

基于数据-模型混合驱动的 电力系统机电暂态快速仿真方法

王鑫¹, 杨珂¹, 黄文琦², 马云飞¹, 耿光超^{1*}, 江全元¹

(1. 浙江大学电气工程学院, 浙江省 杭州市 310027;

2. 南方电网数字电网集团有限公司, 广东省 广州市 510700)

A Fast Electromechanical Transient Simulation Algorithm for Power System Based on Data and Physics Driven Model

WANG Xin¹, YANG Ke¹, HUANG Wenqi², MA Yunfei¹, GENG Guangchao^{1*}, JIANG Quanyuan¹

(1. College of Electrical Engineering, Zhejiang University, Hangzhou 310027, Zhejiang Province, China;

2. China Southern Power Grid Digital Power Grid Group Co., Ltd., Guangzhou 510700, Guangdong Province, China)

ABSTRACT: Data-driven modeling has changed the traditional modeling paradigm of generators, which makes traditional electromechanical transient time domain simulation methods fail to be directly applied to power system with new paradigm. Thus, an integrating data- and physics-driven time domain simulation (DPD-TDS) algorithm for electromechanical transient simulation is proposed. The state variables and nodal injection currents are calculated through data-driven model, and network equations are used to calculate nodal voltages. And a preprocessing matrix calculation method for convergence of DPD-TDS improvement is proposed. A central processing unit-neural network processing unit (CPU-NPU) heterogeneous computing architecture is designed to speed up simulation. Differential algebraic equations are solved in CPU and the forward inference of data-driven model is executed in NPU. In IEEE-39 and Polish-2383 systems, some or all generators are replaced by data-driven models for verification. The results show that the convergence, accuracy and calculation speed of the proposed algorithm are exceptionally impressive.

KEY WORDS: electromechanical transient; time-domain simulation; data and physics driven; convergence; central processing unit-neural network processing unit (CPU-NPU) heterogeneous computing

摘要: 数据驱动建模方法改变了发电机传统的建模范式, 导致传统的机电暂态时域仿真方法无法直接应用于新范式下

基金项目: 南方电网数字电网集团有限公司科技项目 (670000KK52210032); 国家自然科学基金项目 (51977188)。

Research Project of China Southern Power Grid Digital Power Grid Group Co., Ltd (670000KK52210032); Project Supported by National Natural Science Foundation of China (51977188).

的电力系统。为此, 该文提出一种基于数据-模型混合驱动的机电暂态时域仿真(data and physics driven time domain simulation, DPD-TDS)算法。算法中发电机状态变量与节点注入电流通过数据驱动模型推理计算, 并通过网络方程完成节点电压计算, 两者交替求解完成仿真。算法提出一种混合驱动范式下的网络代数方程组预处理方法, 用以改善仿真的收敛性; 算法设计一种中央处理器单元-神经网络处理器单元(central processing unit-neural network processing unit, CPU-NPU)异构计算框架以加速仿真, CPU进行机理模型的微分代数方程求解; NPU作协处理器完成数据驱动模型的前向推理。最后在IEEE-39和Polish-2383系统中将部分或全部发电机替换为数据驱动模型进行验证, 仿真结果表明, 所提出的仿真算法收敛性好, 计算速度快, 结果准确。

关键词: 机电暂态; 时域仿真; 数据-模型混合驱动; 收敛性; CPU-NPU异构运算

0 引言

规模巨大的全国性交直流互联系统建设, 使得电网的稳定性事故可波及的区域更加广泛, 严重的电力系统失稳事故甚至可能导致电力系统的崩溃和瓦解^[1]。作为电力系统稳定性分析的有效方法, 暂态时域仿真: 1) 是实现系统故障预警与控制决策的必要手段^[2]; 2) 可以产生丰富的数据和结果, 是对电力系统故障进行深入分析研究的重要基础^[3]。

时域仿真对描述整个系统状态与运行变量的微分-代数方程组(differential algebraic equations, DAEs)进行求解^[4], 针对仿真中收敛性与仿真速度两个关键问题, 已有学者提出: 功角等效法^[5]、可

变步长牛顿法^[6]、非诚实牛顿法^[7]、逆 Broyden 拟牛顿法^[8]等算法。但基于物理机理的时域仿真方法在计算时需要准确的源-网-荷各部分机理模型及准确的结构参数。然而在实际系统中,无论是对于电源侧还是负荷侧,均存在元件物理机理模型构造困难、结构参数精度有限甚至无法获取的问题^[9-12]。

数据驱动建模的方法可以有效解决元件数学模型不可构建或者参数无法测量的问题^[13-17]。在暂态稳定仿真领域,文献[15]使用长短期记忆网络(long short-term memory, LSTM)模型构建虚拟同步发电机的数据驱动模型;文献[16-17]基于物理信息神经网络(physics-informed neural networks, PINN)构建发电机模型。然而,新的发电机建模方法也改变了传统基于数学模型的仿真范式,导致目前已有的时域仿真算法无法直接应用于新范式下的电力系统暂态仿真。

针对上述问题,本文首先构建了基于“数据-模型混合驱动”的电力系统暂态模型,提出适用于混合驱动范式电力系统的机电暂态时域仿真算法;接着针对仿真收敛性与仿真速度两个关键问题,提出在网络代数方程组中引入预处理矩阵 \tilde{Y} 以及基于中央处理器单元-神经网络处理器单元(central processing unit-neural network processing unit, CPU-NPU)异构协同计算的方法。最后,在 IEEE-39 和 Polish-2383 测试系统中,从结果的准确性,仿真收敛性及速度等方面验证了算法的有效性。

1 数据-模型混合驱动的电网建模与仿真

1.1 数据-模型混合驱动建模结构

电力系统暂态时域仿真的全系统模型数学上描述为一组与系统状态和运行变量相关的 DAEs,具体表示如下:

$$\begin{cases} \dot{x}_i = f(x_i, U_i, I_i) \\ 0 = g(x_i, U_i, I_i) \end{cases}, \quad i = 1, 2, 3, \dots, m \quad (1)$$

$$I_i = h(x_i, U_i, I_i), \quad i = 1, 2, 3, \dots, m \quad (2)$$

$$I = YU \quad (3)$$

式中: f 为动态元件(发电机、感应电动机等)状态变量 x (功角 δ , 转速 ω , 暂态电势 e'_d 、 e'_q , 次暂态电势 e''_d 、 e''_q 等)的函数; g 表示坐标转换相关函数; h 表示节点注入电流 I 计算函数; 式(3)表示网络代数方程组, 其中 U, I 表示节点电压 $U_i (i=1, 2, \dots, n)$ 与节点注入电流 I_i 组成的向量, Y 表示导纳矩阵, n 为系统节点数, m 为动态元件数^[18]。

式(1)、(2)主要由“源-荷”相关方程组成:

1) 源: 源侧同步发电机机电暂态经典二阶模型(其他阶数模型见文献[18])可以描述如下:

微分方程部分:

$$\begin{cases} \dot{\delta}_i = \omega_s(\omega_i - 1) \\ \dot{\omega}_i = \frac{1}{T_{ij}} [P_{im} - P_{ie} - D(\omega - 1)] \end{cases} \quad (4)$$

坐标转换方程:

$$\begin{bmatrix} A_x \\ A_y \end{bmatrix} = \begin{bmatrix} \sin \delta & \cos \delta \\ -\cos \delta & \sin \delta \end{bmatrix} \begin{bmatrix} A_d \\ A_q \end{bmatrix}, \quad A \in \{U, I\} \quad (5)$$

x - y 轴坐标系下的发电机节点注入电流方程:

$$\begin{bmatrix} I_{ix} \\ I_{iy} \end{bmatrix}^T = h(x, U_i, I_i) = I'_i - Y'_i U_i \\ \begin{bmatrix} g_{ix} & b_{ix} \\ b_{iy} & g_{iy} \end{bmatrix} \begin{bmatrix} \bar{E}_{id} \\ \bar{E}_{iq} \end{bmatrix} - \begin{bmatrix} G_{ix} & B_{ix} \\ B_{iy} & G_{iy} \end{bmatrix} \begin{bmatrix} U_x \\ U_y \end{bmatrix} \quad (6)$$

式中: ω_s 、 P_{ie} 、 P_{im} 分别表示为同步角速度、电磁功率以及原动机机械功率; T_{ij} 表示发电机惯性常数; I'_i 、 Y'_i 为发电机虚拟注入电流和虚拟导纳, 其中 g_{ix} 、 g_{iy} 、 b_{ix} 、 b_{iy} 、 G_{ix} 、 G_{iy} 、 B_{ix} 、 B_{iy} 等参数以及 d 、 q 轴电势 \bar{E}_{id} 、 \bar{E}_{iq} 的计算参见文献[18]。

2) 荷: 根据负荷类型的不同可以分为 ZIP 负荷等值模型、感应电动机模型等; 而从负荷特性上, 静态负荷或者动态负荷的机理模型本质上为代数方程或者微分方程, 具体见文献[18]。

虽然目前已有大量源-荷部分的建模研究, 但仍然存在机理模型构建困难或可构建但不准确, 以及对应参数难以精确获得等问题^[19]。而数据驱动建模以与问题相关的数据为基础, 提取变量间的关联关系, 形成输入输出的映射, 避免了对元件复杂物理机理的建模以及难以准确获取的参数需求。此外, 电力系统暂态时域仿真中, 各元件物理机理模型或为微分方程(发电机、电动机负荷等), 或为代数方程(恒阻抗负荷、电力网络方程等)。而无论是 PINN 还是卷积神经网络(recurrent neural network, RNN), 均能以高精度去逼近任意复杂度 DAEs 的解^[20-21], 是神经网络应用于电力系统暂态时域仿真(本质上为 DAEs 的求解)重要途径。

因此, 针对系统中机理模型构造困难, 准确参数获取困难的元件, 考虑通过数据驱动方法进行建模, 而其余机理明确且参数容易获取设备则仍采用机理模型, 整个系统的数据-模型混合建模结构如图 1 所示。本文研究将基于系统中发电机采用数据驱动模型的时域仿真展开。

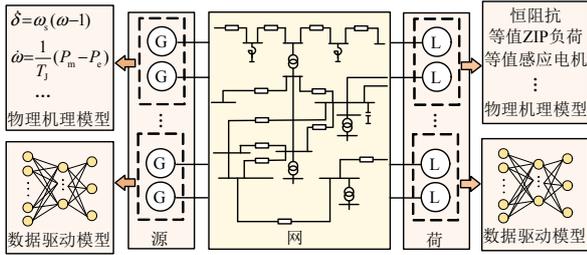


图 1 电网数据-模型混合驱动建模结构

Fig. 1 Data-and physics-driven modeling in power system

1.2 发电机数据驱动建模

同步发电机作为电力系统中最关键的元件之一，虽然已有大量研究建立了基于物理机理的数学模型，但其仍是基于一些特定情况的假设所得，所需参数也随着模型的复杂而急剧增加，并且参数辨识仍存在过程复杂或辨识结果精度有限等不足^[9,12]。机电暂态仿真中发电机机理模型本质上为状态变量相关微分方程与节点注入电流计算方程组成，而文献[21]说明了RNN求解DAEs的可行性，结合LSTM较RNN在解决梯度消失及序列预测长期依赖的优势^[22]，本文将基于LSTM神经网络模型对发电机进行数据驱动建模，避免了对复杂机理的

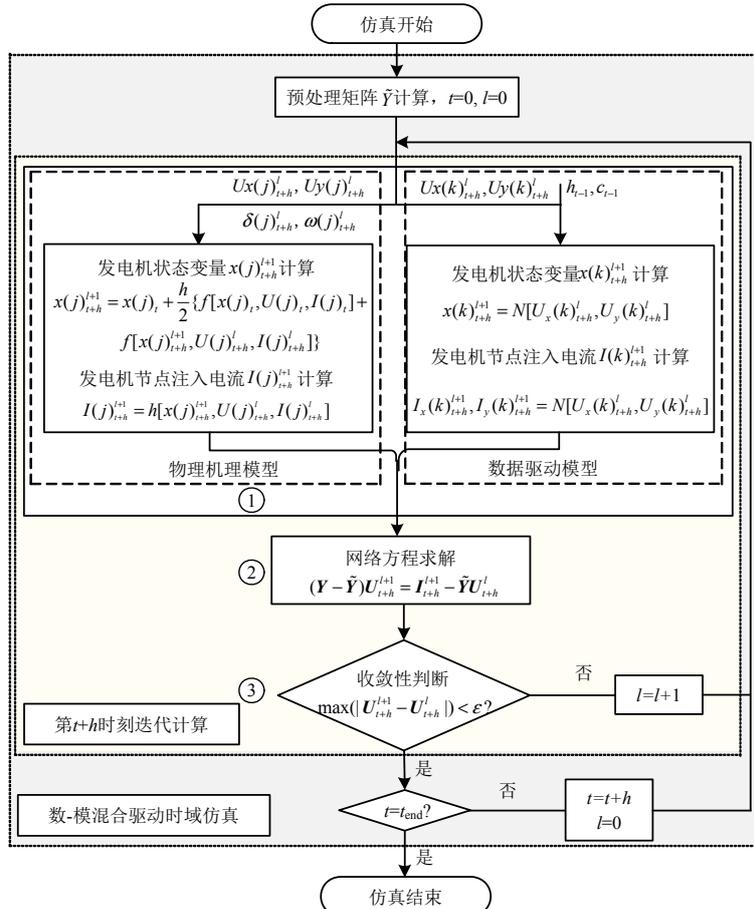
数学模型构建与准确参数的需求。

考虑：1) 发电机节点电压与状态变量、节点注入电流之间均存在映射关系，并且仿真计算中可通过网络代数方程求解节点电压，故选取节点电压 x, y 轴分量 U_x, U_y 作为模型输入，节点注入电流 x, y 轴分量 I_x, I_y ，功角 δ ，角速度 ω 等作为模型输出；2) 发电机节点稳态时的有功、无功出力也直接影响系统各变量仿真结果，故发电机稳态时的有功、无功出力 P_0, Q_0 同样作为模型输入，发电机的数据驱动模型结构见附录 A。式(7)表示所建立发电机数据驱动模型输入输出间的映射关系：

$$[\delta, \omega, I_x, I_y, (h_t, c_t)] = N[U_x, U_y, P_0, Q_0, (h_{t-1}, c_{t-1})] \quad (7)$$

1.3 数-模混合驱动电力系统的机电暂态仿真算法

由于发电机的数据驱动模型难以对所有变量求取梯度，故无法使用联立法；而交替法求解DAEs时微分方程与代数方程天然解耦，状态变量与运行变量交替求解，无需对所有变量的梯度计算。因此，结合1.2节建立的发电机数据驱动模型，本文提出如图2所示基于状态变量与运行变量交替求解的数



*注：为简单表示，图中及后文中发电机数据驱动模型输入 P_0, Q_0, h_t, c_t 不显示写出，状态变量 δ, ω 用 x 表示。

图 2 数-模混合驱动暂态时域仿真算法流程图

Fig. 2 Data- and physics-driven transient time-domain simulation algorithm flowchart

模混合驱动仿真算法。

在整个时域仿真中,开始时,为改善交替迭代的收敛性,首先计算网络的预处理矩阵 \tilde{Y} ,用于后续网络代数方程求解,矩阵 \tilde{Y} 的计算见2.2节;在对系统 $t+h$ 时刻的第 $l+1$ 次迭代计算主要包括以下3个步骤(后文不再继续标示各变量节点号下标 i ,而用下标表示计算时间,上标表示一个时步内的迭代次数):

步骤1:发电机状态变量 x_{t+h}^{l+1} 与节点注入电流 I_{t+h}^{l+1} 求解:

对于机理建模发电机,采用数值积分的方法求解状态变量 x (即解式(1)中微分方程),本文中为

$$x(j)_{t+h}^{l+1} = x(j)_t + h/2[f(x(j)_t, U(j)_t, I(j)_t) + f[x(j)_{t+h}^{l+1}, U(j)_{t+h}^l, I(j)_{t+h}^l]], j \in P \quad (8)$$

式中 P 表示采用机理模型的发电机集合 $\text{GEN}\{1, 2, \dots, p\}$,并注意若 $l=0$,则采用 $x_{t+h}^0 = x_t$;进一步结合式(6)求解得到发电机节点电流 $I(j)_{t+h}^{l+1}$ 。

而对于采用数据驱动模型的发电机,状态变量与节点注入电流计算则以第 l 次迭代计算得到的电压以及前一时刻的模型输出 h_{t-1} 、 c_{t-1} 作为输入,由神经网络模型前向推理直接得到,即:

$$[x(k)_{t+h}^{l+1}, I_x(k)_{t+h}^{l+1}, I_y(k)_{t+h}^{l+1}] = N(U_x(k)_{t+h}^l, U_y(k)_{t+h}^l, h_{t-1}, c_{t-1}), k \in D \quad (9)$$

式中 D 表示采用数据驱动模型的发电机集合 $G_{\text{EN}}\{1, 2, \dots, d\}$,其中 $d+p=m$ 。

步骤2:节点电压 U_{t+h}^{l+1} 求解:

步骤1得到各发电机状态变量和节点注入电流后由式(3)求解各节点电压。为改善迭代收敛性,需引入预处理矩阵 \tilde{Y} ,具体说明见2.2节;

步骤3:仿真计算收敛判断。

在本文所提出的算法中,根据各节点电压前后两次迭代的差进行收敛性判断:

$$\max |U_{t+h}^{l+1} - U_{t+h}^l| < \varepsilon \quad (10)$$

式中: U_{t+h}^{l+1} 和 U_{t+h}^l 分别表示第 $l+1$ 次和第 l 次迭代的节点电压向量; ε 为允许的迭代误差。如果迭代收敛,则仿真时间叠加步长 h 以及迭代次数 l 置0,开始下一时刻计算;否则,设置 $l=l+1$,重复步骤1。

最后当 t 达到仿真终止时刻 t_{end} 后,仿真结束。

2 迭代收敛性提升策略与异构加速算法

2.1 传统交替法收敛性提升

采用交替法求解DAEs时,迭代的收敛性由微

分方程组和代数方程组的求解决定;因此,可以分别对微分方程组^[7]、代数方程组^[5]或者同时对微分方程组和代数方程组^[23]的求解收敛性进行改善,进而实现对DAEs的求解收敛性改善。考虑当系统中存在发电机采用数据驱动模型时,这一部分发电机的状态变量和节点注入电流直接由数据驱动模型推理得到,而非求解微分方程组。因此,本文将从网络代数方程组收敛性改善的角度对整体仿真的收敛性进行改善。

直接求解法求解式(3)存在收敛性问题^[5]。因此本文通过对网络代数方程组添加预处理矩阵的方法改善其收敛性。首先,根据式(2)、(3)、(6),网络代数方程可以表示为

$$YU^{l+1} = I' - Y'U^l \quad (11)$$

为方便观察,在后文忽略各变量的时间下标以及除电压外的迭代次数上标。故对应的迭代矩阵可表示为

$$J = Y^{-1}Y' \quad (12)$$

实际仿真中,为能够使迭代矩阵谱半径 $\rho(J)$ 小于1^[24],以提高网络代数方程组的迭代收敛性,首先进行如下^[25]变换:

$$YU^{l+1} + (Y')^{l+1}U^{l+1} = (I')^{l+1} - (Y')^{l+1}U^l + (Y')^{l+1}U^{l+1} \quad (13)$$

进一步,式(13)的网络方程^[25]可以变换为

$$[Y + (Y')^{l+1}]U^{l+1} = (I')^{l+1} \quad (14)$$

即式(14)中将发电机虚拟导纳合并到网络的节点导纳矩阵中。由于虚拟电流 I' 与节点电压无关,故迭代矩阵的谱半径为0,恒小于1,迭代计算具有良好的收敛性。

在式(14)到(15)变换过程中,引入的误差为

$$\varepsilon = Y'(U^{l+1} - U^l) \quad (15)$$

随着迭代次数增加,方程变换引入误差式(15)不断减小,当满足收敛判据后(即 $U^{l+1} - U^l$ 小于收敛判据值),误差式(15)数值上非常小。

2.2 数-模混合驱动的仿真收敛性提升

在发电机采用数据驱动模型的系统中(为方便说明,令系统中前 d 台发电机采用数据驱动模型,后 p 台发电机采用机理模型),其时域仿真迭代计算过程中网络代数方程可以表示为如下形式:

$$YU^{l+1} = I' = \begin{bmatrix} N(U_d^l) \\ I'_p - Y'_p U_p^l \end{bmatrix} \quad (16)$$

式中: I'_p, Y'_p 采用机理模型的发电机虚拟电流和虚

拟导纳矩阵； U_d^l, U_p^l 分别表示采用数据驱动模型和机理模型发电机节点电压组成的向量。

在本文中，根据虚拟导纳合并入导纳矩阵的方法，将采用矩阵 \tilde{Y} 对式(16)进行预处理，如下所示：

$$\begin{cases} (Y - \tilde{Y})U^{l+1} = \left[\frac{N(U_d^l, h_t)}{I_p' - \tilde{Y}_p' U_p^l} \right] - \tilde{Y}U^l \\ \tilde{Y} = [\tilde{Y}_d \tilde{Y}_p]^T \end{cases} \quad (17)$$

式中 \tilde{Y} 由数据驱动模型部分 \tilde{Y}_d 和机理模型部分 \tilde{Y}_p 组成。进一步，可以变换为

$$U^{l+1} = (Y - \tilde{Y})^{-1} \left[\frac{N(U_d^l, h_t) - \tilde{Y}_d U^l}{I_p' - \tilde{Y}_p' U_p^l - \tilde{Y}_p U^l} \right] \quad (18)$$

虽然数据模型输出的节点注入电流无法显式表示虚拟导纳，但考虑发电机数据模型实质上也是对发电机输入输出的物理意义映射，其输出节点注入电流仍然可以表示为虚拟电流与虚拟导纳的函数，故系统迭代的雅克比矩阵 J 可表示为

$$J = (Y - \tilde{Y})^{-1} \begin{bmatrix} Y_d' + \tilde{Y}_d \\ Y_p' + \tilde{Y}_p \end{bmatrix} \quad (19)$$

对于采用机理模型的发电机，式(14)本质上是通过令 $\tilde{Y}_p = -Y_p'$ 实现的。而对于采用数据驱动模型的发电机，仍可以采用计算矩阵 Y_d' 并令 $\tilde{Y}_d = -Y_d'$ 的处理方法。因此，对于采用数学模型的发电机，预处理矩阵 \tilde{Y} 中机理模型部分 \tilde{Y}_p 仍采用发电机的虚拟导纳，即：

$$\tilde{Y}_j = Y_j' = - \begin{bmatrix} G_{jx} & B_{jx} \\ B_{jy} & G_{jy} \end{bmatrix}, \quad j \in P \quad (20)$$

对于采用数据驱动模型发电机部分 \tilde{Y}_d ，则考虑系统中前后两次迭代的节点注入电流差：

$$\begin{bmatrix} I_{kx}^1 \\ I_{ky}^1 \end{bmatrix} - \begin{bmatrix} I_{kx}^0 \\ I_{ky}^0 \end{bmatrix} = [(I_{dk}^1)' - (\tilde{Y}_{dk})' \begin{bmatrix} U_{kx}^1 \\ U_{ky}^1 \end{bmatrix}] - [(I_{dk}^0)' - (\tilde{Y}_{dk})' \begin{bmatrix} U_{kx}^0 \\ U_{ky}^0 \end{bmatrix}], k \in D \quad (21)$$

在虚拟电流和虚拟导纳的机理模型计算中，其仅相关于发电机参数和对应的状态变量值，根据状态变量的连续变化的特性，在相邻两次迭代计算过程中，状态变量值不发生突变，两次迭代计算的虚拟注入电流变化较小，因此，式(21)进一步变换为

$$\begin{bmatrix} \Delta I_{kx}^1 \\ \Delta I_{ky}^1 \end{bmatrix} = \tilde{Y}_{dk}' \begin{bmatrix} \Delta U_x^1 \\ \Delta U_y^1 \end{bmatrix} \quad (22)$$

因此，结合两次迭代计算时的模型推理结果可以计算得到预处理矩阵 \tilde{Y}_d ：

$$\tilde{Y}_k = Y_k' = \begin{bmatrix} \Delta I_{kx1} & \Delta I_{kx2} \\ \Delta I_{ky1} & \Delta I_{ky2} \end{bmatrix} \begin{bmatrix} \Delta U_{kx1} & \Delta U_{kx2} \\ \Delta U_{ky1} & \Delta U_{ky2} \end{bmatrix}^{-1}, k \in D \quad (23)$$

在所提出的算法应用中，根据式(20)与(23)可以分别计算得到预处理矩阵的机理模型与数据驱动模型部分，由此得到矩阵 \tilde{Y} ：

$$\tilde{Y} = \begin{bmatrix} \tilde{Y}_d & \mathbf{0} \\ \mathbf{0} & \text{diag}\{\tilde{Y}_{p1}, \dots, \tilde{Y}_{pp}\} \end{bmatrix} \quad (24)$$

2.3 CPU-NPU 异构计算加速框架

近些年随着 DianNao 系列架构^[26-27]的推出，专用于深度学习领域的 NPU 得到飞速发展，NPU 通过突破权重实现存储和计算一体化，在神经网络模型的训练与推理方面较 CPU 和图形处理器 (graphics processing unit, GPU)更加具有效率优势。在数据-模型混合驱动时域仿真中，以 CPU-NPU 异构协同的计算框架可充分利用 CPU 强大的通用计算能力与复杂逻辑控制能力，以及 NPU 的神经网络模型快速推理能力。

昇腾计算语言 (ascend computing language, AscendCL) 是华为公司推出的在昇腾 NPU 平台上开发神经网络推理应用 API 库，能够完成 Device(NPU) 管理，内存管理，模型加载与推理等任务。

1.3 节提出的数据-模型混合驱动算法是一个具有逻辑性和顺序性的算法，故在本文提出的 CPU-NPU 异构加速框架中，整体逻辑控制与通用计算在 CPU 侧完成，而以 NPU 作协处理器，利用其神经网络模型的快速推理能力，用于完成耗时较长的神经网络模型推理部分，整个异构加速运算算法如图 3 所示。

3 算例分析与仿真验证

本文中使用了 C++ 编程语言实现提出的数据-模型混合驱动的电力系统暂态时域仿真算法，其中对机理模型驱动的发电机，微分方程求解采用隐式梯形积分方法，对采用数据驱动模型的发电机，模型推理调用 Libtorch 库 (仅用 CPU) 或 AscendCL 库 (CPU-NPU 异构) 实现；对网络代数方程的求解采用开源软件 KLU^[28]。整个算法在 IEEE-39 和 Polish-2383 节点系统中进行测试，测试所用的计算机 CPU 配置为 Intel Xeon Silver 4216，内存 32 GB；NPU 配置为华为 Atlas300T 9000；模型训练基于 Pytorch

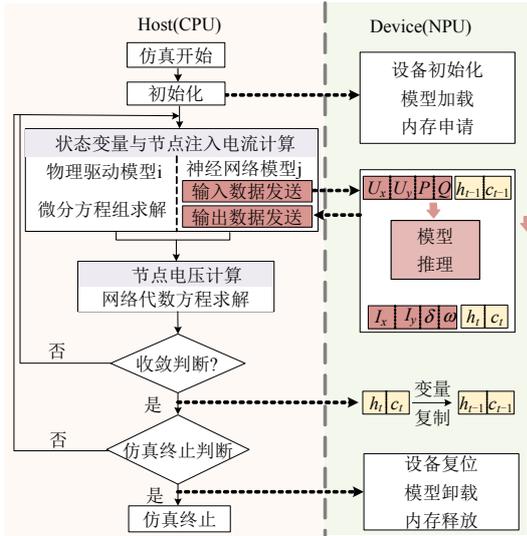


图3 CPU-NPU 异构计算算法流程图
Fig. 3 Diagram of proposed CPU-NPU heterogeneous computing algorithm

深度学习框架进行，硬件平台为 Intel Xeon E5-2650CPU 和 NVIDIA Tesla k20Xm GPU。

3.1 模型训练

本文采用 1.2 节提出的网络结构建立发电机的数据驱动模型。首先在电力系统分析工具(power system analysis toolbox, PSAT)^[29]中搭建 IEEE-39 和 Polish-2383 标准测试系统,通过改变系统中负荷大小、发电机出力以及故障线路、故障持续时间,来获取在不同工况下的系统机电暂态仿真数据共 6 000 条作为模型训练样本。模型训练时优化方法采用 Adam 梯度下降方法,性能评估采用均方根误差(root-mean squared error, RMSE)方法进行计算。

3.2 仿真结果

在两个测试系统中,任意选取其中 1~10 台发电机采用数据驱动模型,其余发电机仍采用机理模型。在本文验证中,发电机使用二阶模型,仿真时步长设置为 0.01s,收敛判据 $\epsilon=10^{-5}$ 。本节中使用 DDM(data-driven model)表示发电机数据驱动模型。

3.2.1 仿真准确性验证

图 4 展示了采用所提出的数据-模型混合驱动方法在 IEEE-39 与 Polish-2383 节点系统中测试得到的时域仿真结果,其中 IEEE-39 系统中故障开始时间为 0.2s,故障切除时间为 0.26s,在 Polish-2383 系统则分别为 0.2 与 0.36s;故障线路的节点号分别为 10-11 与 152-66。图中展示了发电机 1(IEEE-39 与 Polish-2383 节点系统中分别为节点号 30、10 的发电机)的功角、节点电压幅值的时域仿真结果以及相对于 PSAT 仿真结果的相对误差。

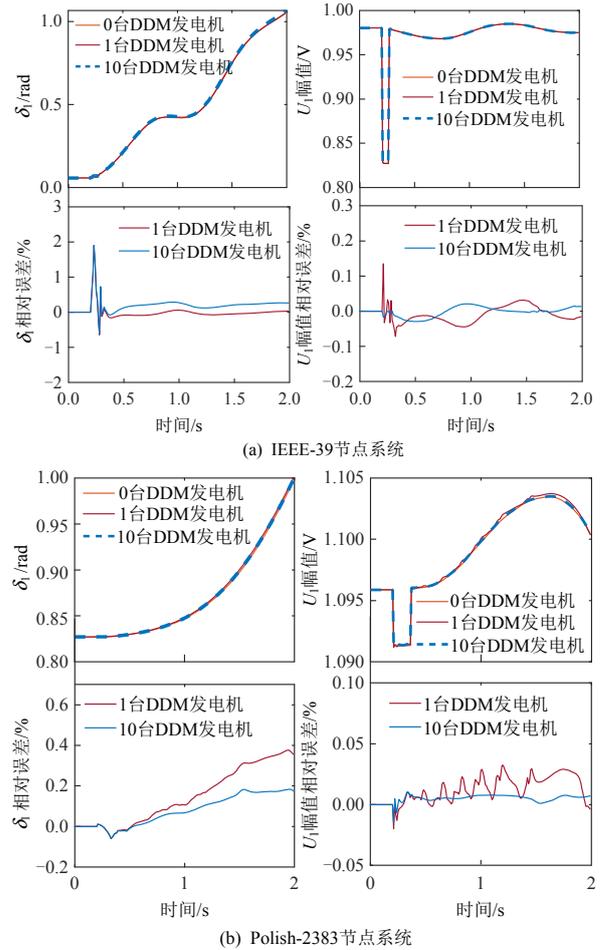


图4 发电机 1 的功角与节点电压幅值仿真曲线
Fig. 4 Rotor angle and nodal voltage amplitude curves of Generator 1

为了进一步说明所提出的数据-模型混合驱动仿真算法的有效性,设置负荷大小和发电机出力在 $\pm 20\%$ 范围内随机变化,通过潮流计算得到不同于训练集的 20 个初始运行点,并在系统中抽取 10 条线路作三相短路实验,接地电阻数值设为 1×10^{-3} 和 1×10^{-6} ,故障持续时长范围为 0.01~0.28(0.03s 为间隔)共 10 个,总共形成 4 000 个不同于训练集的故障场景,以 PSAT 仿真结果 y_{psat} 作为参考标准,采用下式计算所提方法仿真得到的各变量 y_{sim} (包括状态变量 x , 节点电压 U , 节点注入电流 I)的平均相对误差 e :

$$e = \left[\sum_{i=1, j=1}^{i=N, j=L} \left| (y_{sim}^{ij} - y_{psat}^{ij}) / y_{psat}^{ij} \right| \right] / (N \times L) \quad (25)$$

式中: N 表示同一类变量数量(计算 x 取 m , 计算 U, I 取 n); L 为单次仿真中的时间点数。2 个验证系统仿真结果的相对误差结果如表 1 所示。

图 4 和表 1 结果表明,提出的算法能够有效应用于数据-模型混合驱动建模的电力系统机电暂态

表 1 仿真结果相对误差

Table 1 Relative error of simulation results

变量	相对误差 $e/\%$			
	1 台 DDM 发电机		10 台 DDM 发电机	
	IEEE-39	Polish-2383	IEEE-39	Polish-2383
δ	2.7%	0.246%	0.43%	1.23%
I 幅值	0.29%	0.047%	0.078%	0.167%
I 相角	2.94%	0.0813%	0.081%	0.124%
U 幅值	0.035%	0.0031%	0.021%	0.0225%
U 相角	1.75%	0.082%	0.023%	0.0044%

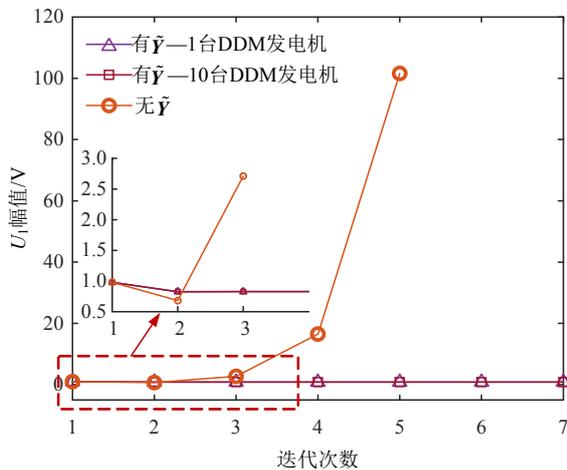
仿真；无论系统中是部分还是全部发电机的采用数据驱动模型，都能够准确得到系统中各状态变量与运行变量结果，与 PSAT 参考结果基本一致。

3.2.2 预处理矩阵对收敛性的影响

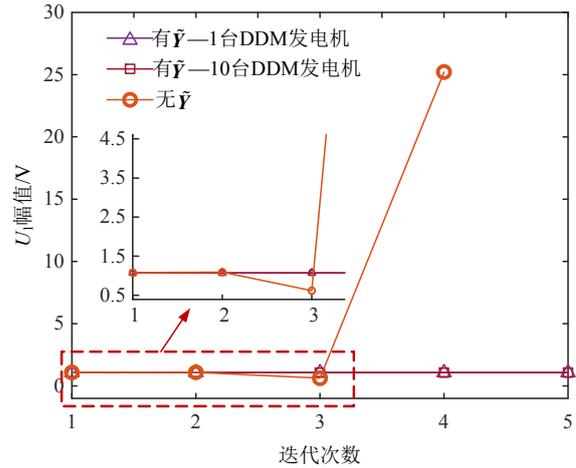
在 IEEE-39 和 Polish-2383 节点系统中均选取故障发生后的一个时步内(本文中为 0.2~0.21 s)发电机 1 的节点电压 U_1 幅值作为观测量，观察系统时域仿真在网络代数方程中是否有引入预处理矩阵时， U_1 幅值的迭代计算情况，结果如图 5 所示。从图 5(a)、(b)中可以看到，在 0.2s 故障发生后，若无预处理矩阵，则节点电压计算发散，无法收敛，进而系统无法继续仿真；而在引入预处理矩阵后，两个系统中无论是 1 台还是 10 台发电机采用数据驱动模型，均可在故障发生或者故障切除后能够顺利进行迭代计算，明显改善了系统仿真的收敛性。

3.2.3 预处理矩阵对迭代矩阵谱半径的影响

利用采用数据驱动模型的发电机实际参数计算虚拟导纳 Y'_d 并结合式(19)验证迭代矩阵谱半径大小。在表 2 中表示出了仿真过程中故障发生前 ($t=0.01$ s)，故障发生期间($t=0.22$ s)以及故障清除后 ($t=0.42$ s)的迭代矩阵的谱半径大小。



(a) IEEE-39节点系统



(b) Polish-2383节点系统

图 5 发电机 1 节点电压幅值迭代情况

Fig. 5 Nodal voltage amplitude of generator 1 during iteration

表 2 仿真过程迭代矩阵的谱半径

Table 2 Spectral radius of iteration matrix during simulation

预处理方法	t/s	谱半径 $\rho(J)$			
		1 台 DDM 发电机		10 台 DDM 发电机	
		IEEE-39	Polish-2383	IEEE-39	Polish-2383
无 \tilde{Y}	0.01	4.317 05	15.55 87	4.317 05	15.558 700
	0.22	5.874 81	16.11 44	5.874 81	16.114 400
	0.42	4.363 77	15.68 15	4.363 77	15.681 500
有 \tilde{Y}	0.01	0.230 50	0.389 78	0.650 67	0.681 136
	0.22	0.226 94	0.389 77	0.647 27	0.681 109
	0.42	0.230 49	0.389 78	0.650 92	0.681 174

表 2 结果显示，若未引入预处理矩阵 \tilde{Y} ，故障前、故障发生及清除后迭代矩阵的谱半径均大于 1，系统无法收敛；而引入矩阵 \tilde{Y} 后，整个仿真过程的迭代矩阵谱半径均小于 1，仿真收敛，进一步验证了所提出仿真收敛性改善方法的有效性。

3.2.4 CPU-NPU 异构运算对仿真速度的提升

在神经网络模型推理时，NPU 完成单次模型推理用时约 0.7 ms，而 CPU 约 7.6 ms。为进一步验证所提出异构算法的加速效果，设置仿真时间为 2 s，在两个验证系统中，均替换 1、3、5、7、10 台发电机为数据驱动模型。图 6 中比较了仅使用 CPU 与采用所提出的 CPU-NPU 异构加速算法的计算用时。

由图 6 仿真用时柱状图和加速比曲线可以看出，在 IEEE-39 节点系统中，本文提出的 NPU 作协处理器的异构加速算法可以相对加速约 9.6 倍，而在 Polish-2383 系统中，则可加速 6 倍左右。由此可见，所提出的 CPU-NPU 异构加速算法可以明显

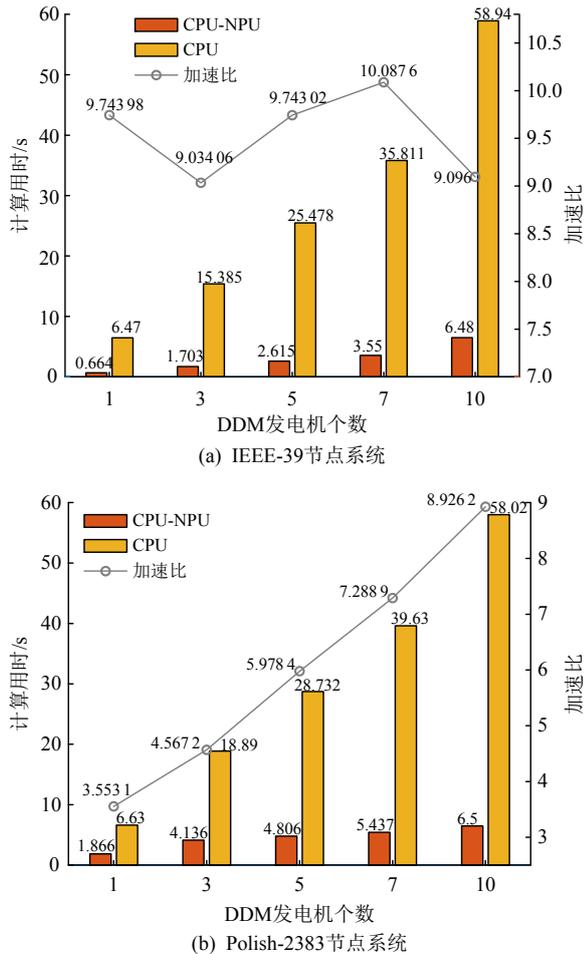


图6 CPU-NPU异构运算的加速效果

Fig. 6 Acceleration effect of heterogeneous operation based on CPU-NPU

减少仿真用时，加快仿真的计算速度。

4 结论

本文研究发电机数据驱动模型在电力系统机电暂态时域仿真中的应用问题，提出基于数据-模型混合驱动的仿真算法，并针对算法的收敛性与仿真速度分别提出对应改进策略，在 IEEE-39 与 Polish-2383 系统进行验证，得到结论如下：

1) 本文提出的算法能够有效应用于数据-模型混合驱动建模范式下的电力系统机电暂态时域仿真，可以在发电机数学模型难以构建时，准确仿真得到系统故障下的机电暂态过程；

2) 根据本文提出的预处理矩阵计算方法，对网络代数方程进行变换求解，能够有效改善混合驱动范式下时域仿真收敛的收敛问题；

3) 根据本文提出的 CPU-NPU 异构运算算法，能够有效利用 NPU 在神经网络模型推理方面的快速性优势，明显加快仿真速度。

在未来新能源大规模并网的电力系统中，构建新能源场站、分布式新能源负荷的数学模型，并通过数据-模型混合驱动的方法进行暂态时域仿真，是对新型电力系统进行暂态稳定分析的重要途径。

参考文献

- [1] 王伟胜, 林伟芳, 何国庆, 等. 美国德州 2021 年大停电事故对我国新能源发展的启示[J]. 中国电机工程学报, 2021, 41(12): 4033-4042.
WANG Weisheng, LIN Weifang, HE Guoqing, et al. Enlightenment of 2021 texas blackout to the renewable energy development in China [J]. Proceedings of the CSEE, 2021, 41(12): 4033-4042(in Chinese).
- [2] 田芳, 黄彦浩, 史东宇, 等. 电力系统仿真分析技术的发展趋势[J]. 中国电机工程学报, 2014, 34(13): 2151-2163.
TIAN Fang, HUANG Yanhao, SHI Dongyu, et al. Developing trend of power system simulation and analysis technology[J]. Proceedings of the CSEE, 2014, 34(13): 2151-2163(in Chinese).
- [3] 黄彦浩, 于之虹, 谢昶, 等. 电力大数据技术与电力系统仿真计算结合问题研究[J]. 中国电机工程学报, 2015, 35(1): 13-22.
HUANG Yanhao, YU Zhihong, XIE Chang, et al. Study on the application of electric power big data technology in power system simulation[J]. Proceedings of the CSEE, 2015, 35(1): 13-22(in Chinese).
- [4] 汤涌. 电力系统全过程动态(机电暂态与中长期动态过程)仿真技术与软件研究[D]. 北京: 中国电力科学研究院, 2002.
TANG Yong. The studies on techniques and software of power system full dynamic(electric-mechanical transient, mid-term and long-term dynamic) simulation[D]. Beijing: China Electric Power Research Institute, 2002(in Chinese).
- [5] 戴汉扬, 汤涌, 宋新立, 等. 基于功角等效法的网络代数方程求解预处理方法[J]. 中国电机工程学报, 2019, 39(8): 2265-2271.
DAI Hanyang, TANG Yong, SONG Xinli, et al. Preconditioning techniques for solving the network algebraic equations based on generator power angle[J]. Proceedings of the CSEE, 2019, 39(8): 2265-2271(in Chinese).
- [6] 吴红斌, 丁明. 用于电力系统暂态稳定仿真的可变步长牛顿法[J]. 中国电机工程学报, 2010, 30(7): 36-41.
WU Hongbin, DING Ming. Newton method with variable step size for power system transient stability simulation [J]. Proceedings of the CSEE, 2010, 30(7): 36-41(in Chinese).

- [7] 吴滋坤, 张俊勃, 黄钦雄, 等. 基于非诚实牛顿法和雅可比迭代的电力系统时域计算隐式梯形积分交替求解算法[J]. 中国电机工程学报, 2022, 42(8): 2864-2872. WU Zikun, ZHANG Junbo, HUANG Qinxiong, et al. An implicit trapezoidal integration alternating solution method based on dishonest newton method and jacobian iteration for power system time-domain analysis [J]. Proceedings of the CSEE, 2022, 42(8): 2864-2872(in Chinese).
- [8] 王建, 陈颖, 沈沉. 基于逆 Broyden 拟牛顿法的分布式暂态稳定仿真算法[J]. 电力系统自动化, 2010, 34(5): 7-12. WANG Jian, CHEN Ying, SHEN Chen. A distributed dynamic simulation algorithm for power systems based on inverse broyden quasi newton method[J]. Automation of Electric Power Systems, 2010, 34(5): 7-12(in Chinese).
- [9] 朱泽翔. 电力系统动态参数辨识与模型降阶研究[D]. 杭州: 浙江大学, 2018. ZHU Zexiang. Research on power system dynamic parameter estimation and model reduction[D]. Hangzhou: Zhejiang University, 2018(in Chinese).
- [10] 郑竞宏, 李康, 朱守真. 暂态稳定分析中负荷模型主导参数研究[J]. 电力自动化设备, 2009, 29(9): 1-6. ZHENG Jinghong, LI Kang, ZHU Shouzhen. Dominant parameters of load model in transient stability analysis[J]. Electric Power Automation Equipment, 2009, 29(9): 1-6(in Chinese).
- [11] 李亚楼, 张星, 胡善华, 等. 含高比例电力电子装备电力系统安全稳定分析建模仿真技术[J]. 电力系统自动化, 2022, 46(10): 33-42. LI Yalou, ZHANG Xing, HU Shanhua, et al. Modeling and simulation technology for stability analysis of power system with high proportion of power electronics [J]. Automation of Electric Power Systems, 2022, 46(10): 33-42(in Chinese).
- [12] ZHU Zexiang, GENG Guangchao, JIANG Quanyuan. Multi-scenario parameter estimation for synchronous generation systems[J]. IEEE Transactions on Power Systems, 2017, 32(3): 1851-1859.
- [13] HUANG Bin, WANG Jianhui. Applications of physics-informed neural networks in power systems - A review[J]. IEEE Transactions on Power Systems, 2023, 38(1): 572-588.
- [14] 汤奕, 崔晗, 李峰, 等. 人工智能在电力系统暂态问题中的应用综述[J]. 中国电机工程学报, 2019, 39(1): 2-13. TANG Yi, CUI Han, LI Feng, et al. Review on artificial intelligence in power system transient stability analysis [J]. Proceedings of the CSEE, 2019, 39(1): 2-13(in Chinese).
- [15] 杨斌, 杜文娟, 王海风. 数据驱动下的虚拟同步发电机等效建模[J]. 电网技术, 2020, 44(1): 35-43. YANG Bin, DU Wenjuan, WANG Haifeng. Equivalent modeling of virtual synchronous generator based on data-driven method[J]. Power System Technology, 2020, 44(1): 35-43(in Chinese).
- [16] MISYRIS G S, VENZKE A, CHATZIVASILEIADIS S. Physics-informed neural networks for power systems[C]//Proceedings of the 2020 IEEE Power & Energy Society General Meeting(PESGM). Montreal, Canada: IEEE, 2020.
- [17] STIASNY J, CHEVALIER S, CHATZIVASILEIADIS S. Learning without data: physics-informed neural networks for fast time-domain simulation[C]//Proceedings of 2021 IEEE International Conference on Communications, Control, and Computing Technologies for Smart Grids. Aachen, Germany: IEEE, 2021.
- [18] 王锡凡, 方万良, 杜正春. 现代电力系统分析[M]. 北京: 科学出版社, 2003. WANG Xifan, FANG Wanliang, DU Zhengchu. Modern power system analysis[M]. Beijing: Science Press, 2003(in Chinese).
- [19] 李峰, 王琦, 胡健雄, 等. 数据与知识联合驱动方法研究进展及其在电力系统中应用展望[J]. 中国电机工程学报, 2021, 41(13): 4377-4389. LI Feng, WANG Qi, HU Jianxiong, et al. Combined data-driven and knowledge-driven methodology research advances and its applied prospect in power systems [J]. Proceedings of the CSEE, 2021, 41(13): 4377-4389(in Chinese).
- [20] RAISSI M, PERDIKARIS P, KARNIADAKIS G E. Physics-informed neural networks: a deep learning framework for solving forward and inverse problems involving nonlinear partial differential equations [J]. Journal of Computational Physics, 2019, 378: 686-707.
- [21] HAYKIN S. Neural networks and learning machines [M]. 3rd ed. New Jersey: Pearson Education, 2009.
- [22] HOCHREITER S, CHMIDHUBER J. Long short-term memory[J]. Neural Computation, 1997, 9(8): 1735-1780.
- [23] 毛承雄, 樊俊, KULICKE B. 电力系统动态仿真新的交替迭代解法[J]. 电力系统自动化, 1998, 22(3): 23-25. MAO Chengxiong, FAN Jun, KULICKE B. A new alternate iteration method for simulation of power system dynamics[J]. Automation of Electric Power Systems, 1998, 22(3): 23-25(in Chinese).
- [24] 易大义, 沈云宝, 李有法. 计算方法[M]. 2版. 杭州: 浙江大学出版社, 2002. YI Dayi, SHEN Yunbao, LI Youfa. Calculation method [M]. 2nd ed. Hangzhou: Zhejiang University Press, 2002(in Chinese).

- [25] 周孝信, 田芳, 李亚楼, 等. 电力系统并行计算与数字仿真[M]. 北京: 清华大学出版社, 2014.
ZHOU Xiaoxin, TIAN Fang, LI Yalou, et al. Parallel computing and digital simulation of power system [M]. Beijing: Tsinghua University Press, 2014(in Chinese).
- [26] CHEN Tianshi, DU Zidong, SUN Ninghui, et al. DianNao: a small-footprint high-throughput accelerator for ubiquitous machine-learning[J]. ACM SIGARCH Computer Architecture News, 2014, 42(1): 269-284.
- [27] LIU Daofu, CHEN Tianshi, LIU Shaoli, et al. PuDianNao: a polyvalent machine learning accelerator [J]. ACM SIGARCH Computer Architecture News, 2015, 43(1): 369-381.
- [28] DAVIS T A, NATARAJAN E P. Algorithm 907: KLU, a direct sparse solver for circuit simulation problems [J]. ACM Transactions on Mathematical Software, 2010, 37(3): 36.
- [29] MILANO F. An open source power system analysis toolbox[J]. IEEE Transactions on Power Systems, 2005, 20(3): 1199-1206.

附录 A

本文基于 LSTM 模型建立的发电机数据驱动模型, 包括 LSTM 模块和全连接层模块, 模型结构如图 A1 所示。图中: P_0 、 Q_0 、 V_x 、 V_y 为模型输入的发电机初始有功、无功、节点电压、y 轴分量; δ 、 ω 、 I_x 、 I_y 为模型输出的状态变量与节点注入电流 x、y 轴分量; σ 与 \tanh 表示激活函数; \odot 表示哈达玛积; \oplus 表示求和。

LSTM 神经网络结构主要包括①单元状态、②输入门、③遗忘门、④输出门 4 个部分。通过全连接层将 LSTM 模型输出的高维信息映射到需要求解的 δ 、 ω 、 I_x 、 I_y ; 整个模型

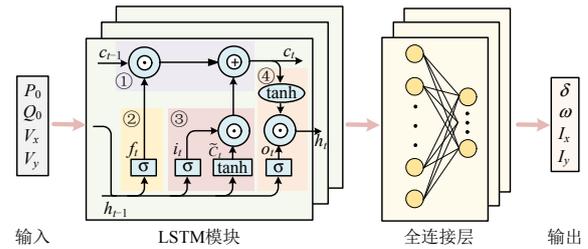


图 A1 基于 LSTM 的发电机数据驱动模型结构

Fig. A1 Data-driven model structure of generator based on LSTM

输入输出可以直接表示为

$$[\delta, \omega, I_x, I_y, (h_t, c_t)] = N[U_x, U_y, P_0, Q_0, (h_{t-1}, c_{t-1})] \quad (\text{A1})$$

式中 (h_{t-1}, c_{t-1}) 和 (h_t, c_t) 表示 LSTM 模型输入和输出的隐藏状态与单元状态。



王鑫

在线出版日期: 2023-04-27。

收稿日期: 2022-10-26。

作者简介:

王鑫(1999), 男, 硕士研究生, 主要从事电力系统发电机数据驱动建模与暂态仿真, zjuwangxin@zju.edu.cn;

*通信作者: 耿光超(1985), 男, 副教授, 博士生导师, 主要从事电力传感与物联、新能源并网与储能技术应用, ggc@zju.edu.cn;

江全元(1975), 男, 教授, 博士生导师, 主要从事电力系统稳定与控制、新能源并网与储能技术应用, jqy@zju.edu.cn。

(责任编辑 邱丽萍)

A Fast Electromechanical Transient Simulation Algorithm for Power System Based on Data and Physics Driven Model

WANG Xin¹, YANG Ke¹, HUANG Wenqi², MA Yunfei¹, GENG Guangchao^{1*}, JIANG Quanyuan¹

(1. College of Electrical Engineering, Zhejiang University; 2. China Southern Power Grid Digital Power Grid Group Co., Ltd.)

KEY WORDS: electromechanical transient; time-domain simulation; data-and physics-driven; convergence; CPU-NPU heterogeneous computing

Electromechanical transient time domain simulation(TDS) is one of the most effective methods for power system stability analysis and it involves the solution of a large number of differential and algebraic equations(DAEs), which are constructed based on modeling of power system network and dynamic elements, including generators. However, in the actual system, there are problems on both generators and load side such as the difficulty in constructing the physical mechanism model of the components, the limited accuracy of the structural parameters, or even the inability to obtain them.

Data-driven method is applied in modeling of power system elements, and the structure of new modeling paradigm is shown in Fig. 1. But this has changed the traditional modeling paradigm of power system, which makes traditional electromechanical transient time domain simulation methods fail to be directly applied to power system with new paradigm. Thus, an integrating data- and physics-driven time domain simulation (DPD-TDS) algorithm for electromechanical transient simulation is proposed in this paper.

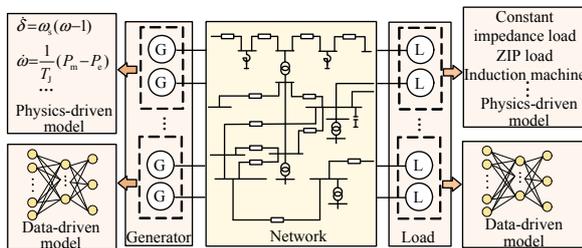


Fig. 1 Data- and physics-driven modeling in power system

In this method, the state variables and nodal injection currents are calculated through data-driven model, and network equations are used to calculate nodal voltages. And these two parts are iteratively calculated alternately. The proposed algorithm flowchart is shown in Fig. 2.

In order to improve the convergence of the DPD-TDS, based on spectral radius theory, a preprocessing matrix calculation method shown in (1) for network

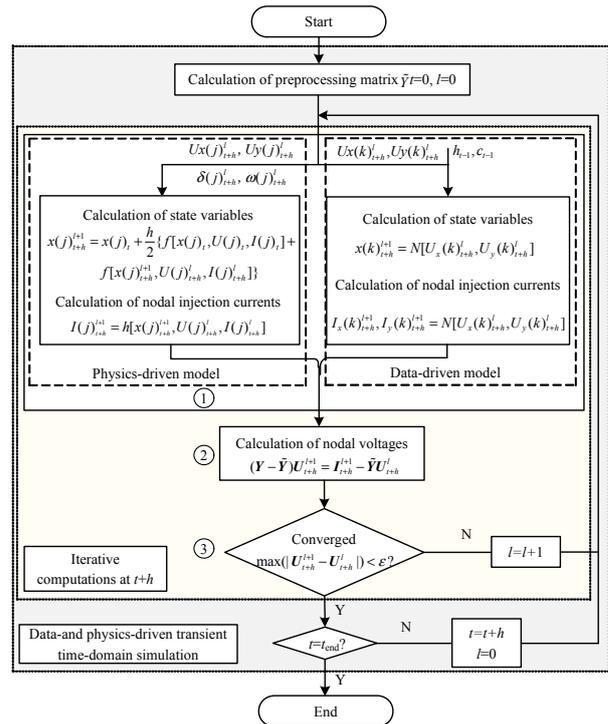


Fig. 2 Data- and physics-driven transient time-domain simulation algorithm flowchart

equations is proposed.

$$\tilde{Y} = \begin{bmatrix} \tilde{Y}_d \\ \tilde{Y}_p \end{bmatrix} = \begin{bmatrix} \text{diag}\{\tilde{Y}_{d1}, \dots, \tilde{Y}_{dd}\} & \mathbf{0} \\ \mathbf{0} & \text{diag}\{\tilde{Y}_{p1}, \dots, \tilde{Y}_{pp}\} \end{bmatrix} \quad (1)$$

For speeding up the simulation, a central processing unit-neural network processing unit (CPU-NPU) heterogeneous computing architecture is designed to in this paper. Differential algebraic equations for physics-driven generators are solved in CPU and the forward inference of data-driven generators is executed in NPU.

Finally, the case study demonstrates in IEEE-39 and Polish-2383 system has shown the effectiveness of the proposed method. With the preprocessing matrix calculation proposed in this paper, the convergence of TDS under hybrid driving paradigm could be obviously improved. And with the proposed CPU-NPU heterogeneous computing algorithm, the simulation speed can be significantly accelerated.