



(21) 申请号 202311595862.9

(22) 申请日 2023.11.28

(65) 同一申请的已公布的文献号

申请公布号 CN 117313552 A

(43) 申请公布日 2023.12.29

(73) 专利权人 菏泽学院

地址 274000 山东省菏泽市大学路

(72) 发明人 卢胜杰 王康

(74) 专利代理机构 北京中济纬天专利代理有限公司 11429

专利代理师 黄攀

(51) Int. Cl.

G06F 30/27 (2020.01)

G06F 30/23 (2020.01)

G06N 3/0464 (2023.01)

G06N 3/084 (2023.01)

G06N 3/0985 (2023.01)

G06F 119/02 (2020.01)

G06F 111/10 (2020.01)

(56) 对比文件

CN 114600165 A, 2022.06.07

CN 116702678 A, 2023.09.05

CN 109279622 A, 2019.01.29

US 2010268519 A1, 2010.10.21

US 2022200780 A1, 2022.06.23

王刚. 基于神经网络的TFET器件优化和性能预测研究.《中国优秀硕士学位论文全文数据库信息科技辑 (月刊)》.2022, 全文.

Dongil Kim 等. Effect of Irrelevant Variables on Faulty Wafer Detection in Semiconductor Manufacturing.《energies》.2019, 全文.

审查员 于湃

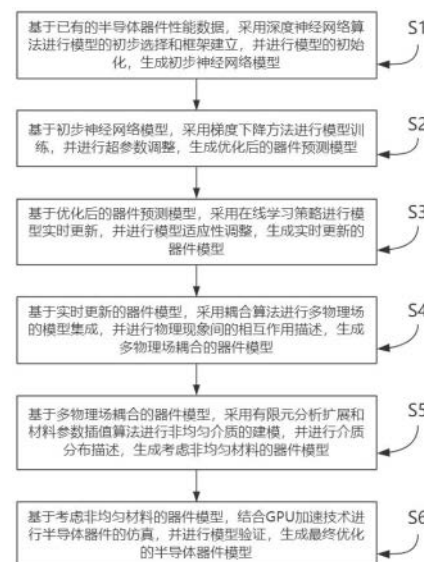
权利要求书4页 说明书17页 附图9页

(54) 发明名称

半导体器件建模方法、系统及电子设备

(57) 摘要

本发明涉及微电子学技术领域, 具体为半导体器件建模方法、系统及电子设备, 包括以下步骤: 基于已有的半导体器件性能数据, 采用深度神经网络算法进行模型的初步选择和框架建立, 并进行模型的初始化, 生成初步神经网络模型。本发明中, 通过深度神经网络, 构建半导体器件性能的预测框架, 结合梯度下降优化算法, 减小模型误差, 确保性能的优化, 在线学习策略允许模型根据新数据实时调整, 以适应不断变化的环境和数据, 耦合算法考虑了电子传输、热传导和光学效应, 为器件提供了多场耦合的全面模拟, 通过有限元分析扩展和材料参数插值算法, 模型能考虑非均匀材料的属性和分布, 提高准确性, GPU加速技术确保了高效仿真, 经过严格验证和优化。



1. 一种半导体器件建模方法,其特征在于,所述方法包括以下步骤:

基于已有的半导体器件性能数据,采用深度神经网络算法进行模型的初步选择和框架建立,并进行模型的初始化,生成初步神经网络模型;

基于所述初步神经网络模型,采用梯度下降方法进行模型训练,并进行超参数调整,生成优化后的器件预测模型;

基于所述优化后的器件预测模型,采用在线学习策略进行模型实时更新,并进行模型适应性调整,生成实时更新的器件模型;

基于所述实时更新的器件模型,采用耦合算法进行多物理场的模型集成,并进行物理现象间的相互作用描述,生成多物理场耦合的器件模型;

基于所述多物理场耦合的器件模型,采用有限元分析扩展和材料参数插值算法进行非均匀介质的建模,并进行介质分布描述,生成考虑非均匀材料的器件模型;

基于所述考虑非均匀材料的器件模型,结合GPU加速技术进行半导体器件的仿真,并进行模型验证,生成最终优化的半导体器件模型;

所述深度神经网络具体为多层前馈神经网络,用于抽象数据特性,所述初步神经网络模型具体指为半导体器件性能的预测框架,所述梯度下降具体为优化算法,用于减少模型误差,所述优化后的器件预测模型包括参数调整、特性学习和性能优化,所述在线学习具体指模型根据新数据进行动态调整,所述实时更新的器件模型具体为适应新数据和环境变化的模型,所述耦合算法具体为同时处理电子传输、热传导和光学效应的数值算法,所述多物理场耦合的器件模型包括电、热、光多场耦合的综合模拟,所述有限元分析扩展具体为针对非均匀材料分布的建模策略,所述考虑非均匀材料的器件模型具体指模拟器件中材料属性和分布的模型,所述GPU加速具体为使用图形处理单元进行的并行计算技术,所述最终优化的半导体器件模型具体为经过验证和优化的模型,用于实际应用中的器件性能预测和设计。

2. 根据权利要求1所述的半导体器件建模方法,其特征在于,基于已有的半导体器件性能数据,采用深度神经网络算法进行模型的初步选择和框架建立,并进行模型的初始化,生成初步神经网络模型的步骤具体为:

基于已有半导体器件性能数据,采用数据标准化方法,进行数据的清洗和格式化,生成预处理后的器件数据;

基于所述预处理后的器件数据,采用深度学习框架张量流,设计深层卷积网络结构,生成初步神经网络框架;

基于所述初步神经网络框架,采用He初始化策略,进行权重的初始化,生成随机初始化的神经网络模型;

基于所述随机初始化的神经网络模型,采用前向传播算法,进行模型的初步评估,生成初步神经网络模型;

所述数据标准化具体为将数据范围缩放到 $[0, 1]$ 或 $[-1, 1]$ 区间内,所述深层卷积网络结构具体为卷积层、池化层和全连接层的组合,所述He初始化具体为根据前一层神经元数量自动调整权重初始值的方法,所述前向传播具体为通过输入数据计算输出结果的过程。

3. 根据权利要求1所述的半导体器件建模方法,其特征在于,基于所述初步神经网络模型,采用梯度下降方法进行模型训练,并进行超参数调整,生成优化后的器件预测模型的步

骤具体为：

基于初步神经网络模型，采用均方误差方法，进行模型预测与真实值的误差计算，生成初步误差评估结果；

基于初步误差评估结果，采用批量梯度下降算法，进行模型的优化训练，生成中间训练模型；

基于中间训练模型，采用网格搜索策略，进行超参数的搜索与确定，生成调整后的超参数集；

基于调整后的超参数集，采用Adam优化器，进行模型的细化训练，生成优化后的器件预测模型；

所述均方误差具体为预测值与实际值之差的平方和的均值，所述批量梯度下降具体为一次处理所有数据进行优化的策略，所述网格搜索策略具体为搜索预设定的超参数范围，寻找最佳组合的方法，所述Adam优化器具体为结合了动量法和RMSProp方法的优化算法。

4. 根据权利要求1所述的半导体器件建模方法，其特征在于，基于所述优化后的器件预测模型，采用在线学习策略进行模型实时更新，并进行模型适应性调整，生成实时更新的器件模型的步骤具体为：

基于所述优化后的器件预测模型，采用混淆矩阵评估方法，进行模型的性能评估，生成初步模型评估报告；

基于所述初步模型评估报告，确定需要进行更新的模型部分，采用迁移学习策略，进行模型的微调，生成在线学习目标；

基于所述在线学习目标，采用在线学习算法，进行模型的实时调整，生成中间在线学习模型；

基于所述中间在线学习模型，采用自适应学习率调整策略，优化模型的学习进程，生成实时更新的器件模型；

所述混淆矩阵具体为表示模型预测正确与错误数量的二维数组，所述迁移学习具体为利用已有模型对新数据进行训练的策略，所述在线学习算法具体为根据新数据实时更新模型的策略，所述自适应学习率调整具体为根据模型训练进度动态调整学习率的方法。

5. 根据权利要求1所述的半导体器件建模方法，其特征在于，基于所述实时更新的器件模型，采用耦合算法进行多物理场的模型集成，并进行物理现象间的相互作用描述，生成多物理场耦合的器件模型的步骤具体为：

基于所述实时更新的器件模型，采用模态分析算法，对物理场的特性进行评估，生成物理场模态分析结果；

基于所述物理场模态分析结果，采用时域耦合算法，实现物理场之间的交互作用，并生成初步多物理场耦合模型；

基于所述初步多物理场耦合模型，运用稳态分析方法，进行模型稳定性评估，并生成稳态分析验证结果；

基于所述稳态分析验证结果，利用迭代修正策略，对耦合模型进行优化，生成多物理场耦合的器件模型；

所述物理场模态分析结果具体为物理场的频率、模态形状和能量分布，所述初步多物理场耦合模型包括热、机械和电磁场之间的相互影响，所述稳态分析验证结果具体指模型

在长时间运行下的稳定性和性能,所述多物理场耦合的器件模型包括经优化后的物理参数和性能特点。

6.根据权利要求1所述的半导体器件建模方法,其特征在于,基于所述多物理场耦合的器件模型,采用有限元分析扩展和材料参数插值算法进行非均匀介质的建模,并进行介质分布描述,生成考虑非均匀材料的器件模型的步骤具体为:

基于所述多物理场耦合的器件模型,采用微元法,对介质进行离散化处理,生成离散化的介质模型;

基于所述离散化的介质模型,应用材料参数插值方法,为非均匀材料赋予具体参数,生成参数赋值的非均匀介质模型;

基于所述参数赋值的非均匀介质模型,采用有限元分析扩展,细化模型,生成非均匀介质有限元模型;

基于所述非均匀介质有限元模型,应用模型简化技术,对模型进行简化和优化,生成考虑非均匀材料的器件模型;

所述离散化的介质模型具体为介质单元的形状、大小和位置分布,所述参数赋值的非均匀介质模型具体指材料的电导率、热导率和介电常数分布,所述非均匀介质有限元模型具体为材料的非线性响应和物理量的分布,所述考虑非均匀材料的器件模型具体为减少的节点数量和保持的关键性能特点。

7.根据权利要求1所述的半导体器件建模方法,其特征在于,基于所述考虑非均匀材料的器件模型,结合GPU加速技术进行半导体器件的仿真,并进行模型验证,生成最终优化的半导体器件模型的步骤具体为:

基于所述考虑非均匀材料的器件模型,采用GPU并行计算框架,为仿真工作配置加速环境,生成加速仿真的预设环境;

基于所述加速仿真的预设环境,使用电磁场仿真算法,对半导体器件进行仿真分析,生成初步的器件仿真结果;

基于所述初步的器件仿真结果,运用后处理技术,对仿真数据进行深入解析和处理,生成处理后的仿真数据;

基于所述处理后的仿真数据,结合验证和对比分析,与已知的实验数据进行验证,生成最终优化的半导体器件模型;

所述加速仿真的预设环境包括并行计算的线程分配、数据传输和存储策略,所述初步的器件仿真结果具体为器件在工作状态下的电流、电压和功率分布,所述处理后的仿真数据具体为滤除噪声后的信号和关键性能参数的提取,所述最终优化的半导体器件模型具体为验证通过、性能优化的半导体器件模型。

8.半导体器件建模系统,其特征在于,所述系统用于执行权利要求1-7任一项所述的半导体器件建模方法,所述半导体器件建模系统包括数据预处理模块、神经网络训练模块、模型评估微调模块、多物理场建模模块、非均匀材料建模模块、仿真配置模块、仿真结果分析模块;

所述数据预处理模块基于已有的半导体器件性能数据,采用数据标准化方法,进行数据的清洗和格式化,生成预处理后的器件数据;

所述神经网络训练模块基于预处理后的器件数据,设计深层卷积网络结构,并利用

Adam优化器进行细化训练,生成优化后的器件预测模型;

所述模型评估微调模块基于优化后的器件预测模型,采用混淆矩阵评估方法,并结合迁移学习策略进行微调,生成实时更新的器件模型;

所述多物理场建模模块基于实时更新的器件模型,利用模态分析算法评估物理场特性,并对多物理场耦合模型进行优化,生成多物理场耦合的器件模型;

所述非均匀材料建模模块基于多物理场耦合的器件模型,利用微元法进行离散化处理,并为非均匀材料赋予参数,生成考虑非均匀材料的器件模型;

所述仿真配置模块基于考虑非均匀材料的器件模型,采用GPU并行计算框架为仿真工作配置加速环境,生成加速仿真的预设环境;

所述仿真结果分析模块基于加速仿真的预设环境,对半导体器件进行仿真分析,并利用后处理技术对数据进行解析,生成最终优化的半导体器件模型。

9. 根据权利要求8所述的半导体器件建模系统,其特征在于,所述数据预处理模块包括数据清洗子模块、数据标准化子模块、数据格式化子模块;

所述神经网络训练模块包括网络结构设计子模块、网络权重初始化子模块、网络模型训练子模块;

所述模型评估微调模块包括性能评估子模块、模型更新子模块、实时调整子模块;

所述多物理场建模模块包括物理场模态分析子模块、物理场耦合子模块、模型稳定性评估子模块;

所述非均匀材料建模模块包括材料离散化子模块、参数赋值子模块、模型细化子模块;

所述仿真配置模块包括计算环境配置子模块、仿真加速子模块、仿真参数设置子模块;

所述仿真结果分析模块包括器件仿真子模块、数据后处理子模块、模型验证子模块。

10. 半导体器件建模电子设备,包括存储器和处理器,其特征在于,所述存储器中存储有计算机程序,所述处理器执行所述计算机程序时实现权利要求1至7任一项所述的半导体器件建模方法的步骤。

半导体器件建模方法、系统及电子设备

技术领域

[0001] 本发明涉及微电子学技术领域,尤其涉及半导体器件建模方法、系统及电子设备。

背景技术

[0002] 微电子学是研究半导体材料、器件、集成电路及其制造技术的科学。该领域涉及固体物理、化学、材料科学、计算机科学、电子工程等多学科交叉。随着技术的进步,集成电路的尺寸不断减小,制程技术也日趋先进。微电子学不仅为现代电子设备和系统提供了核心技术,还在众多行业,如通讯、医疗、能源等,都起到了关键作用。

[0003] 其中,半导体器件建模方法是为了理解和预测半导体器件在不同条件下的工作性能和行为,通过建立数学模型来描述器件的物理和电气特性。这种模型可以基于器件的物理过程,如载流子迁移、复合、隧道效应等,也可以是经验性的、基于测量数据的。建模的目的是为了在设计阶段预测器件的性能,优化器件结构,简化实验过程,加快产品研发速度,并为集成电路设计提供可靠的器件模型。常用的手段包括基于半导体物理原理的物理建模,基于测量数据的经验建模,以及使用如SPICE、TCAD等专业软件进行模型验证和电路模拟。

[0004] 现有的半导体器件建模方法没有充分利用深度学习技术来进行数据的抽象和特性学习,导致模型的精确度有所不足。不具备在线学习的能力,难以适应新的数据和环境变化,使得模型更新和优化受限。现有方法没有充分考虑多物理场的耦合效应,导致在复杂应用场景下的模型预测不够准确。对于非均匀材料的建模,没有采用有效的策略来模拟器件中的材料属性和分布,忽视了器件中某些关键的物理现象或材料特性。此外,没有充分利用并行计算技术如GPU加速,导致仿真效率和速度受限,影响了建模的实时性和应用范围。

发明内容

[0005] 本发明的目的是解决现有技术中存在的缺点,而提出的半导体器件建模方法、系统及电子设备。

[0006] 为了实现上述目的,本发明采用了如下技术方案:半导体器件建模方法,包括以下步骤:

[0007] S1:基于已有的半导体器件性能数据,采用深度神经网络算法进行模型的初步选择和框架建立,并进行模型的初始化,生成初步神经网络模型;

[0008] S2:基于所述初步神经网络模型,采用梯度下降方法进行模型训练,并进行超参数调整,生成优化后的器件预测模型;

[0009] S3:基于所述优化后的器件预测模型,采用在线学习策略进行模型实时更新,并进行模型适应性调整,生成实时更新的器件模型;

[0010] S4:基于所述实时更新的器件模型,采用耦合算法进行多物理场的模型集成,并进行物理现象间的相互作用描述,生成多物理场耦合的器件模型;

[0011] S5:基于所述多物理场耦合的器件模型,采用有限元分析扩展和材料参数插值算

法进行非均匀介质的建模,并进行介质分布描述,生成考虑非均匀材料的器件模型;

[0012] S6:基于所述考虑非均匀材料的器件模型,结合GPU加速技术进行半导体器件的仿真,并进行模型验证,生成最终优化的半导体器件模型;

[0013] 所述深度神经网络具体为多层前馈神经网络,用于抽象数据特性,所述初步神经网络模型具体指为半导体器件性能的预测框架,所述梯度下降具体为优化算法,用于减少模型误差,所述优化后的器件预测模型包括参数调整、特性学习和性能优化,所述在线学习具体指模型根据新数据进行动态调整,所述实时更新的器件模型具体为适应新数据和环境变化的模型,所述耦合算法具体为同时处理电子传输、热传导和光学效应的数值算法,所述多物理场耦合的器件模型包括电、热、光多场耦合的综合模拟,所述有限元分析扩展具体为针对非均匀材料分布的建模策略,所述考虑非均匀材料的器件模型具体指模拟器件中材料属性和分布的模型,所述GPU加速具体为使用图形处理单元进行的并行计算技术,所述最终优化的半导体器件模型具体为经过验证和优化的模型,用于实际应用中的器件性能预测和设计。

[0014] 作为本发明的进一步方案,基于已有的半导体器件性能数据,采用深度神经网络算法进行模型的初步选择和框架建立,并进行模型的初始化,生成初步神经网络模型的步骤具体为:

[0015] S101:基于已有半导体器件性能数据,采用数据标准化方法,进行数据的清洗和格式化,生成预处理后的器件数据;

[0016] S102:基于所述预处理后的器件数据,采用深度学习框架张量流,设计深层卷积神经网络结构,生成初步神经网络框架;

[0017] S103:基于所述初步神经网络框架,采用He初始化策略,进行权重的初始化,生成随机初始化的神经网络模型;

[0018] S104:基于所述随机初始化的神经网络模型,采用前向传播算法,进行模型的初步评估,生成初步神经网络模型;

[0019] 所述数据标准化具体为将数据范围缩放到 $[0, 1]$ 或 $[-1, 1]$ 区间内,所述深层卷积神经网络结构具体为卷积层、池化层和全连接层的组合,所述He初始化具体为根据前一层神经元数量自动调整权重初始值的方法,所述前向传播具体为通过输入数据计算输出结果的过程。

[0020] 作为本发明的进一步方案,基于所述初步神经网络模型,采用梯度下降方法进行模型训练,并进行超参数调整,生成优化后的器件预测模型的步骤具体为:

[0021] S201:基于初步神经网络模型,采用均方误差方法,进行模型预测与真实值的误差计算,生成初步误差评估结果;

[0022] S202:基于初步误差评估结果,采用批量梯度下降算法,进行模型的优化训练,生成中间训练模型;

[0023] S203:基于中间训练模型,采用网格搜索策略,进行超参数的搜索与确定,生成调整后的超参数集;

[0024] S204:基于调整后的超参数集,采用Adam优化器,进行模型的细化训练,生成优化后的器件预测模型;

[0025] 所述均方误差具体为预测值与实际值之差的平方和的均值,所述批量梯度下降具

体为一次处理所有数据进行优化的策略,所述网格搜索策略具体为搜索预设定的超参数范围,寻找最佳组合的方法,所述Adam优化器具体为结合了动量法和RMSProp方法的优化算法。

[0026] 作为本发明的进一步方案,基于所述优化后的器件预测模型,采用在线学习策略进行模型实时更新,并进行模型适应性调整,生成实时更新的器件模型的步骤具体为:

[0027] S301:基于所述优化后的器件预测模型,采用混淆矩阵评估方法,进行模型的性能评估,生成初步模型评估报告;

[0028] S302:基于所述初步模型评估报告,确定需要进行更新的模型部分,采用迁移学习策略,进行模型的微调,生成在线学习目标;

[0029] S303:基于所述在线学习目标,采用在线学习算法,进行模型的实时调整,生成中间在线学习模型;

[0030] S304:基于所述中间在线学习模型,采用自适应学习率调整策略,优化模型的学习进程,生成实时更新的器件模型;

[0031] 所述混淆矩阵具体为表示模型预测正确与错误数量的二维数组,所述迁移学习具体为利用已有模型对新数据进行训练的策略,所述在线学习算法具体为根据新数据实时更新模型的策略,所述自适应学习率调整具体为根据模型训练进度动态调整学习率的方法。

[0032] 作为本发明的进一步方案,基于所述实时更新的器件模型,采用耦合算法进行多物理场的模型集成,并进行物理现象间的相互作用描述,生成多物理场耦合的器件模型的步骤具体为:

[0033] S401:基于所述实时更新的器件模型,采用模态分析算法,对物理场的特性进行评估,生成物理场模态分析结果;

[0034] S402:基于所述物理场模态分析结果,采用时域耦合算法,实现物理场之间的交互作用,并生成初步多物理场耦合模型;

[0035] S403:基于所述初步多物理场耦合模型,运用稳态分析方法,进行模型稳定性评估,并生成稳态分析验证结果;

[0036] S404:基于所述稳态分析验证结果,利用迭代修正策略,对耦合模型进行优化,生成多物理场耦合的器件模型;

[0037] 所述物理场模态分析结果具体为物理场的频率、模态形状和能量分布,所述初步多物理场耦合模型包括热、机械和电磁场之间的相互影响,所述稳态分析验证结果具体指模型在长时间运行下的稳定性和性能,所述多物理场耦合的器件模型包括经优化后的物理参数和性能特点。

[0038] 作为本发明的进一步方案,基于所述多物理场耦合的器件模型,采用有限元分析扩展和材料参数插值算法进行非均匀介质的建模,并进行介质分布描述,生成考虑非均匀材料的器件模型的步骤具体为:

[0039] S501:基于所述多物理场耦合的器件模型,采用微元法,对介质进行离散化处理,生成离散化的介质模型;

[0040] S502:基于所述离散化的介质模型,应用材料参数插值方法,为非均匀材料赋予具体参数,生成参数赋值的非均匀介质模型;

[0041] S503:基于所述参数赋值的非均匀介质模型,采用有限元分析扩展,细化模型,生

成非均匀介质有限元模型；

[0042] S504:基于所述非均匀介质有限元模型,应用模型简化技术,对模型进行简化和优化,生成考虑非均匀材料的器件模型；

[0043] 所述离散化的介质模型具体为介质单元的形状、大小和位置分布,所述参数赋值的非均匀介质模型具体指材料的电导率、热导率和介电常数分布,所述非均匀介质有限元模型具体为材料的非线性响应和物理量的分布,所述考虑非均匀材料的器件模型具体为减少的节点数量和保持的关键性能特点。

[0044] 作为本发明的进一步方案,基于所述考虑非均匀材料的器件模型,结合GPU加速技术进行半导体器件的仿真,并进行模型验证,生成最终优化的半导体器件模型的步骤具体为：

[0045] S601:基于所述考虑非均匀材料的器件模型,采用GPU并行计算框架,为仿真工作配置加速环境,生成加速仿真的预设环境；

[0046] S602:基于所述加速仿真的预设环境,使用电磁场仿真算法,对半导体器件进行仿真分析,生成初步的器件仿真结果；

[0047] S603:基于所述初步的器件仿真结果,运用后处理技术,对仿真数据进行深入解析和处理,生成处理后的仿真数据；

[0048] S604:基于所述处理后的仿真数据,结合验证和对比分析,与已知的实验数据进行验证,生成最终优化的半导体器件模型；

[0049] 所述加速仿真的预设环境包括并行计算的线程分配、数据传输和存储策略,所述初步的器件仿真结果具体为器件在工作状态下的电流、电压和功率分布,所述处理后的仿真数据具体为滤除噪声后的信号和关键性能参数的提取,所述最终优化的半导体器件模型具体为验证通过、性能优化的半导体器件模型。

[0050] 半导体器件建模系统,所述系统用于执行上述半导体器件建模方法,包括数据预处理模块、神经网络训练模块、模型评估微调模块、多物理场建模模块、非均匀材料建模模块、仿真配置模块、仿真结果分析模块；

[0051] 所述数据预处理模块基于已有的半导体器件性能数据,采用数据标准化方法,进行数据的清洗和格式化,生成预处理后的器件数据；

[0052] 所述神经网络训练模块基于预处理后的器件数据,设计深层卷积网络结构,并利用Adam优化器进行细化训练,生成优化后的器件预测模型；

[0053] 所述模型评估微调模块基于优化后的器件预测模型,采用混淆矩阵评估方法,并结合迁移学习策略进行微调,生成实时更新的器件模型；

[0054] 所述多物理场建模模块基于实时更新的器件模型,利用模态分析算法评估物理场特性,并对多物理场耦合模型进行优化,生成多物理场耦合的器件模型；

[0055] 所述非均匀材料建模模块基于多物理场耦合的器件模型,利用微元法进行离散化处理,并为非均匀材料赋予参数,生成考虑非均匀材料的器件模型；

[0056] 所述仿真配置模块基于考虑非均匀材料的器件模型,采用GPU并行计算框架为仿真工作配置加速环境,生成加速仿真的预设环境；

[0057] 所述仿真结果分析模块基于加速仿真的预设环境,对半导体器件进行仿真分析,并利用后处理技术对数据进行解析,生成最终优化的半导体器件模型。

[0058] 作为本发明的进一步方案,所述数据预处理模块包括数据清洗子模块、数据标准化子模块、数据格式化子模块;

[0059] 所述神经网络训练模块包括网络结构设计子模块、网络权重初始化子模块、网络模型训练子模块;

[0060] 所述模型评估微调模块包括性能评估子模块、模型更新子模块、实时调整子模块;

[0061] 所述多物理场建模模块包括物理场模态分析子模块、物理场耦合子模块、模型稳定性评估子模块;

[0062] 所述非均匀材料建模模块包括材料离散化子模块、参数赋值子模块、模型细化子模块;

[0063] 所述仿真配置模块包括计算环境配置子模块、仿真加速子模块、仿真参数设置子模块;

[0064] 所述仿真结果分析模块包括器件仿真子模块、数据后处理子模块、模型验证子模块。

[0065] 半导体器件建模电子设备,包括存储器和处理器,所述存储器中存储有计算机程序,所述处理器执行所述计算机程序时实现上述半导体器件建模方法的步骤。

[0066] 与现有技术相比,本发明的优点和积极效果在于:

[0067] 本发明中,通过采用深度神经网络能有效抽象数据特性并为半导体器件性能建立预测框架。结合梯度下降优化算法,有效地减少了模型的误差,确保了模型的性能优化。通过在线学习策略,模型可以根据新数据进行动态调整,使其始终适应新的数据和环境变化。耦合算法考虑了电子传输、热传导和光学效应,为器件提供了电、热、光多场耦合的综合模拟,确保模型的全面性和准确性。利用有限元分析扩展和材料参数插值算法,模型考虑了非均匀材料的属性和分布,进一步增强了模型的准确性。结合GPU加速技术,确保了仿真的高效性和速度,同时模型经过了严格的验证和优化,适应于实际应用中的器件性能预测和设计。

附图说明

[0068] 图1为本发明的工作流程示意图;

[0069] 图2为本发明的S1步骤细化流程图;

[0070] 图3为本发明的S2步骤细化流程图;

[0071] 图4为本发明的S3步骤细化流程图;

[0072] 图5为本发明的S4步骤细化流程图;

[0073] 图6为本发明的S5步骤细化流程图;

[0074] 图7为本发明的S6步骤细化流程图;

[0075] 图8为本发明的系统流程图;

[0076] 图9为本发明的系统框架示意图。

具体实施方式

[0077] 为了使本发明的目的、技术方案及优点更加清楚明白,以下结合附图及实施例,对本发明进行进一步详细说明。应当理解,此处所描述的具体实施例仅仅用以解释本发明,并

不用于限定本发明。

[0078] 在本发明的描述中,需要理解的是,术语“长度”、“宽度”、“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。此外,在本发明的描述中,“多个”的含义是两个或两个以上,除非另有明确具体的限定。

实施例一

[0079] 请参阅图1,本发明提供一种技术方案:半导体器件建模方法,包括以下步骤:

[0080] S1:基于已有的半导体器件性能数据,采用深度神经网络算法进行模型的初步选择和框架建立,并进行模型的初始化,生成初步神经网络模型;

[0081] S2:基于初步神经网络模型,采用梯度下降方法进行模型训练,并进行超参数调整,生成优化后的器件预测模型;

[0082] S3:基于优化后的器件预测模型,采用在线学习策略进行模型实时更新,并进行模型适应性调整,生成实时更新的器件模型;

[0083] S4:基于实时更新的器件模型,采用耦合算法进行多物理场的模型集成,并进行物理现象间的相互作用描述,生成多物理场耦合的器件模型;

[0084] S5:基于多物理场耦合的器件模型,采用有限元分析扩展和材料参数插值算法进行非均匀介质的建模,并进行介质分布描述,生成考虑非均匀材料的器件模型;

[0085] S6:基于考虑非均匀材料的器件模型,结合GPU加速技术进行半导体器件的仿真,并进行模型验证,生成最终优化的半导体器件模型;

[0086] 深度神经网络具体为多层前馈神经网络,用于抽象数据特性,初步神经网络模型具体指为半导体器件性能的预测框架,梯度下降具体为优化算法,用于减少模型误差,优化后的器件预测模型包括参数调整、特性学习和性能优化,在线学习具体指模型根据新数据进行动态调整,实时更新的器件模型具体为适应新数据和环境变化的模型,耦合算法具体为同时处理电子传输、热传导和光学效应的数值算法,多物理场耦合的器件模型包括电、热、光多场耦合的综合模拟,有限元分析扩展具体为针对非均匀材料分布的建模策略,考虑非均匀材料的器件模型具体指模拟器件中材料属性和分布的模型,GPU加速具体为使用图形处理单元进行的并行计算技术,最终优化的半导体器件模型具体为经过验证和优化的模型,用于实际应用中的器件性能预测和设计。

[0087] 首先,通过在S1中采用深度神经网络,特别是多层前馈神经网络,为半导体器件的性能数据建立了一个高度抽象且灵活的预测框架。这不仅提高了数据处理的效率,而且确保了模型可以捕捉到更复杂、高维的数据特性,从而提高预测准确性。

[0088] 其次,S2的梯度下降优化方法确保了模型能够迅速收敛到一个误差最小的状态。超参数的调整进一步精炼了模型的性能,使其在面对实际数据时能够有更好的泛化能力。

[0089] 在S3中引入的在线学习策略为模型提供了动态更新的能力。这意味着模型不仅可以应对初次建模时的数据,而且能够根据新的数据实时调整,确保模型始终处于最优状态,适应于不断变化的半导体器件性能数据。

[0090] 通过S4的多物理场耦合方法,模型能够同时考虑电、热、光等多种物理场的相互作

用。这为半导体器件建模带来了更高层次的全面性和准确性,特别是在复杂的应用场景中。

[0091] S5步骤中,有限元分析的扩展和材料参数插值算法为非均匀材料提供了深度建模能力,确保模型在考虑非均匀材料的特性时不失准确性。

[0092] 最后,S6中结合的GPU加速技术极大提升了模型的仿真速度。这不仅缩短了仿真时间,还为模型验证提供了更高的效率,确保模型在实际应用中的器件性能预测和设计时能够快速响应。

[0093] 请参阅图2,基于已有的半导体器件性能数据,采用深度神经网络算法进行模型的初步选择和框架建立,并进行模型的初始化,生成初步神经网络模型的步骤具体为:

[0094] S101:基于已有半导体器件性能数据,采用数据标准化方法,进行数据的清洗和格式化,生成预处理后的器件数据;

[0095] S102:基于预处理后的器件数据,采用深度学习框架张量流,设计深层卷积网络结构,生成初步神经网络框架;

[0096] S103:基于初步神经网络框架,采用He初始化策略,进行权重的初始化,生成随机初始化的神经网络模型;

[0097] S104:基于随机初始化的神经网络模型,采用前向传播算法,进行模型的初步评估,生成初步神经网络模型;

[0098] 数据标准化具体为将数据范围缩放到[0,1]或[-1,1]区间内,深层卷积网络结构具体为卷积层、池化层和全连接层的组合,He初始化具体为根据前一层神经元数量自动调整权重初始值的方法,前向传播具体为通过输入数据计算输出结果的过程。

[0099] 首先,收集和清洗已有的半导体器件性能数据,包括检测和处理异常值、缺失值以及噪音。然后,采用数据标准化方法,将数据的范围缩放到[0,1]或[-1,1]区间内,以确保不同特征之间具有可比性。同时,进行数据格式化,以供神经网络使用。

[0100] 在本发明中,上述的半导体器件性能数据包括静态电流、漏电流、饱和电流、输入阻抗、输出阻抗、转移阻抗、击穿电压、导通电压、反向电压以及绝缘电阻各参数项。

[0101] 对于半导体器件性能数据中的各参数项,其中每个参数项(静态电流、漏电流、饱和电流、输入阻抗、输出阻抗、转移阻抗、击穿电压、导通电压、反向电压或绝缘电阻)中均包含有多个对应的数值。

[0102] 对于每个参数项的异常值,对应的处理方法包括如下步骤:

[0103] S1011a,获取每个参数项对应的数值范围,并确定当前数值范围内的最大值;

[0104] S1011b,在当前参数项的多个数值中查找是否存在大于当前数值范围内的最大值的数值,并记为第一数值;

[0105] S1011c,将所述第一数值除以当前数值范围内的最大值以得到一当前异常倍数,并判断所述当前异常倍数是否大于预设异常倍数;

[0106] S1011d,若是,则确认所述第一数值为异常值并进行对应删除。

[0107] 作为补充说明的是,对于当前参数项存在缺失值的情况,本发明采用线性插值的方法进行填充。

[0108] 在进行了异常值、缺失值以及噪音处理得到预处理之后的数据之后,对每个参数项内的数值采用数据标准化方法进行处理,对应的数据标准化处理方法为:

[0109] S1012a、确认当前参数项中的最小值和最大值,分别记为 $\min(x)$ 和 $\max(x)$;

[0110] S1012b、对于当前参数项中的每个当前数值,根据数据标准化公式进行标准化处理以得到当前标准化系数;

[0111] 在本步骤中,数据标准化公式表示为:

$$[0112] \quad a_{ij} = \frac{x_{ij} - \min(x_i)}{\max(x_i) - \min(x_i)};$$

[0113] 其中, a_{ij} 表示第 i 个参数项中第 j 个数值对应的当前标准化系数, x_{ij} 表示第 i 个参数项中的第 j 个数值, x_i 表示第 i 个参数项, $\min(x_i)$ 表示第 i 个参数项中的最小值, $\max(x_i)$ 表示第 i 个参数项中的最大值。

[0114] 在本实施例中, i 的最大取值为10, j 的最大取值为5。也即,参数项的项数为10项,每个参数项中的数值个数设置为5个。例如, x_1 表示第1个参数项静态电流项, x_3 表示第3个参数项饱和电流项, x_7 表示第7个参数项击穿电压项。

[0115] 在计算得到了每个参数项中每个数值对应的标准化系数之后,为了评估整个半导体器件性能数据的整体协同性,用于评估半导体器件的各参数项的数值是否对应匹配,在本实施例中,通过计算得到协同性评价值来评判。

[0116] 具体的,协同性评判值的计算公式表示为:

$$[0117] \quad S = \sum_{i=1}^I \gamma_i \cdot s_i;$$

$$[0118] \quad s_i = \left| \frac{A_i - A_0}{1.08 + A_0} \right|;$$

$$[0119] \quad A_i = \sum_{j=1}^J a_{ij};$$

[0120] 其中, S 表示协同性评价值, γ_i 表示第 i 个参数项对应的权重值, s_i 表示第 i 个参数项对应的偏置系数, A_i 表示第 i 个参数项的标准化总数值, A_0 表示标准化值的基准值, $j \in (1, J]$, J 的取值为5。

[0121] 可以理解的,在计算得到了协同性评价值 S 之后,可通过协同性评价值 S 评判半导体器件中各参数项的数据的一致性。协同性评价值 S 越大,表明半导体器件的各参数项之间的数据不协调,用于反应半导体性能的优良。

[0122] 基于预处理后的器件数据,使用深度学习框架,如张量流,设计深层卷积神经网络(CNN)结构。这个深度卷积网络结构通常包括卷积层、池化层和全连接层的组合,其中卷积层用于提取特征,池化层用于降维,全连接层用于输出最终的预测结果。结构的具体设计取决于问题的复杂性和数据的特性。

[0123] 在神经网络的初始化阶段,采用He初始化策略,根据前一层神经元数量自动调整

权重的初始值。这确保了权重初始值的合理性,有助于模型的快速收敛和更好的性能。初始化后,网络的参数是随机的,准备进行训练。

[0124] 基于随机初始化的神经网络模型,采用前向传播算法,对模型进行初步评估。这包括将训练数据输入到网络中,计算模型的输出结果。评估结果可以包括损失函数的值以及其他性能指标,如准确度或均方误差。

[0125] 请参阅图3,基于初步神经网络模型,采用梯度下降方法进行模型训练,并进行超参数调整,生成优化后的器件预测模型的步骤具体为:

[0126] S201:基于初步神经网络模型,采用均方误差方法,进行模型预测与真实值的误差计算,生成初步误差评估结果;

[0127] S202:基于初步误差评估结果,采用批量梯度下降算法,进行模型的优化训练,生成中间训练模型;

[0128] S203:基于中间训练模型,采用网格搜索策略,进行超参数的搜索与确定,生成调整后的超参数集;

[0129] S204:基于调整后的超参数集,采用Adam优化器,进行模型的细化训练,生成优化后的器件预测模型;

[0130] 均方误差具体为预测值与实际值之差的平方和的均值,批量梯度下降具体为一次处理所有数据进行优化的策略,网格搜索策略具体为搜索预设定的超参数范围,寻找最佳组合的方法,Adam优化器具体为结合了动量法和RMSProp方法的优化算法。

[0131] S201中,执行均方误差评估,需要计算模型的预测值与实际值之间的均方误差(Mean Squared Error,MSE),以评估模型的性能。这是一个标准的回归问题评估指标,用于度量模型的预测与实际值之间的差异。

```
[0132] import numpy as np
```

```
[0133] # 假设 y_true 是实际值,y_pred 是模型的预测值
```

```
[0134] mse = np.mean((y_true - y_pred) ** 2)
```

[0135] S202中,使用批量梯度下降算法来优化神经网络模型。梯度下降是通过计算损失函数对模型参数的梯度来更新参数,从而最小化损失函数。

```
[0136] learning_rate = 0.01
```

```
[0137] epochs = 1000
```

```
[0138] for epoch in range(epochs):
```

```
[0139]     # 计算损失函数关于参数的梯度
```

```
[0140]     gradients = compute_gradients(model, data, labels)
```

```
[0141]     # 更新参数
```

```
[0142]     model.params -= learning_rate * gradients
```

[0143] 在实际应用中,需要定义损失函数,计算梯度,并执行参数更新。这通常需要使用深度学习框架(如TensorFlow或PyTorch)来简化操作。

[0144] S203中,执行超参数调整,使用网格搜索策略来寻找最佳的超参数组合。超参数包括学习率、批量大小、层的数量、神经元数量等。

```
[0145] from sklearn.model_selection import GridSearchCV
```

```
[0146] param_grid = {
```

```
[0147]         'learning_rate': [0.001, 0.01, 0.1],
[0148]         'batch_size': [32, 64, 128],
[0149]         'num_layers': [2, 3, 4],
[0150]         'num_neurons': [64, 128, 256]
[0151]     }
[0152]     grid_search = GridSearchCV(model, param_grid, cv=3, scoring='mean_
squared_error')
[0153]     grid_search.fit(data, labels)
[0154]     best_params = grid_search.best_params_
[0155]     代码使用Scikit-Learn的进行超参数搜索。
[0156]     S204中,使用Adam优化器来进行模型的细化训练。Adam是一种自适应学习率的优
化算法,通常能够更快地收敛于最优解。
[0157]     from tensorflow.keras.optimizers import Adam
[0158]     model.compile(optimizer=Adam(learning_rate=0.001), loss='mean_
squared_error')
[0159]     model.fit(data, labels, epochs=100, batch_size=64)
[0160]     代码使用TensorFlow中的Adam优化器来编译模型,定义损失函数,并进行训练。
[0161]     请参阅图4,基于优化后的器件预测模型,采用在线学习策略进行模型实时更新,
并进行模型适应性调整,生成实时更新的器件模型的步骤具体为:
[0162]     S301:基于优化后的器件预测模型,采用混淆矩阵评估方法,进行模型的性能评
估,生成初步模型评估报告;
[0163]     S302:基于初步模型评估报告,确定需要进行更新的模型部分,采用迁移学习策
略,进行模型的微调,生成在线学习目标;
[0164]     S303:基于在线学习目标,采用在线学习算法,进行模型的实时调整,生成中间在
线学习模型;
[0165]     S304:基于中间在线学习模型,采用自适应学习率调整策略,优化模型的学习进
程,生成实时更新的器件模型;
[0166]     混淆矩阵具体为表示模型预测正确与错误数量的二维数组,迁移学习具体为利用
已有模型对新数据进行训练的策略,在线学习算法具体为根据新数据实时更新模型的策
略,自适应学习率调整具体为根据模型训练进度动态调整学习率的方法。
[0167]     S301中,使用混淆矩阵评估方法来评估模型的性能。混淆矩阵用于表示模型的分
类结果,包括真正例、假正例、真负例和假负例。基于混淆矩阵,可以计算多种性能指标,如
准确度、精确度、召回率和F1分数。
[0168]     from sklearn.metrics import confusion_matrix, accuracy_score,
precision_score, recall_score, f1_score
[0169]     y_true = true_labels # 实际标签
[0170]     y_pred = model.predict(data) # 模型的预测结果
[0171]     conf_matrix = confusion_matrix(y_true, y_pred)
[0172]     accuracy = accuracy_score(y_true, y_pred)
```



```

[0173] precision = precision_score(y_true, y_pred)
[0174] recall = recall_score(y_true, y_pred)
[0175] f1 = f1_score(y_true, y_pred)
[0176] # 生成初步模型评估报告
[0177] report = {
[0178]     'Confusion Matrix': conf_matrix,
[0179]     'Accuracy': accuracy,
[0180]     'Precision': precision,
[0181]     'Recall': recall,
[0182]     'F1 Score': f1
[0183] }

```

[0184] S302中,根据初步模型评估报告,确定需要进行更新的模型部分,然后采用迁移学习策略进行模型微调,生成在线学习目标。迁移学习通常涉及冻结一部分已训练的模型层,只微调少数层以适应新任务。

[0185] # 从优化后的模型中选择需要微调的层

```
[0186] model_to_finetune = select_layers_to_finetune(model, report)
```

[0187] # 创建在线学习目标

```
[0188] online_learning_target = create_online_learning_target(model_to_finetune, data_new, labels_new)
```

[0189] 在本步骤中,根据初步模型评估报告,确定需要进行更新的模型部分的方法具体包括:

[0190] S3021,获取初步模型评估报告中的准确度、精确度、召回率以及F1分数,根据准确度、精确度、召回率以及F1分数分别计算得到对应的准确度偏移系数、精确度偏移系数、召回率偏移系数以及F1分数偏移系数;

[0191] 偏移系数的计算通式表示为:

$$[0192] \quad p_k = p_0 \cdot \sqrt{\left| \frac{M_k - M_k^0}{M_k^0} \right|};$$

[0193] 其中, p_k 表示偏移系数, p_0 表示偏移系数的基准值, M_k 表示准确度、精确度、召回率以及F1分数中第 k 项的数值, M_k^0 表示准确度、精确度、召回率以及F1分数中第 k 项的基准数值, k 的取值为1、2、3或4,第1项为准确度,第2项为精确度,第3项为召回率,第4项为F1分数。

[0194] S3022,判断所述准确度偏移系数、精确度偏移系数、召回率偏移系数以及F1分数偏移系数是否均在各自对应的偏移系数阈值范围内;

[0195] S3023,若否,则确定超出对应偏移系数阈值范围的偏移系数数据类型,并基于当前偏移系数生成对应的调节因子,将对应的调节因子代入器件预测模型的自动调节模型中以对器件预测模型进行更新。

[0196] 在本步骤中,调节因子的通式表示为:

$$[0197] \quad D_k = D_0 \cdot \sqrt{1 + p_k^{1 + \frac{1}{0.23\pi}}};$$

[0198] 其中, D_k 表示第 k 项的调节因子, D_0 表示调节因子的基准值, k 的取值为1、2、3或4,第1项为准确度,第2项为精确度,第3项为召回率,第4项为F1分数。

[0199] 自动调节模型的公式表示为:

$$[0200] \quad y_k = \lambda_k \cdot D_k;$$

[0201] 其中, y_k 表示第 k 项的最终调节指数, λ_k 表示第 k 项的调节权重。

[0202] S303中,使用在线学习算法,根据新数据实时更新模型,生成中间在线学习模型。在线学习算法可以是随时间逐渐适应新数据的算法,例如随机梯度下降。

[0203] # 更新模型参数以适应新数据

[0204] `model_online = update_model_online(online_learning_target, model_to_finetune)`

[0205] S304中,采用自适应学习率调整策略,优化模型的学习进程,生成实时更新的器件模型。自适应学习率调整可确保在训练过程中根据模型的训练进度动态调整学习率。

[0206] # 使用自适应学习率优化模型

[0207] `model_final = adapt_learning_rate_and_train(model_online, data_all, labels_all)`

[0208] 请参阅图5,基于实时更新的器件模型,采用耦合算法进行多物理场的模型集成,并进行物理现象间的相互作用描述,生成多物理场耦合的器件模型的步骤具体为:

[0209] S401:基于实时更新的器件模型,采用模态分析算法,对物理场的特性进行评估,生成物理场模态分析结果;

[0210] S402:基于物理场模态分析结果,采用时域耦合算法,实现物理场之间的交互作用,并生成初步多物理场耦合模型;

[0211] S403:基于初步多物理场耦合模型,运用稳态分析方法,进行模型稳定性评估,并生成稳态分析验证结果;

[0212] S404:基于稳态分析验证结果,利用迭代修正策略,对耦合模型进行优化,生成多物理场耦合的器件模型;

[0213] 物理场模态分析结果具体为物理场的频率、模态形状和能量分布,初步多物理场耦合模型包括热、机械和电磁场之间的相互影响,稳态分析验证结果具体指模型在长时间运行下的稳定性和性能,多物理场耦合的器件模型包括经优化后的物理参数和性能特点。

[0214] 首先,使用模态分析算法对各个物理场的特性进行评估。这可以包括电磁场、热场、机械场等。模态分析通常涉及计算频率、模态形状以及能量分布等参数。这些分析结果将提供有关各个物理场行为的详细信息。

[0215] 基于物理场的模态分析结果,采用时域耦合算法来实现各个物理场之间的相互作用。时域耦合允许物理现象在时间上相互影响。需要建立耦合算法,以描述物理场之间的相

互作用。这可能包括热和机械场的相互影响,电磁场对温度的影响等。结果将是一个初步的多物理场耦合模型。

[0216] 使用稳态分析方法对初步多物理场耦合模型进行评估。这包括考虑模型在长时间运行下的稳定性和性能。需要模拟模型在不同条件下的行为,以确保它在各种情况下都能正常工作。验证结果将为多物理场模型的稳定性提供信息。

[0217] 基于稳态分析验证的结果,采用迭代修正策略来进一步优化多物理场耦合模型,涉及调整耦合算法的参数,修改模型的初始条件,或者校正物理场之间的相互作用描述。优化的目标是确保模型在各种情况下都能准确模拟多物理场的行为。这一步骤需要多次迭代,直到满足性能要求。

[0218] 请参阅图6,基于多物理场耦合的器件模型,采用有限元分析扩展和材料参数插值算法进行非均匀介质的建模,并进行介质分布描述,生成考虑非均匀材料的器件模型的步骤具体为:

[0219] S501:基于多物理场耦合的器件模型,采用微元法,对介质进行离散化处理,生成离散化的介质模型;

[0220] S502:基于离散化的介质模型,应用材料参数插值方法,为非均匀材料赋予具体参数,生成参数赋值的非均匀介质模型;

[0221] S503:基于参数赋值的非均匀介质模型,采用有限元分析扩展,细化模型,生成非均匀介质有限元模型;

[0222] S504:基于非均匀介质有限元模型,应用模型简化技术,对模型进行简化和优化,生成考虑非均匀材料的器件模型;

[0223] 离散化的介质模型具体为介质单元的形状、大小和位置分布,参数赋值的非均匀介质模型具体指材料的电导率、热导率和介电常数分布,非均匀介质有限元模型具体为材料的非线性响应和物理量的分布,考虑非均匀材料的器件模型具体为减少的节点数量和保持的关键性能特点。

[0224] 首先,使用微元法将考虑的介质进行离散化处理。这包括定义介质单元的形状、大小和位置分布。通常,将介质分成小的元素或单元,以便在每个单元内进行物理场建模。

[0225] 基于离散化的介质模型,采用材料参数插值方法,为非均匀材料赋予具体参数。这意味着需要根据离散化模型中每个单元的位置,使用插值技术为每个单元分配材料的电导率、热导率和介电常数等具体参数。这确保了材料参数在空间上的非均匀分布。

[0226] 基于参数赋值的非均匀介质模型,使用有限元分析方法来扩展模型。有限元分析是一种数值方法,用于模拟物理场在离散化介质中的行为。需要建立有限元模型,包括描述非均匀介质中材料的非线性响应和各种物理量(如电场、热场、应力等)的分布。

[0227] 最后,基于非均匀介质的有限元模型,应用模型简化技术。这包括减少模型中的节点数量,以提高计算效率,并优化模型的性能。模型简化通常涉及适当的近似和简化,以便满足特定工程或分析要求,同时保持关键性能特点。

[0228] 请参阅图7,基于考虑非均匀材料的器件模型,结合GPU加速技术进行半导体器件的仿真,并进行模型验证,生成最终优化的半导体器件模型的步骤具体为:

[0229] S601:基于考虑非均匀材料的器件模型,采用GPU并行计算框架,为仿真工作配置加速环境,生成加速仿真的预设环境;

[0230] S602:基于加速仿真的预设环境,使用电磁场仿真算法,对半导体器件进行仿真分析,生成初步的器件仿真结果;

[0231] S603:基于初步的器件仿真结果,运用后处理技术,对仿真数据进行深入解析和处理,生成处理后的仿真数据;

[0232] S604:基于处理后的仿真数据,结合验证和对比分析,与已知的实验数据进行验证,生成最终优化的半导体器件模型;

[0233] 加速仿真的预设环境包括并行计算的线程分配、数据传输和存储策略,初步的器件仿真结果具体为器件在工作状态下的电流、电压和功率分布,处理后的仿真数据具体为滤除噪声后的信号和关键性能参数的提取,最终优化的半导体器件模型具体为验证通过、性能优化的半导体器件模型。

[0234] S601中,配置GPU加速环境,以便进行高性能的半导体器件仿真。这包括线程分配、数据传输和存储策略的设置。

```
[0235] import cupy as cp
[0236] import pyopencl as cl
[0237] import numpy as np
[0238] # 使用CuPy创建GPU数组
[0239] device = cp.cuda.Device(0) # 选择第一个GPU设备
[0240] context = device.make_context()
[0241] queue = cl.CommandQueue(context)
[0242] # 为仿真数据分配GPU内存
[0243] sim_data_gpu = cp.asarray(sim_data)
[0244] # 创建并配置OpenCL环境(可选)
[0245] platforms = cl.get_platforms()
[0246] platform = platforms[0]
[0247] devices = platform.get_devices(cl.device_type.GPU)
[0248] device = devices[0]
[0249] context = cl.Context([device])
[0250] queue = cl.CommandQueue(context)
[0251] S602中,使用电磁场仿真算法对半导体器件进行仿真分析。这可以涉及有限元分析、有限差分时间域(FDTD)等仿真方法。
[0252] # 在GPU上执行电磁场仿真
[0253] sim_result_gpu = perform_em_simulation(sim_data_gpu, simulation_
parameters)
[0254] # 将结果从GPU传回CPU
[0255] sim_result = cp.asnumpy(sim_result_gpu)
[0256] S603中,对仿真数据进行后处理,滤除噪声并提取关键性能参数。
[0257] # 后处理和噪声滤除
[0258] filtered_data = post_process_simulation_data(sim_result)
[0259] # 提取关键性能参数
```

[0260] performance_params = extract_performance_parameters(filtered_data)

[0261] S604中,结合验证和对比分析,将仿真数据与已知的实验数据进行验证,并生成最终优化的半导体器件模型。

[0262] # 与实验数据进行对比分析

[0263] comparison_result = compare_with_experiment(sim_result, experimental_data)

[0264] # 验证通过并优化模型

[0265] if comparison_result.passed_validation and comparison_result.performance_optimized:

[0266] final_model = optimize_and_validate_model(sim_model, performance_params)

[0267] 请参阅图8,半导体器件建模系统,系统用于执行上述半导体器件建模方法,包括数据预处理模块、神经网络训练模块、模型评估微调模块、多物理场建模模块、非均匀材料建模模块、仿真配置模块、仿真结果分析模块;

[0268] 数据预处理模块基于已有的半导体器件性能数据,采用数据标准化方法,进行数据的清洗和格式化,生成预处理后的器件数据;

[0269] 神经网络训练模块基于预处理后的器件数据,设计深层卷积网络结构,并利用Adam优化器进行细化训练,生成优化后的器件预测模型;

[0270] 模型评估微调模块基于优化后的器件预测模型,采用混淆矩阵评估方法,并结合迁移学习策略进行微调,生成实时更新的器件模型;

[0271] 多物理场建模模块基于实时更新的器件模型,利用模态分析算法评估物理场特性,并对多物理场耦合模型进行优化,生成多物理场耦合的器件模型;

[0272] 非均匀材料建模模块基于多物理场耦合的器件模型,利用微元法进行离散化处理,并为非均匀材料赋予参数,生成考虑非均匀材料的器件模型;

[0273] 仿真配置模块基于考虑非均匀材料的器件模型,采用GPU并行计算框架为仿真工作配置加速环境,生成加速仿真的预设环境;

[0274] 仿真结果分析模块基于加速仿真的预设环境,对半导体器件进行仿真分析,并利用后处理技术对数据进行解析,生成最终优化的半导体器件模型。

[0275] 首先,数据预处理模块通过数据标准化与清洗,确保了数据的质量和一致性。这为后续模型的稳定性和准确性打下了坚实的基础,减少了因数据问题导致的模型误差。神经网络训练模块采用深层卷积网络结构和Adam优化器,使得建模过程具有更强的自适应性和训练稳定性,进而能够精确捕捉半导体器件的复杂特性。模型评估微调模块的混淆矩阵评估方法为模型提供了直观、客观的性能反馈。结合迁移学习策略,该系统可以快速调整以适应新的半导体器件数据,提高模型的灵活性和时效性。多物理场建模模块能够综合评估物理场特性,并对模型进行进一步优化,保证了半导体器件在不同物理场下的真实表现能够被准确地模拟。非均匀材料建模模块确保了器件模型能够真实地反映器件中的材料属性和分布,进而提高了模型的真实性和可靠性。仿真配置模块的GPU并行计算框架大大加速了仿真过程,满足了现代半导体产业对高效、快速仿真的迫切需求。最后,仿真结果分析模块为用户提供了直观、明确的仿真数据解析,使得器件的性能和潜在问题可以被快速、准确地识

别和优化。

[0276] 请参阅图9,数据预处理模块包括数据清洗子模块、数据标准化子模块、数据格式化子模块;

[0277] 神经网络训练模块包括网络结构设计子模块、网络权重初始化子模块、网络模型训练子模块;

[0278] 模型评估微调模块包括性能评估子模块、模型更新子模块、实时调整子模块;

[0279] 多物理场建模模块包括物理场模态分析子模块、物理场耦合子模块、模型稳定性评估子模块;

[0280] 非均匀材料建模模块包括材料离散化子模块、参数赋值子模块、模型细化子模块;

[0281] 仿真配置模块包括计算环境配置子模块、仿真加速子模块、仿真参数设置子模块;

[0282] 仿真结果分析模块包括器件仿真子模块、数据后处理子模块、模型验证子模块。

[0283] 数据预处理模块中,数据清洗子模块通过检测和处理异常值、缺失值以及噪音,提高了数据的质量,有益于模型的稳定性和准确性。数据标准化子模块则通过规范化数据的尺度,使得不同特征之间具有可比性,从而加速模型的收敛过程。数据格式化子模块确保数据以适当的格式被输入到神经网络中,为模型提供了一致的输入结构,有助于模型更好地理解和学习数据。

[0284] 神经网络训练模块中,网络结构设计子模块通过选择合适的网络架构,满足问题需求,有助于提高模型的表达能力。网络权重初始化子模块通过巧妙初始化网络参数,促进了模型训练的稳定性和收敛速度。网络模型训练子模块负责使用训练数据优化网络参数,使得模型能够捕捉数据中的模式和规律。

[0285] 模型评估微调模块中,性能评估子模块通过使用测试数据集对模型进行客观评价,提供了改进模型的指导方向。模型更新子模块在性能评估的基础上对模型进行调整,例如调整超参数或增加训练数据,以提高模型的泛化能力。实时调整子模块允许模型根据实时数据变化进行动态调整,使其能够适应不断变化的环境。

[0286] 多物理场建模模块中,物理场模态分析子模块提供了对各个物理场特性的详细了解。物理场耦合子模块模拟了不同物理场之间的相互影响,使模型更贴近实际。模型稳定性评估子模块确保了模型在多物理场模拟中的稳定性,提高了模拟结果的可靠性。

[0287] 非均匀材料建模模块中,材料离散化子模块将非均匀材料分割成离散单元,为模拟提供更精确的基础。参数赋值子模块确定每个单元的物理属性,确保模型的真实性和准确性。模型细化子模块进一步考虑非均匀性的复杂性,提高了模型对真实系统的拟合度。

[0288] 仿真配置模块中,计算环境配置子模块确保仿真环境满足计算需求,提高了仿真的可靠性。仿真加速子模块通过利用并行计算和GPU加速等技术,减少仿真时间,提高了仿真效率。仿真参数设置子模块配置了仿真的相关参数,确保了模拟的精度和可控性。

[0289] 仿真结果分析模块中,器件仿真子模块通过对系统或器件的模拟,提供了对其行为的详细理解。数据后处理子模块对仿真生成的数据进行处理,提取关键信息,为模拟结果提供更深层次的解释。模型验证子模块通过将仿真结果与实际观测或实验进行比较,确保了仿真模型的准确性和可靠性。

[0290] 半导体器件建模电子设备,包括存储器和处理器,存储器中存储有计算机程序,处理器执行计算机程序时实现上述半导体器件建模方法的步骤。

[0291] 以上,仅是本发明的较佳实施例而已,并非对本发明作其他形式的限制,任何熟悉本专业的技术人员可能利用上述揭示的技术内容加以变更或改型为等同变化的等效实施例应用于其他领域,但是凡是未脱离本发明技术方案内容,依据本发明的技术实质对以上实施例所做的任何简单修改、等同变化与改型,仍属于本发明技术方案的保护范围。

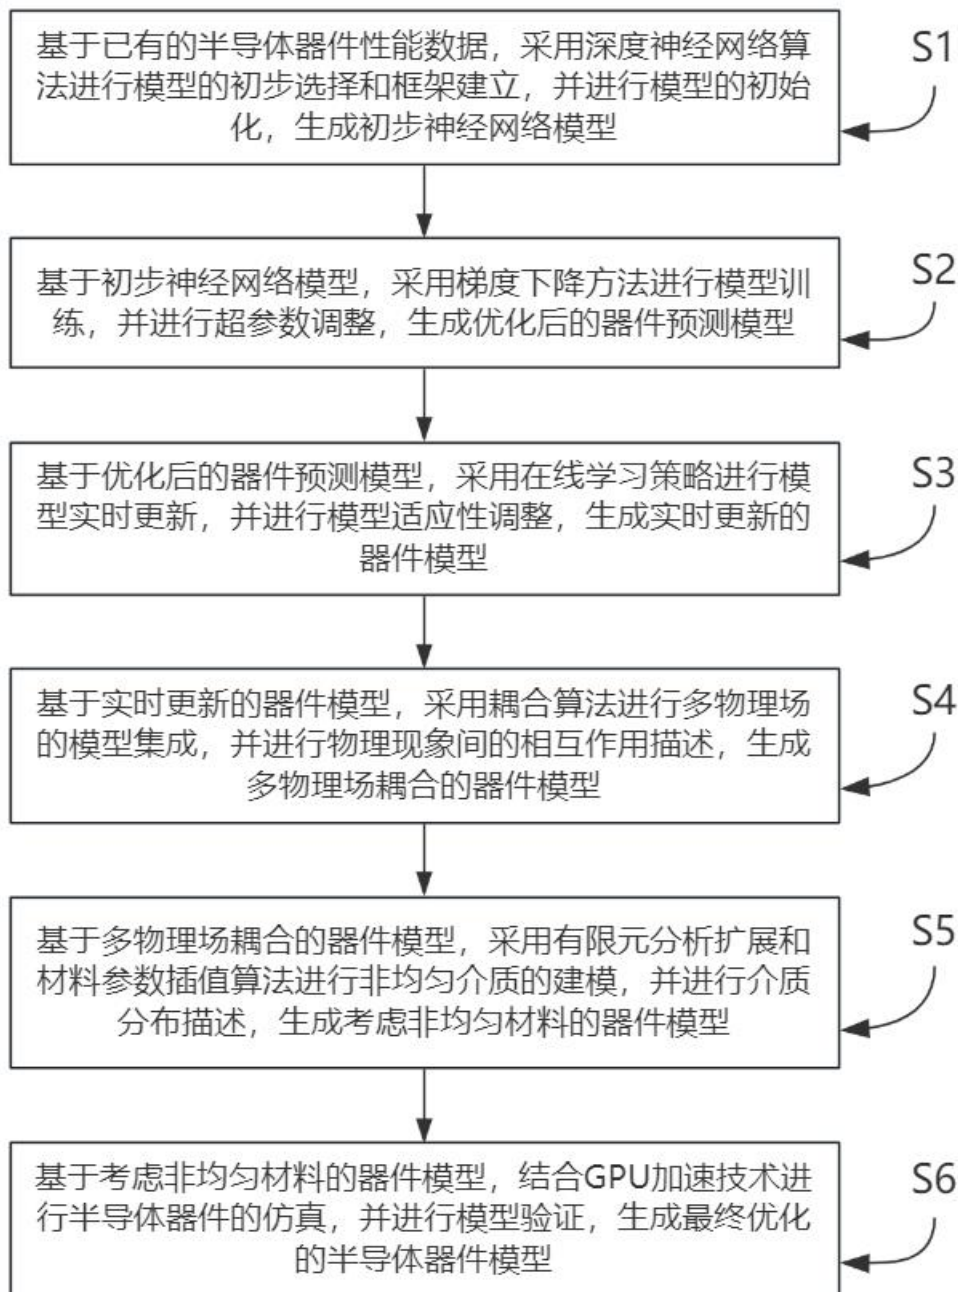


图 1

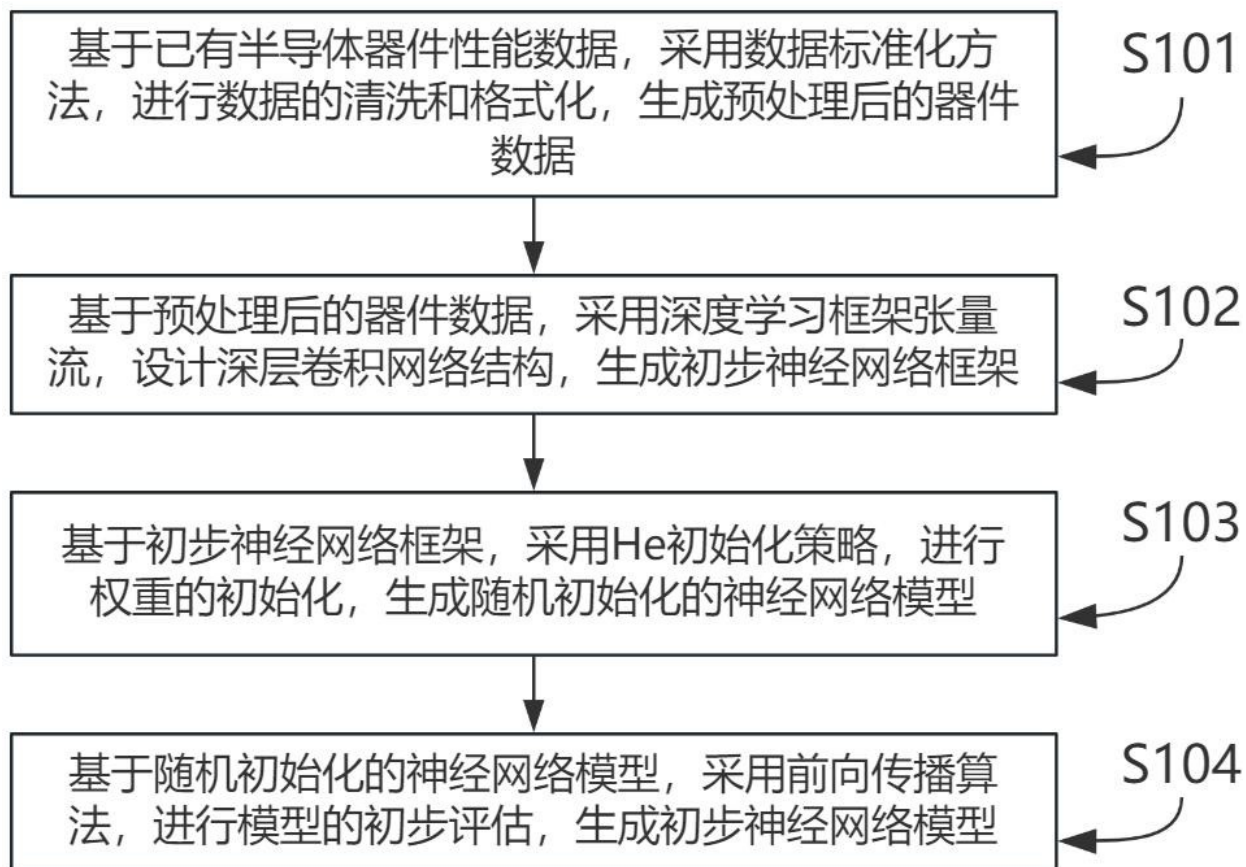


图 2

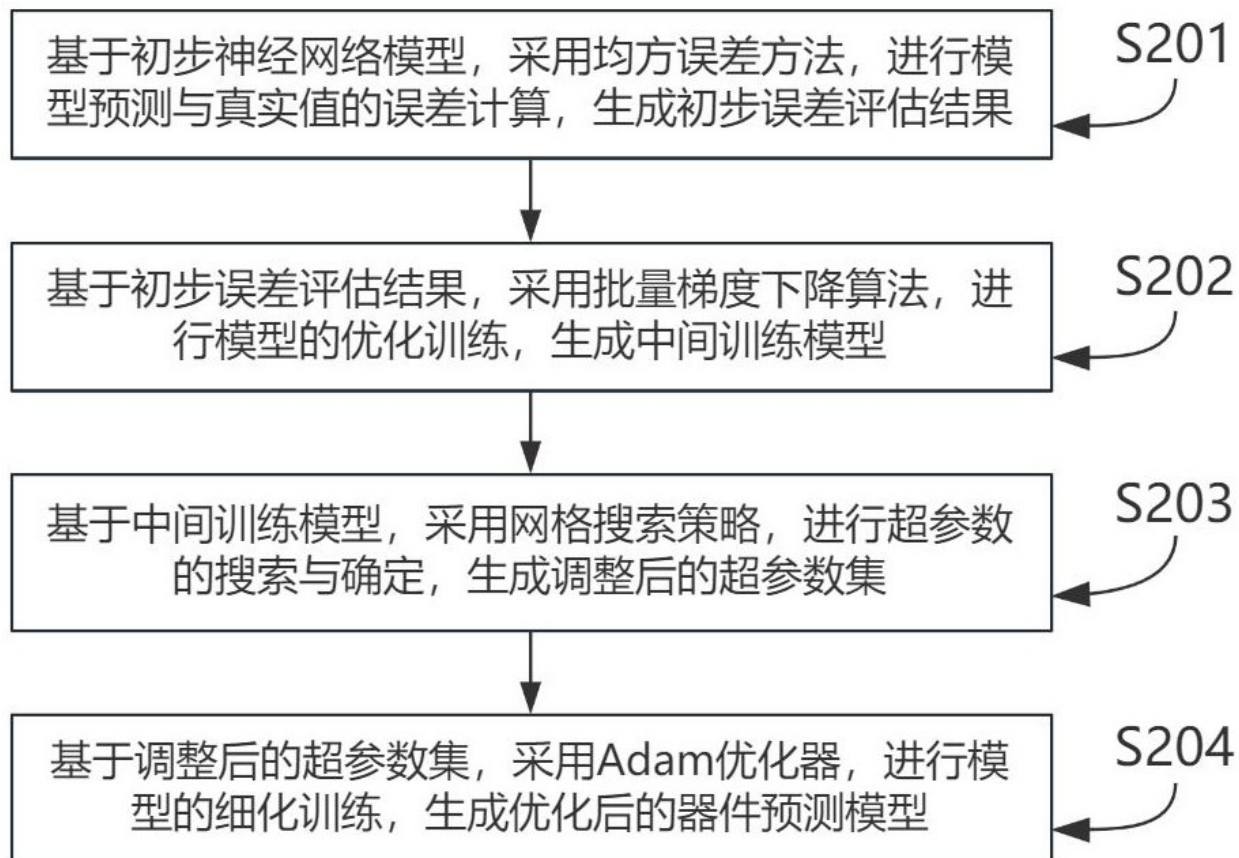


图 3

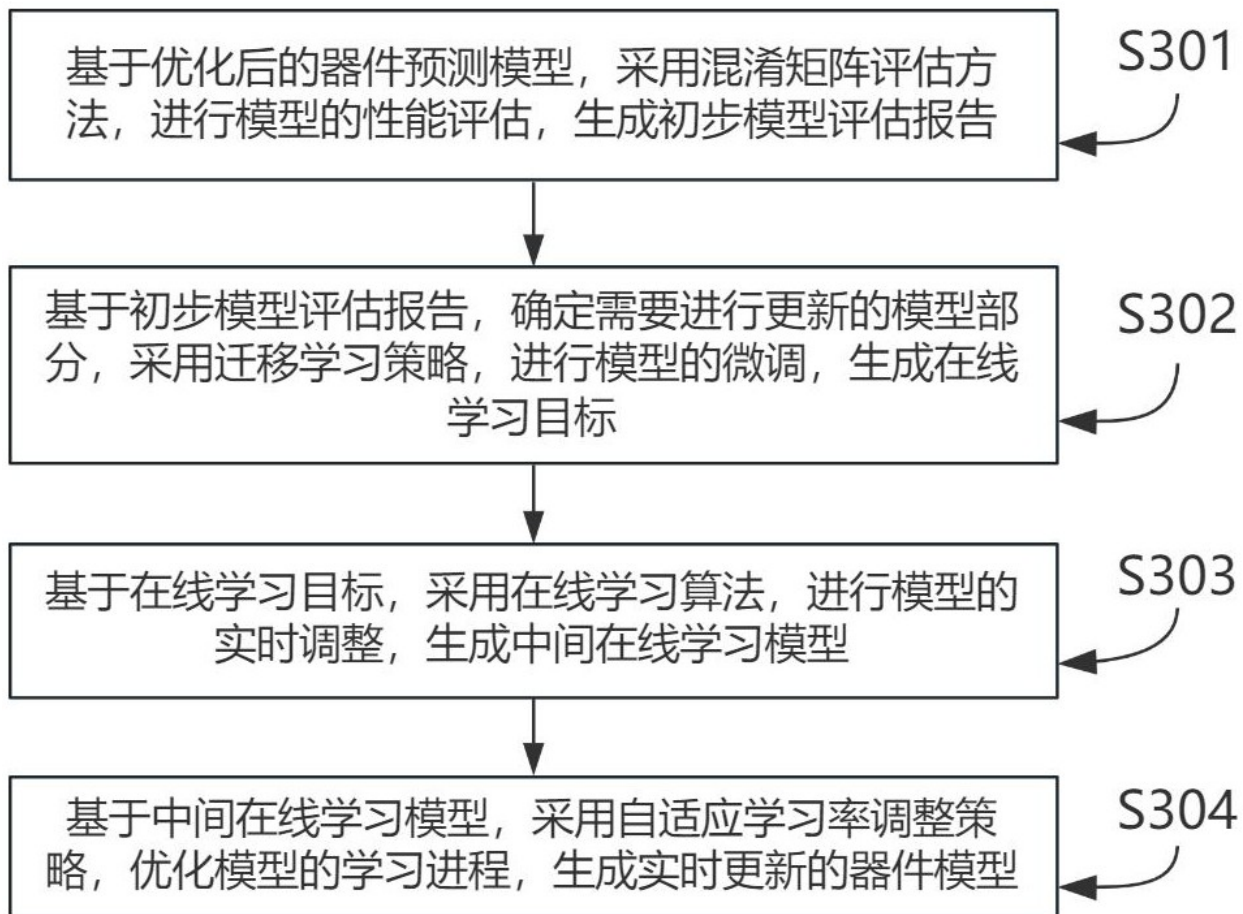


图 4

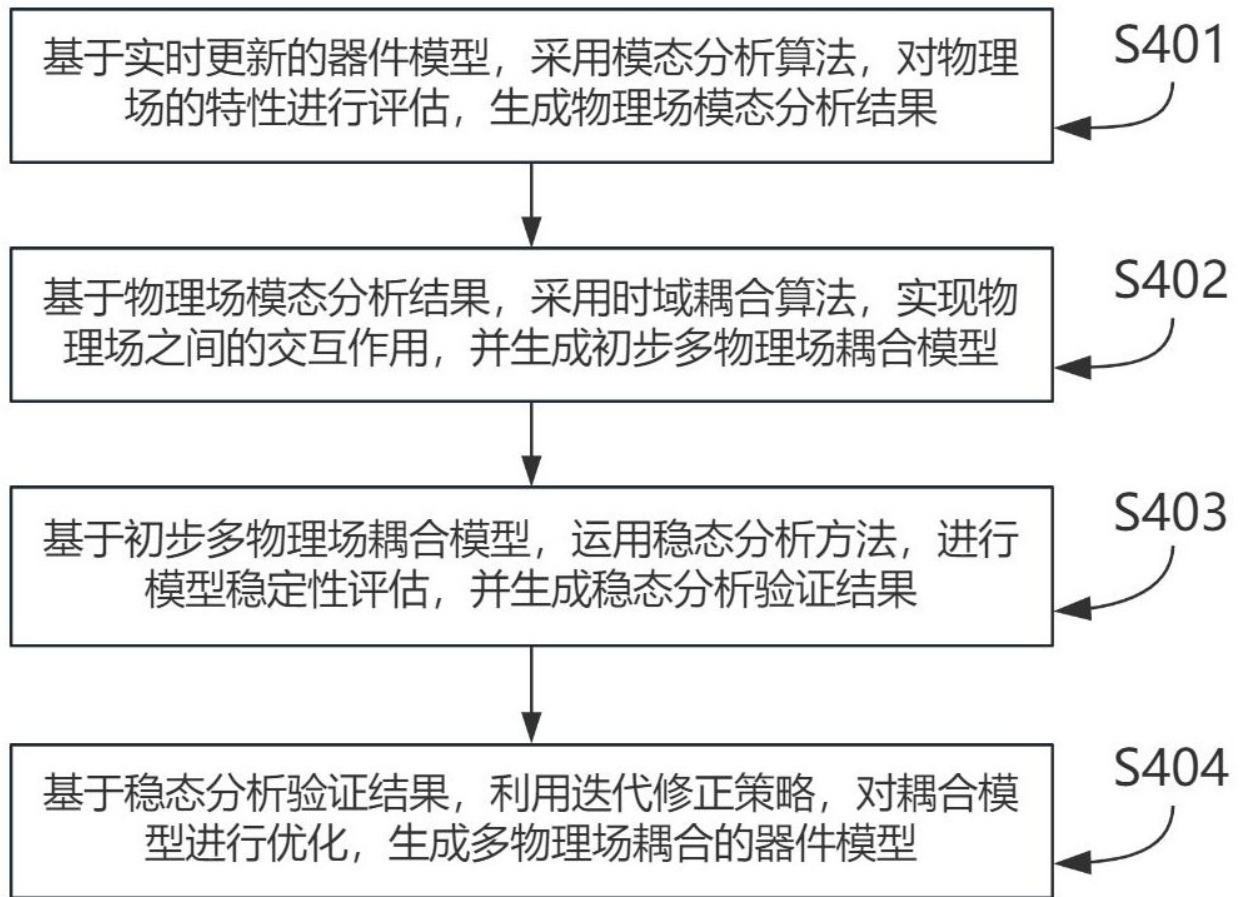


图 5

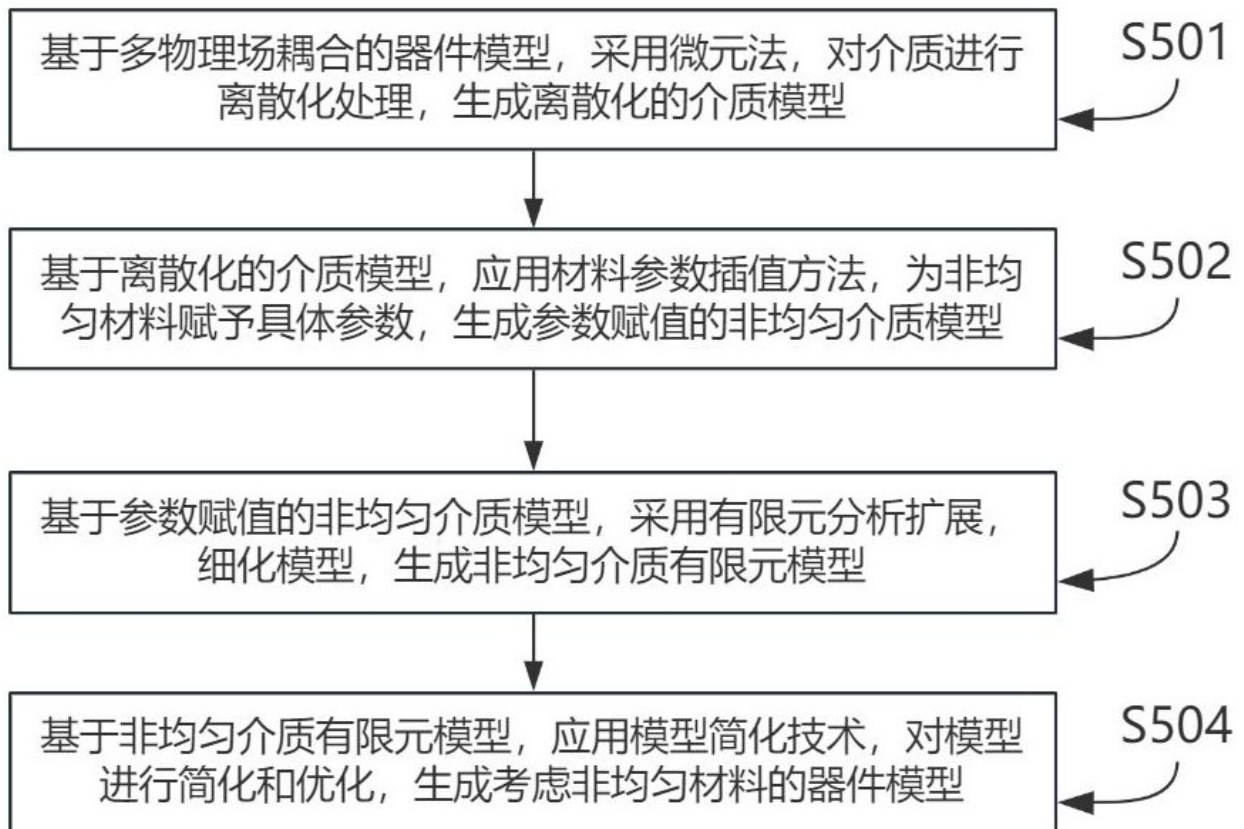


图 6

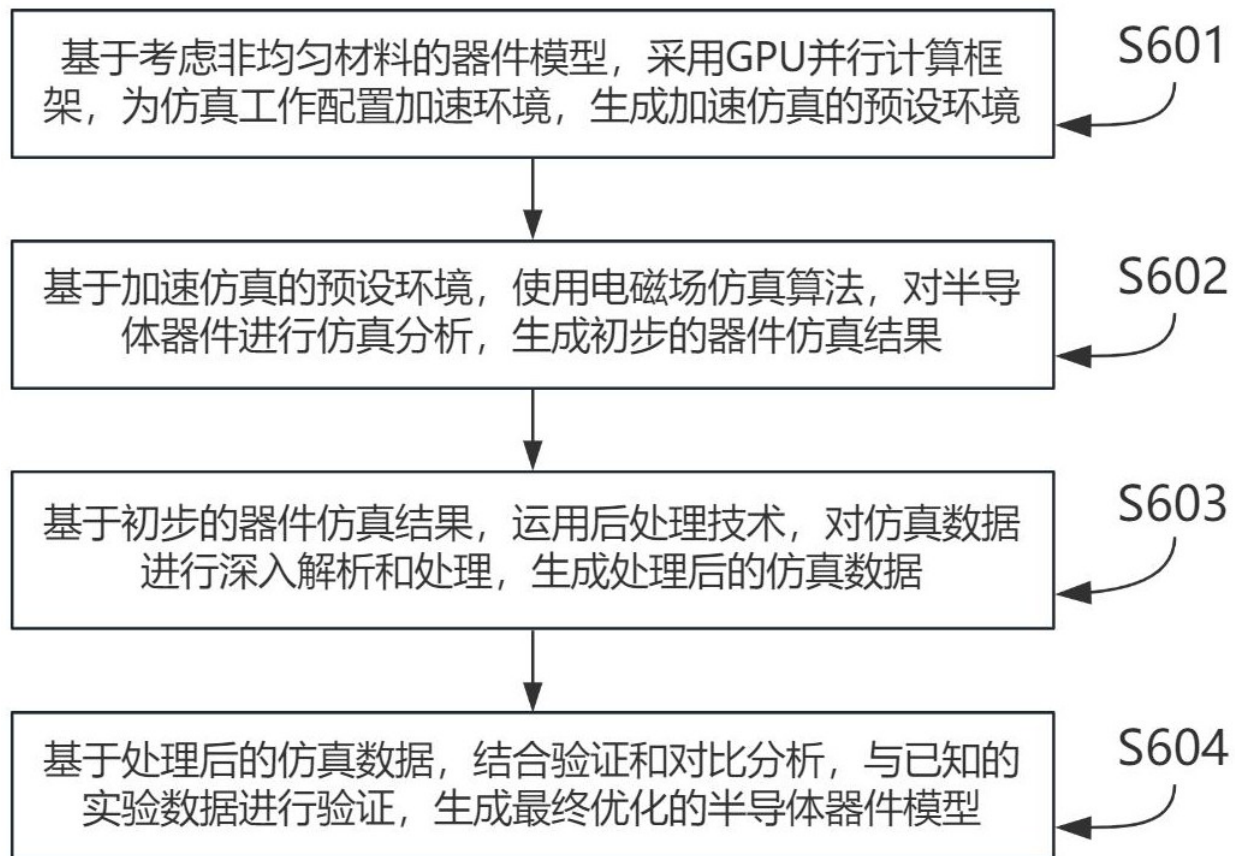


图 7

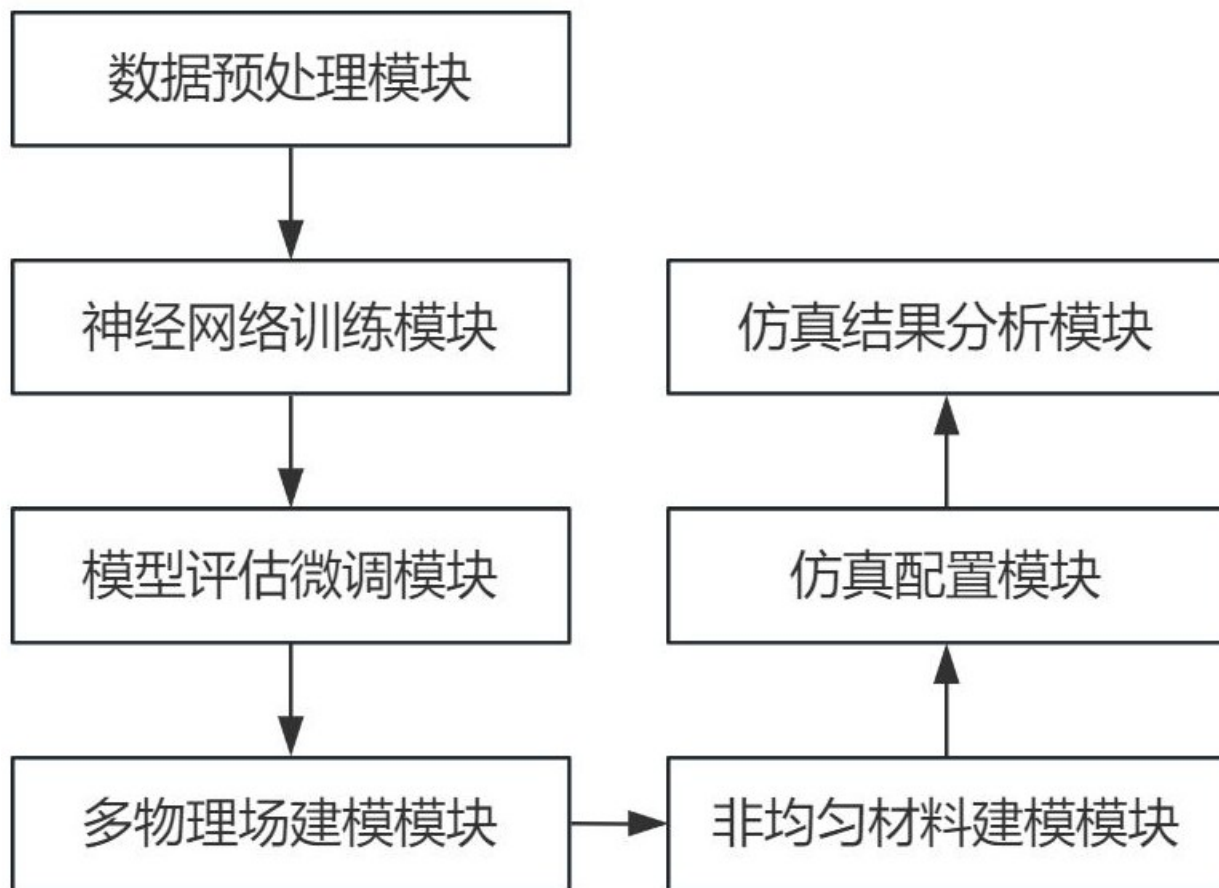


图 8

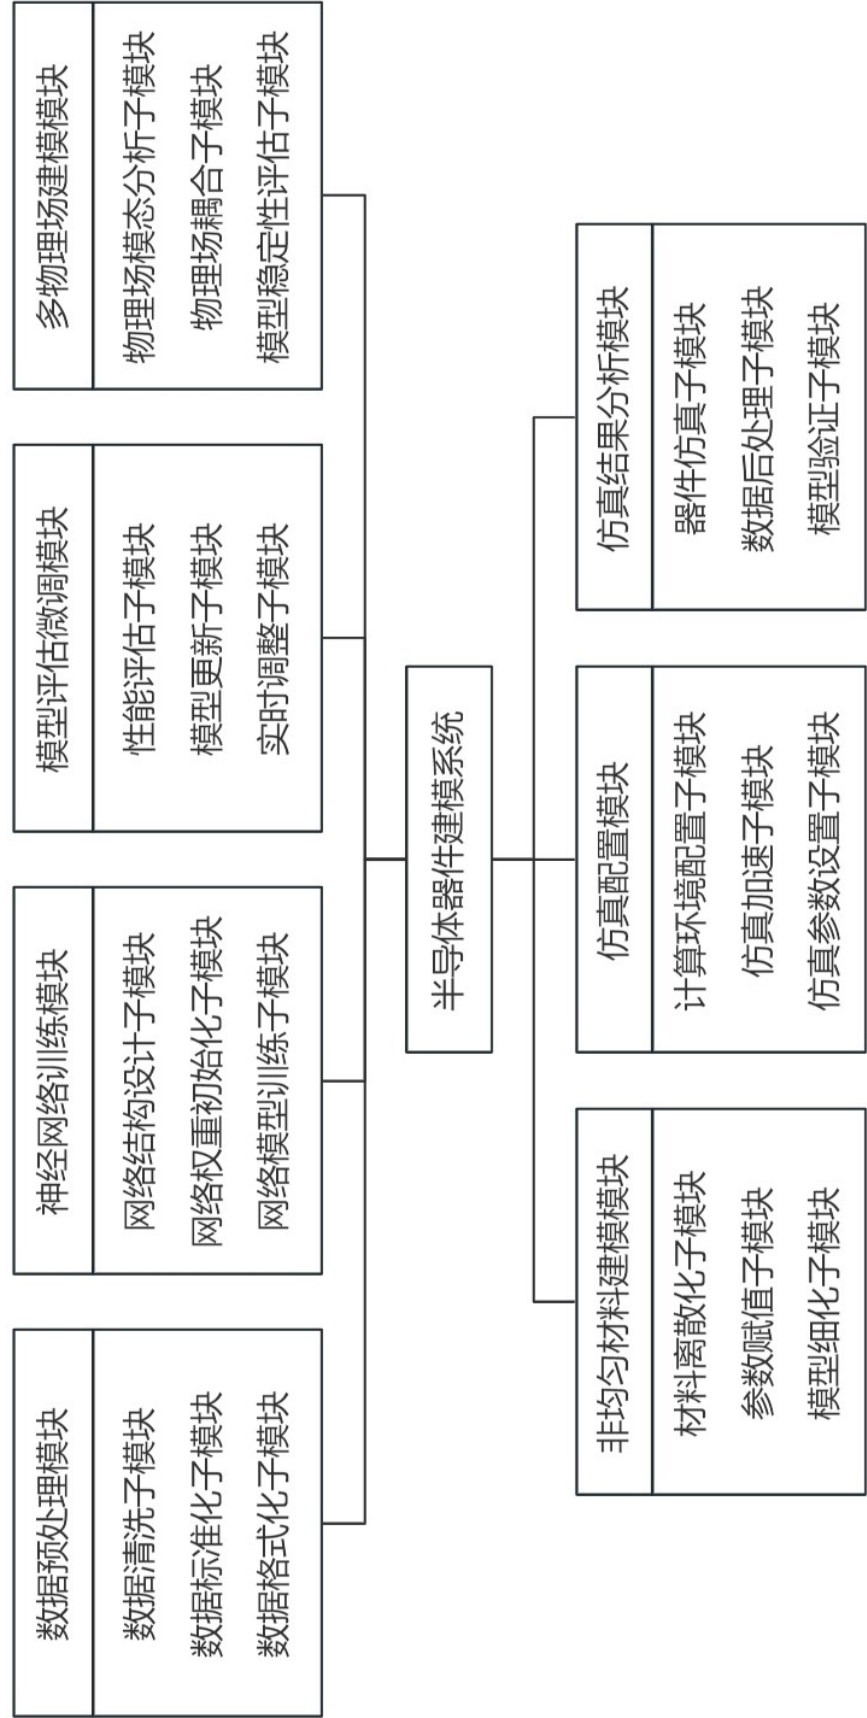


图 9