化问题。

（4） 问题分解

根据目标估计协方差和通信误码率的表达式，可以观察到前者与发射波形、系统运行轨

迹相关，而后者仅与系统运行轨迹相关。因此，本发明将参数分为发射波形相关和运行轨迹相关两部分。随之，原始优化问题P_0可以分解为发射波形优化子问题和系统轨迹优化子问题，这两个优化子问题的数学表示分别为：

$$\begin{aligned}\mathrm{P}_{1.1}:\min_{\mu_k,T_{s,k}}\quad & \Phi(\sum_{l=1}^{L}\text{è}_{l,k}(\boldsymbol{X}_{l,k|k-1},\mu_k,T_{s,k}))\\ s.t.\quad & \mu_{\min}\le\mu_k\le\mu_{\max}\\ & T_{s,\min}\le T_{s,k}\le T_{s,\max}\end{aligned}$$

和

$$\begin{aligned}\mathrm{P}_{1.2}:\min_{v_{k,x},v_{k,y}}\quad & \Phi(\sum_{l=1}^{L}\text{è}_{l,k}(\boldsymbol{X}_{l,k|k-1},\mu_k^*,T_{s,k}^*,v_{k,x},v_{k,y}))+\Phi(\sum_{l=1}^{L}\bar{\text{y}}_{l,k}(\boldsymbol{X}_{l,k|k-1},v_{k,x},v_{k,y}))\\ s.t.\quad & |v_{k,x}|\le Cons_x\\ & |v_{k,y}|\le Cons_y\end{aligned}$$

在将原问题P_0分解为发射波形优化和系统轨迹优化两个子问题之后，下面将依次求解并进行迭代优化。

（5） 发射波形优化

首先，固定一体化系统探测位置，将原问题P_0转化为仅关于发射波形的优化问题$\mathrm{P}_{1.1}$。问题$\mathrm{P}_{1.1}$依旧是一个非凸非线性的优化问题，难以直接得到最优解。鉴于 RGS 算法在波形参数优化问题中的计算便捷性和有效性，本专利采用 RGS 算法求解波形优化问题。通过对波形空间进行迭代搜索，RGS 方法可以找到最小化目标函数的波形。

具体而言，在第t轮迭代搜索中，设定待搜索矩形区域的μ_k和$T_{s,k}$两个维度的区间分别为$[\mu_{k,low}^t,\mu_{k,high}^t]$和$[T_{s,k,low}^t,T_{s,k,high}^t]$。在该矩形搜索区域中，参数$\mu_k$维度上一共有$N_\mu$个格点，参数$T_{s,k}$维度上一共有$N_{T_s}$个格点。因此，对于参数$\mu_k$的维度，格点为$\{\mu_{k,1}^t,\mu_{k,2}^t,\cdots,\mu_{k,N_\mu}^t\}$，对于参数$T_s$维度，格点为$\{T_{s,k,1}^t,T_{s,k,2}^t,\cdots,T_{s,k,N_{T_s}}^t\}$，这些点分别均匀分布于$[\mu_{k,low}^t,\mu_{k,high}^t]$和$[T_{s,k,low}^t,T_{s,k,high}^t]$中。RGS 算法搜索得出最优的参数$\mu_{k,N_\mu^*}^t$和$T_{s,k,N_{T_s}^*}^t$，即：

$$(\mu_{k,N_\mu^*}^t,T_{s,k,N_{T_s}^*}^t)=\arg\min_{\mu_k,T_{s,k}}\Phi(\sum_{l=1}^{L}\text{è}_{l,k}(\boldsymbol{X}_{l,k|k-1},\mu_k,T_{s,k}))) \tag{0.1}$$

在第$t+1$轮迭代搜索中，第t轮得出的最优格点$(\mu_{k,N_\mu^*}^t,T_{s,k,N_{T_s}^*}^t)$成为新的搜索区域的中心，

其周围的点 $[\mu^t_{k,N^*_\mu-1},\mu^t_{k,N^*_\mu+1}]$ 以及 $[T^t_{s,k,N^*_{T_s}-1},T^t_{s,k,N^*_{T_s}+1}]$ 形成新的矩形边界 $[\mu^{t+1}_{k,low},\mu^{t+1}_{k,high}]$ 和 $[T^{t+1}_{s,k,low},T^{t+1}_{s,k,high}]$。经过预设轮数的迭代，可以得到最优的波形参数结果 μ^*_k 和 $T^*_{s,k}$。

（6） 系统轨迹优化

得出最优发射波形参数后，将最优信号参数 μ^*_k 和 $T^*_{s,k}$ 代入轨迹优化问题 $\mathrm{P}_{1.2}$ 中，数学表示为：

$$\begin{aligned}\mathrm{P}_{1.2}:\min_{v_{k,x},v_{k,y}}\quad & \Phi(\sum_{l=1}^{L}\text{ə}_{l,k}(\boldsymbol{X}_{l,k|k-1},\mu^*_k,T^*_{s,k},v_{k,x},v_{k,y}))+\Phi(\sum_{l=1}^{L}\bar{\mathrm{y}}_{l,k}(\boldsymbol{X}_{l,k|k-1},v_{k,x},v_{k,y}))\\ s.t.\quad & |v_{k,x}|\le Cons_x\\ & |v_{k,y}|\le Cons_y\end{aligned}$$

为了方便表示，记 $\mathrm{P}_{1.2}$ 的目标函数为 $\mathrm{L}(v_{k,x},v_{k,y})$。目标函数 $\mathrm{L}(v_{k,x},v_{k,y})$ 具有非凸性，因此使用梯度下降法进行解决。设在第 m 轮迭代中，为了拟合目标函数，对 $\mathrm{L}(v_{k,x},v_{k,y})$ 在给定点 $v^{(m-1)}_{k,x}$ 和 $v^{(m-1)}_{k,y}$ 实施一阶泰勒展开：

$$\begin{aligned}&\mathrm{L}(v_{k,x},v_{k,y})\approx \mathrm{L}(v^{(m-1)}_{k,x},v^{(m-1)}_{k,y})+\nabla\mathrm{L}_{v_{k,x}}(v^{(m-1)}_{k,x},v^{(m-1)}_{k,y})(v_{k,x}-v^{(m-1)}_{k,x})\\ &+\nabla\mathrm{L}_{v_{k,y}}(v^{(m-1)}_{k,x},v^{(m-1)}_{k,y})(v_{k,y}-v^{(m-1)}_{k,y})\end{aligned}$$

其中，$\nabla\mathrm{L}_{v_{k,x}}$ 和 $\nabla\mathrm{L}_{v_{k,y}}$ 分别表示函数 $\mathrm{L}(v_{k,x},v_{k,y})$ 关于 $v_{k,x}$ 和 $v_{k,y}$ 的梯度。将该式右侧的后两项记为 $G(v_{k,x},v_{k,y})$。由此，优化问题 $\mathrm{P}_{1.2}$ 转化为问题 $\mathrm{P}_{1.3}$：

$$\begin{aligned}\mathrm{P}_{1.3}:\min_{v_{k,x},v_{k,y}}\quad & G(v_{k,x},v_{k,y})\\ s.t.\quad & |v_{k,x}|\le Cons_x\\ & |v_{k,y}|\le Cons_y\end{aligned}$$

使用搜索法求得问题 $\mathrm{P}_{1.3}$ 的最优解，并标记为 $v^*_{k,x}$ 和 $v^*_{k,y}$。由于优化问题是最小化问题，$v^*_{k,x}-v^{(m-1)}_{k,x}$ 和 $v^*_{k,y}-v^{(m-1)}_{k,y}$ 表示参数 $v_{k,x}$ 和 $v_{k,y}$ 的下降方向。接着，通过搜索得到可以最小化函数 $\mathrm{L}(v_{k,x},v_{k,y})$ 的步长值 ω^*，其取值区间为 $\omega\in[0,1]$。最终，问题 $\mathrm{P}_{1.2}$ 的局部最优解 $v_{k,x}$ 和 $v_{k,y}$ 由下式给出：

$$\begin{aligned}v^{(m)}_{k,x}&=v^{(m-1)}_{k,x}+\omega^*(v^*_{k,x}-v^{(m-1)}_{k,x})\\ v^{(m)}_{k,y}&=v^{(m-1)}_{k,y}+\omega^*(v^*_{k,y}-v^{(m-1)}_{k,y})\end{aligned}$$

5.4 一体化系统工作流程描述。面向目标跟踪与通信一体化系统的工作流程如图所示，其

中基本步骤如下：

(1) 在第$k-1$时刻，雷达处于位置$\boldsymbol{X}_{k-1}$处，其向目标发送一体化信号用于探测和数据传输。一体化信号的调频率为μ_{k-1}，符号持续时间为$T_{s,k-1}$。接收到目标回波后，雷达接收系统使用最大似然方法获得目标距离和速度的估计值。

(2) 雷达接收系统把目标距离和速度估计值作为目标状态的测量值$\boldsymbol{z}_{l,k\text{-}1}$。系统基于目标预估状态$\boldsymbol{X}_{l,k-1|k-2}$和测量值$\boldsymbol{z}_{l,k\text{-}1}$，使用扩展 Kalman 滤波算法推导出目标状态估计值$\boldsymbol{X}_{l,k-1|k-1}$和状态估计协方差$\boldsymbol{P}_{l,k-1|k-1}$。

(3) 根据目标运动模型，推导出第k时刻的目标状态预估值$\boldsymbol{X}_{l,k|k-1}$和预测协方差$\boldsymbol{P}_{l,k|k-1}$。

(4) 根据提出的一体化发射波形和系统轨迹联合优化算法，求出第k时刻的最优发射信号参数$\mu_k, T_{s,k}$以及探测位置$\boldsymbol{X}_k$。

实施例 2

下面根据一个 Matlab 仿真例子对本发明的方案作进一步验证。在仿真中，考虑由一个机载雷达和两个目标组成的一体化系统。设一体化波形 LFM-SO8PSK 的调频率μ取值范围的最小值为$\mu_{\min}=0.01$MHz/s，最大值为$\mu_{\max}=1$MHz/s。符号持续时间T_s取值范围的最小值为$T_{s,\min}=1\mu s$，最大值为$T_{s,\max}=100\mu s$。采样周期为$\Delta T=1s$。雷达初始位置为$[x_1,y_1]^T=[1000\text{m},1000\text{m}]^T$，两个目标初始位置均为$[x_{l,1},y_{l,1}]^T=[800\text{m},1000\text{m}]^T$，$l=1,2$。目标 RCS 的取值范围是$(0,1]$。噪声功率$N_0=-110$ dBm，发射功率$P_{t,l,k}=10$ dBm，载频$f_c=35$GHz，发射增益$G_{t,l}=35$dB，雷达接收增益$G_{r,l}=36$dB，目标接收增益$G_{c,l}=36$dB，协方差矩阵$\boldsymbol{Q}_k=diag([0.01,0.01])$。雷达在$x$轴的速度限制$Cons_x$和在$y$轴的速度限制$Cons_y$均设为 10m/s。所有仿真的结果均通过蒙特卡洛方法得到。

为了验证联合速度与波形自适应优化（Optimized Velocity and Optimized Waveform, OVOW）方案的性能，本节选取了五种具有代表性的相关方案，在目标跟踪精度和误码率指标两个方面进行比较。对比的具体方案如下：方案一为固定式雷达发射固定波形（Fixed Location and Fixed Waveform, FLFW）方案，其中调频率$\mu=0.1$MHz，符号持续时间$T_s=80\mu s$。

方案二为固定式雷达发射自适应最优波形（Fixed Location and Optimized Waveform, FLOW）方案，采用 RGS 算法优化一体化发射波形。方案三为动态雷达保持恒定速度运行，且发射固定波形（Fixed Velocity and Fixed Waveform, FVFW）方案，其中雷达在 x 轴的运行速度 $v_x=-2$ m/s，在 y 轴的运行速度 $v_y=3$ m/s，调频率 $\mu=0.1$ MHz，符号持续时间 $T_s=80\mu s$ 。方案四为雷达保持恒定速度运行，且发射自适应最优波形（Fixed Velocity and Optimized Waveform, FVOW）方案，其中雷达在 x 轴的运行速度 $v_x=-2$ m/s，在 y 轴的运行速度 $v_y=3$ m/s，并且使用 RGS 算法优化一体化波形。方案五为雷达以最优速度运行，且发射固定波形（Optimized Velocity and Fixed Waveform, OVFW）方案，其中系统使用轨迹优化算法（算法 4.2）求得最优轨迹，调频率 $\mu=0.1$ MHz，符号持续时间 $T_s=80\mu s$ 。

图 4 展示了跟踪线性机动目标时的平均误码率随采样时间的变化曲线。容易看出，本发明所提方法根据目标运动状态的改变，可以自适应地调整运行轨迹，进而和跟踪目标保持较近的距离，最终可以取得较低的误码率。图 5 给出了各个方案估计的目标运行轨迹和真实的目标运行轨迹的对比图。从对比结果来看，本发明所提出的方案表现最优，即估计的轨迹结果最接近真实的运行轨迹。图 6 给出了目标的距离和速度估计的平均均方误差随采样时间的变化曲线。可以看出，所提出的 OVOW 方案可以取得最低的距离和速度估计的平均均方误差。

图 7 展示了跟踪非线性机动目标时，各个方案的平均误码率随采样时间的变化曲线。从该图中可以看出，所提出的方案自适应地调整了运行轨迹，保持了和跟踪目标较近的距离。较近的通信距离可以取得较低的误码率。图 8 给出了各方案下一体化系统估计的目标运行轨迹与目标真实的运行轨迹。可以看出，所提出的方案估计的轨迹结果最接近目标真实运行轨迹。图 9 给出了目标的距离和速度估计的平均均方误差随采样时间的变化曲线。可以看出，所提出的方案可以取得最低的距离和速度估计的平均均方误差。

6. 其他有助于理解本发明创造的技术资料：

（给代理人提供更多的信息，可以有助于代理人更好更快的完成申请文件）

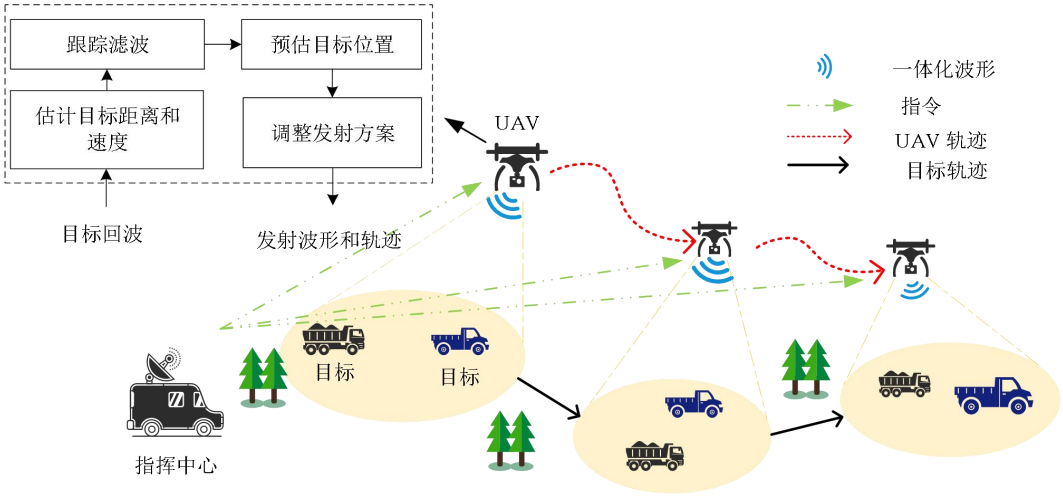


图 1 雷达通信一体化系统示意图

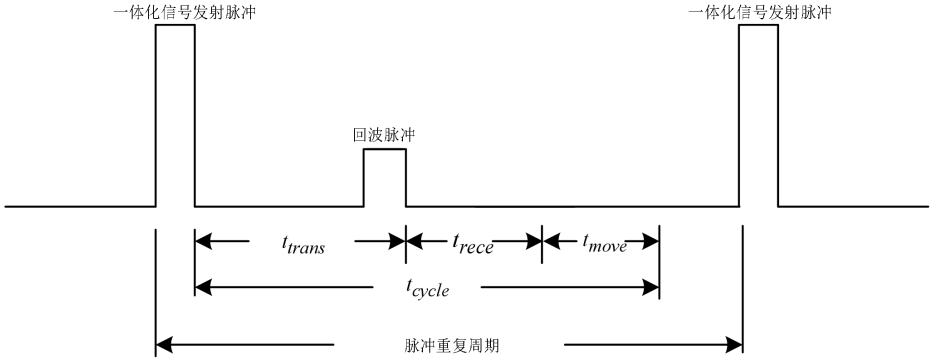


图 2 雷达通信一体化工作时序图

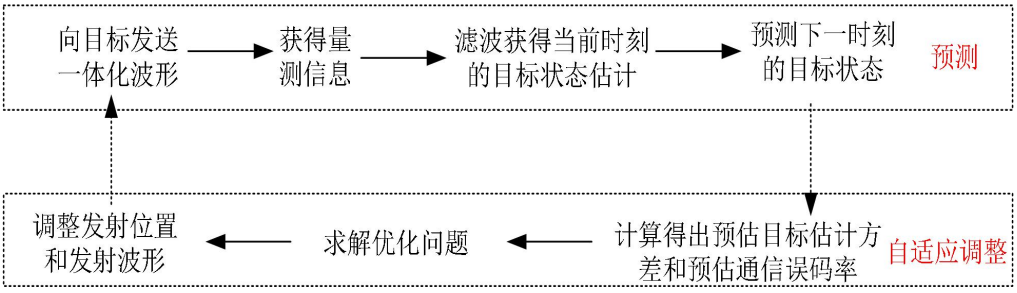


图 3 雷达通信一体化系统工作图

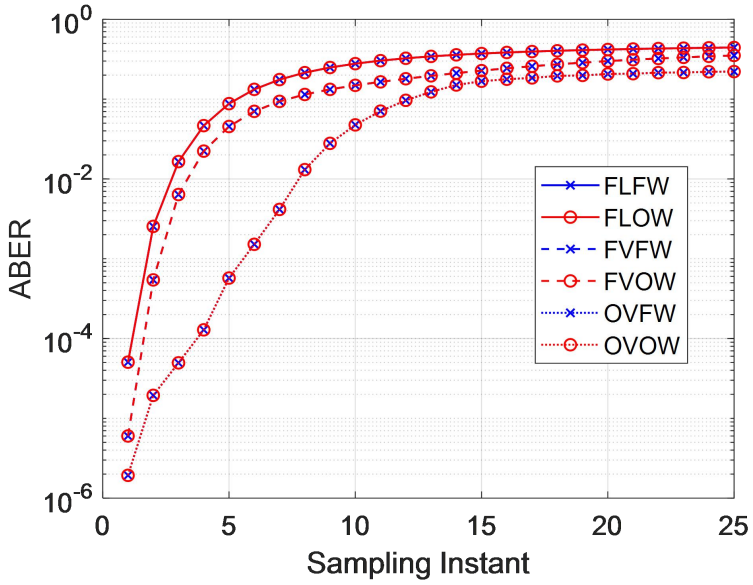


图 4 通信误码率性能对比图（线性机动目标）

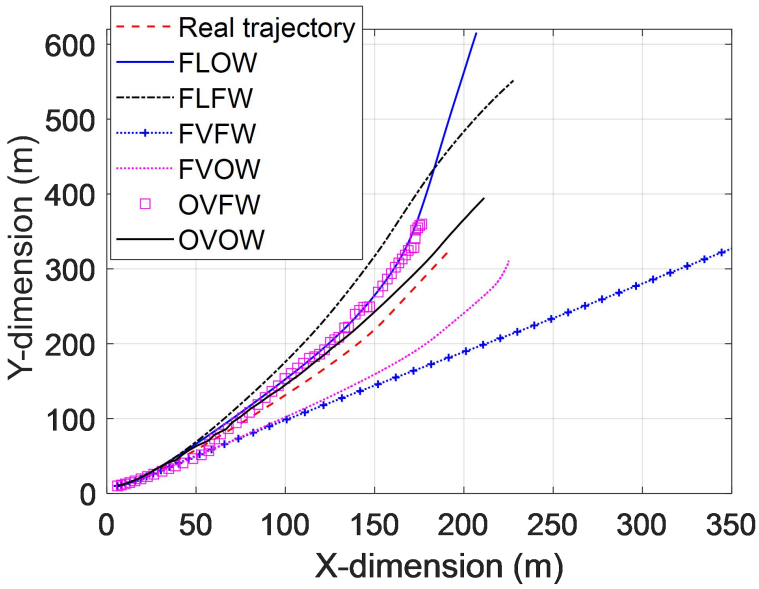
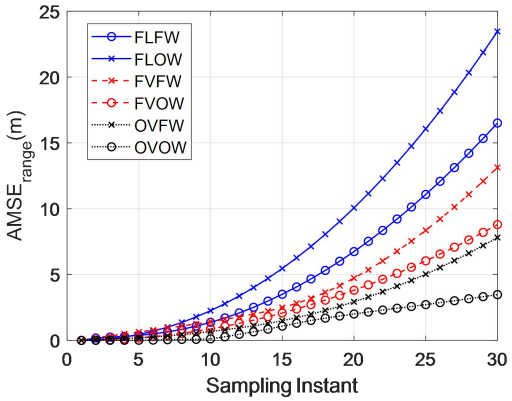
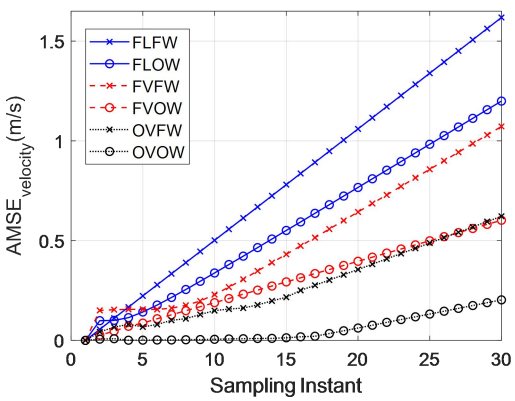


图 5 目标轨迹估计性能对比图（线性机动目标）





(a) 位置估计　　(b) 速度估计

图 6 目标估计性能对比图

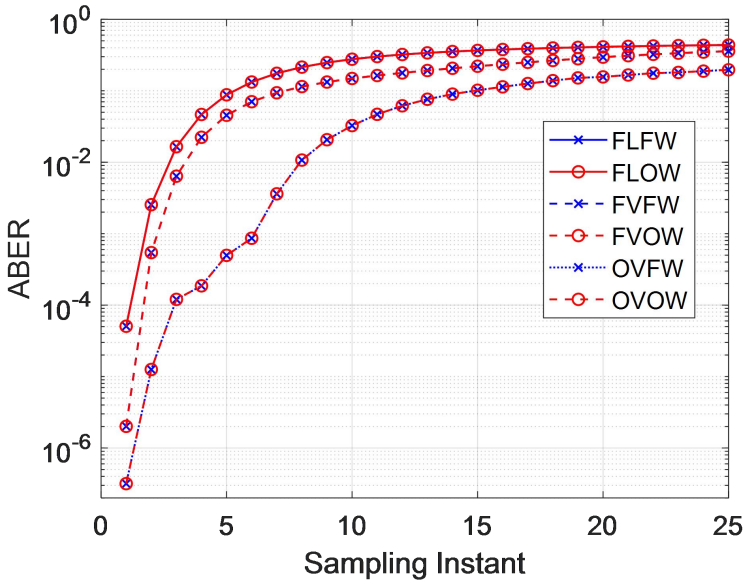


图 7 通信误码率对比图

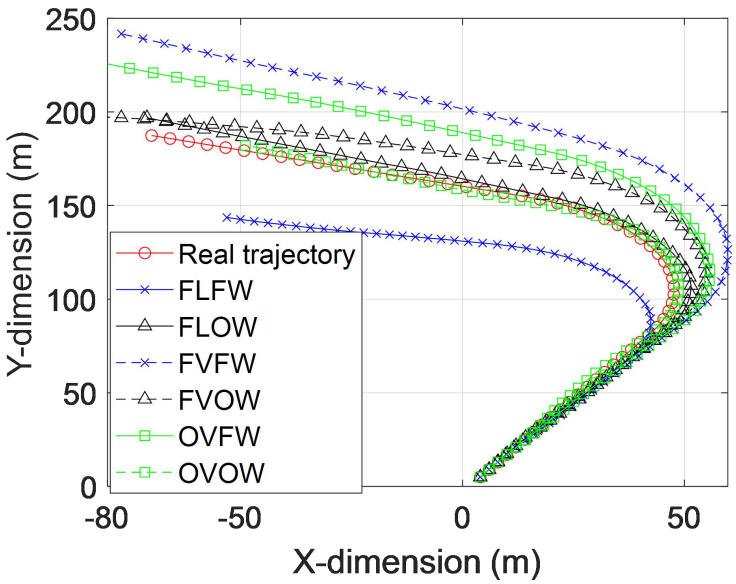
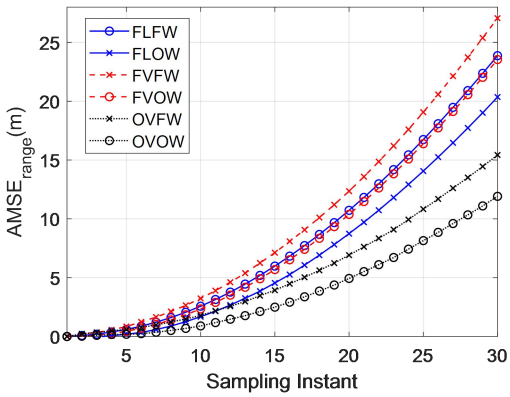
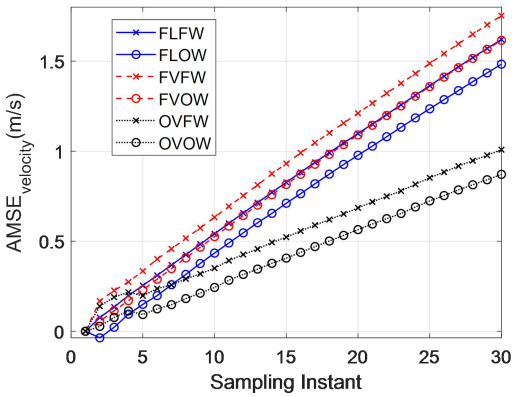


图 8 目标轨迹估计性能对比图



(a) 位置估计



(b) 速度估计

图 9 目标估计性能对比图

申请材料分析说明

1.基础信息

专利名称：一种雷达通信一体化控制方法、装置、介质、程序产品

状态：审查中

2.交底材料

交底材料内容相对较为充实，且提供了非常详细的测试数据。

背景技术以仿照论文的形式进行了引用出处标记，但在专利中不需要给出，当然给出了也可以。

对技术问题的提炼不太准确，其中“未能挖掘一体化波形对性能的优化潜力”，这属于本发明所要开展的研究方向，而并非技术问题。技术问题是指阻碍人们实现某事的技术性的困难障碍。

技术方案的表述上，部分表达由于简写而导致他人阅读理解障碍；如直接写“调整运行轨迹和发射波形”缺乏宾语，而导致不知道是调整谁的飞行轨迹。

3.权利要求书

本案属于方法类的发明，但是由于方法类的专利难以得到有效保护，因而随着法律的进步，本案在对方法保护的基础上，进一步提出了对能够实施本方法的计算机装置、存储有本方法电子数据的存储介质、实施本方法处理步骤的程序产品，提出了专利保护。

4.说明书

背景技术部分，技术问题交代明确——如何联合发挥一体化波形与雷达端运行轨迹两者对目标跟踪与通信性能的提升。

具体实施方式部分，本案属于算法类的专利，存在大量的字符及公式，本案在撰写中对各个字符进行了细致的检查及调整，确保同一个字符始终指代表一个含义，不同含义的采用不同字符，凡是出现的字符均给出中文含义解释。

有益效果部分，针对各条技术创新点所能带来的技术效果，分别进行了充分的展开说明。

申请稿

说明书摘要

本发明提供了一种雷达通信一体化控制方法、装置、介质、程序产品，其中首先预估下一时刻目标的状态，包括目标所处位置信息和速度信息；之后基于下一时刻目标状态的预估值，以目标估计协方差和误码率作为衡量指标，对雷达端运行轨迹以及一体化信号发射波形进行联合优化，得到下一时刻的发射方案，包括雷达端的轨迹位置、波形的调频率和符号持续时间。本发明雷达通信一体化控制方法，解决了现有雷达通信一体化技术中未能挖掘一体化波形对目标跟踪性能优化的问题，在提升跟踪性能的同时，还兼顾了通信的信息传输需求，实现了雷达与通信的动态平衡，使两者在资源共享的情况下实现性能最优，适用于智能交通、车联网、无人机等多个领域。

权利要求书

1.一种雷达通信一体化控制方法，其特征在于：包括：

预估下一时刻目标的状态，包括目标所处位置信息和速度信息；

基于下一时刻目标状态的预估值，以目标估计协方差和误码率作为衡量指标，对雷达端运行轨迹以及一体化信号发射波形进行联合优化，得到下一时刻的发射方案，包括雷达端的轨迹位置、波形的调频率和符号持续时间。

2.根据权利要求 1 所述的雷达通信一体化控制方法，其特征在于：联合优化问题的目标函数为：

$$\mathcal{L}(\mu_k, T_{s,k}, v_k) = \min_{\mu_k, T_{s,k}, v_k} \left[\Phi\left(\sum_{l=1}^{L} P_{l,k} \right) + \Phi\left(\sum_{l=1}^{L} B_{l,k} \right) \right]$$

$$= \min_{\mu_k, T_{s,k}, v_k} \left[\Phi\left(\sum_{l=1}^{L} \mathbb{P}_{l,k}\left(X_{l,k|k-1}, \mu_k, T_{s,k}, v_k \right) \right) + \Phi\left(\sum_{l=1}^{L} \mathbb{B}_{l,k}\left(X_{l,k|k-1}, v_k \right) \right) \right]$$

其中，μ_k为调频率，$T_{s,k}$为符号持续时间，v_k为雷达端的速度，下标 k表示处在 k时刻下，$\Phi(\cdot)$表示归一化操作，L为目标总数，l表示第 l个目标，$P_{l,k}$为目标估计协方差，$B_{l,k}$表示预估误码率。

3.根据权利要求 2 所述的雷达通信一体化控制方法，其特征在于：

目标估计协方差 $P_{l,k}$通过下式计算：

$$P_{l,k} = \mathrm{Tr}\left(P_{l,k|k-1} - P_{l,k|k-1} H_{l,k}^{\mathrm{T}} \left(H_{l,k} P_{l,k|k-1} H_{l,k}^{\mathrm{T}} + \widehat{\mathbb{U}}_{l,k}\left(X_{l,k|k-1}, \mu_k, T_{s,k}, v_k \right) \right)^{-1} H_{l,k} P_{l,k|k-1} \right)$$

$$\widehat{\mathbb{U}}_{l,k}\left(X_{l,k|k-1},\mu_k,T_{s,k},v_k\right)=\boldsymbol{\Gamma}\left(\hat{\eta}_{l,k}\tilde{J}_k\right)^{-1}\boldsymbol{\Gamma}$$

其中，$\mathrm{Tr}(\cdot)$表示迹函数，$P_{l,k|k-1}$表示在$k-1$时刻对k时刻下目标l进行预估得到的目标估计协方差，$X_{l,k|k-1}$表示在$k-1$时刻对k时刻下目标l进行预估得到的目标状态，$H_{l,k}$表示测量函数$\mathbf{h}\left(X_{l,k|k-1},X_k\right)$在预测目标状态$X_{l,k|k-1}$处的雅可比矩阵，$X_k$为雷达端的位置，$\boldsymbol{\Gamma}=\mathrm{diag}[c/2\,,c/(2f_c)]$表示从时延和多普勒频移到距离和速度的转换矩阵，$c$为光速，$f_c$为载频，$\hat{\eta}_{l,k}$表示预估测量信噪比，$\tilde{J}_k$表示 Fisher 信息矩阵$J_{l,k}$中受到波形影响的部分；

$\hat{\eta}_{l,k}$的表达式为：

$$\hat{\eta}_{l,k}=\frac{P_{t,l,k}T_{d,l,k}G_{t,l}G_{r,l}\lambda^2\sigma_l}{64\pi^3T_r\widehat{R}_{l,k}^4N_0}$$

其中，$P_{t,l,k}$表示发射功率，$T_{d,l,k}$表示信号停留时间，$G_{t,l}$表示发射增益，$G_{r,l}$表示雷达的接收增益，λ为光的波长，σ_l表示第l个目标的雷达截面积，T_r表示脉冲重复频率，N_0表示噪声功率密度，$\widehat{R}_{l,k}$为目标l距雷达端的预估相对距离，由测量函数$\left[\widehat{R}_{l,k},\hat{v}_{l,k}\right]^{\mathrm{T}}=\mathbf{h}\left(X_{l,k|k-1},X_k\right)=\mathbf{h}\left(X_{l,k|k-1},X_{k-1},v_k\right)$计算获得，$\hat{v}_{l,k}$为预估相对速度，$X_{k-1}$表示$k-1$时刻雷达端位置；

$\tilde{J}_k$的表达式为：

$$\tilde{J}_k\triangleq\begin{bmatrix}\tilde{J}_{k,\tau\tau} & \tilde{J}_{k,\tau f_\mathrm{d}}\\ \tilde{J}_{k,\tau f_\mathrm{d}} & \tilde{J}_{k,f_\mathrm{d}f_\mathrm{d}}\end{bmatrix}$$

其中$\tilde{J}_{k,\tau\tau}$的表达式为：

$$\tilde{J}_{k,\tau\tau}=\sum_{i=-1}^{6}\bar{J}_{k,\tau\tau}^{(i)}T_{s,k}^i$$

$$\bar{J}_{k,\tau\tau}^{(-1)}=h^2\sum_{n=0}^{N-1}b_n^2\,,\ \bar{J}_{k,\tau\tau}^{(0)}=-\left(\frac{h}{2\mu_k}\sum_{n=0}^{N-1}b_n\right)^2,\ \bar{J}_{k,\tau\tau}^{(1)}=4h\mu_k\sum_{n=0}^{N-1}nb_n+2h\mu_k\sum_{n=0}^{N-1}b_n$$

$$\bar{J}_{k,\tau\tau}^{(2)} = -\frac{hN}{2\mu_k}\sum_{n=0}^{N-1} b_n\ ,\ \bar{J}_{k,\tau\tau}^{(3)} = \frac{4\mu_k^2}{3}(N-1)(N^2+N) + \frac{4}{3}N\mu_k^2 - \frac{h(N-1)N}{2\mu_k}\sum_{n=0}^{N-1} b_n$$

$$\bar{J}_{k,\tau\tau}^{(4)} = -\frac{N^2}{4},\ \bar{J}_{k,\tau\tau}^{(5)} = -(N-1)N^2,\ \bar{J}_{k,\tau\tau}^{(6)} = -\frac{(N-1)^2N^2}{4}$$

$\tilde{J}_{k,f_\mathrm{d}f_\mathrm{d}}$的表达式为：

$$\tilde{J}_{k,f_\mathrm{d}f_\mathrm{d}} = \sum_{i=3}^{4} \bar{J}_{k,f_\mathrm{d}f_\mathrm{d}}^{(i)} T_{s,k}^{i}$$

$$\bar{J}_{k,f_\mathrm{d}f_\mathrm{d}}^{(3)} = \frac{N^3}{3},\ \bar{J}_{k,f_\mathrm{d}f_\mathrm{d}}^{(4)} = -\frac{N^4}{4}$$

$\tilde{J}_{k,\tau f_\mathrm{d}}$的表达式为：

$$\tilde{J}_{k,\tau f_\mathrm{d}} = \tilde{J}_{k,f_\mathrm{d}\tau} = \sum_{i=1}^{4} \bar{J}_{k,\tau f_\mathrm{d}}^{(i)} T_{s,k}^{i}$$

$$\bar{J}_{k,\tau f_\mathrm{d}}^{(1)} = \pi h\sum_{n=0}^{N-1} nb_n + \frac{\pi h}{2}\sum_{n=0}^{N-1} b_n\ ,\ \bar{J}_{k,\tau f_\mathrm{d}}^{(2)} = -\frac{hN^2}{4\mu_k}\sum_{n=0}^{N-1} b_n$$

$$\bar{J}_{k,\tau f_\mathrm{d}}^{(3)} = \frac{2\pi\mu_k}{3}\left(\frac{(N-1)N(2N-1)}{2} + (N-1)\left(\frac{3N}{2}+1\right)\right) - \frac{(N-1)N^3}{4}$$

$$\bar{J}_{k,\tau f_\mathrm{d}}^{(4)} = \frac{N^3}{4}$$

其中，h为调制指数，N为通信符号数量，b_n表示传输的信息序列。

4.根据权利要求 3 所述的雷达通信一体化控制方法，其特征在于：

预估误码率$B_{l,k}$通过下式计算：

$$B_{l,k} = \mathbb{B}_{l,k}\left(X_{l,k|k-1}, v_k\right) = Q\left(\sqrt{d_{\min}^2 SNR_{l,k}}\right)$$

其中，$Q(\cdot)$表示 Q 函数，$d_{\min}$表示归一化最小欧式距离，$SNR_{l,k}$表示通信信道的预估信噪比，其数学表达式为：

$$SNR_{l,k} = P_{t,l,k}h_{l,k}/N_0$$

其中，$h_{l,k}$表示预估通道信道增益，其数学表达式为：

$$h_{l,k} = \frac{G_{t,l}G_{c,l}\lambda^2}{16\pi^2\widehat{R}_{l,k}^2}$$

其中，$G_{c,l}$表示目标接收天线增益。

5.根据权利要求 4 所述的雷达通信一体化控制方法，其特征在于：所述联合优化问题按如下方式求解：

S1，将目标函数 $\mathcal{L}(\mu_k, T_{s,k}, v_k)$分解为：

$$\mathcal{L}_1(\mu_k, T_{s,k}) = \min_{\mu_k, T_{s,k}} \Phi\left(\sum_{l=1}^{L} \mathbb{P}_{l,k}(X_{l,k|k-1}, \mu_k, T_{s,k})\right)$$

$$\mathcal{L}_2(v_k) = \min_{x_k, y_k} \Phi\left(\sum_{l=1}^{L} \mathbb{P}_{l,k}(X_{l,k|k-1}, \mu_k^*, T_{s,k}^*, v_k)\right) + \Phi\left(\sum_{l=1}^{L} \mathbb{B}_{l,k}(X_{l,k|k-1}, v_k)\right)$$

其中，μ_k^*和 $T_{s,k}^*$分别表示 μ_k和 $T_{s,k}$的最优解；

S2，采用 RGS 算法对 $\mathcal{L}_1(\mu_k, T_{s,k})$进行求解，得到 μ_k^*和 $T_{s,k}^*$；

S3，将 μ_k^*和 $T_{s,k}^*$代入 $\mathcal{L}_2(v_k)$，采用梯度下降法对 $\mathcal{L}_2(v_k)$进行求解，得到 v_k的优化结果 v_k^*。

6.根据权利要求 1 所述的雷达通信一体化控制方法，其特征在于：采用扩展卡尔曼滤波进行跟踪滤波，用以预估下一时刻目标状态：

T1，基于经回波探测获得的测量值 $z_{l,k}$，对预估值 $X_{l,k|k-1}$和 $P_{l,k|k-1}$进行修正：

$$X_{l,k|k} = X_{l,k|k-1} + K_{l,k}\left(z_{l,k} - \mathbf{h}(X_{l,k|k-1}, X_k)\right)$$

$$P_{l,k|k} = P_{l,k|k-1} - K_{l,k} S_{l,k} K_{l,k}^{\mathrm{T}}$$

其中，$X_{l,k|k-1}$为在 $k-1$时刻对目标 l进行预测的状态预估值，$P_{l,k|k-1}$为其对应预估协方差，$X_{l,k|k}$为在 k时刻目标 l的状态修正值，$P_{l,k|k}$为对应修正协方差；$K_{l,k}$为卡尔曼增益，$S_{l,k}$为新增协方差，两者数学表达式分别为：

$$K_{l,k} = P_{l,k|k-1} H_{l,k}^{\mathrm{T}} S_{l,k}^{-1}$$

$$S_{l,k} = H_{l,k} P_{l,k|k-1} H_{l,k}^{\mathrm{T}} + U_{l,k}$$

其中，$H_{l,k}$表示测量函数 $\mathbf{h}(X_{l,k|k-1}, X_k)$在预测目标状态 $X_{l,k|k-1}$处的雅可比矩

阵，$U_{l,k}=\mathbf{\Gamma}C_{l,k}\mathbf{\Gamma}$为测量误差的协方差矩阵，$\mathbf{\Gamma}=\mathrm{diag}[c/2,c/(2f_c)]$表示从时延和多普勒频移到距离和速度的转换矩阵，$c$表示光速，$C_{l,k}$表示在第$k$个脉冲间对目标$l$时延和多普勒频移估计的克拉美罗界；

T2，对目标下一时刻的状态进行预测：

$$X_{l,k+1|k}=F_{k+1}X_{l,k|k}$$

$$P_{l,k+1|k}=F_{k+1}P_{l,k|k}F_{k+1}^{\mathrm{T}}+G_{k+1}Q_kG_{k+1}^{\mathrm{T}}$$

其中，F_{k+1}和G_{k+1}分别表示在第k+1 个脉冲间的状态转换矩阵F和过程噪声分布矩阵G；

对于匀速运动模型，F和G分别定义为：

$$F_{\mathrm{CV}}=\begin{bmatrix}\begin{bmatrix}1 & \Delta T\\ 0 & 1\end{bmatrix}\otimes I_2 & 0_{4\times4}\\ 0_{2\times4} & 0_{2\times2}\end{bmatrix},\ G_{\mathrm{CV}}=\begin{bmatrix}\frac{\Delta T^2}{2}\\ \Delta T\\ 0\end{bmatrix}\otimes I_2$$

对于匀加速运动模型，F和G分别定义为：

$$F_{\mathrm{CA}}=\begin{bmatrix}1 & \Delta T & \frac{\Delta T^2}{2}\\ 0 & 1 & \Delta T\\ 0 & 0 & 1\end{bmatrix}\otimes I_2,\ G_{\mathrm{CA}}=\begin{bmatrix}\frac{\Delta T^3}{6}\\ \frac{\Delta T^2}{2}\\ \Delta T\end{bmatrix}\otimes I_2$$

对于长转弯运动模型，F和G分别定义为：

$$F_{\mathrm{CT}}=\begin{bmatrix}\begin{bmatrix}1 & \frac{\sin(\tilde{\omega}\Delta T)}{\tilde{\omega}} & 0 & \frac{\cos(\tilde{\omega}\Delta T)-1}{\tilde{\omega}}\\ 0 & \frac{1-\cos(\tilde{\omega}\Delta T)}{\tilde{\omega}} & 1 & \frac{\sin(\tilde{\omega}\Delta T)}{\tilde{\omega}}\\ 0 & \cos(\tilde{\omega}\Delta T) & 0 & -\sin(\tilde{\omega}\Delta T)\\ 0 & \sin(\tilde{\omega}\Delta T) & 0 & \cos(\tilde{\omega}\Delta T)\end{bmatrix} & 0_{4\times2}\\ 0_{2\times4} & 0_{2\times2}\end{bmatrix},\ G_{\mathrm{CT}}=\begin{bmatrix}\frac{\Delta T^2}{2}\\ \Delta T\\ 0\end{bmatrix}\otimes I_2$$

其中，ΔT为采样周期（即脉冲重复周期），I_2为2*2 形状的单位矩阵，$\tilde{\omega}$表示目标的旋转角速度，$\otimes$表示克罗内克积。

7.根据权利要求 2 所述的雷达通信一体化控制方法，其特征在于：目标的状态定义为：

$$X_{l,k}=\left[x_{l,k},y_{l,k},\dot{x}_{l,k},\dot{y}_{l,k},\ddot{x}_{l,k},\ddot{y}_{l,k}\right]^{\mathrm{T}}$$

其中，$x_{l,k}$和$y_{l,k}$分别表示k时刻目标l在 x 轴和 y 轴的位置，$\dot{x}_{l,k}$和$\dot{y}_{l,k}$分别表示k时刻目标l在 x 轴和 y 轴的速度，$\ddot{x}_{l,k}$和$\ddot{y}_{l,k}$分别表示k时刻目标l在 x 轴和 y 轴的加速度。

雷达端的位置定义为：

$$X_k = [x_k, y_k]^{\mathrm{T}}$$

雷达端的速度定义为：

$$v_k = [\dot{x}_k, \dot{y}_k]^{\mathrm{T}}$$

其中x_k和y_k分别表示k时刻雷达端在 x 轴和 y 轴的位置，$\dot{x}_k$和$\dot{y}_k$分别表示k时刻雷达端在 x 轴和 y 轴的速度。

8.一种计算机装置，其特征在于：包括存储器和处理器；

所述存储器用于存储计算机程序；

所述处理器用于执行所述计算机程序并在执行所述计算机程序时实现如权利要求 1~7 任一项所述的雷达通信一体化控制方法。

9.一种计算机可读存储介质，其特征在于：存储有计算机程序，所述计算机程序被处理器执行时使所述处理器执行如权利要求 1~7 任一项所述的雷达通信一体化控制方法。

10.一种计算机程序产品，其特征在于：包括计算机程序，所述计算机程序被处理器执行时实现如权利要求 1~7 任一项所述的雷达通信一体化控制方法。

一种雷达通信一体化控制方法、装置、介质、程序产品

技术领域

本发明属于雷达通信一体化技术领域，具体涉及一种雷达通信一体化控制方法、装置、介质、程序产品。

背景技术

基于无人机的机载雷达系统，可以实现对雷达端位置的灵活调整，从而减少与目标之间的信号阻挡，取得相比固定式雷达系统更广的覆盖范围，因此在军用和民用领域都得到广泛应用。在很多现代化应用场景下，除了需要使用机载雷达对目标进行跟踪外，还需要实现对目标的通信。而在无人机上额外加装一套对跟踪目标的通信系统，会增加无人机飞行负担，导致机动性和续航能力严重下降。故在此需求背景下发展出了雷达通信一体化技术。

雷达通信一体化技术，可实现雷达与通信共享射频硬件和无线基础设施，通过向目标发出雷达通信一体化信号，同时实现对目标的跟踪与通信功能。但是，机载雷达的高机动性在带来雷达端轨迹自由度的同时，也给雷达通信一体化系统和波形设计带来了新的挑战。如何联合发挥一体化波形与雷达端运行轨迹两者对目标跟踪与通信性能的提升，是当下雷达通信一体化系统的主要控制问题。

发明内容

针对现有技术中存在的不足，本发明提供了一种雷达通信一体化控制方法、装置、介质、程序产品，用以解决雷达端运行轨迹与发射波形的联合优化问题。

本发明通过以下技术手段实现上述技术目的。

一种雷达通信一体化控制方法，包括：

预估下一时刻目标的状态，包括目标所处位置信息和速度信息；

基于下一时刻目标状态的预估值，以目标估计协方差和误码率作为衡量指标，对雷达端运行轨迹以及一体化信号发射波形进行联合优化，得到下一时刻的发射方案，包括雷达端的轨迹位置、波形的调频率和符号持续时间。

进一步地，联合优化问题的目标函数为：

$$\mathcal{L}(\mu_k, T_{s,k}, v_k) = \min_{\mu_k, T_{s,k}, v_k} \left[\Phi\left(\sum_{l=1}^{L} P_{l,k} \right) + \Phi\left(\sum_{l=1}^{L} B_{l,k} \right) \right]$$

$$= \min_{\mu_k, T_{s,k}, v_k} \left[\Phi\left(\sum_{l=1}^{L} \mathbb{P}_{l,k}\left(X_{l,k|k-1}, \mu_k, T_{s,k}, v_k \right) \right) + \Phi\left(\sum_{l=1}^{L} \mathbb{B}_{l,k}\left(X_{l,k|k-1}, v_k \right) \right) \right]$$

其中，μ_k为调频率，$T_{s,k}$为符号持续时间，v_k为雷达端的速度，下标k表示处在k时刻下，$\Phi(\cdot)$表示归一化操作，L为目标总数，l表示第l个目标，$P_{l,k}$为目标估计协方差，$B_{l,k}$表示预估误码率。

进一步地，目标估计协方差$P_{l,k}$通过下式计算：

$$P_{l,k} = \mathrm{Tr}\left(P_{l,k|k-1} - P_{l,k|k-1} H_{l,k}^{\mathrm{T}} \left(H_{l,k} P_{l,k|k-1} H_{l,k}^{\mathrm{T}} + \widehat{\mathbb{U}}_{l,k}\left(X_{l,k|k-1}, \mu_k, T_{s,k}, v_k \right) \right)^{-1} H_{l,k} P_{l,k|k-1} \right)$$

$$\widehat{\mathbb{U}}_{l,k}\left(X_{l,k|k-1}, \mu_k, T_{s,k}, v_k \right) = \mathbf{\Gamma}\left(\hat{\eta}_{l,k} \tilde{J}_k \right)^{-1} \mathbf{\Gamma}$$

其中，$\mathrm{Tr}(\cdot)$表示迹函数，$P_{l,k|k-1}$表示在$k-1$时刻对k时刻下目标l进行预估得到的目标估计协方差，$X_{l,k|k-1}$表示在$k-1$时刻对k时刻下目标l进

行预估得到的目标状态，$H_{l,k}$表示测量函数$\mathbf{h}(X_{l,k|k-1},X_k)$在预测目标状态$X_{l,k|k-1}$处的雅可比矩阵，$X_k$为雷达端的位置，$\mathbf{\Gamma}=\mathrm{diag}[c/2,c/(2f_c)]$表示从时延和多普勒频移到距离和速度的转换矩阵，$c$为光速，$f_c$为载频，$\hat{\eta}_{l,k}$表示预估测量信噪比，$\tilde{J}_k$表示 Fisher 信息矩阵$J_{l,k}$中受到波形影响的部分；

$\hat{\eta}_{l,k}$的表达式为：

$$\hat{\eta}_{l,k}=\frac{P_{t,l,k}T_{d,l,k}G_{t,l}G_{r,l}\lambda^2\sigma_l}{64\pi^3T_r\widehat{R}_{l,k}^4N_0}$$

其中，$P_{t,l,k}$表示发射功率，$T_{d,l,k}$表示信号停留时间，$G_{t,l}$表示发射增益，$G_{r,l}$表示雷达的接收增益，λ为光的波长，σ_l表示第l个目标的雷达截面积，T_r表示脉冲重复频率，N_0表示噪声功率密度，$\widehat{R}_{l,k}$为目标l距雷达端的预估相对距离，由测量函数$[\widehat{R}_{l,k},\hat{v}_{l,k}]^{\mathrm{T}}=\mathbf{h}(X_{l,k|k-1},X_k)=\mathbf{h}(X_{l,k|k-1},X_{k-1},v_k)$计算获得，$\hat{v}_{l,k}$为预估相对速度，$X_{k-1}$表示$k-1$时刻雷达端位置；

$\tilde{J}_k$的表达式为：

$$\tilde{J}_k\triangleq\begin{bmatrix}\tilde{J}_{k,\tau\tau} & \tilde{J}_{k,\tau f_\mathrm{d}}\\ \tilde{J}_{k,\tau f_\mathrm{d}} & \tilde{J}_{k,f_\mathrm{d}f_\mathrm{d}}\end{bmatrix}$$

其中$\tilde{J}_{k,\tau\tau}$的表达式为：

$$\tilde{J}_{k,\tau\tau}=\sum_{i=-1}^{6}\bar{J}_{k,\tau\tau}^{(i)}T_{s,k}^i$$

$$\bar{J}_{k,\tau\tau}^{(-1)}=h^2\sum_{n=0}^{N-1}b_n^2,\ \bar{J}_{k,\tau\tau}^{(0)}=-\left(\frac{h}{2\mu_k}\sum_{n=0}^{N-1}b_n\right)^2,\ \bar{J}_{k,\tau\tau}^{(1)}=4h\mu_k\sum_{n=0}^{N-1}nb_n+2h\mu_k\sum_{n=0}^{N-1}b_n$$

$$\bar{J}_{k,\tau\tau}^{(2)}=-\frac{hN}{2\mu_k}\sum_{n=0}^{N-1}b_n,\ \bar{J}_{k,\tau\tau}^{(3)}=\frac{4\mu_k^2}{3}(N-1)(N^2+N)+\frac{4}{3}N\mu_k^2-\frac{h(N-1)N}{2\mu_k}\sum_{n=0}^{N-1}b_n$$

$$\bar{J}_{k,\tau\tau}^{(4)}=-\frac{N^2}{4},\ \bar{J}_{k,\tau\tau}^{(5)}=-(N-1)N^2,\ \bar{J}_{k,\tau\tau}^{(6)}=-\frac{(N-1)^2N^2}{4}$$

$\tilde{J}_{k,f_\mathrm{d}f_\mathrm{d}}$的表达式为：

$$\tilde{J}_{k,f_{\mathrm{d}}f_{\mathrm{d}}}=\sum_{i=3}^{4}\bar{J}_{k,f_{\mathrm{d}}f_{\mathrm{d}}}^{(i)}T_{s,k}^{i}$$

$$\bar{J}_{k,f_{\mathrm{d}}f_{\mathrm{d}}}^{(3)}=\frac{N^3}{3},\ \bar{J}_{k,f_{\mathrm{d}}f_{\mathrm{d}}}^{(4)}=-\frac{N^4}{4}$$

$\tilde{J}_{k,\tau f_{\mathrm{d}}}$的表达式为：

$$\tilde{J}_{k,\tau f_{\mathrm{d}}}=\tilde{J}_{k,f_{\mathrm{d}}\tau}=\sum_{i=1}^{4}\bar{J}_{k,\tau f_{\mathrm{d}}}^{(i)}T_{s,k}^{i}$$

$$\bar{J}_{k,\tau f_{\mathrm{d}}}^{(1)}=\pi h\sum_{n=0}^{N-1}nb_n+\frac{\pi h}{2}\sum_{n=0}^{N-1}b_n,\ \bar{J}_{k,\tau f_{\mathrm{d}}}^{(2)}=-\frac{hN^2}{4\mu_k}\sum_{n=0}^{N-1}b_n$$

$$\bar{J}_{k,\tau f_{\mathrm{d}}}^{(3)}=\frac{2\pi\mu_k}{3}\left(\frac{(N-1)N(2N-1)}{2}+(N-1)\left(\frac{3N}{2}+1\right)\right)-\frac{(N-1)N^3}{4}$$

$$\bar{J}_{k,\tau f_{\mathrm{d}}}^{(4)}=\frac{N^3}{4}$$

其中，h为调制指数，N为通信符号数量，b_n表示传输的信息序列。

进一步地，预估误码率$B_{l,k}$通过下式计算：

$$B_{l,k}=\mathbb{B}_{l,k}\left(X_{l,k|k-1},v_k\right)=Q\left(\sqrt{d_{\min}^2SNR_{l,k}}\right)$$

其中，$Q(\cdot)$表示 Q 函数，$d_{\min}$表示归一化最小欧式距离，$SNR_{l,k}$表示通信信道的预估信噪比，其数学表达式为：

$$SNR_{l,k}=P_{t,l,k}h_{l,k}/N_0$$

其中，$h_{l,k}$表示预估通道信道增益，其数学表达式为：

$$h_{l,k}=\frac{G_{t,l}G_{c,l}\lambda^2}{16\pi^2\widehat{R}_{l,k}^2}$$

其中，$G_{c,l}$表示目标接收天线增益。

进一步地，所述联合优化问题按如下方式求解：

S1，将目标函数$\mathcal{L}\left(\mu_k,T_{s,k},v_k\right)$分解为：

$$\mathcal{L}_1\left(\mu_k,T_{s,k}\right)=\min_{\mu_k,T_{s,k}}\ \Phi\left(\sum_{l=1}^{L}\mathbb{P}_{l,k}\left(X_{l,k|k-1},\mu_k,T_{s,k}\right)\right)$$

$$\mathcal{L}_2(v_k) = \min_{x_k, y_k} \Phi\left(\sum_{l=1}^{L} \mathbb{P}_{l,k}\left(X_{l,k|k-1}, \mu_k^*, T_{s,k}^*, v_k\right)\right) + \Phi\left(\sum_{l=1}^{L} \mathbb{B}_{l,k}\left(X_{l,k|k-1}, v_k\right)\right)$$

其中，μ_k^*和$T_{s,k}^*$分别表示μ_k和$T_{s,k}$的最优解；

S2，采用 RGS 算法对$\mathcal{L}_1\left(\mu_k, T_{s,k}\right)$进行求解，得到$\mu_k^*$和$T_{s,k}^*$；

S3，将μ_k^*和$T_{s,k}^*$代入$\mathcal{L}_2(v_k)$，采用梯度下降法对$\mathcal{L}_2(v_k)$进行求解，得到v_k的优化结果v_k^*。

进一步地，采用扩展卡尔曼滤波进行跟踪滤波，用以预估下一时刻目标状态：

T1，基于经回波探测获得的测量值$z_{l,k}$，对预估值$X_{l,k|k-1}$和$P_{l,k|k-1}$进行修正：

$$X_{l,k|k} = X_{l,k|k-1} + K_{l,k}\left(z_{l,k} - \mathbf{h}\left(X_{l,k|k-1}, X_k\right)\right)$$

$$P_{l,k|k} = P_{l,k|k-1} - K_{l,k} S_{l,k} K_{l,k}^{\mathrm{T}}$$

其中，$X_{l,k|k-1}$为在$k-1$时刻对目标l进行预测的状态预估值，$P_{l,k|k-1}$为其对应预估协方差，$X_{l,k|k}$为在k时刻目标l的状态修正值，$P_{l,k|k}$为对应修正协方差；$K_{l,k}$为卡尔曼增益，$S_{l,k}$为新增协方差，两者数学表达式分别为：

$$K_{l,k} = P_{l,k|k-1} H_{l,k}^{\mathrm{T}} S_{l,k}^{-1}$$

$$S_{l,k} = H_{l,k} P_{l,k|k-1} H_{l,k}^{\mathrm{T}} + U_{l,k}$$

其中，$H_{l,k}$表示测量函数$\mathbf{h}\left(X_{l,k|k-1}, X_k\right)$在预测目标状态$X_{l,k|k-1}$处的雅可比矩阵，$U_{l,k} = \mathbf{\Gamma} C_{l,k} \mathbf{\Gamma}$为测量误差的协方差矩阵，$\mathbf{\Gamma} = \mathrm{diag}[c/2, c/(2f_c)]$表示从时延和多普勒频移到距离和速度的转换矩阵，$c$表示光速，$C_{l,k}$表示在第$k$个脉冲间对目标$l$时延和多普勒频移估计的克拉美罗界；

T2，对目标下一时刻的状态进行预测：

$$X_{l,k+1|k} = F_{k+1} X_{l,k|k}$$

$$P_{l,k+1|k} = F_{k+1} P_{l,k|k} F_{k+1}^{\mathrm{T}} + G_{k+1} Q_k G_{k+1}^{\mathrm{T}}$$

其中，F_{k+1}和G_{k+1}分别表示在第k+1 个脉冲间的状态转换矩阵F和过程

噪声分布矩阵 G；

对于匀速运动模型， F和 G分别定义为：

$$F_{\mathrm{CV}}=\begin{bmatrix}\begin{bmatrix}1 & \Delta T\\ 0 & 1\end{bmatrix}\otimes I_2 & 0_{4\times4}\\ 0_{2\times4} & 0_{2\times2}\end{bmatrix},\ G_{\mathrm{CV}}=\begin{bmatrix}\frac{\Delta T^2}{2}\\ \Delta T\\ 0\end{bmatrix}\otimes I_2$$

对于匀加速运动模型， F和 G分别定义为：

$$F_{\mathrm{CA}}=\begin{bmatrix}1 & \Delta T & \frac{\Delta T^2}{2}\\ 0 & 1 & \Delta T\\ 0 & 0 & 1\end{bmatrix}\otimes I_2,\ G_{\mathrm{CA}}=\begin{bmatrix}\frac{\Delta T^3}{6}\\ \frac{\Delta T^2}{2}\\ \Delta T\end{bmatrix}\otimes I_2$$

对于长转弯运动模型， F和 G分别定义为：

$$F_{\mathrm{CT}}=\begin{bmatrix}\begin{bmatrix}1 & \frac{\sin(\tilde{\omega}\Delta T)}{\tilde{\omega}} & 0 & \frac{\cos(\tilde{\omega}\Delta T)-1}{\tilde{\omega}}\\ 0 & \frac{1-\cos(\tilde{\omega}\Delta T)}{\tilde{\omega}} & 1 & \frac{\sin(\tilde{\omega}\Delta T)}{\tilde{\omega}}\\ 0 & \cos(\tilde{\omega}\Delta T) & 0 & -\sin(\tilde{\omega}\Delta T)\\ 0 & \sin(\tilde{\omega}\Delta T) & 0 & \cos(\tilde{\omega}\Delta T)\end{bmatrix} & 0_{4\times2}\\ 0_{2\times4} & 0_{2\times2}\end{bmatrix},\ G_{\mathrm{CT}}=\begin{bmatrix}\frac{\Delta T^2}{2}\\ \Delta T\\ 0\end{bmatrix}\otimes I_2$$

其中， ΔT为采样周期（即脉冲重复周期）， I_2为2*2的单位矩阵， $\tilde{\omega}$表示目标的旋转角速度， $\otimes$表示克罗内克积。

进一步地，目标的状态定义为：

$$X_{l,k}=\left[x_{l,k},y_{l,k},\dot{x}_{l,k},\dot{y}_{l,k},\ddot{x}_{l,k},\ddot{y}_{l,k}\right]^{\mathrm{T}}$$

其中， $x_{l,k}$和 $y_{l,k}$分别表示 k时刻目标 l在x轴和y轴的位置， $\dot{x}_{l,k}$和 $\dot{y}_{l,k}$分别表示 k时刻目标 l在x轴和y轴的速度， $\ddot{x}_{l,k}$和 $\ddot{y}_{l,k}$分别表示 k时刻目标 l在x轴和y轴的加速度。

雷达端的位置定义为：

$$X_k=[x_k,y_k]^{\mathrm{T}}$$

雷达端的速度定义为：

$$v_k=[\dot{x}_k,\dot{y}_k]^{\mathrm{T}}$$

其中 x_k和 y_k分别表示 k时刻雷达端在x轴和y轴的位置， $\dot{x}_k$和 $\dot{y}_k$分

别表示 k时刻雷达端在 x 轴和 y 轴的速度。

一种计算机装置，包括存储器和处理器；

所述存储器用于存储计算机程序；

所述处理器用于执行所述计算机程序并在执行所述计算机程序时实现上述的雷达通信一体化控制方法。

一种计算机可读存储介质，存储有计算机程序，所述计算机程序被处理器执行时使所述处理器执行上述的雷达通信一体化控制方法。

一种计算机程序产品，包括计算机程序，所述计算机程序被处理器执行时实现上述的雷达通信一体化控制方法。

本发明的有益效果为：

（1）本发明提供了一种雷达通信一体化控制方法，相较于将雷达跟踪性能与通信性能分开设计的传统方法，本发明解决了现有雷达通信一体化技术中未能挖掘一体化波形对目标跟踪性能优化的问题，在提升跟踪性能的同时，还兼顾了通信的信息传输需求，实现了雷达与通信的动态平衡，使两者在资源共享的情况下实现性能最优，适用于智能交通、车联网、无人机等多个领域。

（2）本发明以一体化信号波形和系统运行轨迹为优化变量，以跟踪性能和通信性能为目标函数，建立了优化模型。该目标函数涵盖了雷达跟踪性能和通信性能两个关键指标，既实现了雷达和通信的协同优化，又权衡了两者之间的资源分配。通过该优化模型，本发明能够实现雷达与通信性能的整体最优配置。在资源受限的情况下，最大化系统性能。

（3）本发明基于矩形网格搜索算法和梯度下降法求解得出最优的一体化波形和运行轨迹。矩形网格搜索算法通过在解空间中进行全局网格搜索，避免了解陷入局部最优。为后续的梯度下降法提供了良好的初始条件，确保了最终解的准确性。此外，梯度下降法利用局部的导数信息进行快速收敛，显著降低了复杂度。

附图说明

图 1 为雷达通信一体化系统的场景示意图；

图 2 为雷达通信一体化工作时序图；

图 3 为本发明控制方法流程图；

图 4 为针对线性机动目标，各控制方案下的通信误码率对比图；

图 5 为针对线性机动目标，各控制方案下的目标轨迹估计对比图；

图 6 为针对线性机动目标，各控制方案下的目标估计性能对比图；

图 7 为针对非线性机动目标，各控制方案下的通信误码率对比图；

图 8 为针对非线性机动目标，各控制方案下的目标轨迹估计对比图；

图 9 为针对非线性机动目标，各控制方案下的目标估计性能对比图。

具体实施方式

下面详细描述本发明的实施例，所示实施例的示例在附图中示出，其中自始至终相同或类似的标号表示相同或类似的元件或具有相同或类似功能的元件。下面通过参考附图描述的实施例是示例性的，旨在用于解释本发明，而不能理解为对本发明的限制。

一、技术方案

1、雷达通信一体化系统

参照图 1 所示，典型的雷达通信一体化系统包含控制端（指挥中心）、雷达端（搭载于无人机上）和需要进行跟踪及通信的若干目标。其中无人机（UVA）在指挥中心的控制下，利用机载雷达向目标传输一体化信号，用以进行对目标端的跟踪和传输指挥信息。在此过程中，通过相关跟踪滤波算法等预估目标状态，并基于目标的预估位置，实时调整无人机的运行轨迹以及雷达信号（雷达通信一体化信号）的发射波形；以此提升跟踪精度和通信准确率。

设上述雷达通信一体化系统中，包含有 1 个雷达端和 L个目标。系统的工作方式是循环执行发射一体化信号→接收目标回波→调整发射方案。在一个循环周期 t_{cycle}内，包含三个时间段：① t_{trans}，表示一体化信号从雷达端到目标再反射回来所用的时长，用于探测目标并与之通信；② t_{rece}，用于对目标回波执行匹配滤波，以获得目标测量信息，并在之后根据跟踪滤波算法预估目标状态；③ t_{move}，用于根据目标预估状态调整发射波形与系统轨迹。三个时间段之间满足：$t_{\text{cycle}} = t_{\text{trans}} + t_{\text{rece}} + t_{\text{move}}$，且 t_{cycle}小于等于一体化信号脉冲的重复周期。假设一个脉冲重复周期内只发生一次循环，则整个一体化系统工作时序图如图 2 所示。

对于其中第 k个雷达信号脉冲间：

1）第 l个目标的状态定义为：

$$X_{l,k} = \left[x_{l,k}, y_{l,k}, \dot{x}_{l,k}, \dot{y}_{l,k}, \ddot{x}_{l,k}, \ddot{y}_{l,k}\right]^{\mathrm{T}}$$

其中角标 T表示转置， $x_{l,k}$和 $y_{l,k}$分别表示目标 l此时在 x 轴和 y 轴的位置，

$\dot{x}_{l,k}$和 $\dot{y}_{l,k}$分别表示目标 l此时在 x 轴和 y 轴的速度，$\ddot{x}_{l,k}$和 $\ddot{y}_{l,k}$分别表示目标 l此时在 x 轴和 y 轴的加速度。

2）雷达端的位置定义为：

$$X_k = [x_k, y_k]^{\mathrm{T}}$$

雷达端的速度定义为：

$$v_k = [\dot{x}_k, \dot{y}_k]^{\mathrm{T}}$$

其中 x_k和 y_k分别表示雷达端此时在 x 轴和 y 轴的位置，$\dot{x}_k$和 $\dot{y}_k$分别表示雷达端此时在 x 轴和 y 轴的速度。

注：本实施例中为简化演示，假设目标以及雷达端的高度位置不变，忽略 z 轴仅建立平行于水平面的 xy 二维坐标系，仅考虑雷达端以及目标在水平面上的位置和速度状态。在实际应用中，根据需要也可以将 z 轴的运动状态考虑进上述定义的状态量 $X_{l,k}$、X_k、v_k中。

2、雷达通信一体化信号模型

2.1，本实施例中，根据探测与通信任务需求，选择 LFM-CPM 信号为发射信号，发射信号的载频 f_c=35GHz，调制指数 h=1/4，传输的信息序列 $b_i \in \{\pm 1, \pm 3\}$，通信符号数量 N=100。一体化系统在第 k个脉冲发送的单脉冲信号为：

$$\tilde{s}_k(t) = s_k(t)\exp(-j2\pi f_c t)$$

其中，j表示虚部，t表示时间，$\exp(\cdot)$表示指数函数，$s_k(t)$表示传输信号的归一化复包络，其数学表达式为：

$$s_k(t) = \sum_{n=0}^{N-1} \mathrm{rect}\left(\frac{t - nT_{s,k}}{T_{s,k}}\right) \exp\left(j\pi\mu_k t^2 + j\pi h\left(b_n \frac{t - nT_{s,k}}{T_{s,k}} + \sum_{i=0}^{n-1} b_i\right)\right)$$

其中，$\mathrm{rect}(\cdot)$表示矩形函数，μ_k表示第 k个脉冲间 LFM 的调频率，$T_{s,k}$表示第 k个脉冲间符号持续时间，$b_n \in \{\pm 1, \pm 3\}$表示传输的信息序列。

2.2，对于距离雷达端相对距离为 $R_{l,k}$、相对速度为 $v_{l,k}$的目标 l，其发出的目标回波的基带表示为：

$$r_k(t)=\sum_{l=1}^{L}\xi_{l,k}s_k\left(t-\tau_{l,k}\right)e^{-j2\pi f_{\mathrm{d}_l,k}t}+n_{l,k}(t)$$

其中，$\xi_{l,k}$表示第l个目标在第k个脉冲间的雷达截面积，$\tau_{l,k}=2R_{l,k}/c$表示时延，$f_{\mathrm{d}\,l,k}=2v_{l,k}f_{\mathrm{c}}/c$表示多普勒频移，$c$为光速，$n_{l,k}(t)$表示均值为 0、实谱密度为$N_0/2$的复高斯白噪声，$N_0$为噪声功率密度。注：在对目标进行通信和探测的时间段t_{trans}以及对信号接收处理的时间段t_{rece}中，雷达端保持悬停状态（不发生位移变化）。

3、目标运动及测量模型

3.1，目前跟踪中常考虑的目标运动模型主要有匀速运动（Constant Velocity，CV）模型、匀加速（Constant Acceleration，CA）运动模型和长转弯（Coordinated Turn，CT）运动模型。目标运动模型的数学表示为：

$$X_{l,k+1}=FX_{l,k}+G\omega_{l,k}$$

其中，$F\in\mathbb{E}^{6\times6}$表示状态转换矩阵，$G\in\mathbb{E}^{6\times2}$表示过程噪声分布矩阵，$\omega_{l,k}\in\mathbb{E}^{2\times1}$表示均值为 0、协方差矩阵为$Q_k$的高斯白噪声向量。

1）对于 CV 模型，F和G分别定义为：

$$F_{\mathrm{CV}}=\begin{bmatrix}\begin{bmatrix}1&\Delta T\\0&1\end{bmatrix}\otimes I_2 & 0_{4\times4}\\ 0_{2\times4} & 0_{2\times2}\end{bmatrix},\ G_{\mathrm{CV}}=\begin{bmatrix}\frac{\Delta T^2}{2}\\ \Delta T\\ 0\end{bmatrix}\otimes I_2$$

2）对于 CA 模型，F和G分别定义为：

$$F_{\mathrm{CA}}=\begin{bmatrix}1&\Delta T&\frac{\Delta T^2}{2}\\0&1&\Delta T\\0&0&1\end{bmatrix}\otimes I_2,\ G_{\mathrm{CA}}=\begin{bmatrix}\frac{\Delta T^3}{6}\\ \frac{\Delta T^2}{2}\\ \Delta T\end{bmatrix}\otimes I_2$$

3）对于 CT 模型，F和G分别定义为：

$$F_{\mathrm{CT}}=\begin{bmatrix}\begin{bmatrix}1&\frac{\sin(\tilde{\omega}\Delta T)}{\tilde{\omega}}&0&\frac{\cos(\tilde{\omega}\Delta T)-1}{\tilde{\omega}}\\0&\frac{1-\cos(\tilde{\omega}\Delta T)}{\tilde{\omega}}&1&\frac{\sin(\tilde{\omega}\Delta T)}{\tilde{\omega}}\\0&\cos(\tilde{\omega}\Delta T)&0&-\sin(\tilde{\omega}\Delta T)\\0&\sin(\tilde{\omega}\Delta T)&0&\cos(\tilde{\omega}\Delta T)\end{bmatrix} & 0_{4\times2}\\ 0_{2\times4} & 0_{2\times2}\end{bmatrix},\ G_{\mathrm{CT}}=\begin{bmatrix}\frac{\Delta T^2}{2}\\ \Delta T\\ 0\end{bmatrix}\otimes I_2$$

其中，ΔT为采样周期（即脉冲重复周期），I_2为形状是$2*2$的单位矩阵，$\tilde{\omega}$表示目标的旋转角速度，$\otimes$表示克罗内克积。

3.2，在第k个脉冲间目标l的测量值为：

$$z_{l,k} = \mathbf{h}\left(X_{l,k}, X_k\right) + \epsilon_{l,k}$$

其中，$\mathbf{h}\left(X_{l,k}, X_k\right) = \left[R_{l,k}, v_{l,k}\right]^{\mathrm{T}}$为测量函数，$\epsilon_{l,k}$表示在第$k$个脉冲间针对目标$l$的测量误差。上述测量函数表征了相对距离为$R_{l,k}$、相对速度为$v_{l,k}$与目标状态$X_{l,k}$之间的非线性关系，具体表达式为：

$$R_{l,k} = \sqrt{\left(x_{l,k} - x_k\right)^2 + \left(y_{l,k} - y_k\right)^2}$$

$$v_{l,k} = \frac{\dot{x}_{l,k}\left(x_{l,k} - x_k\right) + \dot{y}_{l,k}\left(y_{l,k} - y_k\right)}{\sqrt{\left(x_{l,k} - x_k\right)^2 + \left(y_{l,k} - y_k\right)^2}}$$

注：本实施例仅以二维坐标系为例，如果是在三维坐标系下，则上述相对距离、相对速度的计算公式中相应加入 z 轴变量即可。

3.3，测量误差$\epsilon_{l,k}$受测量距离和波形分辨特性的影响，而测量距离与运行轨迹、波形分辨特性与发射波形紧密相关。测量误差$\epsilon_{l,k}$的协方差矩阵$U_{l,k} \in \mathbb{C}^{2\times 2}$可以较好地表征运行轨迹和发射波形对测量误差的影响。测量误差的协方差矩阵$U_{l,k}$的数学表示为：

$$U_{l,k} = \mathbf{\Gamma} C_{l,k} \mathbf{\Gamma}$$

其中，$\mathbf{\Gamma} = \mathrm{diag}[c/2, c/(2f_c)]$表示从时延和多普勒频移到距离和速度的转换矩阵，$c$表示光速，$C_{l,k}$表示在第$k$个脉冲间对目标$l$时延和多普勒频移估计的 CRLB（克拉美罗界），而 CRLB 可以通过参数估计的 Fisher（费希尔）信息矩阵$J_{l,k}$的逆获得，其数学表示为：

$$C_{l,k} = J_{l,k}^{-1}$$

3.4，为了分别分析雷达端运行轨迹和发射波形对性能的影响，将$J_{l,k}$表示为$J_{l,k} = \eta_{l,k}\tilde{J}_k$，其中$\eta_{l,k}$表示第$l$个目标信道在第$k$个脉冲间的信噪比，只受雷

达运行轨迹的影响；$\tilde{J}_k$表示 Fisher 信息矩阵 $J_{l,k}$中受到波形影响的部分。对于 $\eta_{l,k}$和 $\tilde{J}_k$：

1） $\eta_{l,k}$的数学表示为：

$$\eta_{l,k}=\frac{P_{t,l,k}T_{d,l,k}G_{t,l}G_{r,l}\lambda^2\sigma_l}{64\pi^3T_rR_{l,k}^4N_0}$$

其中，$P_{t,l,k}$表示发射功率，$T_{d,l,k}$表示信号停留时间，$G_{t,l}$表示发射增益，$G_{r,l}$表示雷达的接收增益，λ为光的波长，σ_l表示第 l个目标的雷达截面积，T_r表示脉冲重复频率，N_0表示噪声功率密度。

2） $\tilde{J}_k$只受发射波形影响，其定义为发射波形模糊函数 $\chi(\tau,f_\mathrm{d})$在目标时延 τ和多普勒频移 f_d处的 Hessian（黑塞）矩阵：

$$\tilde{J}_k=\begin{bmatrix}-\left.\frac{\partial\chi(\tau,f_\mathrm{d})}{\partial\tau\partial\tau}\right|_{\substack{\tau=0\\f_\mathrm{d}=0}} & -\left.\frac{\partial\chi(\tau,f_\mathrm{d})}{\partial\tau\partial f_\mathrm{d}}\right|_{\substack{\tau=0\\f_\mathrm{d}=0}}\\ -\left.\frac{\partial\chi(\tau,f_\mathrm{d})}{\partial\tau\partial f_\mathrm{d}}\right|_{\substack{\tau=0\\f_\mathrm{d}=0}} & -\left.\frac{\partial\chi(\tau,f_\mathrm{d})}{\partial f_\mathrm{d}\partial f_\mathrm{d}}\right|_{\substack{\tau=0\\f_\mathrm{d}=0}}\end{bmatrix}\triangleq\begin{bmatrix}\tilde{J}_{k,\tau\tau} & \tilde{J}_{k,\tau f_\mathrm{d}}\\ \tilde{J}_{k,\tau f_\mathrm{d}} & \tilde{J}_{k,f_\mathrm{d}f_\mathrm{d}}\end{bmatrix}$$

2.1） $\tilde{J}_{k,\tau\tau}$的数学推导结果为：

$$\tilde{J}_{k,\tau\tau}=\sum_{i=-1}^{6}\bar{J}_{k,\tau\tau}^{(i)}T_{s,k}^i$$

其中，

$$\bar{J}_{k,\tau\tau}^{(-1)}=h^2\sum_{n=0}^{N-1}b_n^2,\ \bar{J}_{k,\tau\tau}^{(0)}=-\left(\frac{h}{2\mu_k}\sum_{n=0}^{N-1}b_n\right)^2,\ \bar{J}_{k,\tau\tau}^{(1)}=4h\mu_k\sum_{n=0}^{N-1}nb_n+2h\mu_k\sum_{n=0}^{N-1}b_n$$

$$\bar{J}_{k,\tau\tau}^{(2)}=-\frac{hN}{2\mu_k}\sum_{n=0}^{N-1}b_n,\ \bar{J}_{k,\tau\tau}^{(3)}=\frac{4\mu_k^2}{3}(N-1)(N^2+N)+\frac{4}{3}N\mu_k^2-\frac{h(N-1)N}{2\mu_k}\sum_{n=0}^{N-1}b_n$$

$$\bar{J}_{k,\tau\tau}^{(4)}=-\frac{N^2}{4},\ \bar{J}_{k,\tau\tau}^{(5)}=-(N-1)N^2,\ \bar{J}_{k,\tau\tau}^{(6)}=-\frac{(N-1)^2N^2}{4}$$

2.2） $\tilde{J}_{k,f_\mathrm{d}f_\mathrm{d}}$的数学推导结果为：

$$\tilde{J}_{k,f_\mathrm{d}f_\mathrm{d}}=\sum_{i=3}^{4}\bar{J}_{k,f_\mathrm{d}f_\mathrm{d}}^{(i)}T_{s,k}^i$$

其中，

$$\bar{J}^{(3)}_{k,f_{\mathrm{d}}f_{\mathrm{d}}}=\frac{N^3}{3},\ \bar{J}^{(4)}_{k,f_{\mathrm{d}}f_{\mathrm{d}}}=-\frac{N^4}{4}$$

2.3） $\tilde{J}_{k,\tau f_{\mathrm{d}}}$的数学推导结果为：

$$\tilde{J}_{k,\tau f_{\mathrm{d}}}=\tilde{J}_{k,f_{\mathrm{d}}\tau}=\sum_{i=1}^{4}\bar{J}^{(i)}_{k,\tau f_{\mathrm{d}}}T^{i}_{s,k}$$

其中，

$$\bar{J}^{(1)}_{k,\tau f_{\mathrm{d}}}=\pi h\sum_{n=0}^{N-1}nb_n+\frac{\pi h}{2}\sum_{n=0}^{N-1}b_n,\ \bar{J}^{(2)}_{k,\tau f_{\mathrm{d}}}=-\frac{hN^2}{4\mu_k}\sum_{n=0}^{N-1}b_n$$

$$\bar{J}^{(3)}_{k,\tau f_{\mathrm{d}}}=\frac{2\pi\mu_k}{3}\left(\frac{(N-1)N(2N-1)}{2}+(N-1)\left(\frac{3N}{2}+1\right)\right)-\frac{(N-1)N^3}{4}$$

$$\bar{J}^{(4)}_{k,\tau f_{\mathrm{d}}}=\frac{N^3}{4}$$

4、跟踪滤波模型

跟踪滤波旨在根据目标运动模型与测量数据预估下一时刻的目标状态。本实施例采用扩展 Kalman（卡尔曼）滤波实现目标跟踪。

4.1，已知在 $k-1$时刻（第 $k-1$个脉冲间）对目标下一时刻（ k时刻）的状态进行了预估，得到相应目标 l的状态预估值 $X_{l,k|k-1}$及其预估协方差 $P_{l,k|k-1}$。在 k时刻发射一体化信号后，经回波探测获得测量值 $z_{l,k}$，则基于测量值对预估值进行修正：

$$X_{l,k|k}=X_{l,k|k-1}+K_{l,k}\left(z_{l,k}-\mathbf{h}\left(X_{l,k|k-1},X_k\right)\right)$$

$$P_{l,k|k}=P_{l,k|k-1}-K_{l,k}S_{l,k}K^{\mathrm{T}}_{l,k}$$

其中， $X_{l,k|k-1}$为在 $k-1$时刻对目标 l进行预测的状态预估值， $P_{l,k|k-1}$为其对应预估协方差， $X_{l,k|k}$为在 k时刻目标 l的状态修正值， $P_{l,k|k}$为对应修正协方差； $K_{l,k}$为卡尔曼增益， $S_{l,k}$为新增协方差，两者数学表达式分别为：

$$K_{l,k}=P_{l,k|k-1}H^{\mathrm{T}}_{l,k}S^{-1}_{l,k}$$

$$S_{l,k}=H_{l,k}P_{l,k|k-1}H^{\mathrm{T}}_{l,k}+U_{l,k}$$

其中，$H_{l,k}$表示测量函数$\mathbf{h}\left(X_{l,k|k-1},X_k\right)$在预测目标状态$X_{l,k|k-1}$处的雅可比矩阵。

4.2，在k时刻，基于运动模型对目标下一时刻的状态进行预测：

$$X_{l,k+1|k}=F_{k+1}X_{l,k|k}$$

相应状态预测协方差为：

$$P_{l,k+1|k}=F_{k+1}P_{l,k|k}F_{k+1}^{\mathrm{T}}+G_{k+1}Q_kG_{k+1}^{\mathrm{T}}$$

其中，F_{k+1}和G_{k+1}分别表示在第k+1 个脉冲间的状态转换矩阵F和过程噪声分布矩阵G。

5、自适应调整发射方案

以在$k-1$时刻调整k时刻的发射方案为例，基于在$k-1$时刻对目标k时刻的预估状态$X_{l,k|k-1}$，调整k时刻雷达端的运行轨迹和发射的一体化信号的波形。

5.1，雷达与通信性能指标

1）本实施例采用目标估计协方差作为雷达跟踪性能的衡量指标。预估目标估计协方差$\widehat{P}_{l,k|k}$的迹数学表示为：

$$P_{l,k}=\mathbb{P}_{l,k}\left(X_{l,k|k-1},\mu_k,T_{s,k},v_k\right)=\mathrm{Tr}\left(\widehat{\mathbb{P}}_{l,k|k}\left(X_{l,k|k-1},\mu_k,T_{s,k},v_k\right)\right)$$
$$=\mathrm{Tr}\left(P_{l,k|k-1}-P_{l,k|k-1}H_{l,k}^{\mathrm{T}}\left(H_{l,k}P_{l,k|k-1}H_{l,k}^{\mathrm{T}}+\widehat{\mathbb{U}}_{l,k}\left(X_{l,k|k-1},\mu_k,T_{s,k},v_k\right)\right)^{-1}H_{l,k}P_{l,k|k-1}\right)$$

其中，$\mathrm{Tr}(\cdot)$表示迹函数，$\widehat{U}_{l,k}=\widehat{\mathbb{U}}_{l,k}\left(X_{l,k|k-1},\mu_k,T_{s,k},v_k\right)$表示预估测量误差协方差（即$U_{l,k}$的估计值），其数学表示为：

$$\widehat{\mathbb{U}}_{l,k}\left(X_{l,k|k-1},\mu_k,T_{s,k},v_k\right)=\mathbf{\Gamma}\left(\hat{\eta}_{l,k}\tilde{J}_k\right)^{-1}\mathbf{\Gamma}$$

其中，$\hat{\eta}_{l,k}$表示预估测量信噪比（即$\eta_{l,k}$的预估值），其数学表示为：

$$\hat{\eta}_{l,k}=\frac{P_{t,l,k}T_{d,l,k}G_{t,l}G_{r,l}\lambda^2\sigma_l}{64\pi^3T_r\widehat{R}_{l,k}^4N_0}$$

其中$\widehat{R}_{l,k}$为目标l距雷达端的预估相对距离（即$R_{l,k}$的预估值）。由于实际的

距离 $R_{l,k}$是未知目标状态 $X_{l,k}$的函数，因此使用目标状态估计值 $X_{l,k|k-1}$计算预估相对距离 $\widehat{R}_{l,k}$，用以替代 $R_{l,k}$：

$$\left[\widehat{R}_{l,k}, \hat{v}_{l,k}\right]^{\mathrm{T}} = \mathbf{h}\left(X_{l,k|k-1}, X_k\right)$$

即：

$$\widehat{R}_{l,k} = \sqrt{\left(x_{l,k|k-1} - x_k\right)^2 + \left(y_{l,k|k-1} - y_k\right)^2}$$

代入雷达端在 k时刻的速度 v_k后，上式变为：

$$\widehat{R}_{l,k} = \sqrt{\left(x_{l,k|k-1} - \left(x_{k-1} + \dot{x}_k t_{\mathrm{X}}\right)\right)^2 + \left(y_{l,k|k-1} - \left(y_{k-1} + \dot{y}_k t_{\mathrm{X}}\right)\right)^2}$$

即：

$$\left[\widehat{R}_{l,k}, \hat{v}_{l,k}\right]^{\mathrm{T}} = \mathbf{h}\left(X_{l,k|k-1}, X_{k-1}, v_k\right)$$

其中，t_{X}为每个脉冲间内雷达端的移动时长，$v_{l,k}$表示相对速度 $\hat{v}_{l,k}$的估计值。

2）在通信领域中，误码率是衡量通信有效性的重要指标。因此与跟踪指标同理，本实施例采用预估误码率作为通信性能衡量指标。一体化系统的预估误码率为：

$$B_{l,k} = \mathbb{B}_{l,k}\left(X_{l,k|k-1}, v_k\right) = Q\left(\sqrt{d_{\min}^2 SNR_{l,k}}\right)$$

其中，$Q(x) = \int_x^{\infty} \frac{1}{\sqrt{2\pi}} e^{-\frac{t^2}{2}} dt$表示 Q 函数，$d_{\min}$表示归一化最小欧式距离，$SNR_{l,k}$表示通信信道的预估信噪比，其数学表达式为：

$$SNR_{l,k} = P_{t,l,k} h_{l,k} / N_0$$

其中，$h_{l,k}$表示预估通道信道增益，其数学表达式为：

$$h_{l,k} = \frac{G_{t,l} G_{c,l} \lambda^2}{16\pi^2 \widehat{R}_{l,k}^2}$$

其中，$G_{c,l}$表示目标接收天线增益。

5.2，优化模型

为综合提升目标跟踪精度与通信准确率，本实施例采用以下方式对雷达端运行轨迹以及发射波形进行联合优化调整。

鉴于雷达性能指标与通信性能指标两者量纲不同，因此先对雷达性能指标 $P_{l,k}$和通信

性能指标 $B_{l,k}$做归一化处理，之后对两者归一化后的结果求和；基于此，联合优化的目标即为最小化上述求和结果：

$$\mathcal{P}_0:\ \min_{\mu_k,T_{s,k},v_k}\ \Phi\left(\sum_{l=1}^{L}P_{l,k}\right)+\Phi\left(\sum_{l=1}^{L}B_{l,k}\right)=$$

$$\min_{\mu_k,T_{s,k},v_k}\Phi\left(\sum_{l=1}^{L}\mathbb{P}_{l,k}\left(X_{l,k|k-1},\mu_k,T_{s,k},v_k\right)\right)+\Phi\left(\sum_{l=1}^{L}\mathbb{B}_{l,k}\left(X_{l,k|k-1},v_k\right)\right)$$

$$s.t.\quad \mu_{\min}\le\mu_k\le\mu_{\max}$$
$$T_{s,\min}\le T_{s,k}\le T_{s,\max}$$
$$|v_k|\le Cons$$

其中，$\Phi(\cdot)$表示归一化操作，$\mu_{\min}$和$\mu_{\max}$分别表示 LFM-CPM 调频率μ_k的最小值和最大值，$T_{s,\min}$和$T_{s,\max}$分别表示通信符号持续时间$T_{s,k}$的最小值和最大值，$Cons$表示雷达端的运行限制。为方便表示，将上述目标函数记作$\mathcal{L}\left(\mu_k,T_{s,k},v_k\right)$。

5.3，优化问题求解

目标函数$\mathcal{L}\left(\mu_k,T_{s,k},v_k\right)$涉及三个相关参数，分别是调频率$\mu_k$、符号持续时间$T_{s,k}$、雷达端的速度$v_k$。从数学角度看，目标函数是非线性和非凸的，同时调频率、符合持续时间、雷达端的运行速度三者之间相耦合。因此，上述优化问题$\mathcal{P}_0$难以直接求得最优解。对此，本实施例给出以下求解方法：

1）问题分解

根据目标估计协方差和通信误码率的表达式，可知前者与发射波形、雷达端运行轨迹相关，后者仅与雷达端运行轨迹相关。因此，本发明将参数分为发射波形相关和与运行轨迹相关两部分。随之，原始优化问题$\mathcal{P}_0$可以分解为发射波形优化子问题$\mathcal{P}_1$和雷达端轨迹优化子问题$\mathcal{P}_2$，这两个优化子问题的数学表示分别为：

$$\mathcal{P}_1:\ \mathcal{L}_1\left(\mu_k,T_{s,k}\right)=\min_{\mu_k,T_{s,k}}\ \Phi\left(\sum_{l=1}^{L}\mathbb{P}_{l,k}\left(X_{l,k|k-1},\mu_k,T_{s,k}\right)\right)$$

$$s.t.\quad \mu_{\min}\le\mu_k\le\mu_{\max}$$
$$T_{s,\min}\le T_{s,k}\le T_{s,\max}$$

$$\mathcal{P}_2:\ \mathcal{L}_2(v_k)=\min_{x_k,y_k}\ \Phi\left(\sum_{l=1}^{L}\mathbb{P}_{l,k}\left(X_{l,k|k-1},\mu_k^*,T_{s,k}^*,v_k\right)\right)+\Phi\left(\sum_{l=1}^{L}\mathbb{B}_{l,k}\left(X_{l,k|k-1},v_k\right)\right)$$

$$s.t.\quad |v_k|\le Cons$$

其中，μ_k^*和$T_{s,k}^*$为经优化问题$\mathcal{P}_1$求解得到的μ_k和$T_{s,k}$最优解。

2）发射波形优化

对于优化问题$\mathcal{P}_1$，其依旧是一个非凸非线性的优化问题，难以直接求解。对此，本实施例采用 RGS（Rectangular grid search, 矩形网格搜索）算法进行求解。RGS 算法在波形参数优化问题中具有计算便捷性和有效性，其通过对波形空间进行迭代搜索，以此找到最小化目标函数的波形。

具体而言，RGS 算法在第m轮迭代搜索中，设定待搜索矩形区域的μ_k和$T_{s,k}$两个维度的区间分别为$\left[\mu_{k_\mathrm{low}}^{(m)},\mu_{k_\mathrm{high}}^{(m)}\right]$和$\left[T_{s,k_\mathrm{low}}^{(m)},T_{s,k_\mathrm{high}}^{(m)}\right]$。在各自矩形搜索区域中，参数$\mu_k$和$T_{s,k}$在维度上分别有$N_\mu$和$N_T$个格点。即对于参数$\mu_k$的维度，格点为$\left\{\mu_{k_1}^{(m)},\mu_{k_2}^{(m)},\cdots,\mu_{k_N_\mu}^{(m)}\right\}$；对于参数$T_{s,k}$的维度，格点为$\left\{T_{s,k_1}^{(m)},T_{s,k_2}^{(m)},\cdots,T_{s,k_N_T}^{(m)}\right\}$；上述格点分别均匀分布于$\left[\mu_{k_\mathrm{low}}^{(m)},\mu_{k_\mathrm{high}}^{(m)}\right]$和$\left[T_{s,k_\mathrm{low}}^{(m)},T_{s,k_\mathrm{high}}^{(m)}\right]$中。RGS 算法从中搜索得出最优的参数$\mu_{k_N_\mu^*}^{(m)}$和$T_{s,k_N_T^*}^{(m)}$：

$$\left(\mu_{k_N_\mu^*}^{(m)},T_{s,k_N_T^*}^{(m)}\right)=\arg\min_{\mu_k,T_{s,k}}\Phi\left(\sum_{l=1}^{L}\mathbb{P}_{l,k}\left(X_{l,k|k-1},\mu_k,T_{s,k}\right)\right)$$

往后在第$m+1$轮迭代搜索中，分别以$\mu_{k_N_\mu^*}^{(m)}$和$T_{s,k_N_T^*}^{(m)}$作为新的搜索区域的中心，并基于各自周围的点$\left[\mu_{k_N_\mu^*-1}^{(m)},\mu_{k_N_\mu^*+1}^{(m)}\right]$和$\left[T_{s,k_N_T^*-1}^{(m)},T_{s,k_N_T^*+1}^{(m)}\right]$形成新的待搜索矩形区域$\left[\mu_{k_\mathrm{low}}^{(m+1)},\mu_{k_\mathrm{high}}^{(m+1)}\right]$和$\left[T_{s,k_\mathrm{low}}^{(m+1)},T_{s,k_\mathrm{high}}^{(m+1)}\right]$。

注：上述上角标(m)和$(m+1)$用于标注迭代次数。

上述过程经循环往复直至达到预设的迭代次数后，输出最终优化结果 μ_k^*和 $T_{s,k}^*$。

3）轨迹优化

在得到 μ_k^*和 $T_{s,k}^*$后，将其代入雷达端轨迹优化子问题 $\mathcal{P}_2$：

$$\mathcal{L}_2(v_k) = \mathcal{L}_2(\dot{x}_k, \dot{y}_k)$$

$$\mathcal{P}_2:\ \mathcal{L}_2(\dot{x}_k, \dot{y}_k) = \min_{\dot{x}_k, \dot{y}_k} \Phi\left(\sum_{l=1}^{L} \mathbb{P}_{l,k}\left(X_{l,k|k-1}, \mu_k^*, T_{s,k}^*, \dot{x}_k, \dot{y}_k\right)\right) + \Phi\left(\sum_{l=1}^{L} \mathbb{B}_{l,k}\left(X_{l,k|k-1}, \dot{x}_k, \dot{y}_k\right)\right)$$

$$s.t. \quad |\dot{x}_k| \le Cons_{\mathrm{x}}$$
$$|\dot{y}_k| \le Cons_{\mathrm{y}}$$

其中，$Cons_{\mathrm{x}}$和 $Cons_{\mathrm{y}}$分别表示雷达端在 x 轴和 y 轴方向上每个时刻运行距离的限制。

目标函数 $\mathcal{L}_2(\dot{x}_k, \dot{y}_k)$具有非凸性，因此本实施例采用梯度下降法进行求解。

具体而言，设在第 m轮迭代中，为拟合目标函数，对 $\mathcal{L}_2(\dot{x}_k, \dot{y}_k)$在给定点 $\dot{x}_k^{(m-1)}$ 和 $\dot{y}_k^{(m-1)}$ 实施一阶泰勒展开：

$$\mathcal{L}_2(\dot{x}_k, \dot{y}_k) \approx \mathcal{L}_2\left(\dot{x}_k^{(m-1)}, \dot{y}_k^{(m-1)}\right) + \nabla\mathcal{L}_{2,\dot{x}_k}\left(\dot{x}_k^{(m-1)}, \dot{y}_k^{(m-1)}\right)\left(\dot{x}_k - \dot{x}_k^{(m-1)}\right) + \nabla\mathcal{L}_{2,\dot{y}_k}\left(\dot{x}_k^{(m-1)}, \dot{y}_k^{(m-1)}\right)\left(\dot{y}_k - \dot{y}_k^{(m-1)}\right)$$

其中 $\nabla\mathcal{L}_{2,\dot{x}_k}$和 $\nabla\mathcal{L}_{2,\dot{y}_k}$分别表示函数 $\mathcal{L}_2(\dot{x}_k, \dot{y}_k)$关于 $\dot{x}_k$和 $\dot{y}_k$的梯度。将上式等号右侧后两项记为

$$\mathrm{G}(\dot{x}_k, \dot{y}_k) = \nabla\mathcal{L}_{2,\dot{x}_k}\left(\dot{x}_k^{(m-1)}, \dot{y}_k^{(m-1)}\right)\left(\dot{x}_k - \dot{x}_k^{(m-1)}\right) + \nabla\mathcal{L}_{2,\dot{y}_k}\left(\dot{x}_k^{(m-1)}, \dot{y}_k^{(m-1)}\right)\left(\dot{y}_k - \dot{y}_k^{(m-1)}\right),$$

则优化问题 $\mathcal{P}_2$转化为：

$$\min_{\dot{x}_k, \dot{y}_k} \mathrm{G}(\dot{x}_k, \dot{y}_k)$$
$$s.t. \quad |\dot{x}_k| \le Cons_{\mathrm{x}}$$
$$|\dot{y}_k| \le Cons_{\mathrm{y}}$$

使用搜索法对上述目标函数进行求解，得到 $\dot{x}_k^{*(m)}$ 和 $\dot{y}_k^{*(m)}$。

由于上述优化问题是最小化问题，$\dot{x}_k^{*(m)} - \dot{x}_k^{(m-1)}$和$\dot{y}_k^{*(m)} - \dot{y}_k^{(m-1)}$表示参数$\dot{x}_k$和$\dot{y}_k$的下降方向。通过搜索可以得到目标函数$\mathcal{L}_2(\dot{x}_k, \dot{y}_k)$的步长$\omega^* \in [0,1]$。第$m$轮迭代的给定点由下式获得，以用于下一轮迭代：

$$\dot{x}_k^{(m)} = \dot{x}_k^{(m-1)} + \omega^* \left(\dot{x}_k^{*(m)} - \dot{x}_k^{(m-1)} \right)$$

$$\dot{y}_k^{(m)} = \dot{y}_k^{(m-1)} + \omega^* \left(\dot{y}_k^{*(m)} - \dot{y}_k^{(m-1)} \right)$$

上述过程经循环往复直至达到预设的迭代次数后，输出最终优化结果$\dot{x}_k^*$和$\dot{y}_k^*$，进而依据X_{k-1}计算得到雷达端在k时刻的位置X_k。

综上，参照图 3 所示，雷达端的循环控制过程为：

步骤 1，在当前时刻（k时刻），基于上一时刻（$k-1$时刻）确定的发射方案，雷达端在X_k位置向目标发送雷达通信一体化信号，其中调频率为μ_k、符号持续时间为$T_{s,k}$；

步骤 2，接收到回波后，采用最大似然方法获得目标的测量值$z_{l,k}$，并以此通过卡尔曼滤波算法对目标状态估计值$X_{l,k|k-1}$和$P_{l,k|k-1}$进行修正，得到修正值$X_{l,k|k}$和$P_{l,k|k}$；再基于目标运动模型预估下一时刻（$k+1$时刻）目标状态$X_{l,k+1|k}$和$P_{l,k+1|k}$；

步骤 3，基于将目标下一时刻（$k+1$时刻）的状态预估值$X_{l,k+1|k}$，对优化问题$\mathcal{P}_0$进行求解，得到下一时刻（$k+1$时刻）的发射方案，即μ_{k+1}、$T_{s,k+1}$、X_{k+1}。

二、仿真测试

本实施例采用 Matlab 仿真软件进行仿真测试，其中一体化系统包括 1 个雷达端和 2 个目标，一体化信号波形 LFM-CPM 调频率的取值范围为$\mu_{\min}$=0.01MHz/s、$\mu_{\max}$=1MHz/s，符号持续时间的取值范围为$T_{s,\min}$=1μs、$T_{s,\max}$=100μs，采样周期ΔT=1s。

雷达端的初始位置$X_1 = [x_1, y_1]^{\mathrm{T}} = [100\mathrm{m}, 100\mathrm{m}]^{\mathrm{T}}$，两个目标的初始位置均为

$[800\text{m}, 1000\text{m}]^{\mathrm{T}}$。目标雷达截面积 $\xi_{l,k}$的取值范围为 $(0,1]$，噪声功率 N_0=-110dBm，发射功率 $P_{t,l,k}$=10dBm，载频 f_c=35GHz，发射增益 $G_{t,l}$=35dB，雷达接收增益 $G_{r,l}$=36dB，目标接收天线增益 $G_{c,l}$=36dB，协方差矩阵 $Q_k = \text{diag}([0.01,0.01])$，雷达端的移速限制 $Cons_x$和 $Cons_y$均为 10m/s。所有仿真的结果均通过蒙特卡洛方法得到。

为验证本发明技术方案性能，本实施例选取了五种具有代表性的现有技术手段，在目标跟踪精度和误码率两项指标上与本发明进行对比测试。所选取的现有技术手段分别为：

①固定式雷达发射固定波形（Fixed Location and Fixed Waveform, FLFW）方案，其中调频率为 0.1MHz，符号持续时间 80μs；

②固定式雷达发射自适应最优波形（Fixed Location and Optimized Waveform，FLOW）方案，其中采用 RGS 算法优化一体化发射波形；

③动态雷达保持恒定速度运行，且发射固定波形（Fixed Velocity and Fixed Waveform，FVFW）方案，其中雷达在 x 轴的运行速度-2m/s，在 y 轴的运行速度 3m/s，调频率为 0.1MHz，符号持续时间为 80μs。

④雷达保持恒定速度运行，且发射自适应最优波形（Fixed Velocity and Optimized Waveform，FVOW）方案，其中雷达在 x 轴的运行速度-2m/s，在 y 轴的运行速度 3m/s，并且使用 RGS 算法优化一体化波形。

⑤雷达以最优速度运行，且发射固定波形（Optimized Velocity and Fixed Waveform，OVFW）方案，其中使用轨迹优化算法求得最优轨迹，调频率 0.1MHz，符号持续时间 80μs。

对比测试结果如图 4~图 9 所示，其中图 4~图 6 所示的为目标做线性机动，图 7~图 9 所示的为目标做非线性机动。

图 4 展示了跟踪线性机动目标时的平均误码率随采样时间的变化曲线，图中所示：本发明所提方法根据目标运动状态的改变，可以自适应地调整雷达端的运行轨迹，进而和跟踪目标保持较近的距离，最终取得较低的误码率。

图 5 所示出了各个方案估计的目标运行轨迹和真实目标运行轨迹的对比图。从对比结果看出，本发明所提出的方案表现最优，即估计的轨迹结果最接近真实的运行轨迹。

图 6 给出了目标的位置和速度估计的平均均方误差随采样时间的变化曲线，图中所示本发明取得最低的位置和速度估计的平均均方误差。

图 7 展示了跟踪非线性机动目标时，各个方案的平均误码率随采样时间的变化曲线。从

该图中可以看出，本发明自适应地调整雷达端运行轨迹，保持了和跟踪目标较近的距离。而较近的通信距离可以取得较低的误码率。

图 8 给出了各方案估计的目标运行轨迹与目标真实运行轨迹之间的对比。可以看出，本发明估计的轨迹结果最接近目标真实运行轨迹。

图 9 给出了目标的位置和速度估计的平均均方误差随采样时间的变化曲线。可以看出，本发明取得最低的位置和速度估计的平均均方误差。

三、装置、存储介质、程序产品

1.基于与上述雷达通信一体化控制方法相同的发明构思，本申请还提供了一种电子装置，该电子装置包括处理器和存储器，存储器中存储了计算机可读代码，其中，当计算机可读代码由处理器执行时，进行本发明雷达通信一体化控制方法的实施。

其中，存储器包括非易失性存储介质和内存储器；非易失性存储介质可存储操作系统和计算机可读代码。该计算机可读代码包括程序指令，该程序指令被执行时，可使得处理器执行雷达通信一体化控制方法。处理器用于提供计算和控制能力，支撑整个电子装置的运行。存储器为非易失性存储介质中的计算机可读代码的运行提供环境，该计算机可读代码被处理器执行时，可使得处理器执行雷达通信一体化控制方法。

应当理解的是，处理器可以是中央处理单元、其他通用处理器、数字信号处理器、专用集成电路、现场可编程门阵列或者其他可编程逻辑器件、晶体管逻辑器件、分立硬件组件等。其中，通用处理器可以是微处理器或是任何常规的处理器。

2.本申请还提供了一种可读存储介质，该可读存储介质可以是前述实施例所述电子装置的内部存储单元，例如所述计算机设备的硬盘或内存。所述可读存储介质也可以是所述电子装置的外部存储设备，例如所述电子装置上配备的插接式硬盘、智能存储卡、安全数字卡等。

3.本申请还提供了一种计算机程序产品，包括计算机程序或指令，该计算机程序或指令被处理器执行时实现本发明雷达通信一体化控制方法。

在本发明的描述中，需要理解的是，术语“上”、“下”、“前”、“后”、“左”、“右”、“竖直”、“水平”、“顶”、“底”、“内”、“外”等指示的方位或位置关系为基于附图所示的方位或位置关系，仅是为了便于描述本发明和简化描述，而不是指示或暗示所指的装置或元件必须具有特定的方位、以特定的方位构造和操作，因此不能理解为对本发明的限制。

本发明并不限于上述实施方式，在不背离本发明的实质内容的情况下，本领域技术人员能够做出的任何显而易见的改进、替换或变形均属于本发明的保护范围。

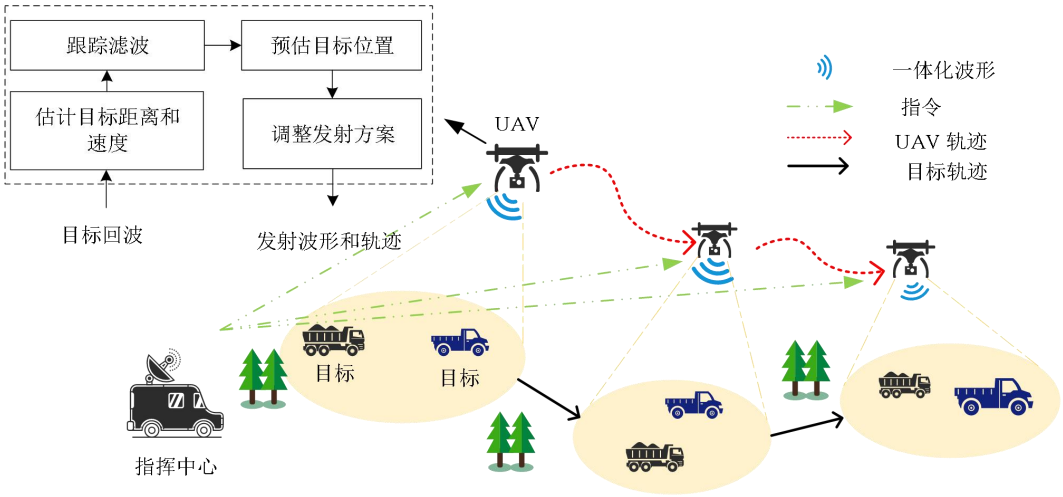

跟踪滤波
预估目标位置
估计目标距离和速度
调整发射方案
目标回波
发射波形和轨迹
UAV
一体化波形
指令
UAV 轨迹
目标轨迹
目标
目标
指挥中心

图 1

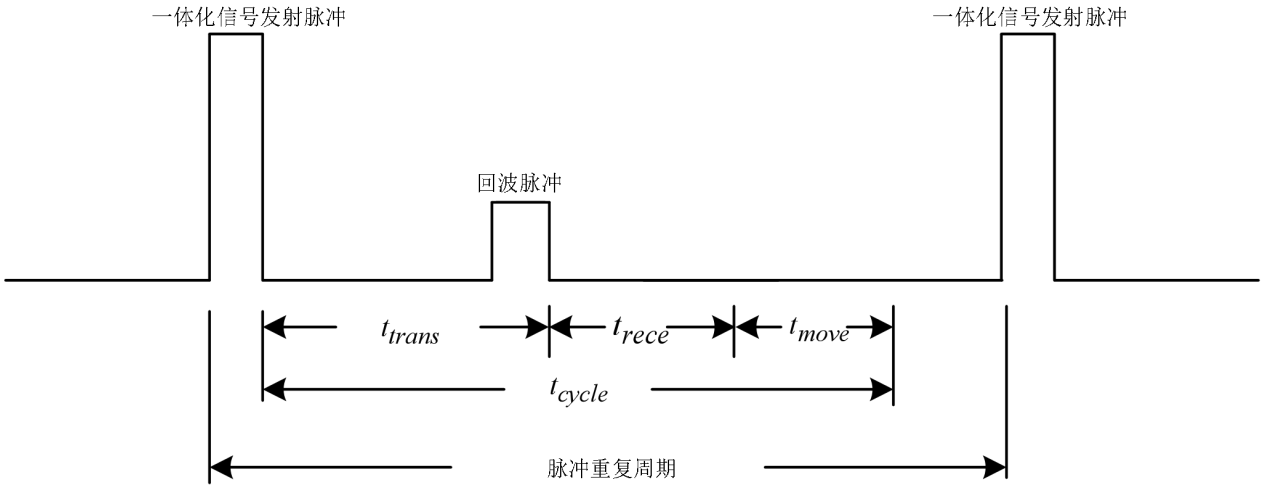

一体化信号发射脉冲
一体化信号发射脉冲
回波脉冲
t_{trans}
t_{rece}
t_{move}
t_{cycle}
脉冲重复周期

图 2


向目标发送一体化波形
获得量测信息
滤波获得当前时刻的目标状态估计
预测下一时刻的目标状态
预测
调整发射位置和发射波形
求解优化问题
计算得出预估目标估计方差和预估通信误码率
自适应调整

图 3

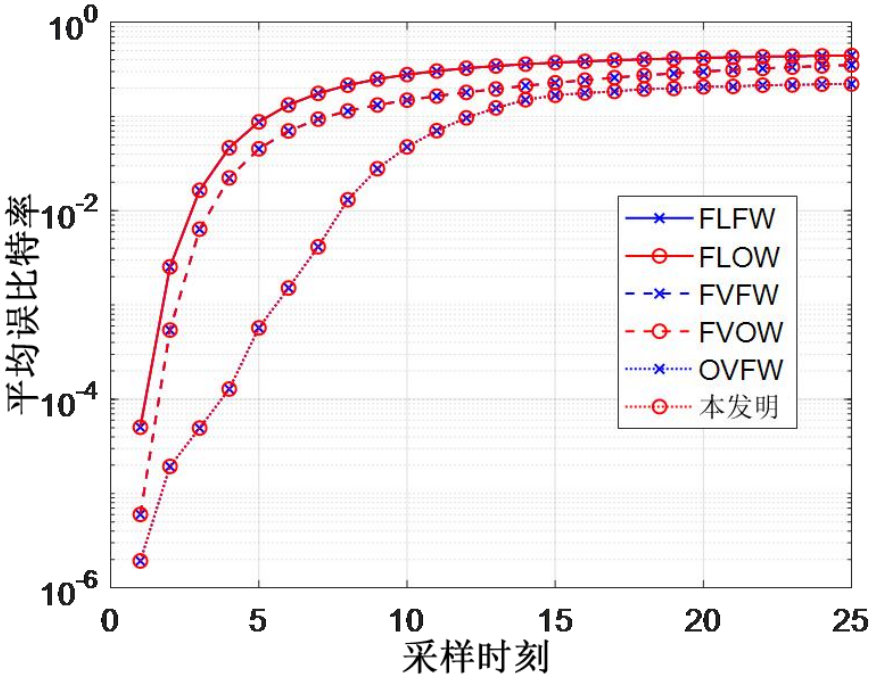

平均误比特率
采样时刻
FLFW
FLOW
FVFW
FVOW
OVFW
本发明

图 4

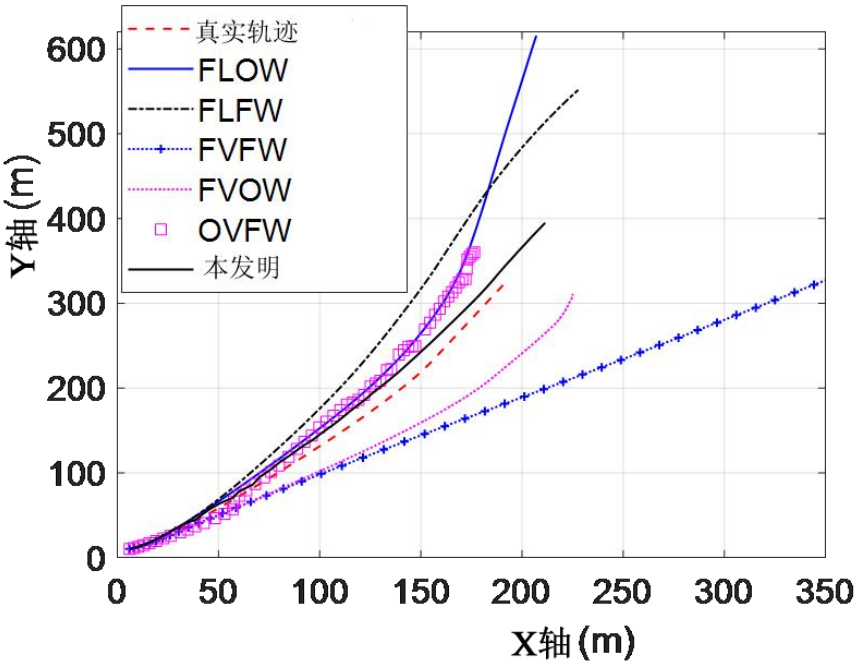
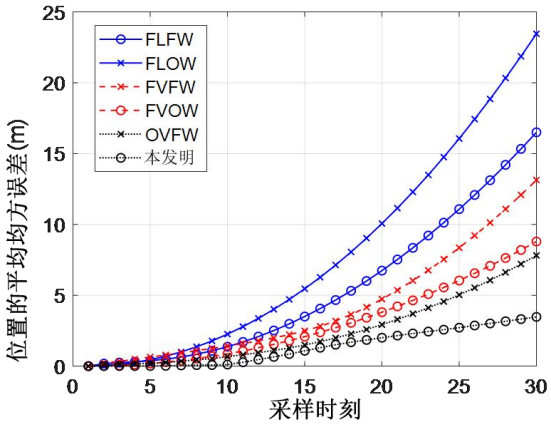
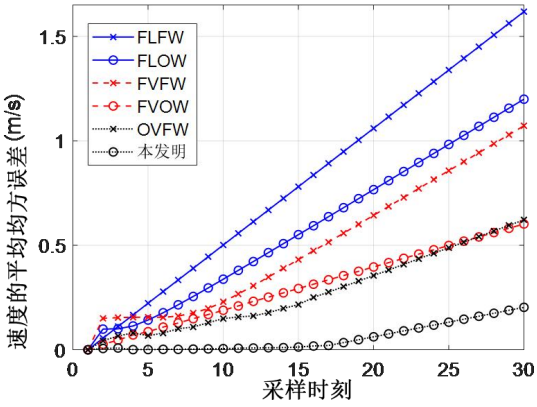

真实轨迹
FLOW
FLFW
FVFW
FVOW
OVFW
本发明
Y轴(m)
X轴(m)

图 5



(c) 位置估计



(d) 速度估计

图 6

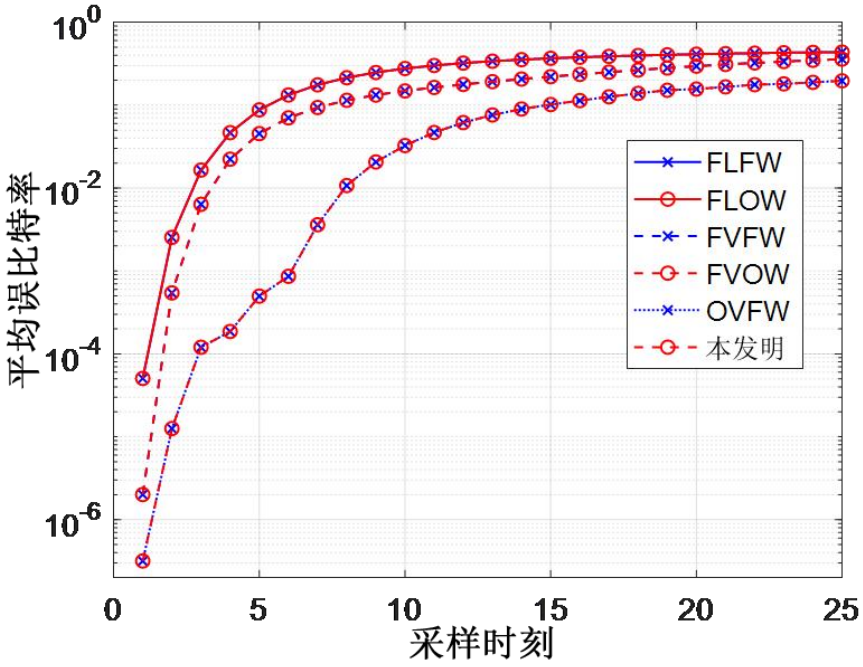


图 7

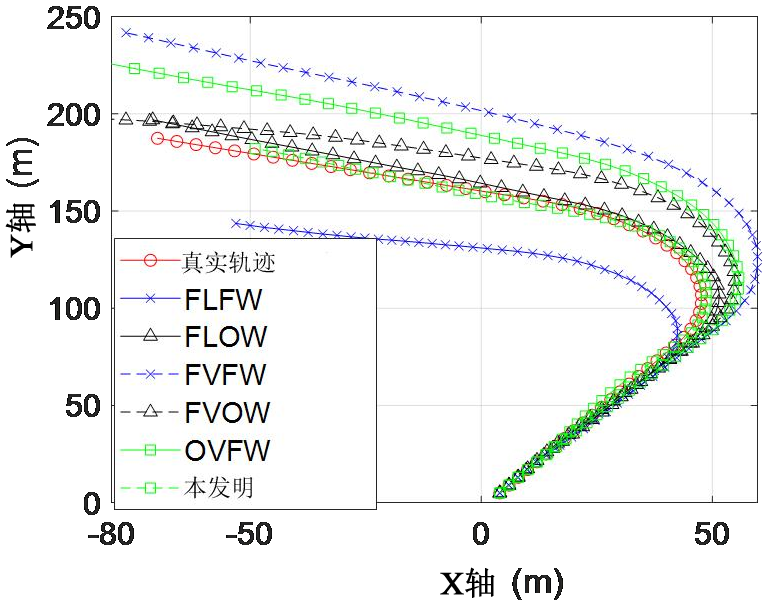
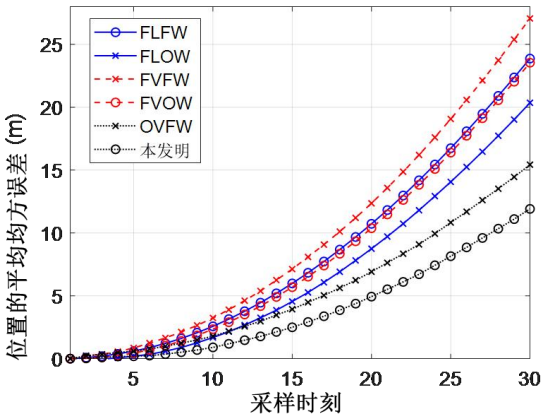
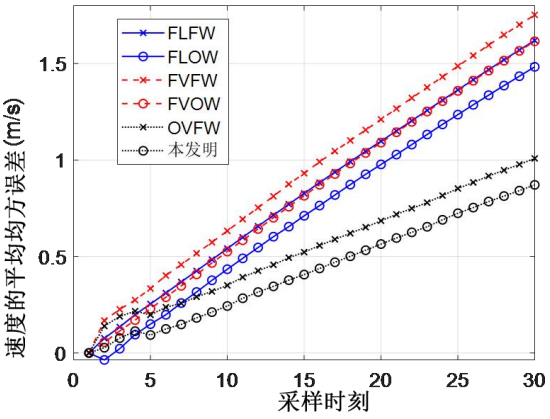


图 8



(c) 位置估计



(d) 速度估计

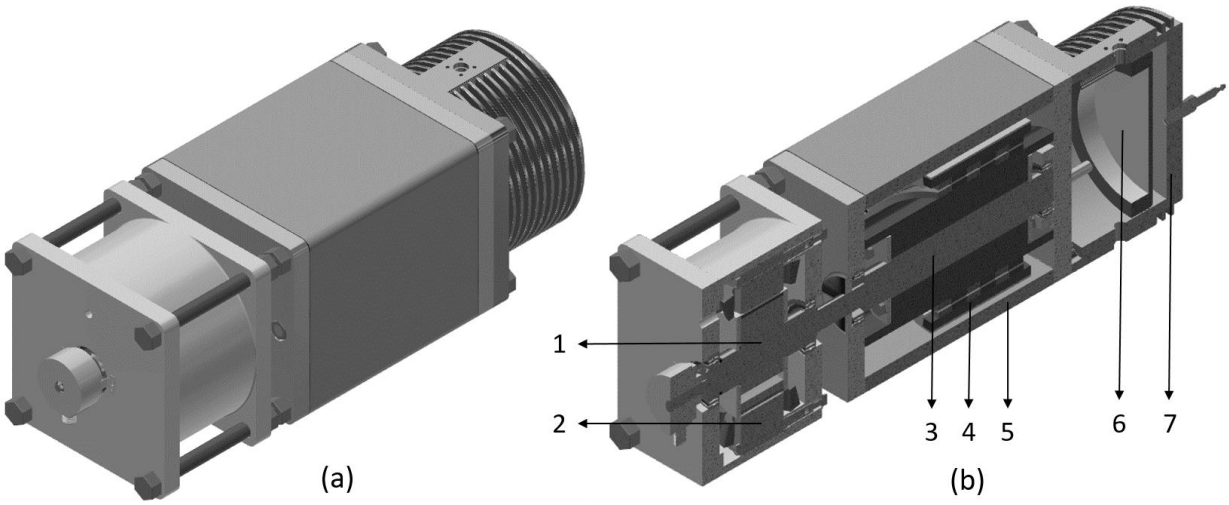
图 9

一种基于磁力曲轴的自由活塞发电装置（发明）

技术交底书

说明书摘要

本发明公开一种基于磁力曲轴的自由活塞发电装置，装置包括发电机、磁力曲轴和发动机，传动过程中磁力曲轴可以通过磁力耦合产生的柔性连接将单一方向的旋转运动和往复运动进行相互转化，电机可以通过拖动磁力曲轴转子来压缩发动机定子燃烧室气体，发动机可以通过推动磁力曲轴动子使发电机产生电能，实现了自由活塞发动机和发电机的之间能量转化和利用，凭借磁力曲轴转子能单一方向旋转储能的特性提高了自由活塞发动机的发电效率。



权利要求书

1．一种基于磁力曲轴的自由活塞发电装置，包括发电机转子（1）、发电机定子（2）、磁力曲轴转子（3）、磁力曲轴动子（4）、磁力曲轴定子（5）、发动机动子（6）和发动机定子（7），其特征在于：所述磁力曲轴可以实现自由活塞发动机和发电机的之间的磁耦合式柔性接触来完成能量转化和利用，且以转子能单一方向旋转储能的特性来提高自由活塞发动机的发电效率；

所述发电机转子（1）包括发电机转子主轴（11）、发电机转子铁芯（12）、发电机转子磁阵（13）、发电机转子端盖（14）、发电机转子硅钢片固定销（15）和发电机转子高速角轴承（16）；

所述发电机定子（2）包括发电机定子铁芯（21）、发电机定子绕组（22）、发电机定子硅钢片固定销（23）、发电机定子机壳（24）、发电机定子端盖（25）、发电机定子螺杆（26）和发电机定子旋转编码器（27）；

所述磁力曲轴转子（3）包括磁力曲轴转子主轴（31）、磁力曲轴转子铁芯（32）、磁力曲轴转子磁阵（33）、磁力曲轴转子端盖（34）和磁力曲轴转子高速角轴承（35）；

所述磁力曲轴动子（4）包括磁力曲轴动子铁芯（41）、磁力曲轴动子磁阵（42）、磁力曲轴动子支架（43）、磁力曲轴动子直线轴承（44）和磁力曲轴动子直线导轨轴（45）；

所述磁力曲轴定子（5）包括磁力曲轴定子机壳（51）、磁力曲轴定子端盖（52）、磁力曲轴定子端盖（53）和磁力曲轴定子密封盖（54）；

所述发动机动子（6）包括发动机动子连杆（61）、发动机动子活塞（62）、发动机动子活塞环（63）；

所述发动机定子（7）包括；发动机定子缸体（71）、进气口（72） 、内壁进气通道（73） 、排气口（74）和发动机定子火花塞（75）。

2．根据权利要求 1 所述的一种基于磁力曲轴的自由活塞发电装置，其特征在于： 发电机转子（1）和磁力曲轴转子（3）可以看成为一个整体，磁力曲轴动子（4）和发动机动子（6）可以看成为一个整体，发电机定子（2）、磁力曲轴定子（5）和发动机定子（7）

可以看成为一个整体，转子旋转运动轴向和动子往复运动轴向同向。

3．根据权利要求 1 所述的一种基于磁力曲轴的自由活塞发电装置，其特征在于： 发电机为永磁同步旋转电机，其拓扑为 10 极 12 槽的分数槽结构，无齿槽扭矩。

4．根据权利要求 1 所述的一种基于磁力曲轴的自由活塞发电装置，其特征在于：磁力曲轴磁阵极对数为 3，磁极以 N、S 相邻的方式在轴向排列，其中磁力曲轴转子磁阵（33）每极磁阵由 4 个同极性螺旋单体磁体以正旋、反旋相邻的方式在径向首位相接排列，磁力曲轴动子磁阵（42）为弧形单体磁体。

5．根据权利要求 4 所述的磁力曲轴磁阵，其特征在于：传动过程中可以将单一方向的旋转运动转化为往复运动（反之亦然），是通过磁力耦合产生的柔性连接，动子结构关于转子圆周对称，不管是静态还是动态情况径向都无磁吸力，摩擦系数小，转子旋转一周同步于动子往复两次。

6．根据权利要求 1 所述的一种基于磁力曲轴的自由活塞发电装置，其特征在于：发动机为单缸双冲程发动机拓扑，动子往复一次完成一次做功，转子旋转一周发动机完成两次做功。

申请材料分析说明

1.基础信息

专利名称：一种自由活塞发电装置

状态：审查中

2.交底材料

本案交底材料是以正式的专利稿形式编制，但权利要求书不用提供。

交底材料内容相对较为充实，且提供了非常详细的测试数据。

背景技术所列技术问题明确。

本案附图直接采用三维模型图，可能存在专利审查方面的问题；对于机械结构类的附图，最好采用机械制图（线稿图）。附图标记较密，在作图时应当突出各图的表达重点。

3.权利要求书

本案属于机械类专利，机械类的专利权利要求应当写进出“元件”+“连接关系”。本案权利要求 1 所采取的表达形式，清楚展示了各个组成元件及其各自之间的连接关系，便于后续专利审查及维权。

4.说明书

背景技术部分，技术问题交代明确——如何在保证自由活塞发电装置紧凑性的同时，解决储能问题并且避免采用复杂的直线负载控制。

具体实施方式部分，除对机械结构做了说明表述外，还对工作过程进行了说明。

对附图做了重新绘制，将要讲解的内容分为多张附图进行说明，避免一幅图中出现过多附图标记；对于讲解工作过程的附图采用彩色图片，更加清楚明了。

有益效果部分，针对各条技术创新点所能带来的技术效果，分别进行了充分的展开说明。

申请稿

说明书摘要

本发明提供了一种自由活塞发电装置，包括发电机、发动机和磁力曲轴模块，磁力曲轴模块中设有：曲轴转子，与所述电机转子相连，随电机转子同步旋转，表面设有螺旋磁阵；曲轴动子，与所述活塞相连，随活塞同步移动，其上设有动子磁阵；所述螺旋磁阵与动子磁阵之间磁力配合，使曲轴转子的单向旋转与曲轴动子的往复平移相联动。本发明自由活塞发电装置，通过加入磁力曲轴模块，克服了传统自由活塞发动机动子不能储能的缺点，提高了发电功率和效率。

权利要求书

1.一种自由活塞发电装置，其特征在于：包括：

发电机（1），其内设有电机转子（13）；

发动机（3），为自由活塞式发动机，其内设有活塞（31）；

磁力曲轴模块（2），其内设有：

曲轴转子（21），与所述电机转子（13）相连，随电机转子（13）同步旋转，表面设有螺旋磁阵（22）；

曲轴动子（23），与所述活塞（31）相连，随活塞（31）同步移动，其上设有动子磁阵（27）；

所述螺旋磁阵（22）与动子磁阵（27）之间磁力配合，使曲轴转子（21）的单向旋转与曲轴动子（23）的往复平移相联动。

2.根据权利要求 1 所述的自由活塞发电装置，其特征在于：

所述螺旋磁阵（22）由多极磁极以 N 极 S 极相邻的方式沿轴向排布而成，每极磁体由 4 个同极性的单体磁体在圆周方向上首尾相接构成，各单体磁体为螺旋状结构，相邻两单体磁体螺旋方向相反；

所述动子磁阵（27）为长条状结构，由多极磁极以 N 极 S 极相邻的方式沿轴向排布而成，动子磁阵（27）设有两个，对称地分布于螺旋磁阵（22）两侧。

3.根据权利要求 2 所述的自由活塞发电装置，其特征在于：所述螺旋磁阵（22）和动子磁阵（27）为 6 极。

4.根据权利要求 2 所述的自由活塞发电装置，其特征在于：所述螺旋磁阵（22）内侧、所述动子磁阵（27）内侧分别设有铁芯，所述铁芯为 HM-S4 软磁复合材料，螺旋磁阵（22）和动子磁阵（27）为 N40SH 钕铁硼永磁体。

5.根据权利要求 1 所述的自由活塞发电装置，其特征在于：所述曲轴动子（23）包括动

子支架，动子支架为环形结构，环绕于曲轴转子（21）外侧；

动子支架两侧通过直线导轨轴（24）与磁力曲轴模块（2）外壳相连，直线导轨轴（24）与曲轴转子（21）轴向平行；

动子支架内侧设有所述动子磁阵（27），动子磁阵（27）与螺旋磁阵（22）位置相对。

6.根据权利要求 1 所述的自由活塞发电装置，其特征在于：曲轴转子（21）与电机转子（13）共轴。

7.根据权利要求 1 所述的自由活塞发电装置，其特征在于：发动机（3）缸体与磁力曲轴模块（2）外壳相连，缸体内活塞（31）一侧为燃烧室，另一侧为油气储藏室；油气储藏室一侧，活塞（31）通过若干连杆（5）与曲轴动子（23）相连；燃烧室一侧设有火花塞（32）；

缸体侧壁设有进气孔（33）和排气孔（36），两者对称地分布于缸体两侧，两者均设有单向阀；油气储藏室一侧的缸内端部开设有通气槽（35），并设有气道（34）连通进气孔（33）与通气槽（35）。

8.根据权利要求 7 所述的自由活塞发电装置，其特征在于：磁力曲轴模块（2）外壳内腔与发动机（3）缸体油气储藏室相连通，磁力曲轴模块（2）外壳相对外界气密。

9.根据权利要求 1 所述的自由活塞发电装置，其特征在于：曲轴动子（23）行程与活塞（31）行程相等。

10.根据权利要求 1 所述的自由活塞发电装置，其特征在于：所述曲轴转子（21）用于存储动能，以推动活塞（31）回归上止点，并在此期间维持电机转子（13）运转。

一种自由活塞发电装置

技术领域

本发明属于自由活塞式发电机技术领域，具体涉及一种自由活塞发电装置。

背景技术

自由活塞发电装置最早于 1940 年起源于美国，近二十年来由于稀土永磁体和电力电子技术的发展，不少研究团队都在该领域立志于研究更轻量化、更高效率的原型机。 目前该领域绝大多数的研究是基于直线电机的自由活塞发电装置，该类装置的优点为其相对简单的结构、较少的运动部件和相对可变的压缩比，因此结构上可以设计的更加紧凑并能够适应不同类型的燃料。但是缺点为因自身不具有可以储能的旋转结构，所以需要额外的直线复位系统，或者是采用双对峙结构从而需要复杂的直线负载控制系统。

因此，自由活塞发电装置当前主要研究挑战是：如何在保证自由活塞发电装置紧凑性的

同时，解决储能问题并且避免采用复杂的直线负载控制。

发明内容

针对现有技术中存在的不足，本发明提供了一种自由活塞发电装置，用以解决自由活塞式发电装置的储能问题。

本发明通过以下技术手段实现上述技术目的。

一种自由活塞发电装置，包括：

发电机，其内设有电机转子；

发动机，为自由活塞式发动机，其内设有活塞；

磁力曲轴模块，其内设有：

曲轴转子，与所述电机转子相连，随电机转子同步旋转，表面设有螺旋磁阵；

曲轴动子，与所述活塞相连，随活塞同步移动，其上设有动子磁阵；

所述螺旋磁阵与动子磁阵之间磁力配合，使曲轴转子的单向旋转与曲轴动子的往复平移相联动。

进一步地：

所述螺旋磁阵由多极磁极以 N 极 S 极相邻的方式沿轴向排布而成，每极磁体由 4 个同极性的单体磁体在圆周方向上首尾相接构成，各单体磁体为螺旋状结构，相邻两单体磁体螺旋方向相反；

所述动子磁阵为长条状结构，由多极磁极以 N 极 S 极相邻的方式沿轴向排布而成，动子磁阵设有两个，对称地分布于螺旋磁阵两侧。

进一步地，所述螺旋磁阵和动子磁阵为 6 极。

进一步地，所述螺旋磁阵内侧、所述动子磁阵内侧分别设有铁芯，所述铁芯为 HM-S4 软磁复合材料，螺旋磁阵和动子磁阵为 N40SH 钕铁硼永磁体。

进一步地，所述曲轴动子包括动子支架，动子支架为环形结构，环绕于曲轴转子外侧；

动子支架两侧通过直线导轨轴与磁力曲轴模块外壳相连，直线导轨轴与曲轴转子轴向平行；

动子支架内侧设有所述动子磁阵，动子磁阵与螺旋磁阵位置相对。

进一步地，曲轴转子与电机转子共轴。

进一步地，发动机缸体与磁力曲轴模块外壳相连，缸体内活塞一侧为燃烧室，另一侧为油气储藏室；油气储藏室一侧，活塞通过若干连杆与曲轴动子相连；燃烧室一侧设有火花塞；

缸体侧壁设有进气孔和排气孔，两者对称地分布于缸体两侧，两者均设有单向阀；油气

储藏室一侧的缸内端部开设有通气槽，并设有气道连通进气孔与通气槽。

进一步地，磁力曲轴模块外壳内腔与发动机缸体油气储藏室相连通，磁力曲轴模块外壳相对外界气密。

进一步地，曲轴动子行程与活塞行程相等。

进一步地，所述曲轴转子用于存储动能，以推动活塞回归上止点，并在此期间维持电机转子运转。

本发明的有益效果为：

（1）本发明提供了一种自由活塞发电装置，通过加入磁力曲轴模块，克服了传统自由活塞发动机动子不能储能的缺点，提高了发电功率和效率。

（2）本发明通过应用磁力曲轴的磁耦合接触特性，减少了摩擦损耗，降低了发电装置过载的风险，增强了发电装置的安全性。

（3）本发明通过结合磁力曲轴和自由活塞的拓扑特性，比较于传统机械曲轴机构，实现了旋转运动和往复运动同轴的分布，降低了结构复杂程度，减少了元件数量，增大了空间利用率。

附图说明

图 1 为本申请实施例发电装置的外部结构图；

图 2 为本申请实施例发电装置的剖视图；

图 3 为本申请实施例发电装置半剖状态发电机侧斜视立体图；

图 4 为本申请实施例发电装置半剖状态发动机侧斜视立体图；

图 5 为本申请实施例中运动部件的结构图；

图 6 为本申请实施例中螺旋磁阵的多视角投影图；

图 7 为本申请实施例中螺旋磁阵的关键尺寸标注图；

图 8 为本申请实施例发电装置的工作过程示意图。

附图标记：

1-发电机；	11-电机定子；	12-定子绕组；	13-电机转子；
14-旋转编码器；	2-磁力曲轴模块；	21-曲轴转子；	22-螺旋磁阵；
23-曲轴动子；	24-直线导轨轴；	25-直线轴承；	26-动子铁芯；
27-动子磁阵；	3-发动机；	31-活塞；	32-火活塞；
33-进气孔；	34-气道；	35-通气槽；	36-排气孔；
4-主轴；	41-轴承；	5-连杆。	

具体实施方式

下面详细描述本发明的实施例，所示实施例的示例在附图中示出，其中自始至终相通或类似的标号表示相同或类似的元件或具有相同或类似功能的元件。下面通过参考附图描述的实施例是示例性的，旨在用于解释本发明，而不能理解为对本发明的限制。

一、结构说明

如图 1 所示的发电装置，包括发电机 1、磁力曲轴模块 2、发动机 3 三部分，其中磁力曲轴模块 2 处于发电机 1 与发动机 3 之间，发动机 3 经由磁力曲轴模块 2 传动驱使发电机 1 运转发电。

参照图 2 至图 5 所示：

1.发电机

包括电机定子 11 和电机转子 13。其中电机定子 11 与发电机 1 外壳相固连。电机定子 11 包括一个环形结构的定子支架，定子支架内侧设有定子铁芯，定子铁芯槽内布置有集中式定子绕组 12。本实施例中，定子支架采用 304 不锈钢，通过螺栓固定在发电机 1 外壳上；定子铁芯采用 35A250 硅钢片，通过销固定在所述环形支架上；定子绕组 12 采用 92% IACS 1mm 线径漆包线，通过槽契和环氧树脂固定于定子铁芯上。

电机转子 13 处于电机定子 11 内侧，并能够相对电机定子 11 旋转。电机转子 13 设置在电机轴（主轴 4）上，电机轴两端通过轴承 41 与发电机 1 外壳相连。电机转子 13 包括转子铁芯和转子磁阵；其中转子铁芯采用 35A250 镂空硅钢片；转子磁阵为 10 极，采用 N40SH 钕铁硼永磁体。电机轴一端由发电机 1 外壳伸出，并在其上设置旋转编码器 14，用于监测电机转子 13 的角位置。

2.磁力曲轴模块

包括曲轴转子 21 和曲轴动子 23。其中曲轴转子 21 通过转轴（主轴 4）可旋转地连接在磁力曲轴模块 2 外壳内；本实施例中，所述转轴与电机轴为共轴设计，主轴 4 一部分穿入发电机 1 中作为电机轴、一部分穿入磁力曲轴模块 2 中作为曲轴转子 21 的转轴；除采用上述共轴设计外，根据布局需要等实际情况，也可以采用其他方式连接两轴。曲轴转子 21 表面设有圆筒状铁芯，圆筒状铁芯为 HM-S4 软磁复合材料；圆筒状铁芯表面设有螺旋磁阵 22，螺旋磁阵 22 采用 N40SH 钕铁硼永磁体。

曲轴转子 21 要求具有足够大的质量，用以储藏动能，在无外力作用下保证电机转子 13 能够平稳运行。

曲轴动子 23 通过直线导轨轴 24 可移动地连接在磁力曲轴模块 2 外壳内。其中直线导轨轴 24 共设有两根，相对主轴 4 平行，对称地布置于主轴 4 两侧，各自分别通过螺栓与磁力曲

轴模块 2 外壳相固连。曲轴动子 23 包括一个环形结构的动子支架，环绕于曲轴转子 21 外侧。所述动子支架外侧通过直线轴承 25 与直线导轨轴 24 活动连接，从而使得曲轴动子 23 能够沿轴向相对曲轴转子 21 往复平移。动子支架内侧设有动子磁阵 27，动子磁阵 27 通过动子铁芯 26 与动子支架相连。本实施例中，动子磁阵 27 采用 N40SH 钕铁硼永磁体，动子铁芯 26 采用 HM-S4 软磁复合材料，动子支架采用 6010 铝合金。

如图 6 和图 7 所示：螺旋磁阵 22 为 6 极，6 极 3 对磁极以 N 极 S 极相邻的方式沿（曲轴转子 21 的）轴向排布；每极磁体由 4 个同极性的单体磁体在圆周方向上首尾相接构成；各单体磁体均为螺旋状结构，且相邻的两单体磁体螺旋方向相反，其余参数相同。

相应的，动子磁阵 27 设有两个，对称地分布于螺旋磁阵 22 两侧。动子磁阵 27 为长条状结构，每个动子磁阵 27 同样为 6 极，以 N 极 S 极相邻的方式沿轴向排布，分别与螺旋磁阵 22 中各极位置一一相对。

螺旋磁阵 22 中单体磁阵的轴向跨度 PL 为极距，本实施例中所述极距对应三分之一总行程；螺旋跨度 SL 为总行程，也即曲轴动子 23 往复移动的最大行程。通过螺旋磁阵 22 与动子磁阵 27 两者之间的磁力作用，在曲轴转子 21 的单向旋转与曲轴动子 23 的往复平移之间形成联动配合。

3.发动机

本实施例中，发动机 3 为二冲程自由活塞式发动机，包括缸体和活动于缸体内的活塞 31，活塞 31 一侧为燃烧室，另一侧为油气储藏室。燃烧室一侧的缸体上设有火花塞 32。油气储藏室一侧的缸体与磁力曲轴模块 2 相连，且该侧活塞 31 端面连接有四根连杆 5，连杆 5 穿过发动机 1 缸体与磁力曲轴模块 2 外壳后连接至曲轴动子 23，使得曲轴动子 23 与活塞 31 之间同步平移。曲轴动子 23 的最大行程与活塞 31 的行程相等。

本实施例中，考虑到成本与可制造性方面的因素，选择将磁力曲轴模块 2 的外壳做气密处理，而在磁力曲轴模块与发动机 3 缸体之间不做密封隔绝，因而注入发动机 3 缸体的低温燃料（油气混合物）可经由连杆 5 所在的通道等孔隙进入磁力曲轴模块 2 内。

发动机 3 缸体侧壁上设有进气孔 33 和排气孔 36，两者对称地分布于缸体两侧，两者均设有单向阀。油气储藏室一侧的缸内端部开设有通气槽 35，并在缸体内壁上开设有一条气道 34，用以连通进气孔 33 与通气槽 35。

二、工作过程

启动过程：发电机 1 以电动状态运行，电机转子 13 拖动曲轴转子 21 至额定转速，与此同时，曲轴转子 21 也将经由曲轴动子 23 同步地拖动发动机 3 活塞 31 进行同频往复运动。达到额定转速后断开发电机 1 电源，启动发动机 3 实施发电。

参照图 8 所示，本实施例发电装置的发电运作过程分为如下阶段：

1）活塞 31 运动至上止点 TDC 位置时，火花塞 32 点火，燃烧室产生动能推动活塞 31 向下止点 BDC 运动；期间，活塞 31 依次经由曲轴动子 23、曲轴转子 21 带动电机转子 13 旋转，驱动发电机 1 对外发电；

2）活塞 31 由 TDC 运动至进气孔 33 及排气孔 36 位置时，一方面燃烧室内燃烧后的废气在压差作用下向外排出；另一方面，随着废气的排出以及活塞 31 的运动作用，储藏在油气储藏室内的油气混合物经由通气槽 35、气道 34、进气孔 33 被压入燃烧室；期间，活塞 31 继续驱动电机转子 13 运转发电；

3）活塞 31 达到下止点 BDC 位置后开始反向回移，此时依靠曲轴转子 21 储藏的动能，一方面继续拖动电机转子 13 运转，另一方面带动活塞 31 向上止点 TDC 回移；期间，油气储藏室空间扩大，压力减小，新的油气混合在压差驱动下，由外界经进气孔 33、气道 34 注入油气储藏室；

4）活塞 31 运动至上止点 TDC 位置后，燃烧室内油气混合物重新被压缩完毕，待火花塞 32 点火，进入下一个循环过程。

在本发明的描述中，需要理解的是，术语“上”、“下”、“前”、“后”、“左”、“右”、“竖直”、“水平”、“顶”、“底”、“内”、“外”等指示的方位或位置关系为基于附图所示的方位或位置关系，仅是为了便于描述本发明和简化描述，而不是指示或暗示所指的装置或元件必须具有特定的方位、以特定的方位构造和操作，因此不能理解为对本发明的限制。

本发明并不限于上述实施方式，在不背离本发明的实质内容的情况下，本领域技术人员能够做出的任何显而易见的改进、替换或变形均属于本发明的保护范围。

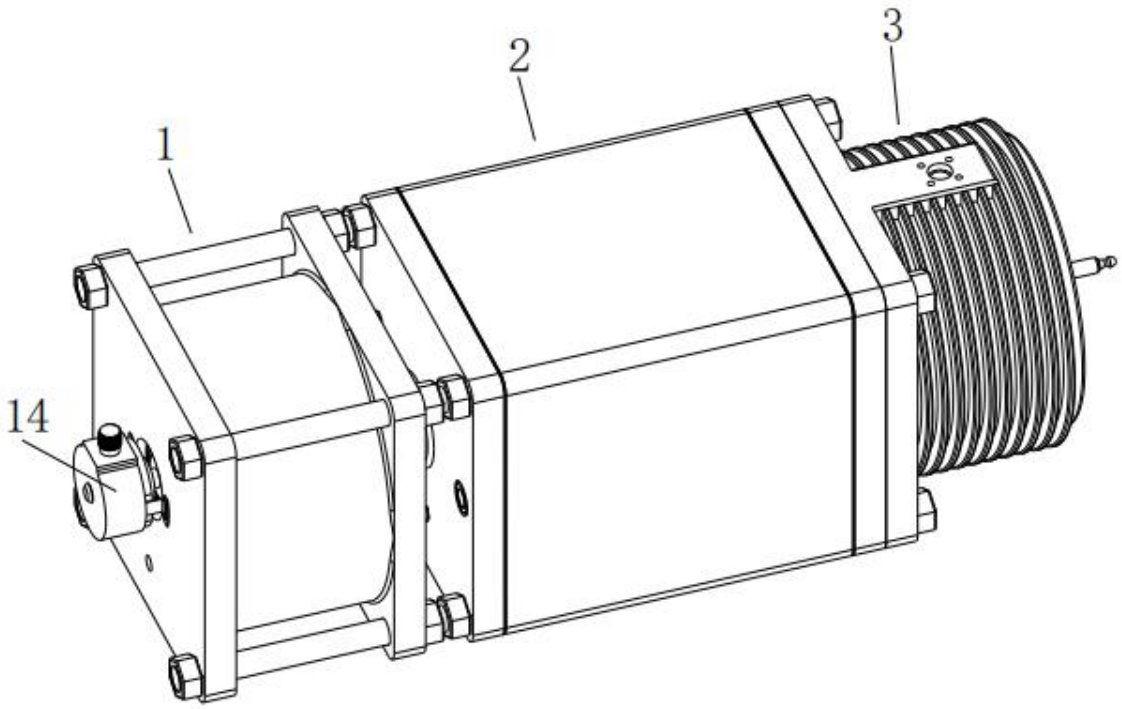


图 1

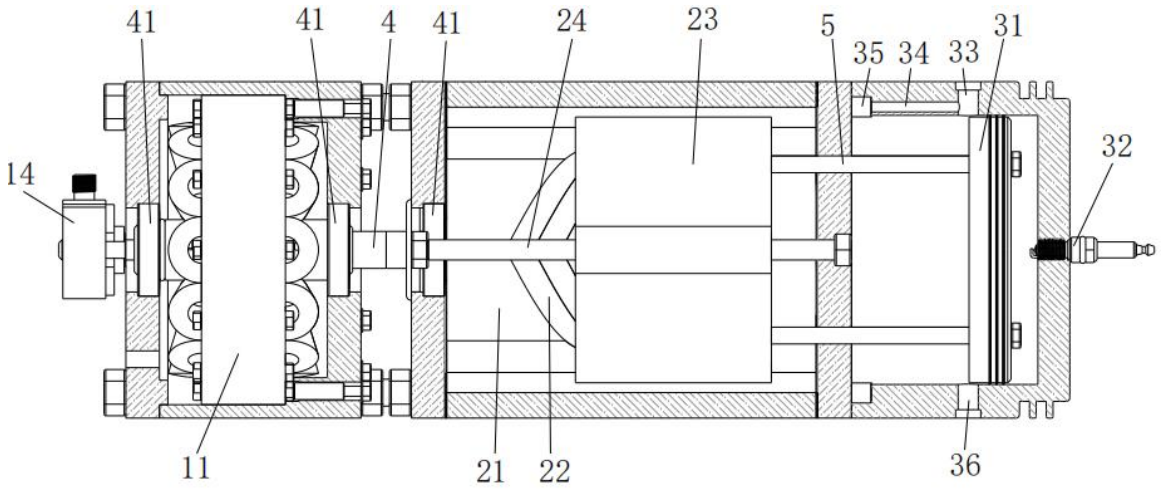


图 2

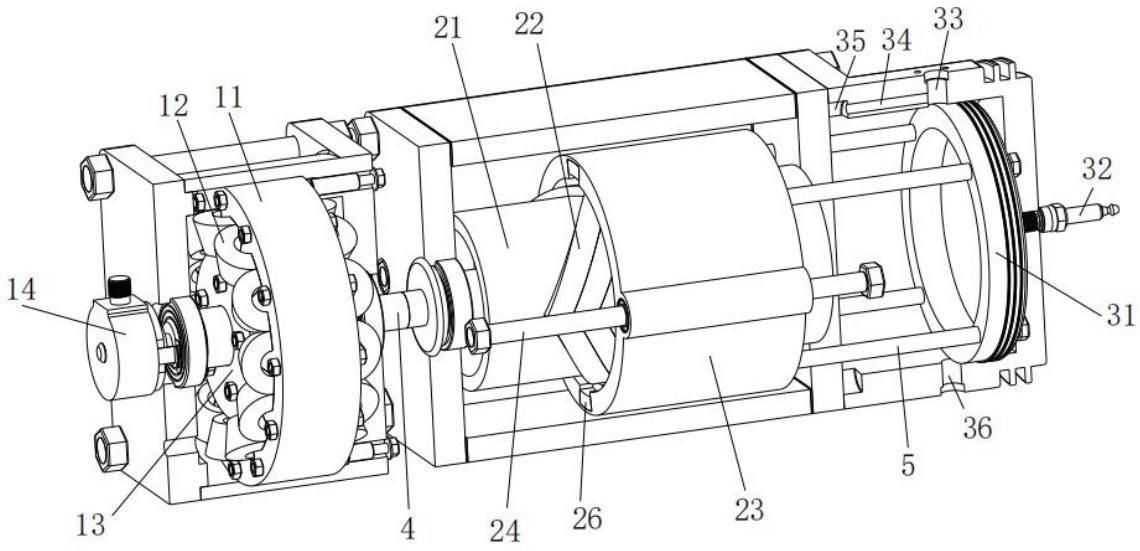

21
22
35
34
33
12
11
32
14
31
36
5
13
4
24
26
23

图 3

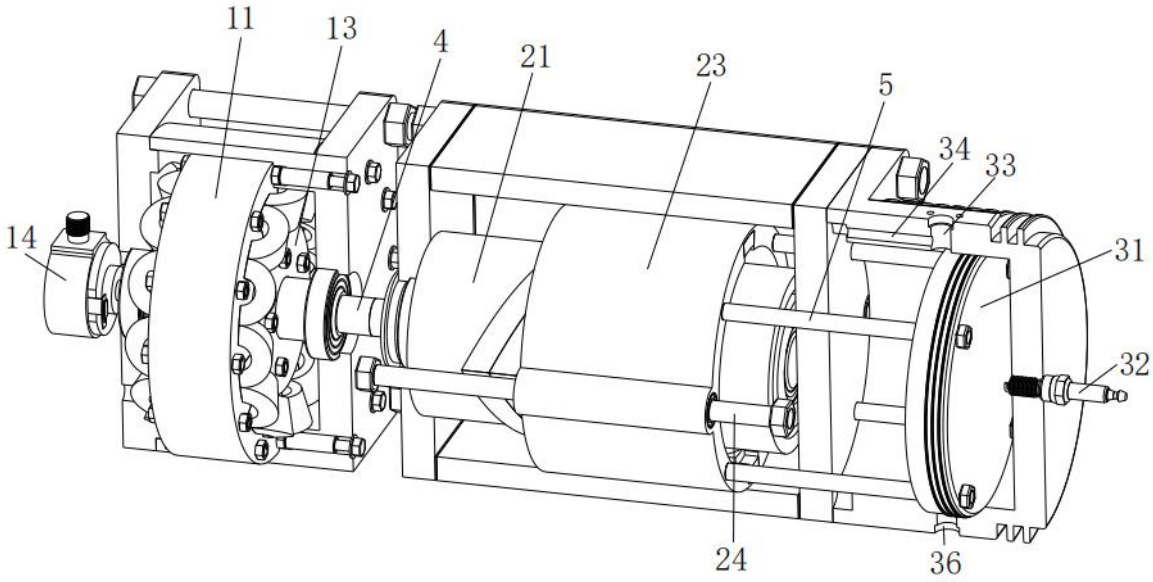

11
13
4
21
23
5
34
33
14
31
32
24
36

图 4

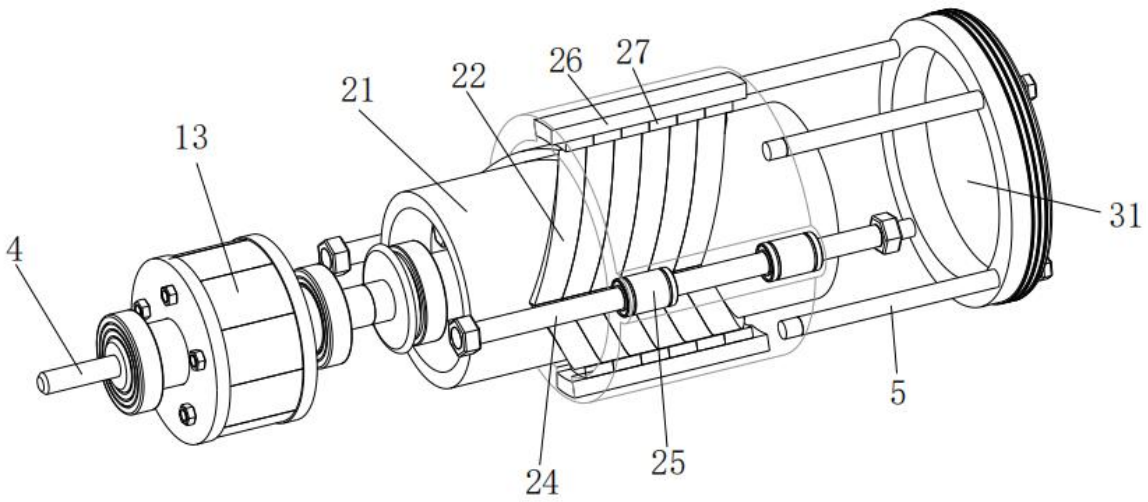


图 5

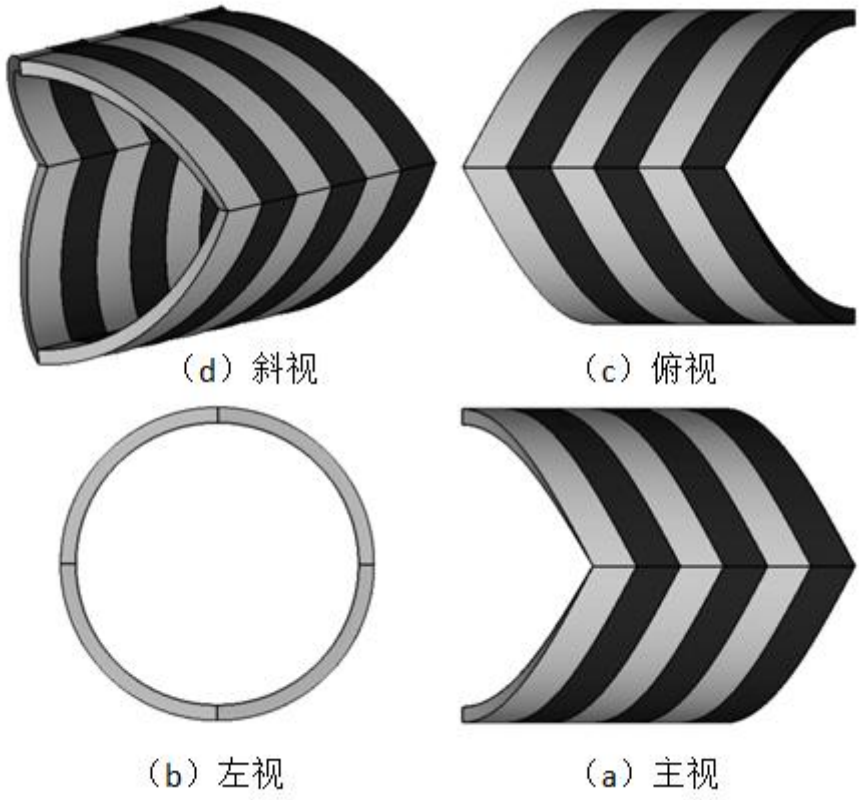


图 6

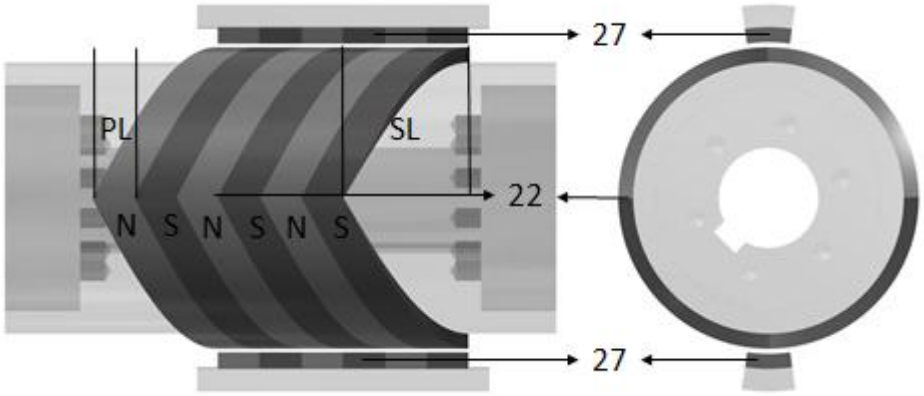


图 7

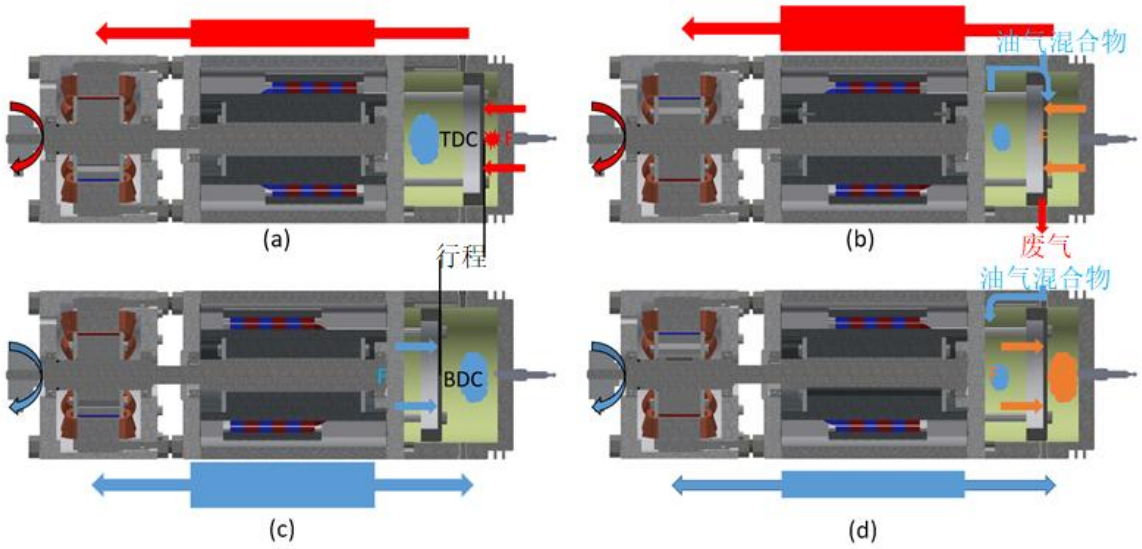


图 8

一种双向切削刨床（实用新型）

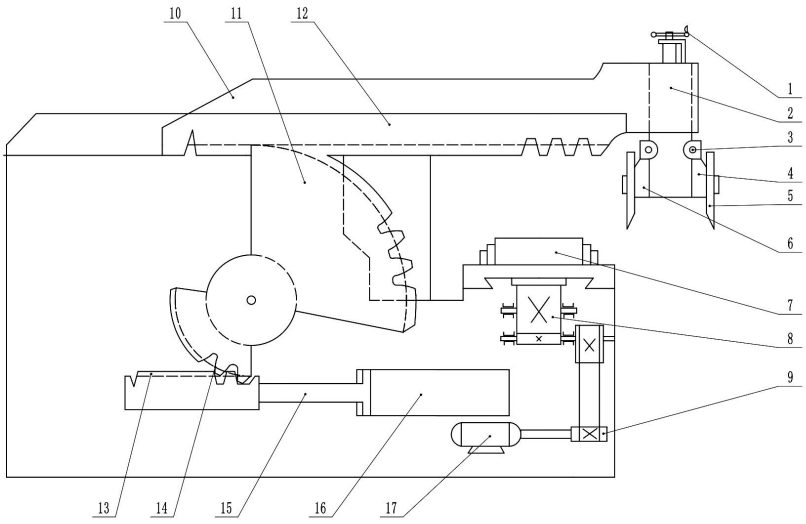
技术交底书

一种双向切削刨床

摘要

本实用新型属于机械加工设备领域，尤其是一种双向切削刨床。针对传统牛头刨床因返程有空行程而出现的加工效率低、往复切削速度不同而出现的切削力不均恒等缺陷，本实用新型采用电磁系统控制两把刨刀、液压传动系统控制刀具进给，实现刨刀双向匀速恒力刨削加工，提高刨削加工效率及质量。

摘要附图



权利要求书

1. 一种双向切削刨床，包括刨床本体、刀架装置、运动装置等。

所述的运动装置，包含有滑枕（10）、齿轮一（11）、齿条一（12）、齿条二（13）、齿轮二（14）、液压杆（15）、液压缸（16）、三位四通电磁换向阀（18）、溢流阀（19），其特征在于：所述的滑枕（10)下表面固定安装有齿条一（12），与齿轮一（11）互相啮合，液压杆（15）上固定安装有齿条二（13），与齿轮二（14）互相啮合，齿轮一（11）和齿轮二（14）拼装固定在一起，底座上安装固定有电机（17）。

所述的刀架装置，包含有主刀架（2）、铰链（3）、刀架一（4）、刀架二（6）、永磁铁二（21）、永磁铁一（22）、电磁铁（23）、弹簧（24），其特征在于：所述的刀架一（4）和刀架二（6）通过铰链与主刀架（2）连接固定，刀架一（4）和刀架二（6）的内侧分别设置有弹簧（24）与主刀架（2）两侧连接，永磁铁一（22）与永磁铁二（21）各被设置在刀架一（4）与刀架二（6）内部，主刀架（2）底部内部设置有电磁铁（23）。

2. 根据权利要求 1 所述的一种双向切削刨床的运动装置，其特征在于：齿轮一（11）和齿轮二（14）为半径不同的部分齿轮，齿轮一（11）和齿轮二（14）拼接固定在一起构成的一个传动构件，分别与滑枕（10）和液压杆（15）上固定安装的齿条一（12）、齿条二（13）啮合，齿轮一(11)的半径大于齿轮二（14）的半径，双向切削刨床的传动装置总传动比>1，保证在液压缸的有效行程内实现较大刨削行程。

3. 根据权利要求 1 所述的双向切削刨床的刀架装置，其特征在于：所述的刀架一（4）和刀架二（6）内部的永磁铁根据磁铁磁极，磁极相对放置在各刀架内部，永磁铁一（22）为左 S 极右 N 极，永磁铁二（21）为右 S 极左 N 极。

4.利用权力要求 1 所述的一种双向切削刨床加工时，其特征在于：将需要加工的工件（7）放置在工作台上固定，根据工件（7）的高度旋转手轮（1）调节刨刀的高度，给电磁铁（23）上电，产生磁场吸合刀架一（4）使刨刀落下工作，刀架二（6）与磁场相斥由弹簧弹起，电磁阀 DT2 线圈得电通过运动装置使滑枕向前运动，刀架一（4）刨刀进程切削完毕，控制系统使电磁阀 DT2 线圈失电致刨床停止刨削运动，原位保持，然后改变电磁铁（23）的电源电流方向产生相反的磁场吸合刀架二（6）刨刀，弹簧（24）弹起刀架一（4），启动电机（17）移动工作台等待回程加工，随即给电磁阀 DT1 得电，刨刀进行回程切削，回程切削完毕电磁阀 DT1 线圈失电，刨刀停止切削原位保持，电磁铁（23）再次改变磁场方向吸合刀架一（4）弹起刀架二（6），启动电机 17 移动工作台等待进程切削加工，如此往复，实现双向刨削加工。

说明书

技术领域

本实用新型涉及一种双向切削刨床结构，属于机械加工设备领域。

背景技术

在实际生产中，刨削加工所占比重逐渐减少。主要因为传统的牛头刨床都是只能做单方向刨削，滑枕在一个往复运动中只有一个方向是刨削行程，另一个方向为回程，即空行程，不做功，所以工作效率低。虽然靠传动的急回特性可以缩短空行程的时间，但是未能从根本上解决加工效率低、空耗大的问题。

传统牛头刨床主传动机构采用曲柄摇杆机构，其运动特性无法实现滑枕往复等速运动，导致刨削行程中的切削力不恒定，加工精度较低。

正是因为有空行程和切削力不均匀，导致牛头刨床在实际生产中的应用受到很大限制。

实用新型内容

传统的牛头刨床其回程为空行程，刨削速度不等和切削力不恒定，刨削效率低，加工精度不高。

针对以上问题，本实用新型目的是对刨刀架和进给系统进行改进设计后可以实现刨床的双向、匀速、恒力的刨削加工，提高生产效率和加工精度，降低能耗，并且机构简单容易制造。

不管是曲柄滑块机构，或是其他的四杆机构演化型式，都无法把电机的旋转运动转化为的平稳匀速地往复直线运动。综合对比分析得出液压系统是较好的选择。不仅可以实现匀速、稳定的直线往复运动，而且经济、结构简单。所以本实用新型采用液压传动，平稳换向，为加工提供了稳定、匀速的切削环境；在使用现有刀具技术、刀具不做较大改进的情况下，改变刀架结构，在主刀架的两侧各装一把刨刀，双刀交替工作，实现双向刨削加工。

为实现上述目的，本实用新型提供如下技术方案：

一种双向切削刨床，包括刨床本体、刀架装置、运动装置等。

所述的运动装置，包含有滑枕、齿轮一、齿条一、齿条二、齿轮二、液压杆、液压缸、三位四通电磁换向阀、溢流阀，所述的滑枕下表面固定安装有齿条一与齿轮一互相啮合，液压杆上固定安装有齿条二与齿轮二互相啮合，齿轮一和齿轮二拼装固定在一起，底座上安装固定有电机。

所述的刀架装置，包含有主刀架、铰链、刀架一、刀架二、永磁铁二、永磁铁一、电磁铁、弹簧，所述的刀架一和刀架二通过铰链与主刀架连接固定，刀架一和刀架二的内侧分别

设置有弹簧与主刀架两侧连接，永磁铁一与永磁铁二各被设置在刀架一与刀架二内部，主刀架底部内部设置有电磁铁。

本实用新型相对于现有技术具备以下有益效果：

本实用新型双向切削刨床结构简单，便于操作；采用液压传动系统控制刀具进给，使得刨削加工时刨削速度和切削力恒等不变，提高了加工精度；对刨刀架进行改进设计，电磁系统控制两把刨刀实现刨床双向切削，提高刨床的加工效率；可根据工件待加工面大小设置控制系统调整行程范围，从而避免部分切削空程，进一步提高加工效率。

附图说明

图 1 为本实用新型刨床的结构示意图；

图 2 为本实用新型液压控制系统液压回路图；

图 3 为本实用新型刀架结构放大图；

图 4 为本实用新型刨床工作流程图；

附图标记说明如下：1、手轮；2、主刀架；3 铰链；4、刀架一；5、刨刀；6、刀架二；7、工件；8、齿轮三；9、三角带轮；10、滑枕；11、齿轮一；12、齿条一；13、齿条二；14、齿轮二；15、液压杆；16 液压缸；17、电机；18、三位四通电磁换向阀；19、溢流阀；20、液压泵；21、永磁铁二；22、永磁铁一；23、电磁铁；24、弹簧。

具体实施方案

为了使本实用新型的目的、技术方案及优点更加清楚明白，以下结合附图及实施例，对本实用新型进行进一步详细说明。此处所描述的具体实施例仅仅用以解释本实用新型，并不用于限定本实用新型。

参照图 1，本实施例中，一种双向切削刨床，包括液压缸 16 和液压杆 15，采用液压传动实现匀速稳定的直线往复运动，平稳换向，为加工提供了稳定、匀速的切削环境，齿条二 13 固定安装在液压杆 15 上与齿轮二 14 啮合传动，齿轮二 14 与齿轮一 11 为两个半径不同的部分齿轮拼接组合而成作为传动装置中的特殊传动构件，齿轮 11 的半径大于齿轮二 14 的半径，传动比>1，延长刨削行程，齿条一 12 固定安装在滑枕 10 上与齿轮一 11 啮合，带动滑枕往复移动，刀架一 4 和刀架二 6 通过铰链 3 与主刀架连接固定，双刀交替工作，双向切削，主刀架 2 上安装有手轮 1 来调节刨刀与工件 7 的相对高度，电机 17 上固定安装有带轮 9，通过带传动与齿轮传动使工作台的移动，小带轮带动大带轮、小齿轮带动大齿轮的，传动比>1 使工作台较小位移。

参照图 2，一种双向切削刨床运动装置的液压控制系统中包括三位四通电磁换向阀 18、溢流阀 19 和液压泵 20，所述的电磁换向阀 18 左位工作时液压杆缩回，即刨床回程刨削运动，

中位工作时原位保持，右位工作时液压杆伸出，刨床进程刨削运动，控制系统根据工件需加工面大小，控制电磁阀线圈的得失电，改变切削行程范围，进一步提高效率。

参照图 3，一种双向切削刨床刀架装置中刀架二内部设置有永磁铁二 21，刀架一设置有永磁铁一 22，两个永磁铁根据磁铁磁极，磁极相对放置在内部，永磁铁一 22 为左 S 极右 N 极，相反的，永磁铁二 21 为右 S 极左 N 极，刀架一和刀架二的内侧分别设置有弹簧 24 与主刀架两侧连接，在电磁铁 23 失电不工作时使两刀架自由弹起，主刀架底部内部设置有电磁铁 23，可以改变电磁铁的电源正负极产生不同方向的电流，产生不同的磁场分别吸合一个永磁铁，使刀架落下，实现双刀交替工作。

参照图 4，通过流程图展现出双向切削刨床的工作流程。

本实施例的具体实施过程如下：在使用时，将需要加工的工件 7 放置在工作台上固定，根据工件 7 的高度旋转手轮 1 调节刨刀的高度改变切削量，设滑枕已复位且初始位置为后限位，给电磁铁 23 上电，电磁铁 23 得电产生磁场与刀架一 4 内部设置的永磁铁互相吸引，刀架二 6 内部永磁铁与磁场相斥被弹簧弹起，刀架一 4 吸合落下等待工作后即可接通电磁阀 DT2 线圈，三位四通电磁换向阀 18 右位工作，液压缸进油伸出液压杆 15，液压杆 15 伸出带动齿条二 13 移动，齿轮二 14 与齿条二 13 啮合，顺时针旋转，齿轮二 14 旋转带动齿轮一 11 旋转，齿轮一 11 与齿条一 12 啮合传动使滑枕 10 向前移动，滑枕 10 移动带动刀架一 4 的刨刀 5 进行切削加工，刨刀 5 切削工件 7，直至进程的切削加工已经完成且刀架二已越过工件，控制系统给电磁阀 DT2 线圈断电，换向阀 18 此时中位工作，刨刀原位停止并保持，然后改变电磁铁 23 的电源电流方向产生相反的磁场，刚刚工作的刀架一 4 的永磁铁与该磁场相斥借势被弹簧弹起，刀架二 6 被吸合落下等待下一步回程切削加工，启动电机 17 使工作台移动后，给电磁阀 DT1 线圈得电进行回程切削加工，电磁阀 DT1 线圈得电使液压杆 15 缩回带动齿条二 13 移动，齿轮二 14 与齿轮一 11 逆时针旋转带动齿条一 12 与滑枕 10 向后移动，刀架二 6 上的刨刀回程切削加工直至刀架一 4 刨刀越过工件，再次改变电磁铁 23 电源电流方向吸合刀架一 4 抬起刀架二 6，此时刨床已经完成了整个行程的切削加工并且回到了初始位置，如需继续加工则需启动电机 17 使工作台移动，重复以上操作即可，实现双向切削

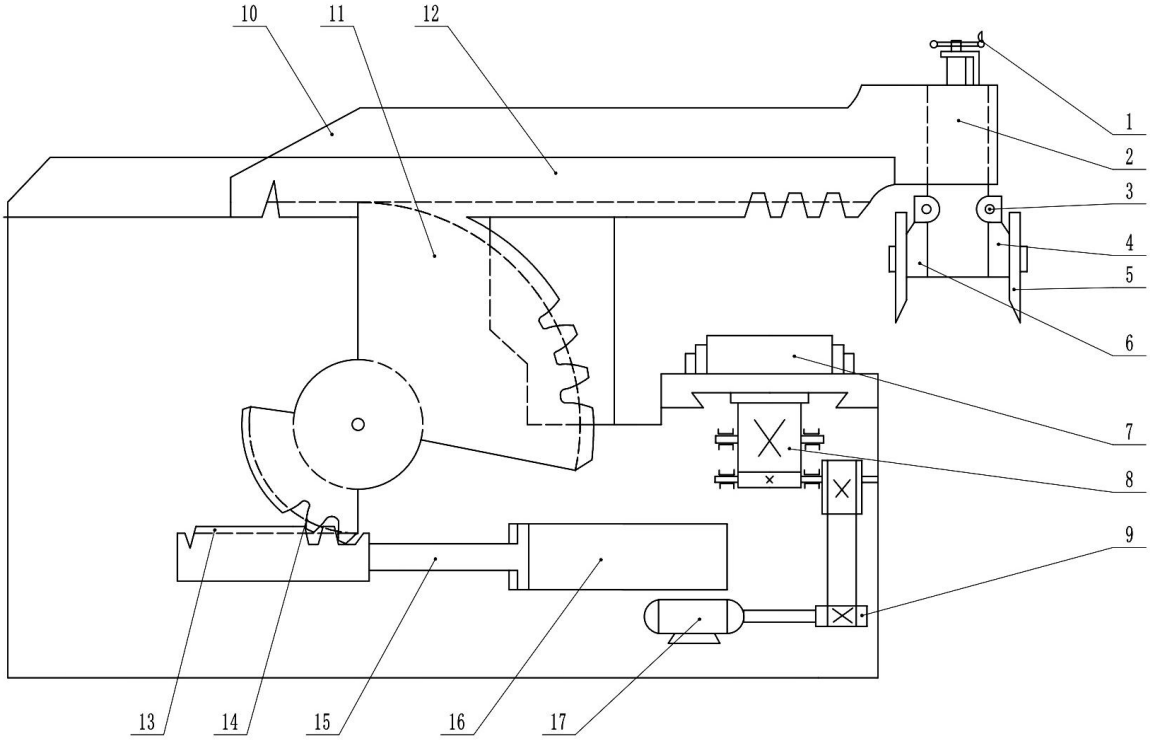


图 1

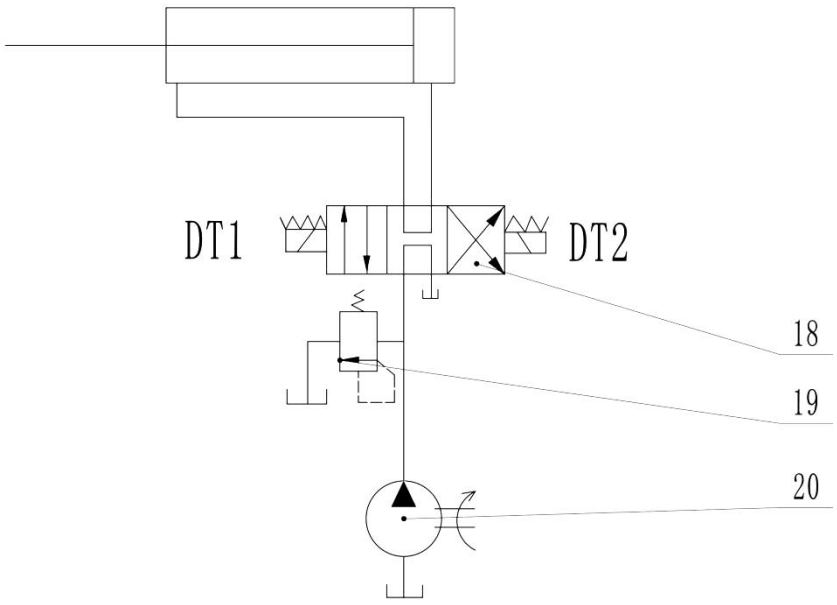


图 2

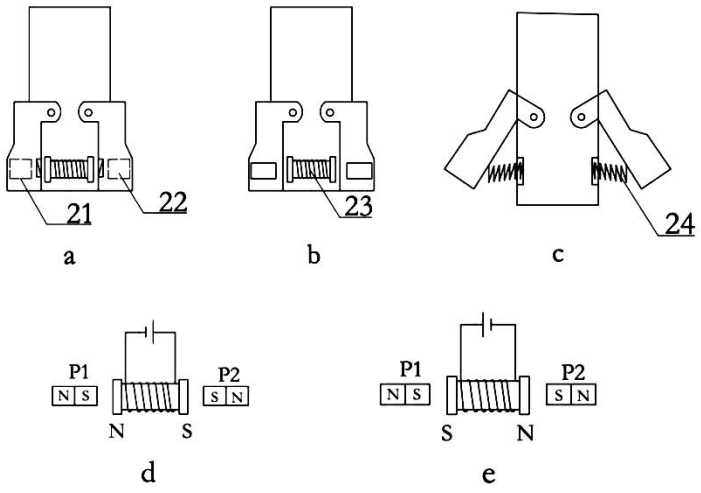

21
22
23
24
a
b
c
P1
N S
P2
S N
N
S
d
P1
N S
P2
S N
S
N
e

图 3

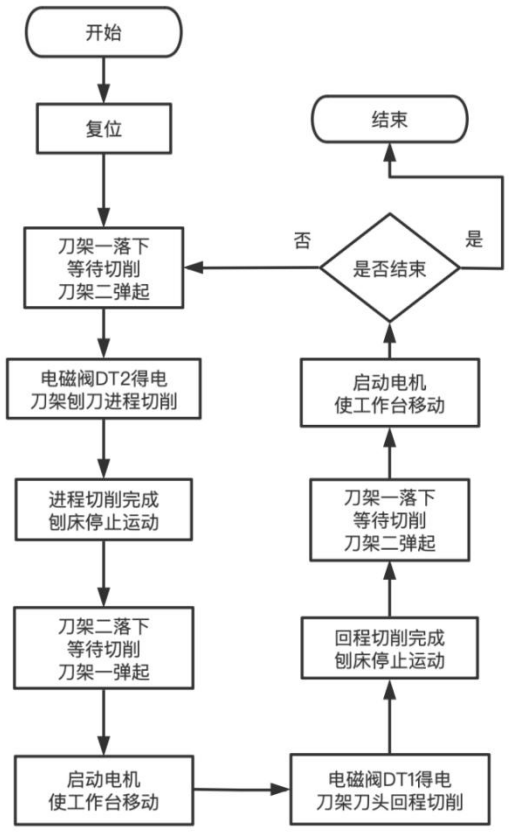

开始
复位
刀架一落下
等待切削
刀架二弹起
电磁阀DT2得电
刀架刨刀进程切削
进程切削完成
刨床停止运动
刀架二落下
等待切削
刀架一弹起
启动电机
使工作台移动
电磁阀DT1得电
刀架刀头回程切削
回程切削完成
刨床停止运动
刀架一落下
等待切削
刀架二弹起
启动电机
使工作台移动
是否结束
否
是
结束

图 4

申请材料分析说明

1.基础信息

专利名称：一种双向切削刨床

状态：授权

2.交底材料

交底材料内容相对较为充实，但是不用提供权利要求书。

背景技术以仿照论文的形式进行了引用出处标记，但在专利中不需要给出，当然给出了也可以。

虽然实用新型对于技术创新的要求相对较低，但是也需要明确好技术问题是什么，本案中明确给出了传统牛头刨床刨削行程中切削力不恒定。

技术方案的表述相对较为完整，因为是机械结构类的实用新型，一般附图给的较为完整，则技术方案大体上都能清楚了解。

3.权利要求书

权利要求撰写清楚，避免出现非必要技术特征。

4.说明书

背景技术部分，原交底材料提供较好，因而直接采用。

结合各附图，逐步讲解清楚产品的构造、形状及其工作原理。

有益效果部分，针对各条技术创新点所能带来的技术效果，分别进行了充分的展开说明。

申请稿

说明书摘要

本实用新型提供了一种双向切削刨床，包括滑枕和工作台，滑枕上设有刀座，刀座处于工作台上方，刀座下端两侧设有刀架，刀架上安装有刨刀；刀架能够携刨刀向上翻起，刀架与刀座之间设有弹性机构和电控磁吸机构，其中弹性机构驱使刀架翻起，电控磁吸机构用于将刀架吸合在刀座上。本实用新型双向切削刨床，通过在刀座下端两侧对称地设置两个可翻折的刀架，并利用弹簧和电磁铁控制刀架吸合或弹起，从而在使用过程中配合滑枕地往复运动，控制两侧刨刀轮流工作刨削工件，实现刨床双向切削功能。

权利要求书

1.一种双向切削刨床，其特征在于：包括滑枕（10）和工作台（8），滑枕（10）上设有刀座（2），刀座（2）处于工作台（8）上方，刀座（2）下端两侧设有刀架，刀架上安装有刨刀（5）；刀架能够携刨刀（5）向上翻起，刀架与刀座（2）之间设有弹性机构和电控磁吸机构，其中弹性机构驱使刀架翻起，电控磁吸机构用于将刀架吸合在刀座（2）上。

2.根据权利要求 1 所述的双向切削刨床，其特征在于：所述电控磁吸机构包括电磁铁（21）和永磁铁（22），两侧刀架内分别设有永磁铁（22），且两侧的永磁铁（22）磁极方向相反，刀座（2）内设有电磁铁（21），电磁铁（21）与两侧永磁铁（22）位置相对。

3.根据权利要求 1 所述的双向切削刨床，其特征在于：所述滑枕（10）由液压驱动。

4.根据权利要求 3 所述的双向切削刨床，其特征在于：液压机构（16）设置在滑枕（10）下方，两者之间通过齿轮齿条机构传动。

5.根据权利要求 4 所述的双向切削刨床，其特征在于：所述滑枕（10）上连接有滑枕齿条（12），液压机构（16）与液压齿条（13）相连，滑枕齿条（12）与液压齿条（13）之间通过一个或多个齿轮传动。

6.根据权利要求 5 所述的双向切削刨床，其特征在于：所述滑枕齿条（12）与液压齿条（13）之间设有一个双侧扇形齿轮，所述双侧扇形齿轮包括两个半径不等的扇形齿轮，两扇形齿轮对向设置在同一圆轴上，其中半径较大的扇形齿轮与滑枕齿条（12）啮合、半径较小的扇形齿轮与液压齿条（13）啮合。

7.根据权利要求 1 所述的双向切削刨床，其特征在于：所述刀座（2）高度可调谐，所述工作台（8）水平位置可调谐。

8.根据权利要求 7 所述的双向切削刨床，其特征在于：所述工作台（8）由电机驱动。

技术领域

本实用新型属于机加工设备技术领域，具体涉及一种双向切削刨床。

背景技术

传统的牛头刨床只能做单向刨削，其中滑枕在一个往复运动中只有一个方向是刨削行程，而另一个方向是回程，属于空行程不做功，所以传统的刨床工作效率较低。虽然通过某些传统机构的急回特性可以缩短空行程的时长，但是这还是未能从根本上解决牛头刨床单向刨削加工效率低、空耗大的问题。

另一方面，传统的牛头刨床主传统机构采用的是曲柄摇杆机构，其运动特性无法实现滑枕匀速往复运动，从而导致刨削行程中的切削力不恒定，影响加工精度。综上空行程和切削力不均衡问题，导致传统的牛头刨床在当下实际生产中的应用受到了很大的限制。

实用新型内容

针对现有技术中存在的不足，本实用新型提供了一种双向切削刨床，用以解决传统牛头刨床无法双向切削问题以及切削力不均衡问题。

本实用新型通过以下技术手段实现上述技术目的。

一种双向切削刨床，包括滑枕和工作台，滑枕上设有刀座，刀座处于工作台上方，刀座下端两侧设有刀架，刀架上安装有刨刀；刀架能够携刨刀向上翻起，刀架与刀座之间设有弹性机构和电控磁吸机构，其中弹性机构驱使刀架翻起，电控磁吸机构用于将刀架吸合在刀座上。

进一步地，所述电控磁吸机构包括电磁铁和永磁铁，两侧刀架内分别设有永磁铁，且两侧的永磁铁磁极方向相反，刀座内设有电磁铁，电磁铁与两侧永磁铁位置相对。

进一步地，所述滑枕由液压驱动。

进一步地，液压机构设置在滑枕下方，两者之间通过齿轮齿条机构传动。

进一步地，所述滑枕上连接有滑枕齿条，液压机构与液压齿条相连，滑枕齿条与液压齿条之间通过一个或多个齿轮传动。

进一步地，所述滑枕齿条与液压齿条之间设有一个双侧扇形齿轮，所述双侧扇形齿轮包括两个半径不等的扇形齿轮，两扇形齿轮对向设置在同一圆轴上，其中半径较大的扇形齿轮与滑枕齿条啮合、半径较小的扇形齿轮与液压齿条啮合。

进一步地，所述刀座高度可调谐，所述工作台水平位置可调谐。

进一步地，所述工作台由电机驱动。

本实用新型的有益效果为：

（1）本实用新型提供了一种双向切削刨床，其中通过在刀座下端两侧对称地设置两个可翻折的刀架，并利用弹簧和电磁铁控制刀架吸合或弹起，从而在使用过程中配合滑枕地往复运动，控制两侧刨刀轮流工作刨削工件，实现刨床双向切削功能。

（2）本实用新型刨床中滑枕由液压驱动往复动作，在滑枕与液压机构之间由齿轮齿条机构实现传动，相比于传动的曲柄摇杆机构，能够保证滑枕在移动的全程都保持力度平稳恒定。

（3）本实用新型中在分别连接滑枕与液压机构的两个齿条之间，通过设置一个特制的双侧扇形齿轮实现传统，相比单一的圆柱齿轮，能够改变传动比，保证滑枕有充足的滑移行程；而相比于由多个齿轮组成的复杂齿轮组，结构相对更简单，所占用的空间也相对较少。

附图说明

图 1 为本实用新型双向切削刨床结构图；

图 2 为本实用新型中刀座结构图；

图 3 为本实用新型中刀座展开状态图。

附图标记：

1-手轮；	2-刀座；	3-铰链；	4-一号刀架；
5-刨刀；	6-二号刀架；	7-工件；	8-工作台；
9-传动机构；	10-滑枕；	11-一号扇形齿轮；	12-滑枕齿条；
13-液压齿条；	14-二号扇形齿轮；	15-液压杆；	16-液压机构；
17-电机；	21-电磁铁；	22-永磁铁；	23-弹簧。

具体实施方式

下面详细描述本实用新型的实施例，所示实施例的示例在附图中示出，其中自始至终相通或类似的标号表示相同或类似的元件或具有相同或类似功能的元件。下面通过参考附图描述的实施例是示例性的，旨在用于解释本实用新型，而不能理解为对本实用新型的限制。

如图 1 所示的双向切削刨床，其中滑枕 10 由液压驱动往复运作。滑枕 10 设置在刨床顶部，液压机构 16 设置在滑枕 10 下方，两者之间通过齿轮齿条机构传统。具体地：滑枕 10 上连接有滑枕齿条 12，液压机构 16 的液压杆 15 与液压齿条 13 相连，滑枕齿条 12 与液压齿条 13 之间通过一个特制的双侧扇形齿轮相连。所述双侧扇形齿轮包括两个半径不等的扇形齿轮，两扇形齿轮对向设置在同一圆轴上，其中半径较大的一号扇形齿轮 11 与滑枕齿条 12 相啮合、半径较小的二号扇形齿轮 14 与液压齿条 13 相啮合。除图中的双侧扇形齿轮形式外，滑枕齿条 12 与液压齿条 13 之间还可以通过①设置一个双联齿轮、②设置多个齿轮组等形式实现传动以及调整传动比；如果无需改变传动比，则也可以仅设置一个普通的圆柱齿轮连接滑枕齿

条 12 与液压齿条 13。通过上述连接关系，当液压机构 16 驱动液压杆 15 伸缩移动时，依靠齿轮齿条之间的传动驱使滑枕 10 往复移动。

刨床上设有工作台 8，用于安置工件 7。通过电机 17 及相应传动机构 9，工作台 8 可水平移动，用以调节工件 7 位置。

滑枕 10 一端设有刀座 2，刀座 2 高度可调。刀座 2 顶端设有手轮 1，用以帮助调节刀座 2 高度。刀座 2 处于工作台 8 上方。刀座 2 下端两侧相对地设有两个刀架，分别为一号刀架 4 和二号刀架 5。两刀架上分别安装有刨刀 5。两刀架上端分别通过铰链 3 与刀座 2 相连，使得刀架可绕铰链 3 向上翻起。

如图 2 和图 3 所示，两个刀架内分别设有永磁铁 22，在刀座 2 内则设有电磁铁 21。电磁铁 21 与两侧的永磁铁 22 位置相对。两侧的永磁铁 22 磁极方向相反。在刀架与刀座 2 之间还设有弹簧 23。当电磁铁 21 通电工作时，一侧的永磁铁 22 将被电磁铁 21 吸合、另一侧的永磁铁 22 将被电磁铁 21 弹开；也即一侧的刀架通过磁吸力克服弹簧 23 紧贴刀座 2，另一侧刀架则在磁力以及弹簧 23 弹力的共同作用下绕铰链 3 向上翻折翘起。其中当刀架吸合紧贴在刀座 2 上时，其上刨刀 5 处于工作状态，能够刨削到工件 7；反之当刀架被弹开翘起时，其上刨刀 5 则远离工件 7 表面，处于空闲状态。

上述刨床工作时，通过工作台 8 调节工件 7 的水平位置，通过调节刀座 2 高度使刨刀 5 能够切削到工件 7 的待加工面。利用液压机构 16 驱动滑枕 10 及其上刀座 2 往复移动，与此同时，通过控制电磁铁 21 的磁极方向，使两侧刨刀 5 轮流处于工作状态，分别在滑枕 10 去程和回程时刨削工件 7，实现双向切削功能。

在本实用新型的描述中，需要理解的是，术语“上”、“下”、“前”、“后”、“左”、“右”、“竖直”、“水平”、“顶”、“底”、“内”、“外”等指示的方位或位置关系为基于附图所示的方位或位置关系，仅是为了便于描述本实用新型和简化描述，而不是指示或暗示所指的装置或元件必须具有特定的方位、以特定的方位构造和操作，因此不能理解为对本实用新型的限制。

本实用新型并不限于上述实施方式，在不背离本实用新型的实质内容的情况下，本领域技术人员能够做出的任何显而易见的改进、替换或变形均属于本实用新型的保护范围。

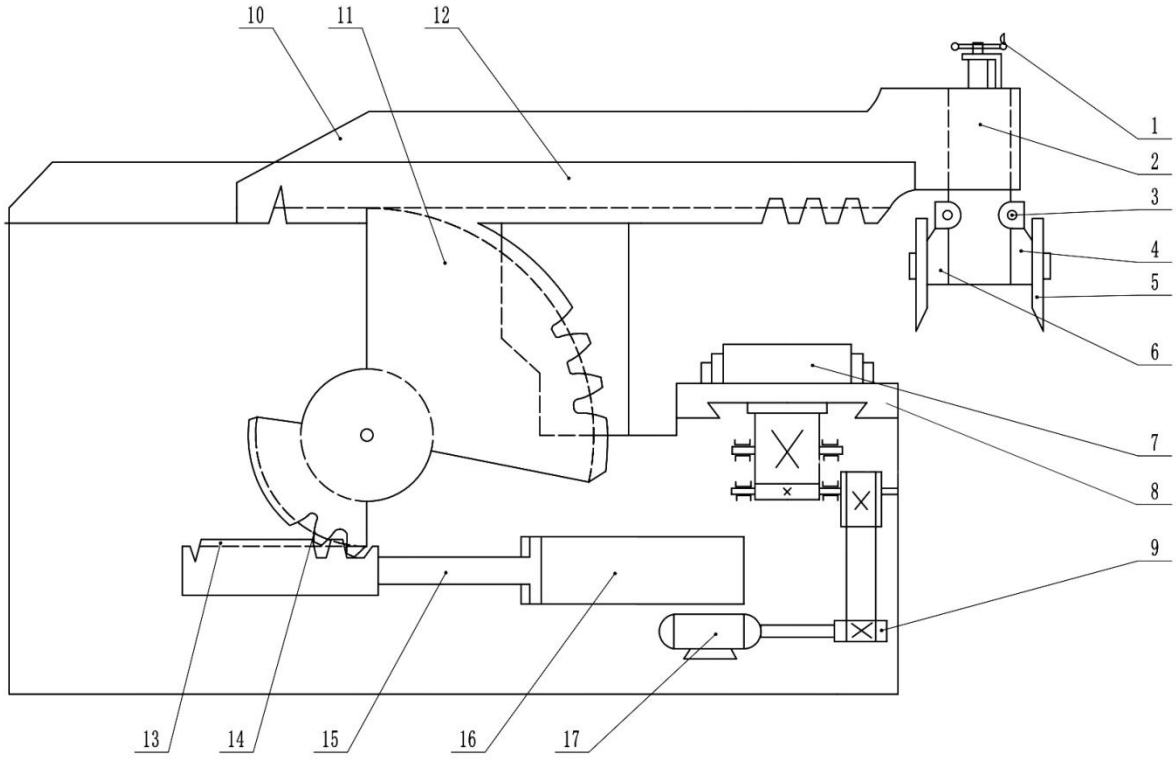


图 1

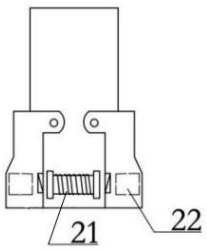


图 2

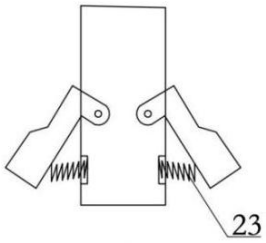


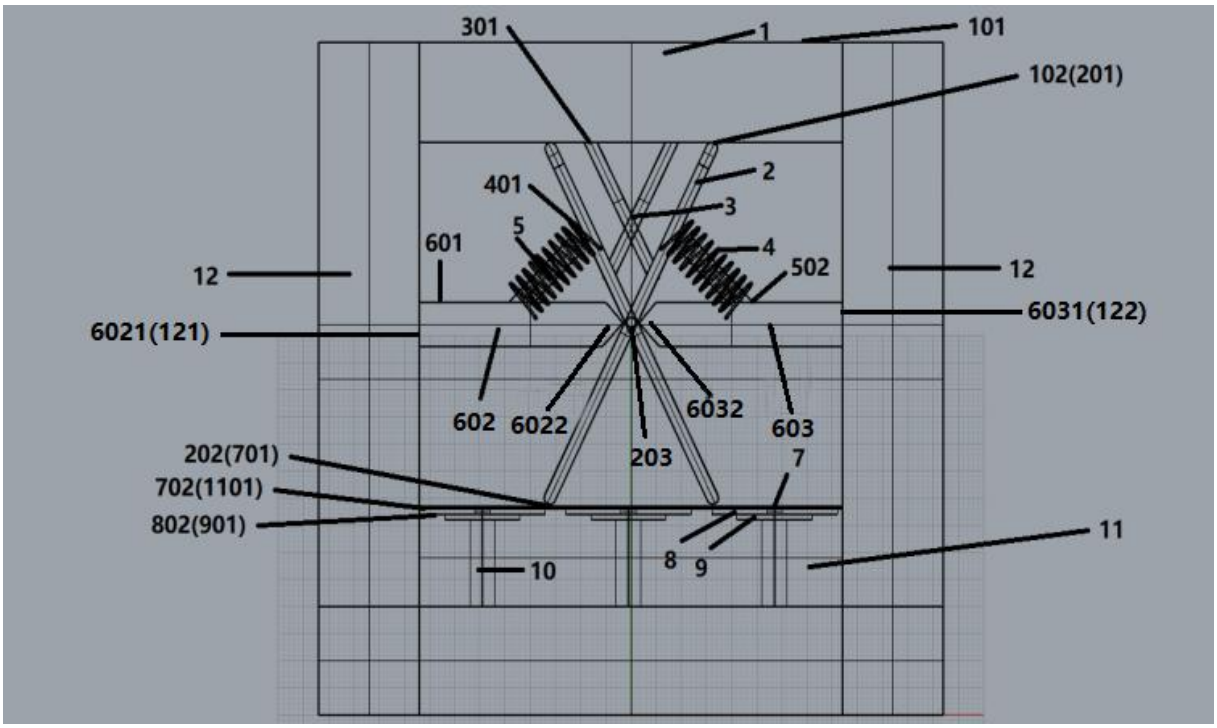
图 3

一种基于压电材料的俘能地板（实用新型）

技术交底书

说明书摘要

本实用新型公开了一种基于压电功能材料的地板俘能系统，属于新能源发电工程领域，在有行人或车辆经过并挤压地板时进行俘能发电。压电陶瓷的原理是对这种陶瓷片施加压力导致它的两端会产生极性相反的电荷，从而在回路中形成电流。通过将压电俘能结构嵌入地板内部，利用对地面踩踏产生的压力使压电陶瓷发生形变，从而对能量进行俘获；当踩踏压力释放后，再通过弹簧使得地板复位，整个过程中将产生的能量通过桥式整流电路采集并储存 ，同时在每个地板中嵌入一个压电陶瓷传感器和一个负系数光敏传感器，白天的俘能电量给蓄电池充电，夜晚压电陶瓷又相当于一个压力传感器，检测到压力的时候，蓄电池放电使路灯发光，从而实现给路灯供能和节能的目标。



权利要求书

1、一种基于压电功能材料地板俘能系统，其特征在于，包括：上盖板(1)；传动机构；复位机构；限位机构；支撑结构；压电机构；外壳体(12)。外壳体(12)为正方形结构将整个内部结构包围；所述压电机构包括按压板(7)，大圆形槽(8)，压电陶瓷组(13)，小圆形槽(9)，通孔(10)，底板(11)；所述传动机构包括：主传动结构(2)，辅助传动结构(3)；所述复位机构包括：复位弹簧(4)；所述限位机构包括：限位棍(5)；所述支撑结构包括：横梁组(6)；底板上端面(1101)和按压板下端面(702)相接，按压板上端面(701)和主传动结构下端面(202)相接，左横梁左端面(6021)与外壳体内侧左端面(121)通过热气体焊接方式固定，右横梁右端面(6031)与外壳体内侧右端面(122)通过热气体焊接方式固定，且主动传动机构的中心点(203)被左横梁顶角(6022)和右横梁顶角(6032)固定，横梁组上端面(601)和限位棍下端面(502)通过热气体焊接方式固定，弹簧上端面(401)与主传动机构(2)侧端面相接，辅助传动结构的下端面(302)和主传动机构的内侧端面(203)通过热气体焊接方式固定。主传动结构上端面(201)和辅助传动结构上端面(301)处于同一平面且都与上盖板下端面(102)相接。

2、根据权力要求 1 所述的一种基于压电功能材料地板俘能系统，其特征在于，所述压电陶瓷组包括九个相同压电陶瓷片(131)，(132)，(133)，(134)，(135)，(136)，(137)，(138)，(139)，通过胶接分别粘贴在圆环形结构体九个大圆形卡槽(801)，(802)，(803)，(804)，(805)，(806)，(807)，(808)，(809)中，均匀分布于方形机构体内表面。

3、根据权力要求 1 所述的一种基于压电功能材料地板俘能系统，其特征在于，所述小圆形槽(9)直径略小于大圆形槽(8)直径，产生直径 10 mm 深度 2mm 的小圆槽，给予压电陶瓷形变空间；

4、根据权力要求 1 所述的一种基于压电功能材料地板俘能系统，其特征在于，所述通孔(10)用来给压电陶瓷组(13)连接电路。

5、根据权力要求 1 所述的一种基于压电功能材料地板俘能系统，其特征在于，所述的主传动结构(2)在上盖板下压时，上端面(201)往左右两侧下降，下端面(202)往左右两侧上升。

6、根据权力要求 1 所述的一种基于压电功能材料地板俘能系统，其特征在于，在上盖板(1)单侧下压时，整体结构呈现倾斜状态，导致部分压电陶瓷未发生复

位，从而不能产生能量，所述的辅助传动结构(3)在单侧下压时，会给另一侧的主传动结构(2)一个下压的力，从而达到压电陶瓷全部复位，产生能量，提高了发电效率。

7、根据权力要求 1 所述的一种基于压电功能材料地板俘能系统，其特征在于，所述的压电陶瓷组(13)在主传动结构下端面(202)上升时，能够利用自身刚性将按压板(7)顶起。

8、根据权力要求 1 所述的一种基于压电功能材料地板俘能系统，其特征在于，所述限位棍(5)能够在上盖板(1)下压 0.3mm 左右时，阻止主传动机构(2)继续下降。

9、根据权力要求 1 所述的一种基于压电功能材料地板俘能系统，其特征在于，所述复位弹簧(4)在上盖板失去压力后，利用弹簧弹力将上盖板(1)抬回原位，并将主传动机构(2)恢复原状，进而将按压板(7)重新下压至压电陶瓷组(13)形变，完成产生能量的一整个流程。

一种基于压电功能材料的地板俘能系统

技术领域

本发明属于新能源发电工程领域，尤其涉及一种俘能地板。

背景技术

能源问题已经成为我国乃至世界政治经济、环境保护等诸问题的中心问题。而化石能源开发利用的迅猛发展给我们的环境正带来严重的污染，我们也正在承受着破坏环境带来的恶果。可喜的是，人们正在逐步限制并控制化石能源的开采及使用，采取积极措施开发利用新能源，向低碳经济、绿色经济转变，实现社会经济的可持续发展。经测，人体的各种运动能产生或多或少的能量，特别是人行走产生接近 67W 的能量，已知压电俘能器可收集微小的震动能源，利用此特点，能把行走时产生的机械能转换为电能给一些电子产品供电，基于压电材料制成的压电俘能地板结构简单、构型灵活，成本低，所以所以压电俘能地板有着广泛的应用场景和巨大的经济效益。

发明内容

本发明提供了一种基于压电功能材料的俘能地板，通过将压电俘能结构嵌入地板内部，利用物体给予的压力使压电陶瓷发生形变，再通过弹簧使得地板完成复位，将产生的能量通过桥式整流电路汇聚并储存进蓄电池，实现发电目标。

为实现以上目的，本发明采用以下技术方案：

一种基于压电功能材料的俘能地板，包括：上盖板(1)；传动机构；复位机构；限位机构；支撑结构；压电机构；外壳体(12)。外壳体(12)为正方形结构将整个内部结构包围；所述压电机构包括按压板(7)，大圆形槽(8)，压电陶瓷组(13)，小圆形槽(9)，通孔(10)，底板(11)；所述传动机构：主传动结构(2)，辅助传动结构(3)；所述复位机构：复位弹簧(4)；所述限位机构：限位棍(5)；所述支撑结构：横梁组(6)；底板上端面(1101)和按压板下端面(702)相接，按压板上端面(701)和主传动结构下端面(202)相接，左横梁左端面(6021)与外壳体内侧左端面(121)通过热气体焊接方式固定，右横梁右端面(6031)与外壳体内侧右端面(122)通过热气体焊接方式固定，且主动传动机构的中心点(203)被左横梁顶角(6022)和右横梁顶角(6032)固定，横梁组上端面(601)和限位棍下端面(502)通过热气体焊接方式固定，弹簧上端面(401)与主传动机构(2)侧端面相接，辅助传动结构的下端面(302)和主传动机构的内侧端面(203)通过热气体焊接方式固定。主传动结构上端面(201)和辅助传动结构上端面(301)处于同一平面且都与上盖板下端面(102)相接。

所述的一种基于压电功能材料地板俘能系统，其特征在于，所述压电陶瓷组包括九个相同压电陶瓷片(131)，(132)，(133)，(134)，(135)，(136)，(137)，(138)，(139)，通过胶接分别粘贴在圆环形结构体九个大圆形卡槽(801)，(802)，(803)，(804)，(805)，(806)，(807)，(808)，(809)中，均匀分布于方形机构体内表面。

所述的一种基于压电功能材料地板俘能系统，其特征在于，所述小圆形槽(9)直径略小于大圆形槽(8)直径，产生直径 10 mm 深度 2mm 的小圆槽，给予压电陶瓷形变空间；

所述的一种基于压电功能材料地板俘能系统，其特征在于，所述通孔(10)用来给压电陶瓷组(13)连接电路。

所述的一种基于压电功能材料地板俘能系统，其特征在于，所述的主传动结构(2)在上盖板下压时，上端面(201)往左右两侧下降，下端面(202)往左右两侧上升。

所述的一种基于压电功能材料地板俘能系统，其特征在于，在上盖板(1)单侧下压时，整体结构呈现倾斜状态，导致部分压电陶瓷未发生复位，从而不能产生能量，所述的辅助传动结构(3)在单侧下压时，会给另一侧的主传动结构(2)一

个下压的力，从而达到压电陶瓷全部复位，产生能量，提高了发电效率。

所述的一种基于压电功能材料地板俘能系统，其特征在于，所述的压电陶瓷组(13)在主传动结构下端面(202)上升时，能够利用自身刚性将按压板(7)顶起。

所述的一种基于压电功能材料地板俘能系统，其特征在于，所述限位棍(5)能够在上盖板(1)下压 0.3mm 左右时，阻止主传动机构(2)继续下降。

所述的一种基于压电功能材料地板俘能系统，其特征在于，所述复位弹簧(4)在上盖板失去压力后，利用弹簧弹力将上盖板(1)抬回原位，并将主传动机构(2)恢复原状，进而将按压板(7)重新下压至压电陶瓷组(13)形变，完成产生能量的一整个流程。

本发明的有益效果：本发明提供了一种基于压电功能材料的俘能地板通过将压电俘能结构嵌入地板内部，利用物体给予的压力使压电陶瓷发生形变，再通过弹簧使得地板完成复位，将产生的能量通过桥式整流电路汇聚并储存进蓄电池 ，再在每个地板中嵌入一个压电陶瓷传感器和一个负系数光敏传感器，白天的俘能电量给蓄电池充电，夜晚压电陶瓷又相当于一个压力传感器，检测到压力的时候，蓄电池放电使路灯发光，从而实现夜晚给路灯供能和节能目标。基于压电材料制成的压电俘能地板结构简单、构型灵活，成本低。经测，人体的各种运动能产生或多或少的能量，特别是人行走产生接近 67W 的能量，已知压电俘能器可收集微小的震动能源，利用此特点，能把行走时产生的机械能转换为电能给一些电子产品供电，所以压电俘能地板有着广泛的应用场景和巨大的经济效益。

附图说明

图 1 是本发明的整体结构示意图。

图 2 是本发明的整体结构剖视图。

图 3 是本发明的底板示意图。

图 4 是本发明的限位棍和复位弹簧示意图。

图 5 是本发明的主传动机构与辅助传动机构示意图。

图 6 是本发明按压状态下的整体结构示意图。

图 7 是本发明按压状态下的整体结构剖视图。

图中，1 为上盖板，2 为主传动结构，3 为辅助传动结构，4 为复位弹簧，5 为限位棍，6 为横梁组，7 为按压板，8 为大圆形槽，9 为小圆形槽，10 为通孔，

11 为底板，12 为外壳体。101 为上盖板上端面，102 为上盖板下端面，201 为主动传动结构上端面，202 为主动传动机构下端面，203 为主动传动机构的中心点，301 为辅助传动机构上端面，302 为辅助传动机构上端面，401 为复位弹簧上端面，502 为限位棍下端面，602 为左横梁，6021 为左横梁左端面，6022 为左横梁顶角，603 为右横梁，6031 为右横梁右端面，6032 为右横梁顶角 701 为按压板上端面，702 为按压板下端面，802 为大圆形槽下端面，901 为小圆形槽上端面，1101 为底板上端面，121 为外壳体内侧左端面，122 为外壳体内侧右端面，13 为压电陶瓷组，131—139 为压电陶瓷片。

具体实施方案

下面结合附图和具体实施例对本发明进行详细说明。

如图 2 所示 ，一种基于压电功能材料的俘能地板，其特征在于，包括：上盖板(1)；传动机构；复位机构；限位机构；支撑结构；压电机构；外壳体(12)。外壳体(12)为正方形结构将整个内部结构包围；所述压电机构包括按压板(7)，大圆形槽(8)，压电陶瓷组(13)，小圆形槽(9)，通孔(10)，底板(11)；

所述传动机构：主传动结构(2)，辅助传动结构(3)；所述复位机构：复位弹簧(4)；所述限位机构：限位棍(5)；所述支撑结构：横梁组(6)；

底板上端面(1101)和按压板下端面(702)相接，按压板上端面(701)和主传动结构下端面(202)相接，左横梁左端面(6021)与外壳体内侧左端面(121)通过热气体焊接方式固定，右横梁右端面(6031)与外壳体内侧右端面(122)通过热气体焊接方式固定，且主动传动机构的中心点(203)被左横梁顶角(6022)和右横梁顶角(6032)固定，横梁组上端面(601)和限位棍下端面(502)通过热气体焊接方式固定，弹簧上端面(401)与主传动机构(2)侧端面相接，辅助传动结构的下端面(302)和主传动机构的内侧端面(203)通过热气体焊接方式固定。主传动结构上端面(201)和辅助传动结构上端面(301)处于同一平面且都与上盖板下端面(102)相接。

所述的一种基于压电功能材料地板俘能系统，其特征在于，所述压电陶瓷组包括九个相同压电陶瓷片(131)，(132)，(133)，(134)，(135)，(136)，(137)，(138)，(139)，通过胶接分别粘贴在圆环形结构体九个大圆形卡槽(801)，(802)，(803)，(804)，(805)，(806)，(807)，(808)，(809)中，均匀分布于方形机构体内表面。

所述的一种基于压电功能材料地板俘能系统，其特征在于，所述小圆形槽(9)

直径略小于大圆形槽(8)直径，产生直径 10 mm 深度 2mm 的小圆槽，给予压电陶瓷形变空间；

所述的一种基于压电功能材料地板俘能系统，其特征在于，所述通孔(10)用来给压电陶瓷组(13)连接电路。

所述的一种基于压电功能材料地板俘能系统，其特征在于，所述的主传动结构(2)在上盖板下压时，上端面(201)往左右两侧下降，下端面(202)往左右两侧上升。

所述的一种基于压电功能材料地板俘能系统，其特征在于，在上盖板(1)单侧下压时，整体结构呈现倾斜状态，导致部分压电陶瓷未发生复位，从而不能产生能量，所述的辅助传动结构(3)在单侧下压时，会给另一侧的主传动结构(2)一个下压的力，从而达到压电陶瓷全部复位，产生能量，提高了发电效率。

所述的一种基于压电功能材料地板俘能系统，其特征在于，所述的压电陶瓷组(13)在主传动结构下端面(202)上升时，能够利用自身刚性将按压板(7)顶起。

所述的一种基于压电功能材料地板俘能系统，其特征在于，所述限位棍(5)能够在上盖板(1)下压 0.3mm 左右时，阻止主传动机构(2)继续下降。

所述的一种基于压电功能材料地板俘能系统，其特征在于，所述复位弹簧(4)在上盖板失去压力后，利用弹簧弹力将上盖板(1)抬回原位，并将主传动机构(2)恢复原状，进而将按压板(7)重新下压至压电陶瓷组(13)形变，完成产生能量的一整个流程。

以上仅是本发明的优选实施例，将有助于本领域的技术人员进一步理解本发明，但不以任何形式限制本发明。应当指出的是对本领域的普通技术人员来说，在不脱离本发明构思的前提下，做出的若干变形和改进都属于本发明的保护范围。

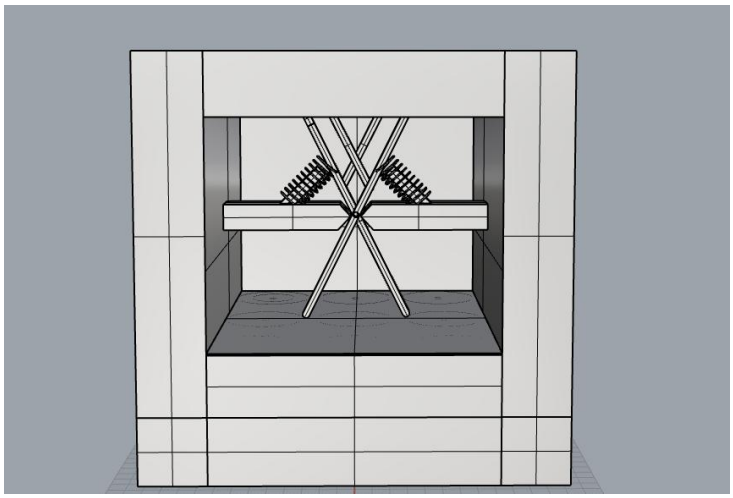


图 1

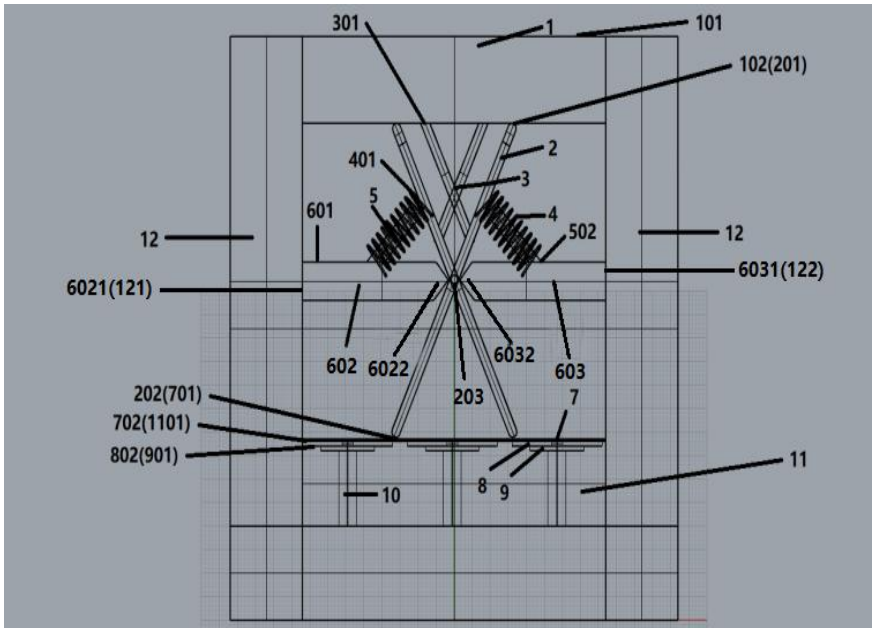

301
1
101
102(201)
401
2
3
5
4
601
502
12
12
6031(122)
6021(121)
602
6022
6032
603
203
7
202(701)
702(1101)
802(901)
11
8
9
10

图 2

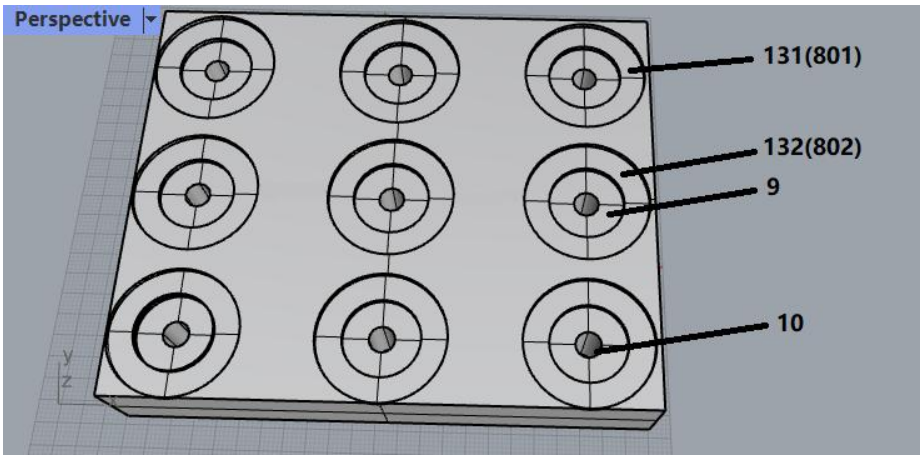


图 3

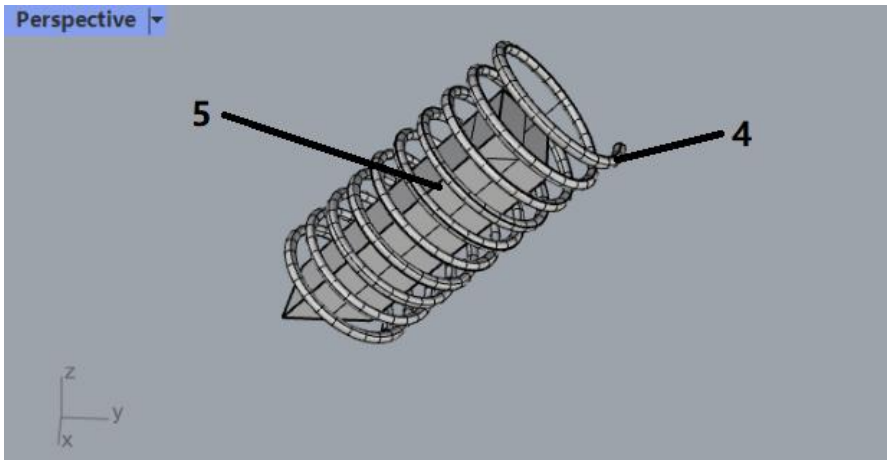


图 4

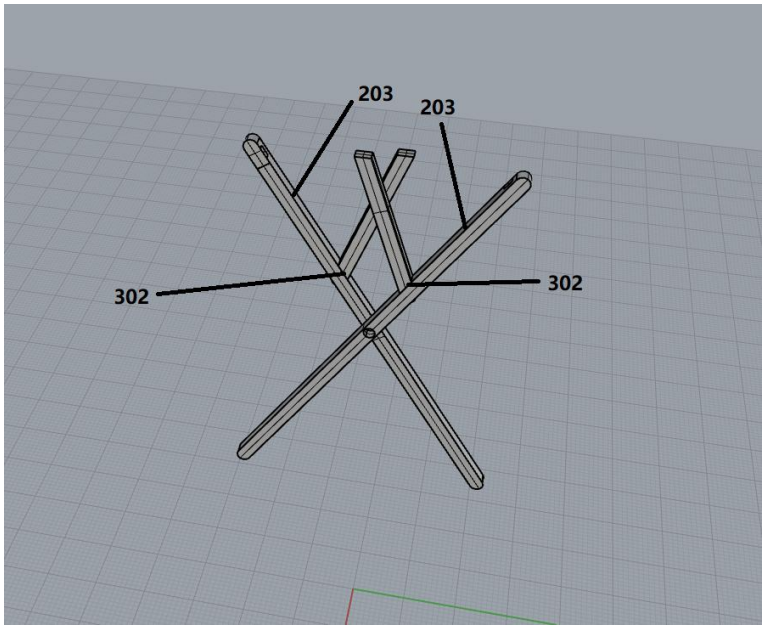


图 5

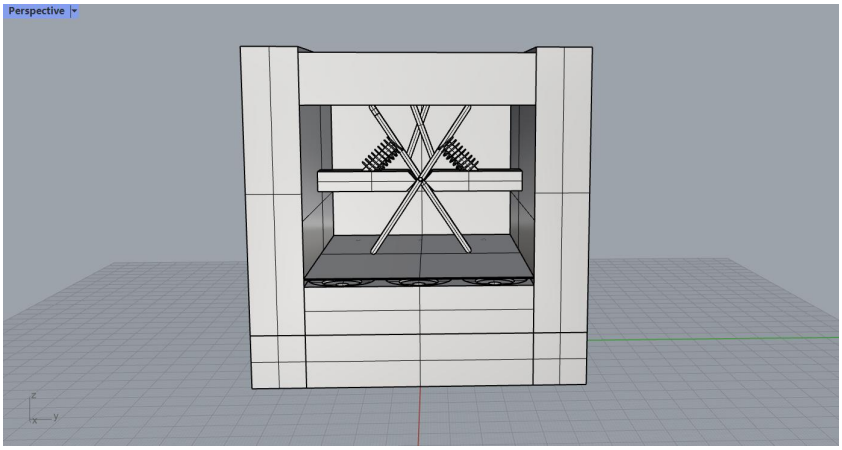


图 6

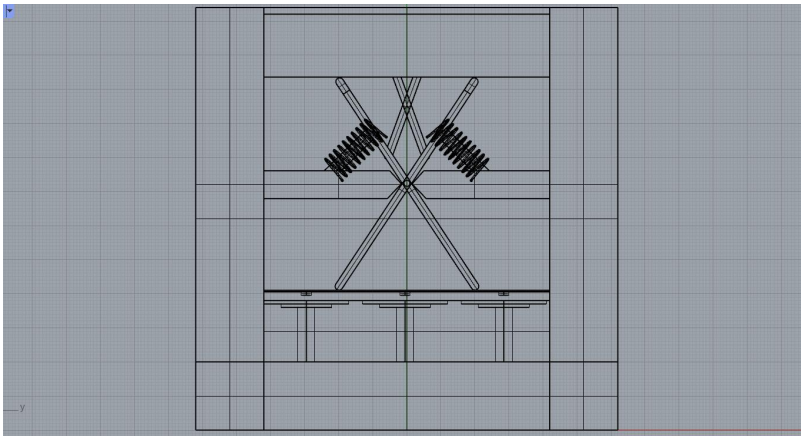


图 7

申请材料分析说明

1.基础信息

专利名称：一种基于压电材料的俘能地板

状态：授权

2.交底材料

交底材料内容相对较为充实，但是不用提供权利要求书。

背景技术的核心是指出当下存在的技术问题，而本案仅仅只是介绍了本案的创意来源，这不仅对本案申请无益，反而会引导审查员认为现有技术对本案具有技术启示，从而否定本案的创造性。

技术方案的表述较为啰嗦，专利不是作业指导书，专利说明书的撰写应当聚焦于本案的发明创新点，而对于如“某某与某某通过热气体焊接方式固定”这类明显属于现有常规手段的内容，则可以省略。

附图制作不规范，图片背景应当采用白色，机械结构类的附图尽量采用线稿图，不要直接贴三维图，并且要避免出现如绘图软件的文字图标界面等无关内容。

3.权利要求书

权利要求撰写清楚，避免出现非必要技术特征。

4.说明书

背景技术部分，重新整理，明确出本案所要针对解决的技术问题。

具体实施方式部分，围绕发明创新点对本案技术内容进行撰写。

附图部分，重新绘制符合专利规范的线稿图。

有益效果部分，结合技术特征点对效果进行说理式表述。

申请稿

说明书摘要

本实用新型提供了一种基于压电材料的俘能地板，其中顶部设有可下压的上盖板，底部设有压电模块，上盖板与压电模块之间通过传动件传递力；所述传动件为剪刀叉结构，通过横梁连接在地板框架中部，其中剪刀叉结构的上摆臂与上盖板相抵，下摆臂与压电模块相抵；传动件内设有弹性复位机构，在地板不受踩踏时，驱使上盖板上移并下压压电模块。本实用新型俘能地板，能够均衡压电模块的受力情况；其中通过设计剪刀叉结构形式的传动件，在上盖板与压电模块之间传递压力，其中在未踩踏时压电模块受压形变，而在踩踏时压电模块复原产生电能。此外，踩踏力是经上盖板及传动件的横梁直接作用在地板外框架上，避免压电模块直接受压而因压力过大导致损害事故。

权利要求书

1.一种基于压电材料的俘能地板，其特征在于：其中顶部设有可下压的上盖板（1），底部设有压电模块（4），上盖板（1）与压电模块（4）之间通过传动件（2）传递力；所述传动件（2）为剪刀叉结构，通过横梁（23）连接在地板框架中部，其中剪刀叉结构的上摆臂与上盖板（1）相抵，下摆臂与压电模块（4）相抵；传动件（2）内设有弹性复位机构，在地板不受踩踏时，驱使上盖板（1）上移并下压压电模块（4）。

2.根据权利要求 1 所述的基于压电材料的俘能地板，其特征在于：所述压电模块（4）上表面平铺有下盖板（3）与传动件（2）相抵接。

3.根据权利要求 1 所述的基于压电材料的俘能地板，其特征在于：所述传动件（2）通过剪刀叉结构的转轴（25）连接固定在横梁（23）上，其中剪刀叉结构的上摆臂通过复位弹簧（21）与横梁（23）相连，复位弹簧（21）内套置有导向柱（22），导向柱（22）一端固定在横梁（23）上，另一端距所述上摆臂有一段供复位弹簧（21）压缩的间隙。

4.根据权利要求 1 所述的基于压电材料的俘能地板，其特征在于：所述传动件（2）平行地设有两组，两组传动件（2）之间通过连杆（24）相连驱使同步运作。

5.根据权利要求 1 所述的基于压电材料的俘能地板，其特征在于：所述上盖板（1）底部设有凸台（11），凸台（11）安插于地板框架顶部开口内，并与框架滑动配合。

6.根据权利要求 1 所述的基于压电材料的俘能地板，其特征在于：所述压电模块（4）内均布有多个压电片。

7.根据权利要求 6 所述的基于压电材料的俘能地板，其特征在于：所述压电片嵌于压电模块（4）上表面开设的安装槽（41）内，安装槽（41）底部设有形变槽（42）供压电片形变，

形变槽（42）底部开设有导线孔（43）。

一种基于压电材料的俘能地板

技术领域

本实用新型属于新能源发电技术领域，具体涉及一种基于压电材料的俘能地板。

背景技术

人行走能产生约 67W 的能量，基于压电材料制成的压电俘能器是一种可收集微小振动能量的器件，利用压电俘能器的特性，理论上可将人行走时产生的机械能转换为电能进行回收，为缓解能源问题提供一种新的解决方向。

现有的一些压电俘能地板大多比较简单，停留在浅层原理阶段，存在不少实用性方面的问题。其中比较突出的一项问题是，由于无法保证每次行走都正好踩踏在地板正中间；而地板侧边受力，往往导致地板内层的压电模块受力不均，无法充分发挥全部性能，显著影响发电效率。

实用新型内容

针对现有技术中存在的不足，本实用新型提供了一种基于压电材料的俘能地板，用以解决发电稳定性问题。

本实用新型通过以下技术手段实现上述技术目的。

一种基于压电材料的俘能地板，其中顶部设有可下压的上盖板，底部设有压电模块，上盖板与压电模块之间通过传动件传递力；所述传动件为剪刀叉结构，通过横梁连接在地板框架中部，其中剪刀叉结构的上摆臂与上盖板相抵，下摆臂与压电模块相抵；传动件内设有弹性复位机构，在地板不受踩踏时，驱使上盖板上移并下压压电模块。

进一步地，所述压电模块上表面平铺有下盖板与传动件相抵接。

进一步地，所述传动件通过剪刀叉结构的转轴连接固定在横梁上，其中剪刀叉结构的上摆臂通过复位弹簧与横梁相连，复位弹簧内套置有导向柱，导向柱一端固定在横梁上，另一端距所述上摆臂有一段供复位弹簧压缩的间隙。

进一步地，所述传动件平行地设有两组，两组传动件之间通过连杆相连驱使同步运作。

进一步地，所述上盖板底部设有凸台，凸台安插于地板框架顶部开口内，并与框架滑动配合。

进一步地，所述压电模块内均布有多个压电片。

进一步地，所述压电片嵌于压电模块上表面开设的安装槽内，安装槽底部设有形变槽供

压电片形变，形变槽底部开设有导线孔。

本实用新型的有益效果为：

（1）本实用新型提供了一种基于压电材料的俘能地板，能够均衡压电模块的受力情况；其中通过设计剪刀叉结构形式的传动件，在上盖板与压电模块之间传递压力，其中在未踩踏时压电模块受压形变，而在踩踏时压电模块复原产生电能。除此之外，踩踏力是经上盖板及传动件的横梁直接作用在地板外框架上，避免压电模块直接受压而因压力过大导致损害事故。

（2）本实用新型中在上盖板的凸台和传动件上的导向柱两处设计了限位结构，防止过分下压造成结构损伤。

附图说明

图 1 为本实用新型地板总体结构图；

图 2 为本实用新型地板主视图；

图 3 为本实用新型地板内部结构图；

图 4 为本实用新型中压力传导机构的结构图；

图 5 为本实用新型中压电模块结构图；

图 6 为本实用新型地板铺装示意图。

附图标记：

1-上盖板；	11-凸台；	2-传动件；	21-复位弹簧；
22-导向柱；	23-横梁；	24-连杆；	25-转轴；
3-下盖板；	4-压电模块；	41-安装槽；	42-形变槽；
43-导线孔。			

具体实施方式

下面详细描述本实用新型的实施例，所示实施例的示例在附图中示出，其中自始至终相通或类似的标号表示相同或类似的元件或具有相同或类似功能的元件。下面通过参考附图描述的实施例是示例性的，旨在用于解释本实用新型，而不能理解为对本实用新型的限制。

如图 1 和图 2 所示，单块地板为立方体结构，包括外侧的立方体框架，以及设于框架顶部供人踩踏的上盖板 1。上盖板 1 与框架之间为活动连接，当人踩踏时，上盖板 1 能够小幅下移。其中上盖板 1 底部设有凸台 11，凸台 11 安插于所述框架的顶部开口内，并与框架内侧面滑动配合。

在框架内侧底部则设有压电模块 4，所述上盖板 1 与压电模块 4 之间设有相应压力传导机构。从而当人踩踏上盖板 1 时，通过压力传导机构将形变能量传递至压电模块 4，驱使压

电模块 4 产生电能。所述压力传导机构包括剪刀叉结构的传动件 2。其中传动件 2 上端与上盖板 1 相接触，传动件 2 下端与下盖板 3 相接触，下盖板 3 则平铺于压电模块 4 上表面。

如图 4 所示，传动件 2 设置在横梁 23 上。其中传动件 2 中部通过转轴 25 与横梁 23 相连接，并围绕该转轴 25 做剪刀叉运动。传动件 2 上半部两侧摆臂又分别通过复位弹簧 21 与横梁 23 弹性连接，从而在不受外力作用时利用复位弹簧 21 驱使传动件 2 复位。横梁 23 上设有导向柱 22，所述复位弹簧 21 套置在导向柱 22 上。在不受外力作用时，导向柱 22 与传动件 2 上摆臂之间有一段间隙，用以供复位弹簧 21 压缩形变。

为保证上盖板 1 受到的踩踏力能够均衡地传递至下盖板 3，上述传动件 2 平行地设有两组，两组传动件 2 的摆臂之间通过连杆 24 相连；从而保证两传动件 2 同步运作。

如图 5 所示，压电模版 4 表面均匀开设有若干组凹槽，其中每组凹槽内由上至下依次设有安装槽 41 和形变槽 42。安装槽 41 用于安装固定压电片，形变槽 42 则用于提供压电片形变空间。在形变槽 42 底部设有导线孔 43，用于供压电片连接外界导线。

如图 6 所示为本实用新型俘能地板的使用示意。其中当人行走踩踏到某块地板的上盖板 1 时，该上盖板 1 受压下移；剪刀叉结构的传动件 2 在上盖板 1 作用下，下摆臂上翘，下盖板 3 失去压力；最终压电模块 4 内的压电片自然回弹，产生电能。反之当脚离开时，传动件 2 在其内复位弹簧 21 的驱动下复位，一方面驱使上侧的上盖板 1 上移归位，另一方面下压下侧的下盖板 3，压电模块 4 重新回到受压状态。

在本实用新型的描述中，需要理解的是，术语“上”、“下”、“前”、“后”、“左”、“右”、“竖直”、“水平”、“顶”、“底”、“内”、“外”等指示的方位或位置关系为基于附图所示的方位或位置关系，仅是为了便于描述本实用新型和简化描述，而不是指示或暗示所指的装置或元件必须具有特定的方位、以特定的方位构造和操作，因此不能理解为对本实用新型的限制。

本实用新型并不限于上述实施方式，在不背离本实用新型的实质内容的情况下，本领域技术人员能够做出的任何显而易见的改进、替换或变形均属于本实用新型的保护范围。

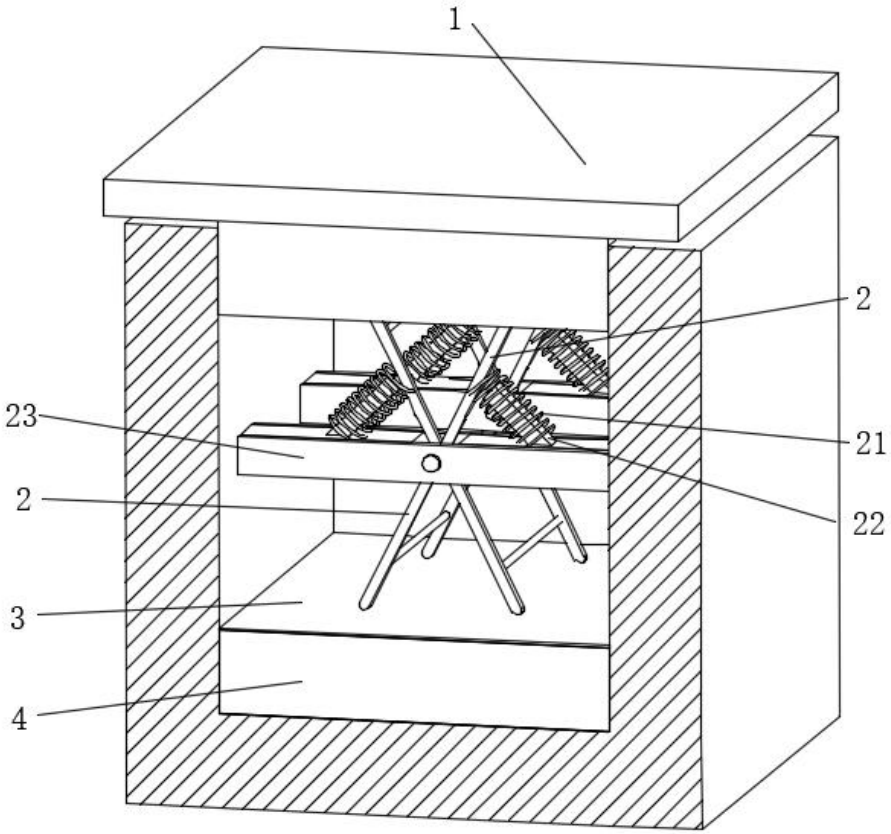


图 1

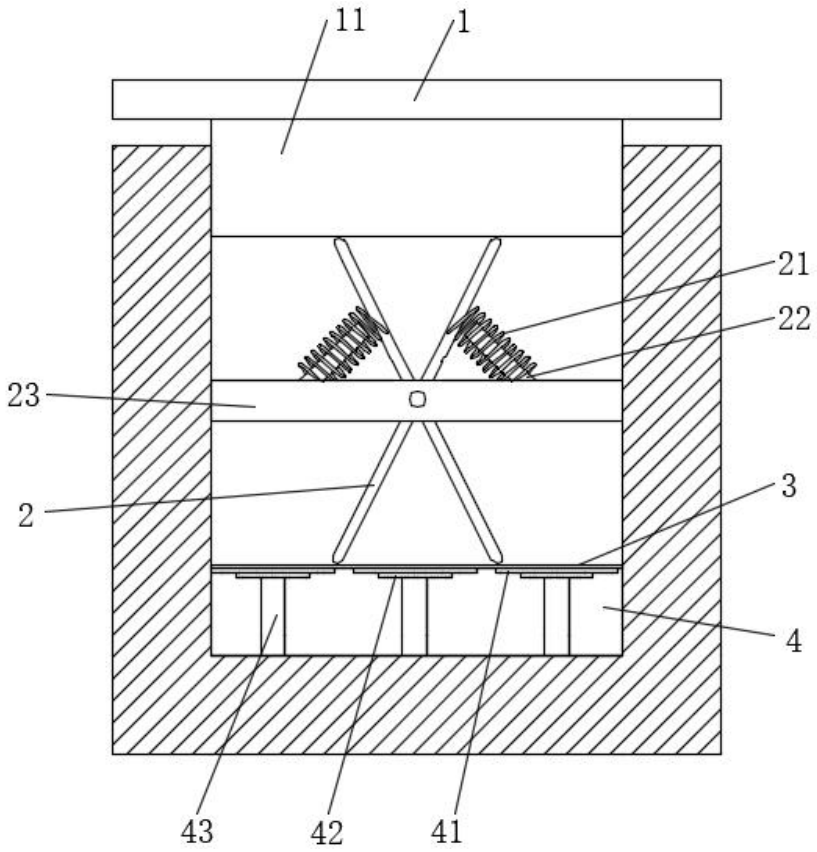


图 2

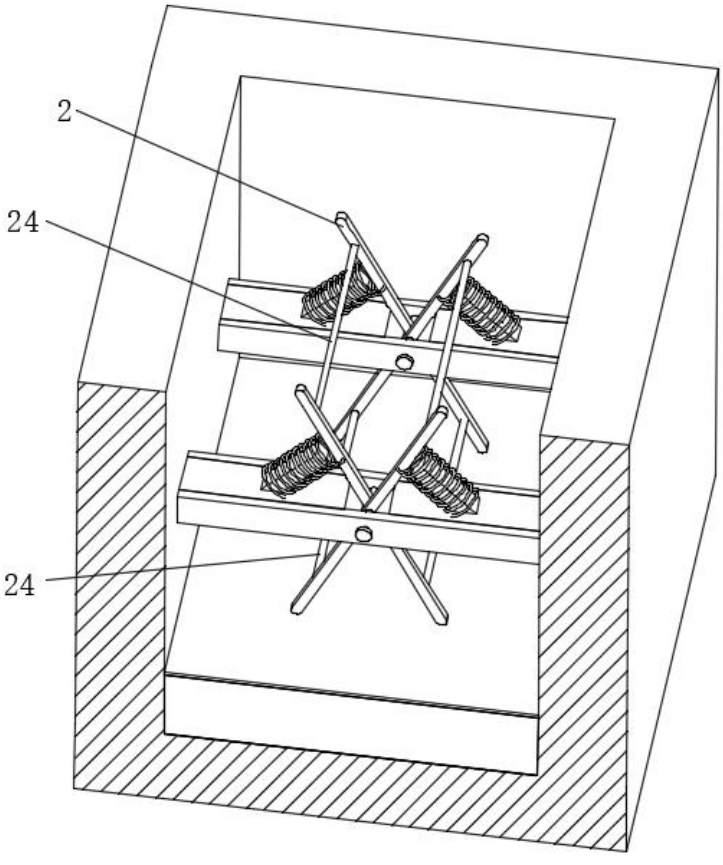


图 3

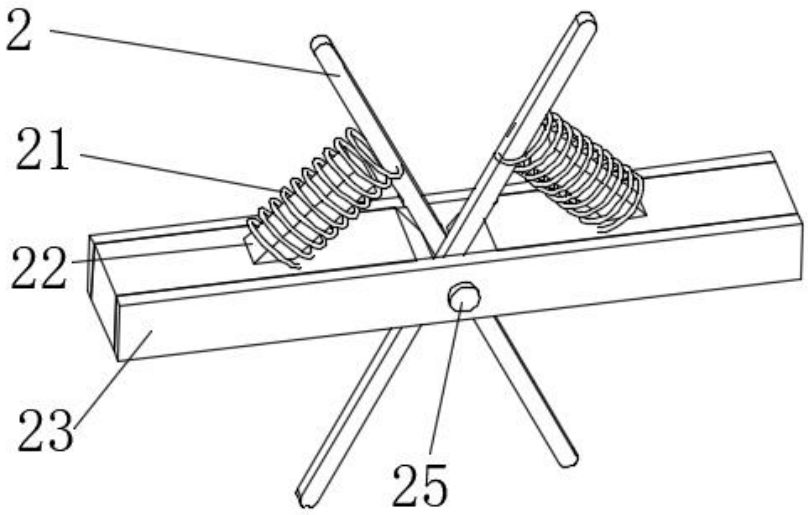


图 4

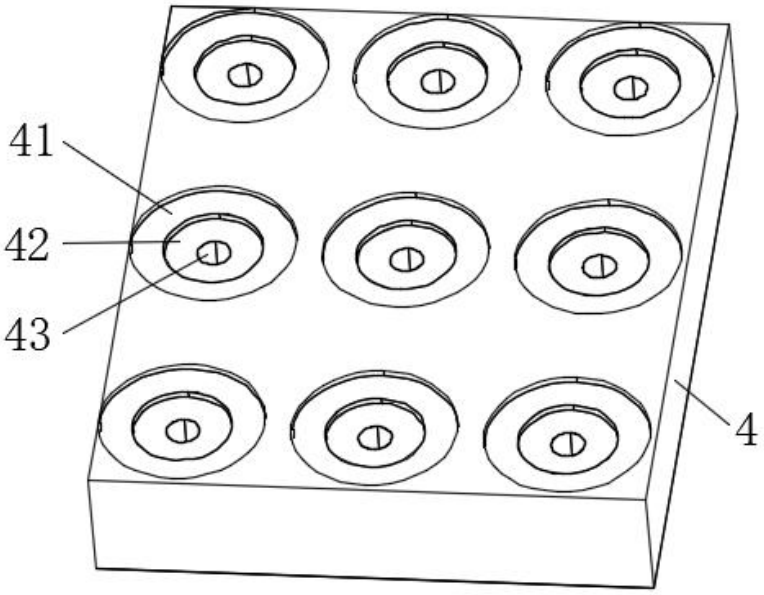


图 5

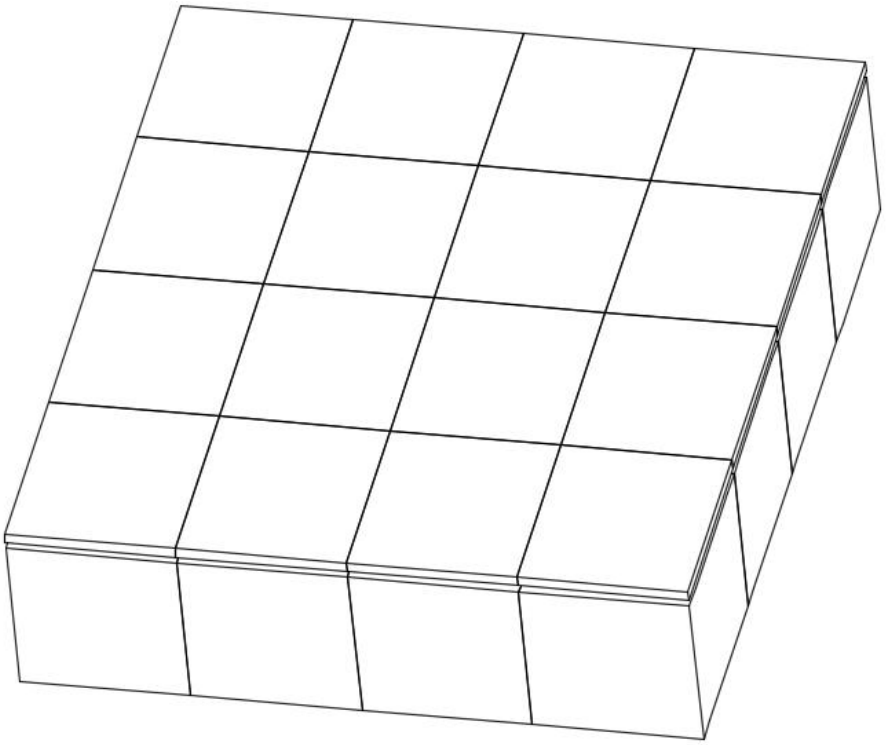


图 6

一种粮食晒收装置（非正常）

技术交底书

说明书摘要

本发明公开的一种粮食晒收装置，属于农业机械技术领域，解决了粮食晾晒和收集的专用机械化设备问题，包括：收集箱，吸粮装置，绞龙，传输带，传输带电机，万向轮，蜗杆电机，锥齿轮电机，蜗轮蜗杆，锥齿轮，曲柄摇杆，丝杆，传动轴，单片机，中转槽，电机支架，内外直齿轮，晒粮台，粮食拨杆，收放支撑杆，升降套筒。本发明采用实用的技术方案，通过吸粮绞龙、上方传输带、晒粮台、中转槽和下方传输带，最后回到收集箱内。可以减少粮食晾晒收集工作中人员的工作量，并保证快捷简便、高效安全地完成粮食晾晒收集工作。

权利交底书

1.一种粮食晒收装置，包括：收集箱，吸粮装置，绞龙，传输带，传输带电机，万向轮，蜗杆电机，锥齿轮电机，蜗轮蜗杆，锥齿轮，曲柄摇杆，丝杆，传动轴，单片机，中转槽，电机支架，内外直齿轮，晒粮台，粮食拨杆，收放支撑杆，升降套筒；其特征在于：在小车焊接了两根支架，与下方的四个万向轮配合方便人员推动，所述的蜗杆电机带动蜗轮蜗杆转动，所述丝杆带动小圆环上的大小支撑杆使晒粮台放下，所述的小圆环与收放支撑杆是通过铰链连接的，所述的收集箱可以独立放置，工作时需要人为放置至小车上端，所述的吸粮装置底部是直通于收集箱内的粮食，所述的吸粮装置为其传输粮食的第一个中间环节，通过焊接连接左右各一根握把，正对上方传输带又焊接一个出粮口，所述的上方传输带由电机带动，把从出粮口的粮食送到晒粮台上，所述的粮食拨杆通过转动达到翻粮的功能，所述的大圆环上部分通过铰链连接粮食拨杆，所述的大圆环的下部分有外齿轮与内齿轮啮合，所述的内齿轮上六个铰链座，六个连接杆通过铰链和晒粮台上的孔连接，所述的锥齿轮通过锥齿轮电机带动传动轴上内外齿轮，所述的锥齿轮底座通过小车上的支架支撑，所述的蜗轮蜗杆通过底下底座支撑，所述的单片机、锥齿轮电机、蜗轮蜗杆电机放置在小车上焊接的支撑板，所述的曲柄摇杆通过单片机控制使大圆环向上移动，曲柄摇杆放置在粮食中转槽上方用来支撑晒粮台中心的内齿轮，所述的中转槽放置晒粮台下方齿轮外壳上，其内部是倾斜的，用来过渡从晒粮台下来的粮食，再其右边有一个方孔，粮食由此到下方传

输带，所述的下方传输带通过电机把晒好粮食运回收集箱。

2.根据权利要求 1 所述的一种粮食晒收装置，其特征在于：所述的收集箱箱体为正方体，上方是无盖设计，方便粮食装取。

3.根据权利要求 1 所述的一种粮食晒收装置，其特征在于：所述的吸粮装置、上下传输装置均可以自由拆卸。

4.根据权利要求 1 所述的一种粮食晒收装置，其特征在于：所述的万向轮是焊接在小车下方支架上的，这种方式固定可靠。

5.根据权利要求 1 所述的一种粮食晒收装置，其特征在于：所述的晒粮台分为六个大小相同的扇形区域，且与收放支撑杆接触的位置有四个盲孔；当结束晒粮的时候，晒粮台由水平放置收至竖起，这样可以节省空间。

6.根据权利要求 1 所述的一种粮食晒收装置，其特征在于：所述的丝杆是用来进行配合小圆环和收放支撑杆，让晒粮台进行收放；

其中，所述的丝杆会有一段伸到小车下方的通孔，这不会影响小车的平衡。

一种粮食晒收装置

技术领域

本发明涉及农机领域，具体涉及一种家用小型粮食晾晒收集装置。

背景技术

目前，谷粒类粮食在收割后，由于含有较多的水分，无法长期保存，以人力操作为主，加之社会发展，大量农村人员进城打工，农村劳动人员减少，粮食晾晒的劳动量显著增加，这对于一些种植面积较小的普通农民来说无力使用粮食烘干机进行烘干，因此传统的农业生产方式是在谷粒类粮食收割后不久，利用太阳对谷粒类粮食进行晒干，然后收集起来进行长期储备。这种粮食烘干方式虽然操作麻烦，劳动量较大，而且晾晒时间长、占地面积大，但是其花费成本较低，因此在广大农村地区农忙时节十分常见。但是，这种摊晒方式，如果遭遇天气突变，更可能因为收集效率的低下而造成回收不及时，粮食因而淋雨发霉。目前，市场中相关的机械装置相对较少，因此提供一种能够减少收集人员工作量并代替人工进行具体操作的装置，不仅能够降低农民的工作负担，同时也能够提升粮食晾晒之后的收集工作效率。

发明内容

本发明的目的为了解决上述问题而提供一种粮食晒收装置，以解决传统粮食晒收时遇到的收粮速度慢、效率低、质量重、占地作业面积大等问题。所要解决的技术问题是：提供一种能够有效替代人工进行晒收粮食的工作，完成入箱的具体操作，同时装置能够具有高效、安全且结构简单，易于操作的特点。

为实现上述目的，本发明提供了以下技术方案：

本发明提供的一种粮食晒收装置，包括：收集箱，吸粮装置，绞龙，传输带，传输带电机，万向轮，蜗杆电机，锥齿轮电机，蜗轮蜗杆，锥齿轮，曲柄摇杆，丝杆，传动轴，单片机，中转槽，电机支架，内外直齿轮，晒粮台，粮食拨杆，收放支撑杆，升降套筒；其特征在于：在小车焊接了两根支架，与下方的四个万向轮配合方便人员推动，所述的蜗杆电机带动蜗轮蜗杆转动，所述丝杆带动小圆环上的大小支撑杆使晒粮台放下，所述的小圆环与收放支撑杆是通过铰链连接的，所述的收集箱可以独立放置，工作时需要人为放置至小车上端，所述的吸粮装置底部是直通于收集箱内的粮食，所述的吸粮装置为其传输粮食的第一个中间环节，通过焊接连接左右各一根握把，正对上方传输带又焊接一个出粮口，所述的上方传输带由电机带动，把从出粮口的粮食送到晒粮台上，所述的粮食拨杆通过转动达到翻粮的功能，所述的大圆环上部分通过铰链连接粮食拨杆，所述的大圆环的下部分有外齿轮与内齿轮啮合，所述的内齿轮上六个铰链座，六个连接杆通过铰链和晒粮台上的孔连接，所述的锥齿轮通过锥齿轮电机带动传动轴上内外齿轮，所述的锥齿轮底座通过小车上的支架支撑，所述的蜗轮蜗杆通过底下底座支撑，所述的单片机、锥齿轮电机、蜗轮蜗杆电机放置在小车上焊接的支撑板，所述的曲柄摇杆通过单片机控制使大圆环向上移动，曲柄摇杆放置在粮食中转槽上方用来支撑晒粮台中心的内齿轮，所述的中转槽放置晒粮台下方千斤顶外壳上，其内部是倾斜的，用来过渡从晒粮台下来的粮食，再其右边有一个方孔，粮食由此到下方传输带，所述的下方传输带通过电机把晒好粮食运回收集箱。进一步，本发明提供的一种粮食晒收装置，所述的集箱箱体为正方体，上方是无盖设计，方便粮食装取。进一步，本发明提供的一种粮食晒收装置，所述的粮装置、上下传输装置均可以自由拆卸。进一步，本发明提供的一种粮食晒收装置，所述的万向轮是焊接在小车下方支架上的，这种方式固定可靠。进一步，本发明提供的一种粮食晒收装置，所述的晒粮台分为六个大小相同的扇形区域，且与收放支

撑杆接触的位置有四个盲孔；其中，当结束晒粮的时候，晒粮台由水平放置收至竖直，这样可以节省空间。进一步，本发明提供的一种粮食晒收装置，所述的丝杆是用来进行配合小圆环和收放支撑杆，让晒粮台进行收放；其中，所述的丝杆会有一段伸到小车下方的通孔，这不会影响小车的平衡。

本发明取得的有益效果在于：(1)可以减少人工工作量，节约人力资源；(2)便于粮食收集完成后的运输操作；(3) 占地面积小，转向调整灵活方便，可以推到任意平地进行操作，实用性高；（4）整体操作简便，高效安全。

附图说明

图 1 是本发明的三维图。

图 2 是本发明的主视图。

图 3 是本发明的图 2 的局部放大图。

图 4 是本发明晒粮台收起时的三维图。

图 5 是本发明吸粮装置的绞龙示意图

附图标记说明如下：

1-收集箱；2-握把；3-出粮口；4-上方传送带；5-上方带电机；6-下方传送带；7-万向轮；8-蜗杆电机；9-锥齿轮电机；10-晒粮台；11-内齿轮；12-大圆环及外齿轮；13-传动轴；14-传动丝杆；15-收放支撑杆；16-小圆环；17-晒粮台连接杆；18-粮食拨杆；19-绞龙；20-下方带电机；21-齿轮外壳；22-中转槽；23-单片机；24-曲柄摇杆；25-升降套筒；26-蜗轮底座；27-蜗轮；28-蜗杆及轴；29-锥齿轮底座；30-锥齿轮；31-锥齿轮轴

具体实施方式

下面结合以上附图详细描述实施例，本发明提供的一种粮食晒收装置，包括在小车前后焊接了两根支架，晒粮时，把小车推到合适的平地然后固定万向轮 7，蜗杆电机 8 带动蜗轮蜗杆转动，丝杆 14 带动小圆环 16 上的收放支撑杆 15 使晒粮台 10 放下，收集箱 1 可以独立放置，工作时需要人为放至小车上端，吸粮装置底部是直通于收集箱 1 内的粮食，吸粮装置为其传输粮食的第一个中间环节，通过焊接连接左右各一根握把 2，正对上方传输带 4 又焊接一个出粮口 3，上方传输带 4 由电机 5 带动，把粮食送到晒粮台 10 上 ，粮食拨杆 18 通过转动达到翻粮的功能，晒粮结束后曲柄摇杆 24 通过单片机 23 控制使大圆环 12 向上移动，

晒粮台 10 上的粮食落到中转槽 22 内，再从右边方孔滑到下方传输带 6，最后通过下方传输带把晒好粮食运回收集箱。

根据附图所示，大圆环 12 的下部分有外齿轮，上部分有铰链座，内齿轮 11 上有六个铰链座，六个连接杆 17 通过铰链和晒粮台 10 上的孔连接。

根据附图所示，锥齿轮 30 通过锥齿轮电机 9 带动传动轴 13 上内外齿轮，粮食拨杆 18 通过铰链与大圆环 12 连接进行转动。

根据附图所示，中转槽 22 放置晒粮台 10 下方，齿轮外壳 21 上，其内部是倾斜的，用来过渡晒粮台 10 下来的粮食。

根据附图所示，蜗杆电机 8 带动蜗轮蜗杆上的丝杆 14 旋转，丝杆上的小圆环 16 通过铰链与收放支撑杆 15 连接，收放支撑杆的小杆于晒粮台 10 进行孔接触，从而达到晒粮台收放。

根据附图所示，锥齿轮和蜗轮蜗杆底座都是由小车上的支架支撑的。

以上所述，为本发明的具体实施方式，但本发明的实施方式并不局限于此，凡 在本发明范围内所作的任何修改、等同替换和改进等，均包含在本实用新型的保护范围之内。

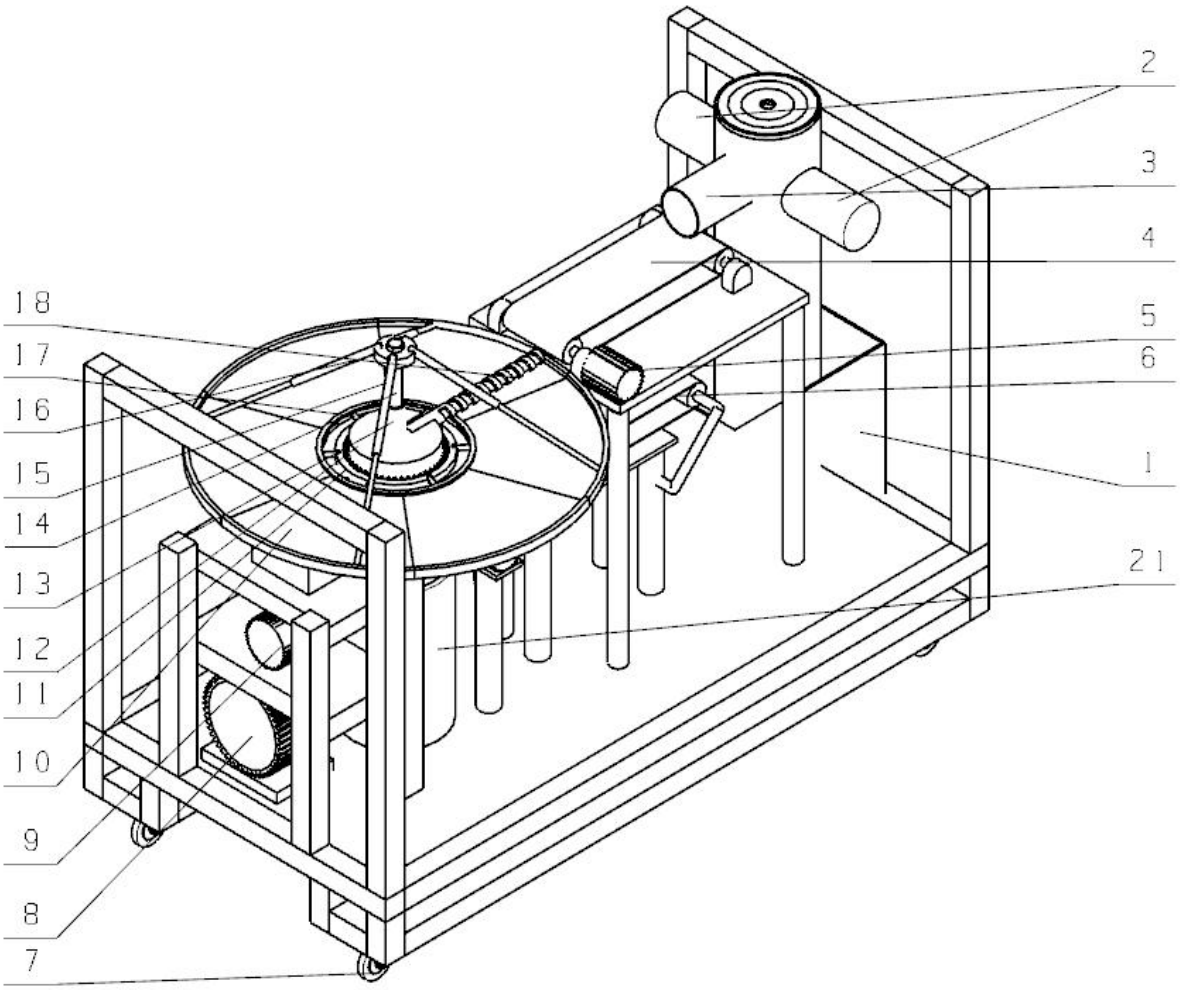


图 1

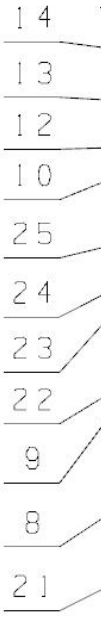


图 2

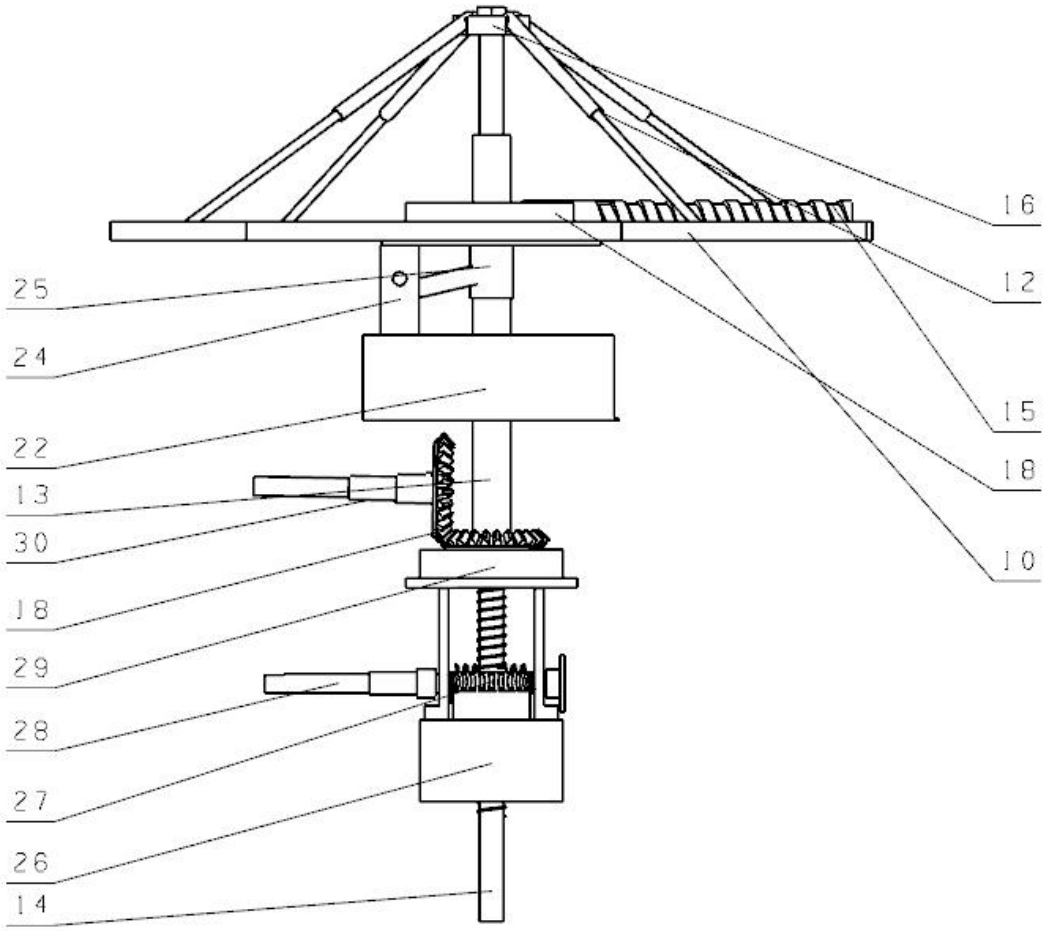


图 3

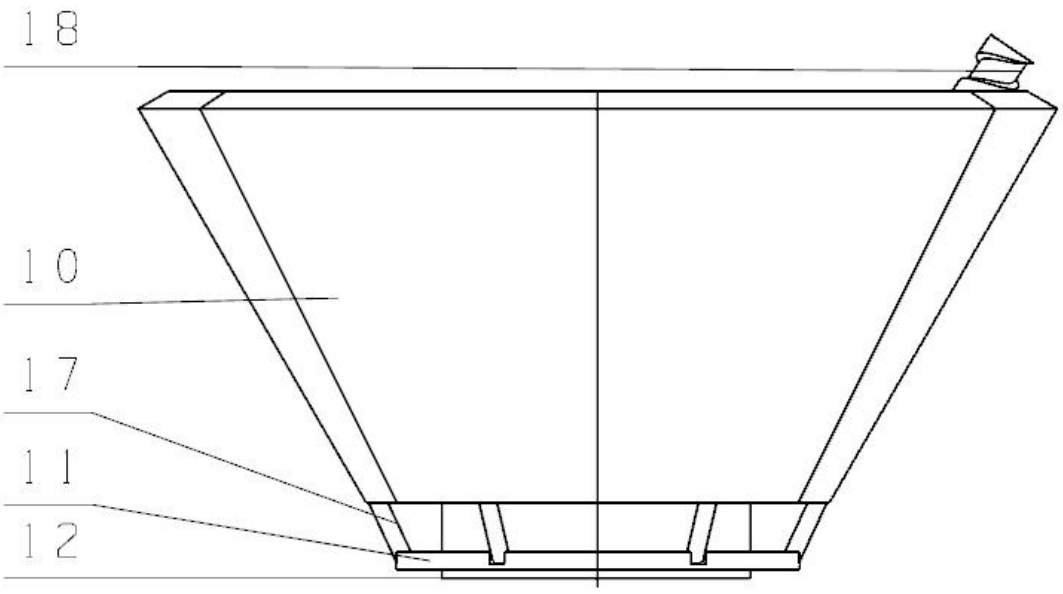


图 4

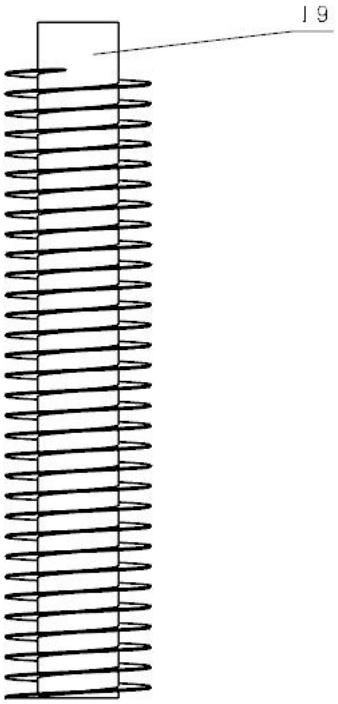


图 5

申请材料分析说明

1.基础信息

专利名称：一种粮食晒收装置

状态：非正常——主动撤回

2.非常分析

可能的非正常原因：

所提出的专利申请的发明创造为明显不符合技术改进、设计常理，或者变劣、堆砌、非必要限缩保护范围的。——《规范申请专利行为的规定》第三条（四）

内容分析：

本案是一种生产生活类的工具器械，提出了一种替代人工实现自动化地晒粮装置，也即本案针对的技术问题是“如何替代人工实现自动化”。对于这种机器替人的“自动化”，往往不太好认可为是一种恰当的技术问题。因为凡是手工操作的，都能够去用机械代替实现自动化，这更多是一种产品开发层面的功能需求问题，而非技术问题。

技术问题准确来说是指：在人们想要做而难以做成某事过程中，所存在的技术层面困难障碍。而很多机械替人的自动化设计，是只要有这一需求就能基于当下现有技术得到实现的，因此其中并不存在技术问题。

就本案给出的机械结构设计而言，其虽然理论上实现了自动化晒粮，但是相比设备的体积，其有效晒粮面积却较小；根据一般人的生活认知可知，即使是农村家庭晒粮，往往都会要铺满几十到一两百平的面积。因此本案仅仅只是做到了一种理论上可行的设计，但严重缺乏实用性，技术繁琐却只是实现效率低下的简单功能，因此是“以复杂手段实习简单功能”而被认定为“不符合设计常理”的非正常专利申请。

一种阻尼减振刀柄（非正常）

技术交底书

说明书摘要

本发明专利涉及刀柄技术领域，涉及一种在铣削加工中监测振频和提高稳定性的装置。是一种惯性比常规的刀柄惯性更大，刀柄更不易振动，抗震性能大幅提高的一种应用金属阻尼的多轴监测减震刀柄。使用机床进行铣削加工的过程中，铣刀由于切深、材料纯度以及切屑的形成等因素影响，切削工件时刀刃处产生的切削力发生变化产生振动；断续切削振动比连续切削振动大经常会遇到深孔、深槽等难加工的工况，随着近年来难加工材料的应用和高速切削的技术推广，振动成为了提高加工效率的的障碍之一，振动的产生直接影响了交给你个精度和表面粗糙度，使刀具磨损加快，甚至产生崩刀，降低刀具寿命，振动使得机床各齿轮受损，精度下降。无线振动传感器可对旋转设备的垂直和水平振动、温度进行长期的实时监测，并且内置国标的状态识别，可分析、预判设备状态。无线振动传感器的优点：采用无线传感器网络技术监测机械振动可以实现实时监测刀具振频。针对监测旋转机械的特定需要，传感器应当具备成本和功耗低、体积小、安装简便的特点，并且具有高效测量多轴向的高频振动信号、实时存储大数据量和可靠传输数据等性能。切削加工的问题进行了研究设计出了这一种智能监测刀具振频并提高稳定性的多轴刀柄。

为解决这一系列的问题，本发明对如何减少刀具振动形螺栓的螺杆接头与伸入主轴轴孔中的刀柄内螺孔连接；(1)拉钉（2）上刀柄：与主轴连接的锥柄，同时下刀柄提供固定并振动；（3）下刀柄：为阻尼组件，减震螺和定位头提供安装位置；（4）第一限位块：与减振柱螺纹连接，对阻尼单元进行限位；（5）缓冲垫：抵消掉轴径方向上分力的振动；（6）阻尼：采用高密度金属制作，从而使刀柄抗震性能大幅提高；（7）限位轴：限制定位头的移动；（8）定位轴：对阻尼组件和弹性组件进行限位同时为刀具的安装提供位置；（9）垫圈：安装在缓冲垫两侧，用于固定缓冲垫；（10）阻尼油密封胶圈：防止阻尼油漏出；（11）减震柱：抵消部分振动所述减震柱的材料为钨；（12）减震胶圈：一定程度上抵消径向产生的分力震动；（13）弹性垫：通过其产生的预紧力防止螺钉松动；（14）钢垫：垫圈预紧力的下压面积；（15）弹簧：抵消轴向产生的分力震动；（16）螺钉：固定弹簧，并为弹簧提供压力；（17）容纳腔：为阻尼组件和弹性组件提供安装位置，容置腔内设有减震柱，刀柄不易振动，抗震性能好；（18）第二限位块；对阻尼单元进行限位；（19）密封垫圈；防止漏油；(20) 阻尼组件；用于提高刀柄的惯性从而使刀柄抗震性能大幅提高；（21）阻尼固定螺栓；与锥度螺栓连接；（22）

抗震胶圈；抵消径向产生的震动，

本发明装置在下刀柄内设置有容纳腔。容纳腔内设有阻尼单元。该阻尼单元与下刀柄弹性连接与减振柱弹性连接。当震动传来时减振柱能够将震动传递给阻尼单元。在此过程中振动则会在减振柱与阻尼单元之间的弹性运动中消耗掉一部分。与此同时上述限位块中的抗震胶圈能够抵消掉一部分的径向方向上的力产生的分力震动。缓冲垫组件以及弹簧则能抵消掉大部分轴径方向上分力的振动。由于上刀柄与下刀柄为弹性连接。下刀柄能通过其中的凹槽进行小幅度的移动，抵消掉一部分的震动，从而提高减震效果。由于减振柱及组尼单元以高密度合金为材料。刀柄内部装有振动传感器，与计算机软件相配合，通过 PID 大数据模糊推导，PID 控制对铣削机械加工稳进行定性分析,建立了振动传感器智能检测系统。可以对加工时的刀柄内部情况进行检测分析，让操作者更加了解加工过程时刀具的受力。让操作者实时了解刀柄振频，抗震性大幅提高。从而提高加工机床的使用寿命。并提高了加工效率。

权利要求书

1.一种在铣削加工中实时监测振频和提高稳定性的装置，其特征，一种减震刀柄，包括前刀体及用于安装刀具的后刀体所述下刀柄的右端面与定位头通过销连接；所述下刀柄沿轴向设置有容纳腔，所述1容纳腔内安装有阻尼组件、减震组件和减振柱，所述阻尼组件包括限位块、阻尼单元、抗震胶圈、密封胶圈；所述阻尼组件套设在减振柱上，所述减震件包括螺钉、弹簧、钢垫、弹性垫。所述减震模块包括阻尼块及弹性单元，所述 弹性单元设置在所述阻尼块与前刀体及后刀体之间，减振柱通过定位头固定于下刀柄右侧，拉钉穿过上刀柄沿轴线打的通孔与下刀柄容纳腔左侧进行螺纹连接。减震柱右端可安装各类刀具。监测振频的装置传感器安装在刀柄外侧后将安装位置填胶固定，避免高速工作下影响刀柄动平衡，振动信号传至数据终端形成振幅波形图一种金属阻尼的多轴减震刀柄。

2，根据权利要求1一种在铣削加工中实时监测振频和提高稳定性的装置，其特征在于：阻尼组件包括限位块、缓冲垫、阻尼单元、垫圈、密封胶圈，所述限位块包括第一限位块和第二限位块，所述限位块通过螺纹与减振柱连接且限位块外侧设有凹槽，所述凹槽用于安装抗震胶圈。采用上述进一步方案的有益效果是，定位凹槽可实现对弹性单元进行稳定定位以便于稳定定位的弹性单元能够配合阻尼块满足减震的效果。所述定位凹槽设有四个，四个所述装置分别设置在所述阻尼块的前端、后端及外表面的前端及后端上。采用上述进一步方案的有益效果是，弹性单元对应设置在定位凹槽内，弹性单元设置在阻尼块的轴向截面的四个角位置，四个弹性单元能对阻尼块起到很好的支撑和保护作用。监测振频的装置传感器安装在

刀柄外侧后将安装位置填胶固定，避免高速工作下影响刀柄动平衡，振动信号传至数据终端形成振幅波形图一种金属阻尼的多轴减震刀柄。

3.根据权利要求 2 所述的所述的一种在铣削加工中实时监测振频和提高稳定性的装置，其特征在于：第二限位块的内径大于第一限位块。

4.根据权利要求 2 所述的所述的一种在铣削加工中实时监测振频和提高稳定性的装置，其特征在于：阻尼单元用高密度的高密度合金做成，所述阻尼单元打有注油孔（流体减振）阻尼单元与下刀柄及减振柱之间有间隙，间隙内有阻尼油。前刀体与后刀体之间设有密封件。方案的有益效果是，一方面增加前、后刀体的密封性，另一方面保证减震腔内压力稳定性，避免减震阻尼油的泄漏 。监测振频的装置传感器安装在刀柄外侧后将安装位置填胶固定，避免高速工作下影响刀柄动平衡，振动信号传至数据终端。通过 PID 大数据模糊推导，PID 控制对铣削机械加工稳进行定性分析,建立了振动传感器智能检测系统，振动传感器采集振动加速度、速度、位移信息，内置频域分析等智能算法形成振幅图；输出实时振幅图提供给操作者可视化监测，

减震组件可以被认为是一种弹簧-阻尼系统，为了达到较好的减震效果，我们要对系统中的弹簧以达到最佳的减震效果，为此建立如下的单元阻尼模型：

流体阻力是指流体经过一定形状的物体时，产生的抵抗力。其计算公式为:阻力系数

Kx 流体密度 px 流速 ux 流速 ux 物体面积 A，即 $F=Kpu^2A$

流体阻力是流体运动中不可缺少的一个重要组成部分，它是流体动力学研究中不可忽视的因素。在实际应用中，流体阻力的大小对系统的性能有很大的影响，如流道尺寸、结构形状等都会影响流体阻力。

5. 根据权利要求 1 所述的一种在铣削加工中实时监测振频和提高稳定性的装置，其特征在于，所述减震组件包括弹性垫、钢垫、弹簧和螺钉，螺钉通过螺纹与刀柄内部的容纳腔连接，所述减震组件右侧与减振柱连接。采用上述进一步方案的有益效果是，前刀体与后刀体之间的连接具体可以是通过 螺纹进行连接，如后刀体的前端有连接圆柱部，前刀体上有带有内螺纹的插装孔，连接圆柱部的外表面上设有与插装孔配合的外螺纹，通过螺纹配合可以实现前刀体与后刀体之间的连接，前刀体与后刀体通过螺纹连接，提高连接强度，也起到密封作用。

6. 根据权利要求 5 所述的一种在铣削加工中实时监测振频和提高稳定性的装置，所述减震组件中的弹性垫外侧与下刀柄容纳腔接触，其端面与减振柱接触，起到防止阻尼油漏出的作用。保证减震腔内压力稳定性。

7.根据权利要求 1 所述的一种在铣削加工中实时监测振频和提高稳定性的装置，其特征在于，减振柱尺寸，其左端直径小于右端的直径。

8. 根据权利要求 1 所述的监测振频的装置传感器安装在刀柄外侧后将安装位置填胶固定，避免高速工作下影响刀柄动平衡，振动信号传至数据终端形成振幅波形图。振动传感器采集振动加速度、速度、位移信息，内置频域分析等智能算法；输出实时振幅图提供给操作者可视化监测。

通过 PID 大数据模糊推导，PID 控制对铣削机械加工稳进行定性分析,建立了振动传感器智能检测系统，PID 控制器是一种线性控制器，它根据给定值 r(t)与实际输出值 y(t)构成偏差：e(t)=r(t)-y(t)。将偏差的比例(P)、积分(I)和微分(D)通过线性组合构成控制量，对受控对象进行控制。其控制规律为：

$$u(t)=K_p\left[e(t)+\frac{1}{T_i}\int_0^t e(t)\,dt+T_d\frac{de(t)}{dt}\right]=K_pe(t)+K_i\int_0^t e(t)\,dt+K_d\frac{de(t)}{dt}$$

Kp 为比例系数，Ti 为积分时间常数，Td 为微分时间常数；Ki=Kp/Ti，为积分系数；Kd=Kp*Td，为微分系数。

技术领域

一种实用新型涉及刀柄技术领域，一种在铣削加工中实时监测振频和提高稳定性的装置

背景技术

使用机床进行加工的过程中，经常会遇到深孔、深槽等较难加工的工况，要求加工刀具的长径比大，容易导致刀具磨损加剧，甚至导致刀具弯曲和断裂。在实际生产过程中会有很多复杂难加工的工况所使用的长径比往往会大于 1，特别是在刀具高速运转过程中则会产生较大的震动。

振动会直接影响了工件的精度和表面粗糙度，同时振动也会导致零件产生应力，可能影响零件的强度和稳定性。同时振动使得机床各部件之间的受损，精度下降，严重时会使切削加工无法进行。随着现有材料种类的更新不断，难加工材料也越来越多的应用到产品中。加工震动问题也成为了提高加工效率和加工质量的最大障碍，同时降低了机床使用寿命，也降低了生产效率，加工成本也大幅提高。

以上的振动带来的种种问题需要进行研究解决

发明内容

本发明装置所要解决的问题是：提供一种在铣削加工中实时监测振频和提高稳定性的装置

用于解决刀具振动的问题。以及实时监测

本发明装置为解决上述问题所提供的技术方案为：一种在铣削加工中实时监测振频和提高稳定性的装置。包括上刀柄和下刀柄以及定位头，还有阻尼组一通孔，拉钉穿过该通孔与下刀柄上设有的容纳腔类的螺纹旋合。容纳腔内设有螺钉、弹簧、钢垫、弹性垫等等。其中螺钉通过螺纹与下刀柄连接，在容纳腔内弹簧置于钢垫与螺钉之间。钢垫靠近定位头的一端设有弹性垫。弹性垫的右侧与减振柱相接触。减振柱的右侧上有螺纹能与限位块通过螺纹连接到一起。限位块上设有凹槽。凹槽上有抗震胶圈。而限位块的右侧具有缓冲垫，缓冲垫的两侧就设有垫圈，将其夹在中间。在减振柱与下刀柄之间的空间内还设有阻尼组件。阻尼组件包括有阻尼单元。阻尼单元内侧与减振柱以及外表面与下刀柄的间隙之间有减震油。并通过密封胶圈防止减震油泄露。减振柱的最右侧有螺纹，能与螺帽旋合方便夹持刀具。在下刀柄的右侧设有一通孔。在对应位置的定位头上也同样设有通孔。这两个瞳孔是用于放置被定位销穿过。同时定位头的右端面同样也设有缓冲垫及垫圈。同样的。垫圈分别置于缓冲垫的左右端面。监测振频的装置传感器安装在刀柄外侧后将安装位置填胶固定，避免高速工作下影响刀柄动平衡，振动信号传至数据终端形成振幅波形图。振动传感器采集振动加速度、速度、位移信息，内置频域分析等智能算法；输出实时振幅图提供给操作者可视化监测。

1.在一种优选的实施方式中，包括上刀柄和下刀柄，所述下刀柄的左端面与所述上刀柄配合，所述下刀柄的右端面与定位头通过销连接；所述下刀柄沿轴向设置有容纳腔，所述容纳腔内安装有阻尼组件、减震组件和减振柱，所述阻尼组件包括限位块、阻尼单元、抗震胶圈、密封胶圈；所述阻尼组件套设在减振柱上，所述减震组件包括螺钉、弹簧、钢垫、弹性垫。所述减震组件安装于减振柱的左端面并位于下刀柄的容纳腔内，减振柱通过定位头固定于下刀柄右侧，拉钉穿过上刀柄沿轴线打的通孔与下刀柄容纳腔左侧进行螺纹连接。减震柱右端可安装刀具。多轴精密刀柄外部装有振动传感器，与计算机软件相配合，建立了振动传感器智能检测系统。可以对加工时的刀柄内部情况进行检测分析，让操作者更加了解加工过程时刀具的受力情况。

2.在一种优选的实施方式中，阻尼组件包括限位块、缓冲垫、阻尼单元、垫圈、密封胶圈和孔塞，所述限位块通过螺纹与减震柱连接且外侧设有凹槽，所述凹槽用于安装抗震胶圈。

3.在一种优选的实施方式中，第二限位块的内径大于第一限位块。

4.在一种优选的实施方式中，阻尼单元用高密度的高密度合金做成，所述阻尼单元打有注油孔，注油孔内有孔塞。阻尼单元与下刀柄及减振柱之间有间隙，间隙内有阻尼油。

5.在一种优选的实施方式中，其特征在于，所述减震组件包括弹性垫、钢垫、弹簧和螺

钉，螺钉通过螺纹与下刀柄内部的容纳腔连接，所述减震组件右侧与减振柱连接。消除减振组件内部共振。

6. 在一种优选的实施方式中，所述下刀柄与定位头的连的接处设置有定位孔，所述定位头上与定位孔对应的位置上也设置有定位孔并通过定位销连接。

7.在一种优选的实施方式中，其特征在于，减振柱左端的直径小于右端的直径。

本发明装置的有益效果是：

本发明装置在下刀柄内设置有容纳腔。容纳腔内设有阻尼组件。该阻尼组件与下刀柄弹性连接，同时。也与减振柱弹性连接。当震动传来时减振柱能够将震动传递给阻尼单元。在此过程中振动则会在减振柱与阻尼单元之间的弹性运动中消耗掉一部分。与此同时上述限位块中的抗震胶圈能够抵消掉一部分的径向方向上的力产生的分力震动。缓冲垫组件以及弹簧则能抵消掉大部分轴径方向上分力的振动。由于上刀柄与下刀柄之间的连接方式为弹性连接。下刀柄能通过其中的凹槽进行小幅度的移动，从而进一步地抵消掉一部分的震动。从而提高。由于减振柱及组尼单元以高密度合金为材料。它们使得刀柄整体的惯性比常规的刀柄惯性更大，刀柄更不易振动，抗震性能大幅提高。多轴精密刀柄外部装有振动传感器，与计算机软件相配合，建立了振动传感器智能检测系统。监测振频的装置传感器安装在刀柄外侧后将安装位置填胶固定，避免高速工作下影响刀柄动平衡，振动信号传至数据终端形成振幅波形图。振动传感器采集振动加速度、速度、位移信息，内置频域分析等智能算法。可以对加工时的刀柄内部情况进行检测分析，输出实时振幅图提供给操作者可视化监测，让操作者更加了解加工过程时刀具的受力情况。从而提高加工机床及刀具的使用寿命。

需要说明的是，如无特殊说明，当某一特征被称为“固定”、“连接”在另一个特征，它可以直接固定、连接在另一个特征上，也可以间接地固定、连接在另一个特征上。此外，本 实用新型中所使用的上、下、左、右等描述仅仅是相对于附图中本发明装置各组成部分的相互位置关系来说的。

此外，除非另有定义，本文所使用的所有的技术和科学术语与本技术领域的技术人员通常理解的含义相同。本文说明书中所使用的术语只是为了描述具体的实施例，而不是为了限制本发明装置。本文所使用的术语“及/或”包括一个或多个相关的所列项目的任意的组合。

附图说明

下面结合附图和实施例对本发明装置做进一步说明。

图 1 是本发明专利一个实施例的抗震刀柄的剖视图；

图 2 是本发明专利一个在线实时监测流程全；

附图标注：1-拉钉；2-上刀柄；3-下刀柄；4-第一限位块；5-缓冲垫；6-监测模块；7-定位销；8-定位头；9-垫圈；10-密封胶圈 ；11-减振柱；12-抗震胶圈；13-弹性垫；14-钢垫；15-弹簧；16-螺钉；17-容纳腔；18-第二限位块；19-密封垫圈；20 -阻尼组件；21-阻尼固定螺栓；22-抗震胶圈

具体实施方式

以下将结合实施例和附图对本发明装置的构思、具体结构及产生的技术效果进行 清楚、完整的描述，以充分地理解本发明装置的目的、方案和效果。本文说明书中所使用的术语只是为了描述具体的实施例，而不是为了限制本发明装置。本文所使用的术语“及/或”包括一个或多个相关的所列项目的任意的组合。

本发明装置的具体实施例如附图所示：1-拉钉；2-上刀柄；3-下刀柄；4-第一限位块；5-缓冲垫；6-监测模块；7-定位销；8-定位头；9-垫圈；10-密封胶圈 ；11-减震柱-；12 抗震胶圈-；13-弹性垫；14-钢垫；15-弹簧；16-螺钉；17-容纳腔；18-第二限位块；19-密封垫圈；20 -阻尼组件；21-阻尼固定螺栓；22-抗震胶圈

上刀柄 2 沿轴线方向打有一通孔，拉钉 1 穿过通孔与下刀柄 3 上设有的容纳腔内左侧的螺纹旋合。容纳腔内设有螺钉 16、弹簧 15、钢垫 14、弹性垫 13 阻尼组件。其中螺钉 16 通过螺纹与下刀柄 3 连接，在容纳腔内弹簧 15 置于钢垫 14 与螺钉 16 之间。钢垫 14 靠近定位头 8 的一端设有弹性垫 13。弹性垫 13 的右侧与减振柱 11 相接触。减振柱 11 的右侧上有螺纹能与限位块 4 通过螺纹连接到一起。限位块 4 上设有凹槽。凹槽上设有抗震胶圈 12。而限位块的右侧具有缓冲垫 5，缓冲垫 5 的两侧设有垫圈 9，将缓冲垫 5 夹在中间。在减振柱 11 与下刀柄 3 之间的空间内还设有阻尼组件。阻尼组件包括有阻尼单元 7、限位块 4。阻尼单元 6 内侧与减振柱 11 以及外表面与下刀柄的间隙之间有阻尼油。并通过密封胶圈 10 防止减震油泄露。减振柱 11 的最右侧有螺纹，能与螺帽旋合方便夹持刀具。在下刀柄 3 的右侧设有一通孔。在对应位置的定位头 8 上也同样设有通孔。这两个通孔是用于被定位销 8 穿过。同时定位头 8 的右端面同样也设有缓冲垫 5 及垫圈 6。同时垫圈 6 置于缓冲垫 5 的左右端面。

在本实施例中，所述阻尼单元 7 的内侧与减振柱 11 之间具有间隙，所述阻尼单元 7 的两端设置有固定槽，所述固定槽内安装有密封胶圈 10，所述密封胶圈 10 的内圆圈面与减振柱

11 的外圆周面接触，所述阻尼单元 5 与锁紧螺杆 10 之间的间隙内填充有减震油。

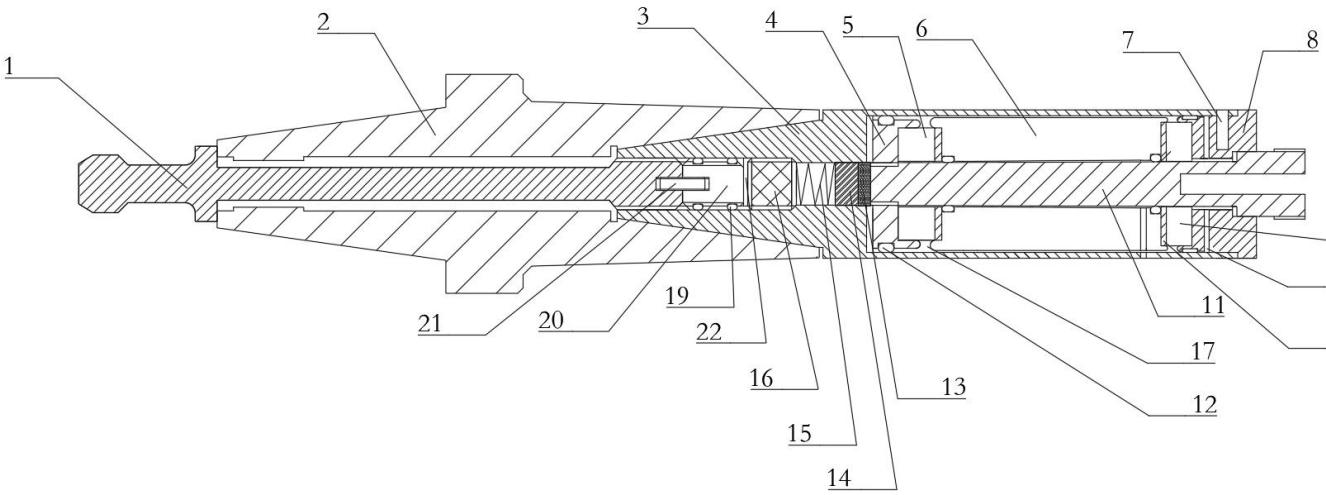
其中，所述阻尼单元 20 采用高密度的高密度合金做成。可以在有限的空间内达到最大质量，并通过抗震胶圈 12、垫圈 9 和缓冲垫 5 支撑在下刀柄 3 的容纳腔内，使刀具在切削过程中，刀柄前端刀具发生振动变形第一时间因阻尼体自身频率与刀柄前端的频率相反，并且加之减震油的原因产生一定的缓冲，其利用相反的作用力之间施加阻尼来抵消振动，抗震胶圈能抵消径向产生的分力震动，缓冲垫大部分来抵消轴向产生的分力震动。

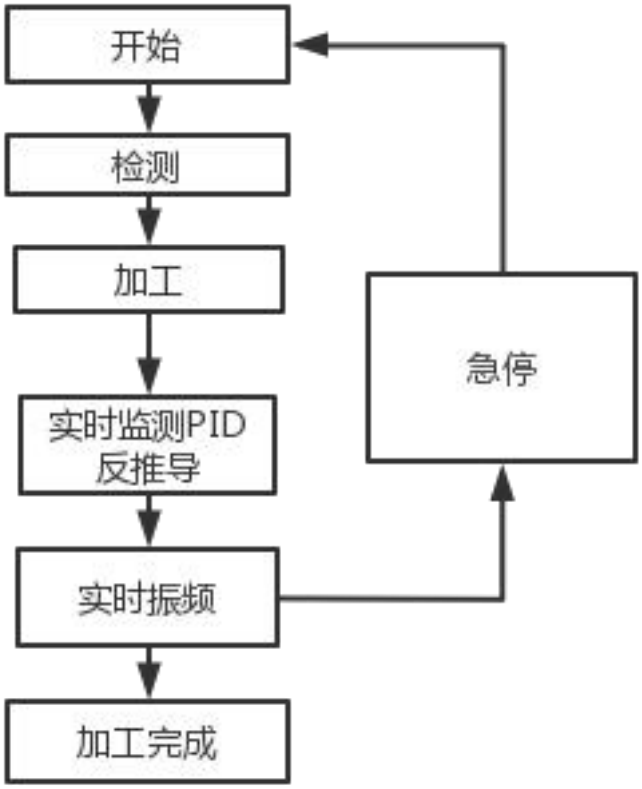
进一步的，当振动较大的时候减振柱 11 的左端通过弹簧 15 与下刀柄 3 连接，弹性元件夹持在螺钉 16 与减振柱 11 之间，其中，所述弹性元件包括弹性垫 13、钢垫 14、弹簧 15 在本实施例中，弹性元件 7 为压缩弹簧，弹性垫 13 的材质为橡胶。当刀具将振动传导至减振柱 11 时，振动能量消耗在减振柱 11 与 下刀柄 3 的弹性远动中，从而使得振动减弱。
进一步的，可使减振柱 11 的密度与阻尼单元 6 的密度相等并大于下刀柄 3 的密度，由此，刀柄的惯性增大，刀柄不易振动。并通过监测振频的装置实时检测振动台的振动信号拾取，并转换为电信号使用 A/D 转换应当注意的是模拟信号输入电压不能超过 A/D 芯片所规定的最大输入电压，然后将振动的模拟信号转换为数字信号，完成对振动信号的采集。由从蓝牙模块实现对振动信号的无线发射，最后将其变换结果的频谱曲线也显示在用户界面上，方便我们直观地了解振动情况。

为进一步减震，下刀柄 3 的左端设置有锥形的接头，上刀柄 2 的右端对应设置有锥形的凹槽，接头插接在凹槽中，同时上刀柄 2 沿轴心方向设置有通孔，拉钉 1 的右端穿过通孔后与下刀柄容纳腔内壁上的内螺纹进行螺纹连接，拉钉 1 还与上刀柄 2 的左端面抵持，由此可使接头与凹槽 18 抵持，下刀柄 3 的振动传导至上刀柄 2 上时，由于凹槽可轻微张开，接头与凹槽为一种弹性的连接方式，振动能量在此会消耗一部分。

上刀柄 2 的左端设置有锥形的接头，该接头可用于与机床主轴进行连接。

本发明方案所公开的技术手段不仅限于上述技术手段所公开的技术手段，还包括以上技术特征等同替换所组成的技术方案。本发明的未尽事宜，属于本领域技术人员的公知常识。


1
2
3
4
5
6
7
8
11
12
13
14
15
16
17
19
20
21
22


开始
检测
加工
实时监测PID
反推导
实时振频
加工完成
急停

图二

申请材料分析说明

1.基础信息

专利名称：一种阻尼减振刀柄

状态：非正常——主动撤回

2.非常分析

可能的非正常原因：

所提出的多件专利申请的发明创造内容明显相同，或者实质上由不同发明创造特征、要素简单组合形成的——《规范申请专利行为的规定》第三条（一）

内容分析：

本案发明人为应对专利申请以外的目的，而刻意追求专利数量，硬是拆分出多件相似专利；除本案外，同期申请的相似专利还有 202310866116.2《一种多工位式锥度可调节刀柄》。

另一方面，本案技术内容也相对较为简单，主要是在刀柄内设置缓冲弹簧和阻尼结构，此属于阻尼减振的常规手段，并存在较为类似的现有技术如 201810724639.2《一种卧式装配型减振铣刀》。

敬業
樂羣