

嵌入输入凸神经网络的静态电压稳定控制 替代建模方法及其解析算法

刘友波¹,王天翔¹,邱高¹,魏巍²,周波²,刘挺坚¹,刘俊勇¹,梅生伟³

(1. 四川大学 电气工程学院,四川 成都 610065;2. 国网四川省电力公司电力科学研究院,四川 成都 610041;

3. 清华大学 电机工程与应用电子技术系,北京 100084)

摘要:电力系统静态电压稳定控制通常依赖于精准的物理建模,可能导致收敛和时效性问题。从数据驱动的角度出发,提出一种嵌入输入凸神经网络(ICNN)的静态电压稳定控制替代建模方法及其解析算法。利用ICNN精准地参数化由运行变量映射的凸非线性电压稳定边界;考虑ICNN的计算实时性和去迭代优势,将ICNN嵌入预防控制模型,替代电压稳定计算的非线性方程迭代过程,规避机理计算的收敛问题,从而生成电压稳定的凸非线性简化控制模型;通过解析ICNN的深度结构表达式推导出ICNN超参数驱动的控制梯度,提出有效耦合内点法的ICNN最速下降求解策略,实现电压稳定控制提效。IEEE 14节点系统和IEEE 118节点系统的测试结果表明,所提ICNN驱动的电压稳定凸非线性控制可有效耦合机理建模和数据模型,相比传统方法能更好地兼顾控制精度和计算效率,具有一定的在线应用潜力。

关键词:静态电压稳定;预防控制;内点法;输入凸神经网络;替代建模

中图分类号:TM 712

文献标志码:A

DOI:10.16081/j.epae.202207013

0 引言

随着电网规模、负荷以及不确定性的增大,电力系统运行更加接近安全稳定极限点,电压崩溃风险增加^[1-2],亟需研究针对静态电压稳定(static voltage stability, SVS)的态势评估及防控方法。然而,SVS问题具有较强的非线性和非凸性,其控制效率和精度难以平衡。

目前,针对SVS控制已开展较多研究,主要方法为灵敏度方法和最优潮流(optimal power flow, OPF)法。灵敏度方法通过推演电压稳定裕度与控制变量间的直接灵敏度关系实现预防控制^[3-5],但该方法依赖于局部线性化假设,可能会造成电压稳定的欠调或过调,导致控制精度下降。OPF法直接将精准的电压稳定评估模型嵌入预防控制模型中,并采用启发式算法^[6-7]、非线性规划算法^[8-9]进行求解,以制定电压稳定裕度提升策略。文献[6]利用亚临界霍普夫分岔值表征系统电压稳定裕度,将其作为OPF的优化目标,但该方法未考虑控制成本。文献[7]考

虑系统发电成本、柔性交流输电系统(flexible AC transmission system, FACTS)设备成本、负荷切除量等,构建多目标优化模型以改善系统电压稳定,最终利用多目标差分进化算法进行求解。但将启发式算法的随机搜索求解方式应用于大电网时计算效率偏低,且在鞍结分岔点附近电压稳定约束的病态可能导致不收敛。文献[8]基于负荷裕度期望值构建电压稳定约束,并嵌入预防控制模型,但设定的期望值偏大时模型求解可能不收敛。文献[9]构建含大量预想故障电压稳定约束的最优潮流模型,并结合Benders分解算法和连续潮流(continuation power flow, CPF)模型进行求解。CPF模型虽能直观地进行系统SVS分析^[10],但其较重的计算负担降低了控制策略的生成效率。总体而言,灵敏度方法以牺牲控制精度为代价来提高控制效率,而基于OPF法构建的预防控制模型虽然清晰,但复杂且非凸,现有方法难以平衡SVS问题的控制效率和精度。

数据驱动的替代建模技术已在电力系统中得到广泛应用^[11-15],其利用机器学习模型替代非线性系统的复杂机理分析过程,以简化、缩减高维非线性控制中最复杂的部分,实现控制提效。该技术已成为处理复杂高维非线性控制的有效方法,其中线性回归和决策树(decision tree, DT)因具有易解析的特点而受到关注。文献[11]构建弹性网络线性回归模型,将其作为替代模型定量描述系统电压的不确定性,并将其嵌入线性规划模型以实现储能配置。文献[12]基于DT模型识别关键线路,并生成关键线路串补策略以保证系统电压稳定性。但上述模型属于

收稿日期:2021-12-14;修回日期:2022-04-10

在线出版日期:2022-07-19

基金项目:国家自然科学基金资助项目(51977133);国网四川省电力公司科技项目(52199720035);四川省青年科技创新研究团队项目(2021LDTD0016-LH)

Project supported by the National Natural Science Foundation of China(51977133), the Science and Technology Project of State Grid Sichuan Electric Power Company(52199720035) and the Youth Science and Technology Innovation Research Team Project of Sichuan Province(2021LDTD0016-LH)

浅层学习,难以挖掘数据深层特征,泛化能力有限,且单一线性模型在非线性的安全边界附近的性能可能陡降。为此,大量研究引入泛化能力更强的深度学习(deep learning, DL)来构建替代模型,且模型表现出优良的性能^[13-15]。文献[13]使用基于贝叶斯神经网络的替代模型构建考虑暂态稳定约束的OPF模型,并采用无梯度贝叶斯优化制定预防控制策略。文献[14]基于深度信念网络和进化算法进行暂态稳定预防控制。虽然替代建模简化了原始模型,但元启发式求解策略仍存在“维数灾”问题,基于梯度的求解算法能在目标最速下降的方向上搜索可行解,更适合求解高维非线性的安全预防控制问题^[15],但传统DL的非凸性将造成梯度算法收敛性的下降。

输入凸神经网络(input convex neural network, ICNN)能以非线性凸函数形式精准地参数化输出与输入特征的关联规则,构建出凸且紧致安全边界,可有效避免利用非凸安全边界约束导致的模型收敛困难或局部最优问题出现^[16-17]。相较于传统神经网络,ICNN可以严格证明凸性,且其构造的凸超参边界更适合与快速梯度决策算法进行耦合。本文引入ICNN来替代CPF,在不丢失非线性前提下,建立电压稳定裕度快速精准凸控制模型。同时,基于ICNN参数化规则,通过推导电压稳定裕度对控制变量的雅可比矩阵和海森矩阵,得到稳定裕度的控制梯度信息,从而有效耦合内点法(interior point method, IPM)来实现利用最速下降策略求解控制模型。最后,以IEEE 14节点系统和IEEE 118节点系统验证所提方法,结果表明,相较于传统灵敏度方法和非凸神经网络的替代建模方法,所提数据驱动电压稳定凸控制模型可更优地权衡控制效率和精度。

1 电力系统SVS预防控制模型

本文SVS预防控制模型的主要目标为以最小的成本调节电压稳定裕度至设定水平,数学模型如下。

1.1 目标函数

考虑的控制变量包括发电机出力、发电机机端电压以及并联电容器无功补偿功率,目标则综合考虑运行成本最小化。目标函数为:

$$\min_{P_{Gi}, Q_{Cn}} F = \sum_{i \in \Omega_G} C_{Pi}(P_{Gi}) + \sum_{n \in \Omega_C} C_{Cn}(Q_{Cn}) \quad (1)$$

式中: F 为控制模型的目标函数; P_{Gi} 、 Q_{Cn} 分别为节点 i 的发电机有功出力及节点 n 的并联电容器组无功补偿功率; Ω_G 、 Ω_C 分别为发电机节点集合和无功补偿节点集合; $C_{Pi}(P_{Gi})$ 、 $C_{Cn}(Q_{Cn})$ 分别为节点 i 的发电机运行成本计算函数和节点 n 的无功补偿成本计算函数,分别如式(2)、(3)所示。

$$C_{Pi}(P_{Gi}) = a_i P_{Gi}^2 + b_i P_{Gi} + c_i \quad (2)$$

$$C_{Cn}(Q_{Cn}) = c_s Q_{Cn} / P_s \quad (3)$$

式中: a_i 、 b_i 、 c_i 为节点 i 的发电机有功出力成本系数; c_s 为单台电容器可用投切次数的单次平均成本; P_s 为单台电容器投入的无功补偿功率。

1.2 约束条件

1)潮流等式约束,即:

$$\begin{cases} P_{Gi} - P_{Li} - V_i \sum_{j \in \Omega_n} V_j (G_{ij} \cos \theta_{ij} + B_{ij} \sin \theta_{ij}) = 0 \\ Q_{Gi} + Q_{Ci} - Q_{Li} - V_i \sum_{j \in \Omega_n} V_j (G_{ij} \sin \theta_{ij} - B_{ij} \cos \theta_{ij}) = 0 \end{cases} \quad (4)$$

式中: $i \in \Omega_B$, Ω_B 为系统节点集合; P_{Li} 、 Q_{Li} 分别为节点 i 的有功负荷和无功负荷; V_i 为节点 i 的电压幅值; θ_{ij} 为节点 i 、 j 电压间的相角差; Q_{Ci} 为节点 i 的发电机无功出力; G_{ij} 、 B_{ij} 分别为节点 i 、 j 对应的导纳矩阵中元素的实部和虚部。

2)运行不等式约束。

(1)发电机出力上、下限约束,即:

$$\begin{cases} \underline{P}_{Gi} \leq P_{Gi} \leq \bar{P}_{Gi} \\ \underline{Q}_{Gi} \leq Q_{Gi} \leq \bar{Q}_{Gi} \end{cases} \quad i \in \Omega_G \quad (5)$$

式中: $\bar{P}_{Gi}$ 、 $\underline{P}_{Gi}$ 和 $\bar{Q}_{Gi}$ 、 $\underline{Q}_{Gi}$ 分别为节点 i 的发电机有功出力和无功出力上、下限。

(2)无功补偿上、下限约束,即:

$$\underline{Q}_{Cn} \leq Q_{Cn} \leq \bar{Q}_{Cn} \quad n \in \Omega_C \quad (6)$$

式中: $\bar{Q}_{Cn}$ 、 $\underline{Q}_{Cn}$ 分别为节点 n 的电容器组无功补偿功率上、下限。

(3)电压约束,即:

$$\underline{V}_i \leq V_i \leq \bar{V}_i \quad i \in \Omega_B \quad (7)$$

式中: $\bar{V}_i$ 、 $\underline{V}_i$ 分别节点 i 的电压幅值上、下限。

(4)线路潮流约束,即:

$$P_{ij} = \frac{V_i^2 g_{ij}}{k_{ij}^2} - \frac{V_i V_j (g_{ij} \cos \theta_{ij} + b_{ij} \sin \theta_{ij})}{k_{ij}} \quad (8)$$

$$\underline{P}_{ij} \leq P_{ij} \leq \bar{P}_{ij} \quad i, j \in \Omega_B \quad (9)$$

式中: P_{ij} 为线路 ij 传输的有功功率; g_{ij} 、 b_{ij} 分别为线路 ij 的电导和电纳; k_{ij} 为线路 ij 上变压器的变比; $\bar{P}_{ij}$ 、 $\underline{P}_{ij}$ 分别为线路 ij 传输有功功率的上、下限。

(5)SVS裕度约束,即:

$$\lambda_{cr} \geq \underline{\lambda}_{cr} \quad (10)$$

式中: λ_{cr} 为负荷裕度,其值通过CPF模型式(11)进行计算; $\underline{\lambda}_{cr}$ 为设定的负荷裕度下限。

$$\begin{cases} \max \lambda \\ \text{s.t. } P_{Gi}(1 + \lambda n_{Gi}) - P_{Li}(1 + \lambda n_{PLi}) = \\ \quad V_i \sum_{j \in \Omega_n} V_j (G_{ij} \cos \theta_{ij} + B_{ij} \sin \theta_{ij}) \\ Q_{Gi} - Q_{Li}(1 + \lambda n_{QLi}) = \\ \quad V_i \sum_{j \in \Omega_n} V_j (G_{ij} \sin \theta_{ij} - B_{ij} \cos \theta_{ij}) \\ s(x) \leq 0 \end{cases} \quad (11)$$

式中: λ 为负荷增长参数; $i \in \Omega_B$; n_{Gi} 、 n_{PLi} 、 n_{QLi} 分别为节点 i 的发电机有功出力、有功负荷和无功负荷的增长方向; $s(\mathbf{x}) \leq 0$ 为系统安全约束, $\mathbf{x}$ 为系统状态变量。区别于常规潮流计算, CPF 将 λ 作为系统负荷增长参数, 构建参数化潮流方程。通过递增参数 λ 来重复计算系统潮流, 直至潮流雅可比矩阵奇异, 求得系统负荷裕度 λ_{cr} , 从而量化系统的 SVS^[18], 但该方法对系统规模较敏感, 计算难度较大, 同时, 在上述电压稳定控制模型的求解过程中, 反复利用 CPF 评估电压稳定裕度将消耗大量的计算成本。为此, 本文将考虑基于 DL 构建 CPF 的替代模型, 实现电压稳定的快速辅助决策。

2 电压稳定控制策略的 ICNN 替代建模

基于式(11)求解负荷裕度存在收敛性与效率问题, 当系统规模较大时, 式(1)~(11)的变量维度较高, 为此, 引入 ICNN 作为替代模型, 建立负荷裕度与决策变量间的精准凸关联规则, 并对式(11)进行去模型(model-free)变式, 生成数据驱动下的电压稳定凸优化控制模型, 有效地保证控制效率与控制精度。

2.1 ICNN 结构

ICNN 包含大量非线性激活元, 可在超参空间准确构建凸非线性电压稳定安全边界, 解决传统机器学习在优化控制模型中的非凸性导致的收敛问题^[17]。附录 A 图 A1 给出了含 k 层隐藏层的 ICNN 结构。图中: ICNN 为全连接结构; $\mathbf{X}$ 、 $\mathbf{Y}$ 分别为 ICNN 的输入特征和标签, 本文采用的输入特征 $\mathbf{X} = [P_{Gi}, V_{Gi}, Q_{Ci}, P_{Li}]$, V_{Gi} 为发电机节点 i 的机端电压, 标签 $\mathbf{Y}$ 为负荷裕度 λ_{cr} ; δ 为激活函数; $\mathbf{w}_\ell$ ($\ell = 1, 2, \dots, k+1$) 为各层间的权重参数; $\mathbf{T}_\ell$ ($\ell = 1, 2, \dots, k-1$) 为第 $\ell+1$ 层隐藏层与输入层间的权重参数; $\mathbf{z}_\ell$ ($\ell = 1, 2, \dots, k$) 为第 ℓ 层隐藏层的输出。ICNN 的凸性以及非线性拟合能力可由如下定理 1 和定理 2 保证^[17]。

定理 1 ICNN 结构中的权重 $\mathbf{w}_2 \sim \mathbf{w}_k$ 为非负数且激活函数 δ 为非减凸函数, 这可以保证模型中的输出 $\mathbf{Y}$ 为输入 $\mathbf{X}$ 的凸函数, 且该凸函数的海森矩阵(计算方法见附录 A 式(A1)~(A3))正定。

定理 2 ICNN 函数 $f_{\text{ICNN}}: \mathbf{R}^d \rightarrow \mathbf{R}$ 能逼近紧致域(compact domain)中的任意利普希茨凸函数 $f: \mathbf{R}^d \rightarrow \mathbf{R}$ ($\mathbf{R}^d$ 为 d 维欧氏空间), 即存在极小数 ε , 使得对于紧致域中的任意 $\mathbf{X}$, 均有 $|f_{\text{ICNN}}(\mathbf{X}) - f(\mathbf{X})| \leq \varepsilon$ 。

定理 1 对网络权重进行了非负限制, 弱化了网络的表达能力, 因此, ICNN 在输入层与隐藏层神经元之间增加“直通”层(passthrough layer)以强化深度神经网络的学习能力, 有效提升电压稳定评估能力。第 ℓ 层隐藏层输出 $\mathbf{z}_\ell$ 为:

$$\mathbf{z}_\ell = \delta(\mathbf{w}_\ell \mathbf{z}_{\ell-1} + \mathbf{b}_\ell^w + \mathbf{T}_{\ell-1} \mathbf{X} + \mathbf{b}_{\ell-1}^T) \quad \ell = 1, 2, \dots, k \quad (12)$$

式中: $\mathbf{b}_\ell^w$ 、 $\mathbf{b}_{\ell-1}^T$ 分别为第 ℓ 层隐藏层和第 $\ell-1$ 层“直通”层的偏置。

2.2 替代模型的构建

作为一种监督学习模型, ICNN 基于结构风险以及先验分布下的离散抽样样本进行训练。对于本文所研究的电压稳定预防控制问题, 基于离线生成的以负荷裕度为标签的样本集对 ICNN 进行训练。

2.2.1 样本生成方法

监督学习的样本组织结构由输入特征和目标特征构成。输入特征为发电机有功出力、发电机机端电压、系统无功补偿量、负荷有功功率。目标特征(标签)为负荷裕度, 可通过式(11)求解。

在上述样本组织结构下, 通过在电网运行变量上、下限构成的先验分布下随机抽样生成大量运行点集合, 提取各运行点的输入特征, 计算各运行点的负荷裕度并将其作为目标特征(标签), 即可形成用于 ICNN 训练和测试的样本集合。考虑到拉丁超立方抽样(Latin hypercube sampling, LHS)采样效率高^[19], 本文采用 LHS 作为随机抽样方法。电网运行的先验分布根据如下经验和设备标称限额进行确定: 发电机机端电压波动范围为 0.94~1.06 p.u.; 发电机有功出力范围按照式(5)给出的上、下限确定; 并联电容器组无功补偿范围为 0~10 Mvar; 负荷水平范围为某典型运行日负荷水平的 90%~130%。

2.2.2 ICNN 损失函数及训练

为清晰地显示 ICNN 数学结构, 定义如下函数来展现 ICNN 层间的连接关系:

$$\begin{cases} \mathbf{Y}_\ell(\mathbf{z}_{\ell-1}) = \mathbf{w}_\ell \mathbf{z}_{\ell-1} + \mathbf{b}_\ell^w & \mathbf{w}_\ell \in \mathbf{R}^{N_\ell \times N_{\ell-1}} \\ \mathbf{w}_\ell = [\mathbf{w}_\ell^1; \dots; \mathbf{w}_\ell^m; \dots; \mathbf{w}_\ell^{N_\ell}] & \mathbf{w}_\ell^m \in \mathbf{R}^{1 \times N_{\ell-1}} \\ \mathbf{b}_\ell^w = [\mathbf{b}_\ell^{w1}; \dots; \mathbf{b}_\ell^{wm}; \dots; \mathbf{b}_\ell^{wN_\ell}] \end{cases} \quad (13)$$

$$\begin{cases} \mathbf{D}_{\ell-1}(\mathbf{X}) = \mathbf{T}_{\ell-1} \mathbf{X} + \mathbf{b}_{\ell-1}^T & \mathbf{T}_{\ell-1} \in \mathbf{R}^{N_\ell \times N_0} \\ \mathbf{T}_{\ell-1} = [\mathbf{T}_{\ell-1}^1; \dots; \mathbf{T}_{\ell-1}^m; \dots; \mathbf{T}_{\ell-1}^{N_\ell}] & \mathbf{T}_{\ell-1}^m \in \mathbf{R}^{1 \times N_0} \\ \mathbf{b}_{\ell-1}^T = [\mathbf{b}_{\ell-1}^{T1}; \dots; \mathbf{b}_{\ell-1}^{Tm}; \dots; \mathbf{b}_{\ell-1}^{TN_\ell}] \end{cases} \quad (14)$$

式中: $\mathbf{Y}_\ell(\mathbf{z}_{\ell-1})$ 、 $\mathbf{D}_{\ell-1}(\mathbf{X})$ 分别为第 ℓ 层隐藏层中来自前一隐藏层和输入层的输入; N_ℓ 为 ICNN 第 ℓ 层隐藏层的神经元个数, N_0 为输入特征的维度, N_{k+1} 为标签的维度; $\mathbf{w}_\ell^m$ 、 $\mathbf{b}_\ell^{wm}$ ($m=1, 2, \dots, N_\ell$) 分别为第 ℓ 层隐藏层的第 m 维神经元与前一层输出相连接的权重和偏置; $\mathbf{T}_{\ell-1}^m$ 、 $\mathbf{b}_{\ell-1}^{Tm}$ ($m=1, 2, \dots, N_\ell$) 分别为第 ℓ 层隐藏层的第 m 维神经元与输入特征相连接的权重和偏置。根据 ICNN 特性, 选取隐藏层激活函数 $\delta(\mathbf{x}_z)$ 为 CeLu 函数, 具体表达式为:

$$\delta(\mathbf{x}_z) = \begin{cases} \mathbf{x}_z & \mathbf{x}_z \geq 0 \\ \alpha(e^{\mathbf{x}_z/\alpha} - 1) & \mathbf{x}_z < 0 \end{cases} \quad (15)$$

式中: $\mathbf{x}_z$ 为隐藏层输入; α 为系数。

对附录 A 图 A1 所示的 ICNN 进行解析, 其输出为:

$$\begin{cases} \Phi^0(\mathbf{X}) = Y_{k+1}(\mathbf{z}_k) \\ \mathbf{z}_k = \delta \left(Y_k \left(\cdots Y_3 \left(\delta \left(Y_2 \left(\delta \left(Y_1(\mathbf{X}) \right) \right) + D_1(\mathbf{X}) \right) \right) + D_2(\mathbf{X}) \right) \cdots + D_{k-1}(\mathbf{X}) \right) \\ \boldsymbol{\theta} = \left\{ (\mathbf{w}_\ell, \mathbf{b}_\ell^w)_{\ell=1,2,\dots,k+1}, (\mathbf{T}_\ell, \mathbf{b}_\ell^T)_{\ell=1,2,\dots,k-1} \right\} \end{cases} \quad (16)$$

式中: $\Phi^0(\mathbf{X})$ 为 ICNN 的负荷裕度估计值, $\boldsymbol{\theta}$ 为 ICNN 超参数; $Y_{k+1}(\mathbf{z}_k)$ 为 ICNN 输出层的输出。在损失函数的构建中引入 L2 正则化策略, 防止训练结果的过拟合, 得到 ICNN 的结构风险损失为:

$$\begin{aligned} \min_{\substack{\mathbf{w}_2, \mathbf{w}_3, \dots, \mathbf{w}_k \geq 0 \\ \mathbf{T}_\ell, \mathbf{b}_\ell^w, \mathbf{b}_\ell^T}} L_{\text{ICNN}} &= H^\Phi \|\Phi^0(\mathbf{X}) - Y\|_2^2 + H^w \sum_{\ell=1}^k \|\mathbf{w}_\ell\|_2^2 + \\ & H^T \sum_{\ell=1}^{k-1} \|\mathbf{T}_\ell\|_2^2 \end{aligned} \quad (17)$$

式中: L_{ICNN} 为 ICNN 的损失函数; H^Φ 为不包含正则化项的损失函数参数; H^w 、 H^T 为正则化参数。则式(17)可以通过如式(18)所示的投射梯度下降方法进行训练。

$$\begin{cases} \boldsymbol{\theta}' = \boldsymbol{\theta} - \nabla_{\boldsymbol{\theta}} L_{\text{ICNN}} \\ \boldsymbol{\theta}^{t+1} = \boldsymbol{\theta}' - \gamma \Pi_{\mathbf{w}_{2,k} \geq 0}(\boldsymbol{\theta}') \end{cases} \quad t \geq 1 \quad (18)$$

式中: $\boldsymbol{\theta}'$ 为第 $t-1$ 次迭代后的 ICNN 超参数; $\nabla_{\boldsymbol{\theta}} L_{\text{ICNN}}$ 为 ICNN 损失函数的梯度; γ 为步长; $\Pi_{\mathbf{w}_{2,k} \geq 0}(\boldsymbol{\theta}')$ 为中间变量 $\boldsymbol{\theta}'$ 在超参空间域的投射。

训练后的 ICNN 可表示为:

$$\begin{cases} \boldsymbol{\theta}^* = \operatorname{argmin} L_{\text{ICNN}} \\ \tilde{\lambda}_{\text{cr}} = \Phi^0(\mathbf{X}) \end{cases} \quad (19)$$

式中: argmin 表示使得函数最小的变量取值; $\boldsymbol{\theta}^*$ 为训练后使 ICNN 损失函数最小的超参数; $\tilde{\lambda}_{\text{cr}}$ 为由替代模型估计的负荷裕度。

2.3 嵌入 ICNN 的电压稳定控制模型

2.2 节构建的 ICNN 模型可以不失非线性地实现电压稳定快速评估, 因此, 利用式(19)替代第 1 节电压稳定控制模型中的负荷裕度计算模型式(11), 得到嵌入 ICNN 的电压稳定控制模型为:

$$\begin{cases} \text{式(1)} \\ \text{s.t. 式(2)—(9)} \\ \Phi^0(\mathbf{X}) \geq \tilde{\lambda}_{\text{cr}} \end{cases} \quad (20)$$

构建的电压稳定凸优化控制模型式(20)可有效地保证控制效率与控制精度。为进一步保证大规模 ICNN 替代优化模型的求解效率, 需要在最速下降方向搜索策略。为此, 引入非线性规划(nonlinear programming, NLP)方法, 但 ICNN 模型存在天然隐式特征, 这导致传统规划算法难以处理耦合 ICNN 的优

化模型。因此, 本文提出 ICNN 解析方法, 推导雅可比矩阵和海森矩阵, 为内点法提供深度替代模型的梯度信息, 从而有效耦合 ICNN 约束与非线性规划。ICNN 整体应用流程如图 1 所示。




图1 ICNN的整体应用流程

Fig.1 Overall application flowchart of ICNN

3 内点法与 ICNN 求导结合的解析算法

3.1 内点法

内点法通过在原始目标中添加障碍函数处理模型不等式约束, 并将模型转化为拉格朗日函数进行求解。基于变量的所有控制梯度信息, 易求得满足拉格朗日函数极值的控制变量最优解。因此, 通过解析 ICNN 模型, 推导出电压稳定裕度对电网控制变量的超参化梯度信息, 可实现利用内点法快速生成电压稳定的最优控制策略。内点法求解步骤如下。

1) 将模型式(20)表示为一般形式, 即:

$$\begin{cases} \min F(\mathbf{x}) \\ \text{s.t. } \mathbf{g}(\mathbf{x}) = 0 \\ \underline{\mathbf{h}}(\mathbf{x}) \leq \mathbf{h}(\mathbf{x}) \leq \bar{\mathbf{h}}(\mathbf{x}) \end{cases} \quad (21)$$

式中: $F(\mathbf{x})$ 为预防控制模型的目标函数, 待求解变量 $\mathbf{x} = [P_{Gi}, Q_{Gi}, Q_{Cn}, V_j, \theta_j] (i \in \Omega_G, n \in \Omega_C, j \in \Omega_N)$, θ_j 为节点 j 的电压相角; $\mathbf{g}(\mathbf{x})$ 为等式约束; $\mathbf{h}(\mathbf{x})$ 为不等式约束; $\bar{\mathbf{h}}(\mathbf{x})$ 、 $\underline{\mathbf{h}}(\mathbf{x})$ 分别为不等式约束的上、下限。利用不等式约束上、下限以及松弛变量 $\mathbf{u} = [u_1, u_2, \dots, u_r]^T$ 、 $\mathbf{l} = [l_1, l_2, \dots, l_r]^T$ 将不等式约束转换为等式约束, 并利用障碍常数 μ 构造障碍函数。其中 r 为不等式约束数量, u_c 、 $l_c (c=1, 2, \dots, r)$ 分别为第 c 个不等式约束的上限和下限松弛变量。最终采用拉格朗日乘子法构建的拉格朗日函数 L 为:

$$\begin{aligned} L &= F(\mathbf{x}) - \boldsymbol{\gamma}^T \mathbf{g}(\mathbf{x}) - \mathbf{z}^T (\mathbf{h}(\mathbf{x}) - \mathbf{l} - \underline{\mathbf{h}}(\mathbf{x})) - \\ & e^T (\mathbf{h}(\mathbf{x}) + \mathbf{u} - \bar{\mathbf{h}}(\mathbf{x})) - \mu \left(\sum_{c=1}^r \ln l_c + \sum_{c=1}^r \ln u_c \right) \end{aligned} \quad (22)$$

式中: $\mathbf{y} = [y_1, y_2, \dots, y_{2N_b}]^T$ 为等式约束的拉格朗日乘子, N_b 为系统节点数, $y_s (s=1, 2, \dots, 2N_b)$ 为第 s 个等式约束的拉格朗日乘子; $\mathbf{z} = [z_1, z_2, \dots, z_r]^T$ 、 $\mathbf{e} = [e_1, e_2, \dots, e_r]^T$ 分别为由不等式约束下限和上限所构造等式约束的拉格朗日乘子, $z_c, e_c (c=1, 2, \dots, r)$ 分别为由第 c 个不等式约束下限和上限所构造等式约束的拉格朗日乘子。

2) 采用牛顿-拉夫逊法迭代求解拉格朗日函数, 得到 $\mathbf{x}$ 、 $\mathbf{y}$ 的修正量 $\Delta \mathbf{x}$ 、 $\Delta \mathbf{y}$ 的修正方程为:

$$\begin{bmatrix} \mathbf{H} & \nabla_{\mathbf{x}} \mathbf{g}(\mathbf{x}) \\ \nabla_{\mathbf{x}}^T \mathbf{g}(\mathbf{x}) & 0 \end{bmatrix} \begin{bmatrix} \Delta \mathbf{x} \\ \Delta \mathbf{y} \end{bmatrix} = - \begin{bmatrix} \mathbf{T} \\ -\mathbf{g}(\mathbf{x}) \end{bmatrix} \quad (23)$$

$$\mathbf{H} = -\nabla_{\mathbf{x}}^2 F(\mathbf{x}) + \nabla_{\mathbf{x}}^2 \mathbf{g}(\mathbf{x}) \mathbf{y} + \nabla_{\mathbf{x}}^2 \mathbf{h}(\mathbf{x})(\mathbf{z} + \mathbf{e}) - \nabla_{\mathbf{x}} \mathbf{h}(\mathbf{x})(\mathbf{L}^{-1} \mathbf{Z} - \mathbf{U}^{-1} \mathbf{E}) \nabla_{\mathbf{x}}^T \mathbf{h}(\mathbf{x}) \quad (24)$$

$$\begin{aligned} \mathbf{T} &= \nabla_{\mathbf{x}} F(\mathbf{x}) - \nabla_{\mathbf{x}} \mathbf{g}(\mathbf{x}) \mathbf{y} - \nabla_{\mathbf{x}} \mathbf{h}(\mathbf{x})(\mathbf{z} + \mathbf{e}) + \\ &\nabla_{\mathbf{x}} \mathbf{h}(\mathbf{x}) [\mathbf{L}^{-1} (\mathbf{l} \cdot \mathbf{z} - \mu \Theta + \mathbf{Z} \mathbf{L}_z) + \mathbf{U}^{-1} (\mathbf{u} \cdot \mathbf{e} + \mu \Theta - \mathbf{E} \mathbf{L}_e)] \end{aligned} \quad (25)$$

式中: “ $\cdot$ ” 表示矩阵点乘; $\mathbf{L} = \text{diag}(l_1, l_2, \dots, l_r)$; $\mathbf{U} = \text{diag}(u_1, u_2, \dots, u_r)$; $\mathbf{Z} = \text{diag}(z_1, z_2, \dots, z_r)$; $\mathbf{E} = \text{diag}(e_1, e_2, \dots, e_r)$; $\Theta = [1, 1, \dots, 1]^T$, 维度为 r ; $\mathbf{L}_z$ 、 $\mathbf{L}_e$ 分别为拉格朗日函数对拉格朗日乘子 $\mathbf{z}$ 、 $\mathbf{e}$ 的偏导。该步骤利用了 ICNN 的控制梯度信息, 可实现模型求解。

3) 求取 $\mathbf{z}$ 、 $\mathbf{l}$ 、 $\mathbf{e}$ 、 $\mathbf{u}$ 的修正量 $\Delta \mathbf{z}$ 、 $\Delta \mathbf{l}$ 、 $\Delta \mathbf{e}$ 、 $\Delta \mathbf{u}$, 即:

$$\begin{cases} \Delta \mathbf{z} = \mathbf{L}^{-1} (\mathbf{l} \cdot \mathbf{z} - \mu \Theta) - \mathbf{L}^{-1} \mathbf{Z} \Delta \mathbf{l} \\ \Delta \mathbf{l} = \nabla_{\mathbf{x}}^T \mathbf{h}(\mathbf{x}) \Delta \mathbf{x} - \mathbf{L}_z \\ \Delta \mathbf{e} = \mathbf{U}^{-1} (\mathbf{u} \cdot \mathbf{e} + \mu \Theta) - \mathbf{U}^{-1} \mathbf{E} \Delta \mathbf{u} \\ \Delta \mathbf{u} = \mathbf{L}_e - \nabla_{\mathbf{x}}^T \mathbf{h}(\mathbf{x}) \Delta \mathbf{x} \end{cases} \quad (26)$$

4) 基于修正量和式(27)求得第 $\tau+1$ 次迭代的变量修正结果。

$$\begin{cases} \alpha_p = 0.9995 \left[\min \left(\frac{-l_c}{\Delta l_c}, \Delta l_c < 0; \frac{-u_c}{\Delta u_c}, \Delta u_c < 0 \right), 1 \right] \\ \alpha_d = 0.9995 \left[\min \left(\frac{-z_c}{\Delta z_c}, \Delta z_c < 0; \frac{-e_c}{\Delta e_c}, \Delta e_c > 0 \right), 1 \right] \end{cases} \quad (27)$$

$$\begin{cases} \mathbf{x}^{(\tau+1)} = \mathbf{x}^{(\tau)} + \alpha_p \Delta \mathbf{x}, \quad \mathbf{y}^{(\tau+1)} = \mathbf{y}^{(\tau)} + \alpha_d \Delta \mathbf{y} \\ \mathbf{l}^{(\tau+1)} = \mathbf{l}^{(\tau)} + \alpha_p \Delta \mathbf{l}, \quad \mathbf{z}^{(\tau+1)} = \mathbf{z}^{(\tau)} + \alpha_d \Delta \mathbf{z} \\ \mathbf{u}^{(\tau+1)} = \mathbf{u}^{(\tau)} + \alpha_p \Delta \mathbf{u}, \quad \mathbf{e}^{(\tau+1)} = \mathbf{e}^{(\tau)} + \alpha_d \Delta \mathbf{e} \end{cases} \quad (28)$$

式中: α_p 、 α_d 为步长。

5) 更新障碍参数 μ , 即:

$$\mu = \sigma \frac{G_{\text{IPM}}}{2r} = \sigma \frac{\mathbf{l}^T \mathbf{z} - \mathbf{u}^T \mathbf{e}}{2r} \quad (29)$$

式中: $\sigma \in (0, 1)$ 为中心参数; G_{IPM} 为对偶间隙, 当 $G_{\text{IPM}} > \zeta$ (ζ 为设定的收敛值) 时, 重复步骤 2)—4), 直到 G_{IPM} 收敛。

求解算法流程图见附录 A 图 A2。

3.2 替代模型解析

为耦合内点法, 推导出 ICNN 控制梯度, 先将式(16)重写为如下形式:

$$\begin{cases} \Gamma(t) = O_k \\ O_1 = Y_2(\delta(Y_1(X(t)))) + D_1(X(t)) \\ O_2 = Y_3(\delta(O_1)) + D_2(X(t)) \\ \vdots \\ O_{k-1} = Y_k(\delta(O_{k-2})) + D_{k-1}(X(t)) \\ O_k = Y_{k+1}(\delta(O_{k-1})) \end{cases} \quad (30)$$

式中: O_k 为 ICNN 的输出; $O_l (l=1, 2, \dots, k-1)$ 为第 $l+1$ 层隐藏层的输入; $\Gamma(t)$ 为 ICNN 的输出。式(30)更清晰地展示了具有 k 层隐藏层的 ICNN 完整的前馈过程。结合式(30), 利用链式求导法可快速推导 ICNN 输出 $\Gamma(t)$ 对输入特征 $X(t)$ 的雅可比矩阵和海森矩阵, 具体步骤如下。

1) 推导激活函数 CeLu 的一次和二次导数, 即:

$$\frac{d\delta(\mathbf{x}_z)}{d\mathbf{x}_z} = \begin{cases} 1 & \mathbf{x}_z \geq 0 \\ e^{\mathbf{x}_z/\alpha} & \mathbf{x}_z < 0 \end{cases} \quad (31)$$

$$\frac{d^2\delta(\mathbf{x}_z)}{d\mathbf{x}_z^2} = \begin{cases} 0 & \mathbf{x}_z \geq 0 \\ \frac{1}{\alpha} e^{\mathbf{x}_z/\alpha} & \mathbf{x}_z < 0 \end{cases} \quad (32)$$

2) 基于链式求导法则和激活函数的一次导数, 推导 $O_l (l=1, 2, \dots, k-1)$ 和 $\Gamma(t)$ 对 ICNN 输入特征 X 的一阶导数, 即:

$$\begin{cases} \frac{\partial O_1}{\partial X} = \frac{\partial Y_2(\delta(Y_1(X(t))))}{\partial \delta(Y_1(X(t)))} \frac{\partial \delta(Y_1(X(t)))}{\partial Y_1(X(t))} \frac{\partial Y_1(X(t))}{\partial X} + \\ \frac{\partial D_1(X(t))}{\partial X} \\ \vdots \\ \frac{\partial O_{k-1}}{\partial X} = \frac{\partial Y_k(\delta(O_{k-2}))}{\partial \delta(O_{k-2})} \frac{\partial \delta(O_{k-2})}{\partial O_{k-2}} \frac{\partial O_{k-2}}{\partial X} + \\ \frac{\partial D_{k-1}(X(t))}{\partial X} \\ \frac{\partial \Gamma(t)}{\partial X} = \frac{\partial Y_{k+1}(\delta(O_{k-1}))}{\partial \delta(O_{k-1})} \frac{\partial \delta(O_{k-1})}{\partial O_{k-1}} \frac{\partial O_{k-1}}{\partial X} \end{cases} \quad (33)$$

3) 结合 2.2.2 节内容, 对式(33)逐层求解并回代, 得到 ICNN 的雅可比矩阵求解式为:

$$\begin{cases} \frac{\partial \Gamma(t)}{\partial X} = \mathbf{w}_{k+1} \frac{d\delta(O_{k-1})}{dO_{k-1}} \frac{\partial O_{k-1}}{\partial X} \\ \frac{\partial O_{k-1}}{\partial X} = \mathbf{w}_k \frac{d\delta(O_{k-2})}{dO_{k-2}} \frac{\partial O_{k-2}}{\partial X} + \mathbf{T}_{k-1} \\ \vdots \\ \frac{\partial O_1}{\partial X} = \mathbf{w}_2 \frac{d\delta(Y_1(X(t)))}{dY_1(X(t))} \mathbf{w}_1 + \mathbf{T}_1 \end{cases} \quad (34)$$

$$\frac{d\delta(Y_1(X(t)))}{dY_1(X(t))} = \begin{bmatrix} \frac{d\delta(Y_1^1(X(t)))}{dY_1^1(X(t))} & 0 & 0 \\ 0 & \ddots & 0 \\ 0 & 0 & \frac{d\delta(Y_1^{N_1}(X(t)))}{dY_1^{N_1}(X(t))} \end{bmatrix} \quad (35)$$

$$\begin{cases} Y_1(X(t)) = [Y_1^1(X(t)); \dots; Y_1^{N_1}(X(t))] \in \mathbf{R}^{N_1 \times 1} \\ Y_1^m(X(t)) = w_1^m X(t) + b_1^m \quad m=1, 2, \dots, N_1 \\ w_1^m \in \mathbf{R}^{1 \times N_0}, X(t) \in \mathbf{R}^{N_0 \times 1} \end{cases} \quad (36)$$

$$\frac{d\delta(O_l)}{dO_l} (l=1, 2, \dots, k-1) \text{ 的计算公式可以根据}$$

式(35)、(36)推导得到。

4) 基于链式求导法则和激活函数的二次导数, 继续推导 $\frac{\partial O_l}{\partial X} (l=1, 2, \dots, k-1)$ 和 $\Gamma(t)$ 对 $x_i (X=(x_i), i=1, 2, \dots, N_0)$ 的一阶导数, 如附录A式(A1)所示。类似步骤3), 得到 ICNN 海森矩阵的第 i 行求解式, 如附录A式(A2)所示。至此, 可求得所提控制模型中电压稳定裕度对控制变量的全部梯度信息。此外, 注意到 ICNN 的雅可比矩阵和海森矩阵计算不会向决策变量空间引入变量, 均在超参数空间下进行, 因此不会增加优化算法求解复杂度, 而且梯度计算是基于矩阵并行计算的, 也不会明显增加计算时间。

4 算例分析

本文采用附录A图A3、A4所示 IEEE 14 和 IEEE 118 节点测试系统。对于负荷裕度计算, 在 MATLAB 上使用 Matpower 工具箱进行仿真。对于替代模型构建, 在 Python 平台上基于 PyTorch 建立 ICNN, 基于 scikit-learn 库搭建对比替代模型, 即 DT 模型和混合逻辑斯特回归 (mixed logistic regression, MLR) 模型。

4.1 替代模型的构建及测试

2个测试系统均采用如下测试方法: 首先, 根据2.2.1节的样本生成方法, 生成8000个样本, 将其中6400个样本划分为训练集, 将其余1600个样本划分为测试集; 然后, 搭建含有6层隐藏层的 ICNN 模型, 并基于训练集构建 ICNN 输入特征与负荷裕度之间的凸关联规则; 最后, 通过与 DT、MLR、传统反向传播神经网络 (back propagation neural network, BPNN) (含6层隐藏层) 模型进行对比, 验证 ICNN 对负荷裕度的拟合精度与泛化能力。由于 IEEE 118 节点系统规模较大, 因此在构建 ICNN 模型时, 隐藏层神经元数量需适当多于 IEEE 14 节点系统, 以保证模型的学习能力。测试结果如表1所示。表中:

平方相关系数 (square correlation coefficient, SCC) 的表征对象为负荷裕度真实值与替代模型估计值; 均方误差 (mean square error, MSE) 计算公式如式(37)所示, 为标么值。

$$M_{SM} = \frac{1}{N_{\text{test}}} \sum_{i \in \Omega_i} (\lambda_{\text{cri}} - \tilde{\lambda}_{\text{cri}})^2 \quad (37)$$


式中: M_{SM} 为替代模型的 MSE; N_{test} 为样本测试集大小; Ω_i 为样本测试集; $\lambda_{\text{cri}}, \tilde{\lambda}_{\text{cri}}$ 分别为样本测试集中第 i 个样本的负荷裕度真实值和替代模型估计值。

表1 测试结果


Table 1 Test results

测试系统	替代模型	SCC	MSE
IEEE 14	DT	0.9920	1.0636×10^{-3}
	MLR	0.9670	4.7073×10^{-3}
	BPNN	0.9996	4.4613×10^{-5}
	ICNN	0.9997	3.8870×10^{-5}
IEEE 118	DT	0.8188	8.6994×10^{-3}
	MLR	0.9029	5.6286×10^{-3}
	BPNN	0.9986	7.5251×10^{-5}
	ICNN	0.9986	7.4766×10^{-5}

由表1可知, IEEE 14 节点系统中, ICNN 的 MSE 为 3.8870×10^{-5} p.u., 测试集误差的均方差为 0.0062 p.u., IEEE 118 节点系统中, ICNN 的 MSE 为 7.4766×10^{-5} p.u., 测试集误差的均方差为 0.0086 p.u., 均优于 DT、MLR、BPNN 模型。图2更直观地展示了 ICNN 在各测试系统中的性能表现 (图中预测值、实际值、误差均为标么值)。上述结果表明: 基于 ICNN 构建的电



(a) IEEE 14 节点系统



(b) IEEE 118 节点系统

图2 ICNN在测试集上的性能可视化

Fig.2 Visualization of ICNN performance on test set

压稳定评估模型的拟合精度高且模型具有较强的泛化能力,能够有效保留 CPF 模型的非线性,可进一步用于后续电压稳定控制。

4.2 所提预防控制模型的测试

为了较直观地展示测试工况的运行状态,本文根据负荷裕度将需要进行预防控制的系统运行状态分为 I 类状态、II 类状态和 III 类状态,如表 2 所示。

表 2 运行状态分类

Table 2 Classification of operation conditions

稳定裕度	系统运行状态
小于 20 %	I 类
[20 %, 50 %)	II 类
[50 %, 80 %)	III 类

本文设定预防控制目标为将负荷裕度提升至 80 %。同时,为验证并分析嵌入 ICNN 的电压稳定控制模型的控制效率与控制精度,在本文构建的电压稳定预防控制模型的基础上,基于如下 2 种对比方法构建替代模型,并利用内点法进行求解:对比方法 1,基于传统灵敏度分析方法^[3-4],推演出负荷裕度与控制量的灵敏度关系,构建电压稳定替代模型;对比方法 2,选取 4.1 节中构建的 BPNN 模型(非凸神经网络)作为电压稳定替代模型。此外,设置对比方法 3,即采用多目标遗传算法求解未经替代的原始 SVS 控制模型。

首先,选取 4.1 节中构建的 ICNN 作为替代模型,在 IEEE 14 节点系统中测试本文方法的有效性。本文方法能将 III 类状态的负荷裕度提升至预防控制目标,但受限于系统可调资源,无法将 I 类状态和 II 类状态的负荷裕度提升至预防控制目标。因此,在上述每类运行状态中各选取 100 组测试工况,通过与灵敏度方法的对比来测试本文方法的有效性,结果如表 3 所示。

表 3 IEEE 14 节点系统测试结果

Table 3 Test results of IEEE 14-bus system

系统运行状态	替代模型	平均负荷裕度提升量 / %	平均计算时间 / s
I 类	灵敏度方法	3.03	0.253 5
	ICNN	3.47	0.028 7
II 类	灵敏度方法	5.15	0.319 1
	ICNN	5.09	0.030 5

由表 3 可知,本文方法能有效提升系统负荷裕度,且在对 I 类状态和 II 类状态进行预防控制时,本文方法的平均计算时间分别为 0.028 7 s 和 0.030 5 s,均优于传统灵敏度方法,本文方法展现出较高的控制效率。为进一步分析本文方法的控制精度、控制效率以及在较大系统中的应用能力,将本文方法应用于 IEEE 118 节点系统中,得到的测试结果如附录 A 表 A1 所示。由表可知,在 IEEE 118 节点系统中,

所提方法仍展现出较高的控制精度与控制效率,在提升系统负荷裕度的同时,使计算时间保持在 5 s 左右。为了便于解释所提模型的控制策略,图 3—5 给出了该测试系统下将负荷裕度从 32.55 % 提升至 80.43 % 的预防控制策略(图 5 中电压为标么值)。




图 3 发电机有功出力调控

Fig.3 Adjustment and control of active power for generators




图 4 无功功率补偿

Fig.4 Reactive power compensation




图 5 机端电压调控

Fig.5 Adjustment and control of terminal voltage for generators

上述结果表明,本文方法能够有效识别系统关键补偿点并制定补偿策略,且通过综合考虑无功补偿成本和发电机出力成本制定出的发电机有功出力、发电机机端电压和无功补偿调控策略能够精准地控制系统负荷裕度至目标水平。

4.3 方法对比

为进一步分析本文方法的控制精度与控制效率,首先将本文方法与对比方法 1、对比方法 2 应用于 IEEE 118 节点系统,得到的测试结果如附录 A 图 A5 所示。结果表明,相较于对比方法 1 和对比方法 2,本文方法具有最高的控制精度,能够对负荷裕度低于 80 % 的测试工况进行更加有效的预防控制

(100%的场景控制成功率),而对比方法1、对比方法2的场景控制成功率分别为72.5%、85%。

进一步,附录A表A2给出了不同对比方法对3个典型测试工况控制成功后的计算时间和运行成本。综合比较可知,本文方法具有较高的控制效率。结合图A3中测试场景预防控制成功后的平均运行成本(ICNN为 4.3224×10^5 元,非凸神经网络为 4.3273×10^5 元,灵敏度方法为 4.3298×10^5 元)可知,本文方法能有效地保证控制策略成本的最优性。

综上,与传统方法相比,所提嵌入ICNN的电压稳定控制替代建模方法及其解析算法,不仅具有较高的计算效率和控制精度,而且更能保证控制策略的成本最优。

5 结论

本文提出一种嵌入ICNN的SVS控制替代建模方法及其解析算法,通过IEEE 14节点系统及IEEE 118节点系统对所提方法进行分析,得到如下结论:

1)构建的ICNN模型不仅能快速准确地评估系统SVS,而且能正确判断运行变量与负荷裕度的灵敏度关系,快速辅助生成最优策略;

2)通过经验学习,ICNN能精准地刻画系统运行变量与SVS边界的凸关联规则;

3)利用本文方法能发现系统运行变量与电压稳定边界存在的凸非线性关系,这表明人工智能方法具有直觉引导的可能。

所提ICNN凸非线性驱动的SVS控制方法具有以下优势:

1)区别于机理计算模型,ICNN可实现去迭代、高并行的实时电压稳定计算,且其在超参数空间的计算可有效规避变量空间下的高维度机理建模;

2)ICNN参数化的凸稳定边界保证了物理机理约束的可靠凸耦合,进而保证了快速非线性梯度算法求解的收敛性;

3)在超参空间下解析ICNN,得到电压稳定控制的精确灵敏度,可有效缩减优化变量维度;

4)所提数据驱动与物理建模凸耦合的优化方法具有一定的推广性,可用于其他包含高维复杂、非凸非线性、计算耗时约束的优化问题。

附录见本刊网络版(<http://www.epae.cn>)。

参考文献:

- [1] 陈昌,姜彤,万凯遥,等. 直接计算静态电压稳定裕度的改进崩溃点法[J]. 电力自动化设备,2020,40(11):150-156.
CHEN Chang,JIANG Tong,WAN Kaiyao,et al. Improved point of collapse method for direct calculation of static voltage stability margin[J]. Electric Power Automation Equipment,2020,40(11):150-156.
- [2] 卢秀琼,颜伟,余娟,等. 静态电压稳定预防控制的风险评估[J]. 电力自动化设备,2014,34(8):65-70,97.

- HU Xiuqiong,YAN Wei,YU Juan,et al. Risk assessment for preventive control of static voltage stability[J]. Electric Power Automation Equipment,2014,34(8):65-70,97.
- [3] 蔡广林,张勇军,余涛,等. 基于统一灵敏度法的静态电压稳定预防控制[J]. 高电压技术,2008,34(4):748-752.
CAI Guanglin,ZHANG Yongjun,YU Tao,et al. Static voltage stability preventive control by unified sensitivity method[J]. High Voltage Engineering,2008,34(4):748-752.
- [4] 李帅虎,曹一家,刘光晔,等. 基于电压稳定在线监测指标的预防控制方法[J]. 中国电机工程学报,2015,35(18):4598-4606.
LI Shuaihu,CAO Yijia,LIU Guangye,et al. Preventive control method of electric power system based on on-line voltage stability monitoring index[J]. Proceedings of the CSEE,2015,35(18):4598-4606.
- [5] 赵晋泉,江晓东,张伯明. 一种在线电力系统静态稳定增强控制算法[J]. 中国电机工程学报,2005,25(8):7-12.
ZHAO Jinquan,JIANG Xiaodong,ZHANG Boming. An on-line enhancement control algorithm for static stability in power system[J]. Proceedings of the CSEE,2005,25(8):7-12.
- [6] 陈刚,荀旭,张继红. 基于2阶段家族保护遗传算法的电压稳定霍普夫分岔控制[J]. 电网技术,2011,35(1):53-58.
CHEN Gang,GOU Xu,ZHANG Jihong. Hopf bifurcation control of voltage stability based on two-stage kindred-protected genetic algorithm[J]. Power System Technology,2011,35(1):53-58.
- [7] ROSELYN J P,DEVARAJ D. Adaptive multi objective differential evolution with fuzzy decision making in preventive and corrective control approaches for voltage security enhancement[J]. Journal of the Franklin Institute,2018,355(11):4553-4582.
- [8] 卢秀琼,颜伟,余娟. 互联网静态电压稳定预防控制模型及其算法[J]. 电力自动化设备,2015,35(2):68-74.
HU Xiuqiong,YAN Wei,YU Juan. Preventive control model of static voltage stability and its algorithm for interconnected power grid[J]. Electric Power Automation Equipment,2015,35(2):68-74.
- [9] 邹晓松,罗先觉. 多预想事故静态电压稳定预防控制阻塞管理方法[J]. 电网技术,2010,34(2):143-148.
ZOU Xiaosong,LUO Xianjue. Acongesti on management method based on preventive controls for voltage stability considering multi contingency[J]. Power System Technology,2010,34(2):143-148.
- [10] 王艳松,宣德之,李强. 基于源-荷功率动态匹配的海上平台电力系统静态电压稳定分析[J]. 电力自动化设备,2021,41(4):132-138.
WANG Yansong,XUAN Dezhi,LI Qiang. Static voltage stability analysis of offshore platform power system based on source-load power dynamic matching[J]. Electric Power Automation Equipment,2021,41(4):132-138.
- [11] CHEN P W,TAO S,XIAO X N,et al. Uncertainty level of voltage in distribution network:an analysis model with elastic net and application in storage configuration[J]. IEEE Transactions on Smart Grid,2018,9(4):2563-2573.
- [12] LEONIDAKI E A,GEORGIADIS D P,HATZIARGYRIOU N D. Decision trees for determination of optimal location and rate of series compensation to increase power system loading margin[J]. IEEE Transactions on Power Systems,2006,21(3):1303-1310.
- [13] LIU T J,LIU Y B,LIU J Y,et al. A Bayesian learning based scheme for online dynamic security assessment and preventive control[J]. IEEE Transactions on Power Systems,2020,35(5):4088-4099.
- [14] SU T,LIU Y B,ZHAO J B,et al. Deep belief network enabled surrogate modeling for fast preventive control of

- power system transient stability[J]. IEEE Transactions on Industrial Informatics, 2022, 18(1): 315-326.
- [15] QIU G, LIU Y B, ZHAO J B, et al. Analytic deep learning-based surrogate model for operational planning with dynamic TTC constraints[J]. IEEE Transactions on Power Systems, 2021, 36(4): 3507-3519.
- [16] YANG S, BEQUETTE B W. Optimization-based control using input convex neural networks[J]. Computers & Chemical Engineering, 2021, 144: 107143-107151.
- [17] CHEN Y, SHI Y, ZHANG B. Data-driven optimal voltage regulation using input convex neural networks[J]. Electric Power Systems Research, 2020, 189: 106741-106747.
- [18] 赵晋泉, 张伯明. 连续潮流及其在电力系统静态稳定分析中的应用[J]. 电力系统自动化, 2005, 29(11): 91-97.
- ZHAO Jinquan, ZHANG Boming. Summarization of continuation power flow and its applications in static stability analysis of power system[J]. Automation of Electric Power Systems, 2005, 29(11): 91-97.
- [19] 韦鹏飞, 徐永海, 王金浩, 等. 基于拉丁超立方采样的节点敏感设备暂降免疫水平评估[J]. 电工技术学报, 2018, 33(15):

3415-3425.

WEI Pengfei, XU Yonghai, WANG Jinhao, et al. Sag immunity-level evaluation of sensitive equipment at node based on Latin hypercube sampling[J]. Transactions of China Electrotechnical Society, 2018, 33(15): 3415-3425.

作者简介:



刘友波

刘友波(1983—),男,副教授,博士研究生导师,博士,主要研究方向为电力系统机器学习算法、主动配电网规划与运行(E-mail: liuyoubo@scu.edu.cn);

王天翔(1997—),男,硕士研究生,主要研究方向为电力系统稳定与控制(E-mail: wangtianxiang@stu.scu.edu.cn);

邱高(1994—),男,副研究员,博士,通信作者,主要研究方向为电力系统数据挖掘与知识发现技术(E-mail: qiugscu@163.com)。

(编辑 王锦秀)

Surrogate modeling method and its analytical algorithm for static voltage stability control embedded with input convex neural network

LIU Youbo¹, WANG Tianxiang¹, QIU Gao¹, WEI Wei², ZHOU Bo², LIU Tingjian¹,
LIU Junyong¹, MEI Shengwei³

(1. College of Electrical Engineering, Sichuan University, Chengdu 610065, China;

2. Electric Power Research Institute of State Grid Sichuan Electric Power Company, Chengdu 610041, China;

3. Department of Electrical Engineering, Tsinghua University, Beijing 100084, China)

Abstract: The static voltage stability control of power system is generally dependent on precise physical modeling, which may cause convergence and timeliness problems. From the data-driven perspective, the surrogate modeling method and its analytical algorithm for static voltage stability control embedded with input convex neural network (ICNN) are proposed. ICNN is used to accurately parameterize a convex and nonlinear voltage stability boundary mapped by the operational variables. Considering the real-time calculation performance and iteration-free advantage of ICNN, ICNN is embedded into the preventive control model for replacing the nonlinear iteration process of voltage stability calculation and avoiding the convergence problem of mechanism calculation, thus a convex and nonlinear simplified control model oriented to voltage stability is constructed. The control gradient driven by the super parameters of ICNN is derived by analyzing the deep structure expression of ICNN, a steepest decent solution strategy of ICNN effectively coupled with the interior point method is proposed, which realizes the improvement of voltage stability control efficiency. The test results of IEEE 14-bus system and IEEE 118-bus system show that the proposed ICNN-driven voltage stability convex and nonlinear control can effectively couple mechanism modeling and data model, it can better balance the control accuracy and calculation efficiency compared with the traditional methods, and has certain online application potential.

Key words: static voltage stability; preventive control; interior point method; input convex neural network; surrogate modeling

附录 A




图 A1 输入凸神经网络

Fig.A1 Input convex neural network

ICNN 海森矩阵求解式

式 (A1) 和 (A2) 为 ICNN 海森矩阵求解式。式中 $\frac{\partial \mathbf{O}_{k-1}}{\partial \mathbf{x}_i}$ 为雅可比矩阵 $\frac{\partial \mathbf{O}_{k-1}}{\partial \mathbf{X}}$ 的第 i 列； $\frac{d^2 \delta(\mathbf{Y}_1(\mathbf{X}(t)))}{d\mathbf{Y}_1(\mathbf{X}(t))^2}$ 的计算公式如式 (A3) 所示， $\frac{d^2 \delta(\mathbf{O}_l)}{d\mathbf{O}_l^2}$ ($l=1,2,\dots,k-1$) 的计算公式可根据式 (A3) 推导。

$$\begin{cases}
 \frac{\partial^2 \mathbf{O}_1}{\partial \mathbf{X} \partial \mathbf{x}_i} = \left[\frac{\partial^2 \mathbf{Y}_2(\delta(\mathbf{Y}_1(\mathbf{X}(t))))}{\partial \delta(\mathbf{Y}_1(\mathbf{X}(t)))^2} \frac{\partial \delta(\mathbf{Y}_1(\mathbf{X}(t)))}{\partial \mathbf{Y}_1(\mathbf{X}(t))} \frac{\partial \mathbf{Y}_1(\mathbf{X}(t))}{\partial \mathbf{x}_i} \right] \frac{\partial \delta(\mathbf{Y}_1(\mathbf{X}(t)))}{\partial \mathbf{Y}_1(\mathbf{X}(t))} \frac{\partial \mathbf{Y}_1(\mathbf{X}(t))}{\partial \mathbf{X}} + \\
 \frac{\partial \mathbf{Y}_2(\delta(\mathbf{Y}_1(\mathbf{X}(t))))}{\partial \delta(\mathbf{Y}_1(\mathbf{X}(t)))} \left[\frac{\partial^2 \delta(\mathbf{Y}_1(\mathbf{X}(t)))}{\partial \mathbf{Y}_1(\mathbf{X}(t))^2} \frac{\partial \mathbf{Y}_1(\mathbf{X}(t))}{\partial \mathbf{x}_i} \right] \frac{\partial \mathbf{Y}_1(\mathbf{X}(t))}{\partial \mathbf{X}} + \\
 \frac{\partial \mathbf{Y}_2(\delta(\mathbf{Y}_1(\mathbf{X}(t))))}{\partial \delta(\mathbf{Y}_1(\mathbf{X}(t)))} \frac{\partial \delta(\mathbf{Y}_1(\mathbf{X}(t)))}{\partial \mathbf{Y}_1(\mathbf{X}(t))} \frac{\partial^2 \mathbf{Y}_1(\mathbf{X}(t))}{\partial \mathbf{X} \partial \mathbf{x}_i} + \frac{\partial^2 \mathbf{D}_1(\mathbf{X}(t))}{\partial \mathbf{X} \partial \mathbf{x}_i} \\
 \vdots \\
 \frac{\partial^2 \mathbf{O}_{k-1}}{\partial \mathbf{X} \partial \mathbf{x}_i} = \left[\frac{\partial^2 \mathbf{Y}_k(\delta(\mathbf{O}_{k-2}))}{\partial \delta(\mathbf{O}_{k-2})^2} \frac{\partial \delta(\mathbf{O}_{k-2})}{\partial \mathbf{O}_{k-2}} \frac{\partial \mathbf{O}_{k-2}}{\partial \mathbf{x}_i} \right] \frac{\partial \delta(\mathbf{O}_{k-2})}{\partial \mathbf{O}_{k-2}} \frac{\partial \mathbf{O}_{k-2}}{\partial \mathbf{X}} + \\
 \frac{\partial \mathbf{Y}_k(\delta(\mathbf{O}_{k-2}))}{\partial \delta(\mathbf{O}_{k-2})} \left[\frac{\partial^2 \delta(\mathbf{O}_{k-2})}{\partial \mathbf{O}_{k-2}^2} \frac{\partial \mathbf{O}_{k-2}}{\partial \mathbf{x}_i} \right] \frac{\partial \mathbf{O}_{k-2}}{\partial \mathbf{X}} + \\
 \frac{\partial \mathbf{Y}_k(\delta(\mathbf{O}_{k-2}))}{\partial \delta(\mathbf{O}_{k-2})} \frac{\partial \delta(\mathbf{O}_{k-2})}{\partial \mathbf{O}_{k-2}} \frac{\partial^2 \mathbf{O}_{k-2}}{\partial \mathbf{X} \partial \mathbf{x}_i} + \frac{\partial^2 \mathbf{D}_{k-1}(\mathbf{X}(t))}{\partial \mathbf{X} \partial \mathbf{x}_i} \\
 \frac{\partial^2 \Gamma(t)}{\partial \mathbf{X} \partial \mathbf{x}_i} = \left[\frac{\partial^2 \mathbf{Y}_{k+1}(\delta(\mathbf{O}_{k-1}))}{\partial \delta(\mathbf{O}_{k-1})^2} \frac{\partial \delta(\mathbf{O}_{k-1})}{\partial \mathbf{O}_{k-1}} \frac{\partial \mathbf{O}_{k-1}}{\partial \mathbf{x}_i} \right] \frac{\partial \delta(\mathbf{O}_{k-1})}{\partial \mathbf{O}_{k-1}} \frac{\partial \mathbf{O}_{k-1}}{\partial \mathbf{X}} + \\
 \frac{\partial \mathbf{Y}_{k+1}(\delta(\mathbf{O}_{k-1}))}{\partial \delta(\mathbf{O}_{k-1})} \left[\frac{\partial^2 \delta(\mathbf{O}_{k-1})}{\partial \mathbf{O}_{k-1}^2} \frac{\partial \mathbf{O}_{k-1}}{\partial \mathbf{x}_i} \right] \frac{\partial \mathbf{O}_{k-1}}{\partial \mathbf{X}} + \frac{\partial \mathbf{Y}_{k+1}(\delta(\mathbf{O}_{k-1}))}{\partial \delta(\mathbf{O}_{k-1})} \frac{\partial \delta(\mathbf{O}_{k-1})}{\partial \mathbf{O}_{k-1}} \frac{\partial^2 \mathbf{O}_{k-1}}{\partial \mathbf{X} \partial \mathbf{x}_i} \\
 i = 1, 2, \dots, N_0
 \end{cases} \quad (\text{A1})$$

$$\begin{cases}
 \frac{\partial^2 \Gamma(t)}{\partial \mathbf{X} \partial \mathbf{x}_i} = \mathbf{w}_{k+1} \left[\frac{d^2 \delta(\mathbf{O}_{k-1})}{d\mathbf{O}_{k-1}^2} \text{diag} \left(\frac{\partial \mathbf{O}_{k-1}}{\partial \mathbf{x}_i} \right) \right] \frac{\partial \mathbf{O}_{k-1}}{\partial \mathbf{X}} + \mathbf{w}_{k+1} \frac{d\delta(\mathbf{O}_{k-1})}{d\mathbf{O}_{k-1}} \frac{\partial^2 \mathbf{O}_{k-1}}{\partial \mathbf{X} \partial \mathbf{x}_i} \\
 \frac{\partial^2 \mathbf{O}_{k-1}}{\partial \mathbf{X} \partial \mathbf{x}_i} = \mathbf{w}_k \left[\frac{d^2 \delta(\mathbf{O}_{k-2})}{d\mathbf{O}_{k-2}^2} \text{diag} \left(\frac{\partial \mathbf{O}_{k-2}}{\partial \mathbf{x}_i} \right) \right] \frac{\partial \mathbf{O}_{k-2}}{\partial \mathbf{X}} + \mathbf{w}_k \frac{d\delta(\mathbf{O}_{k-2})}{d\mathbf{O}_{k-2}} \frac{\partial^2 \mathbf{O}_{k-2}}{\partial \mathbf{X} \partial \mathbf{x}_i} \\
 \vdots \\
 \frac{\partial^2 \mathbf{O}_1}{\partial \mathbf{X} \partial \mathbf{x}_i} = \mathbf{w}_2 \left[\frac{d^2 \delta(\mathbf{Y}_1(\mathbf{X}(t)))}{d\mathbf{Y}_1(\mathbf{X}(t))^2} \text{diag} \left(\frac{\partial \mathbf{Y}_1(\mathbf{X}(t))}{\partial \mathbf{x}_i} \right) \right] \mathbf{w}_1
 \end{cases} \quad (\text{A2})$$

$$\frac{d^2\delta(Y_1(X(t)))}{dY_1(X(t))^2} = \begin{pmatrix} \frac{d^2\delta(Y_1^1(X(t)))}{dY_1^1(X(t))^2} & 0 & 0 \\ 0 & \ddots & 0 \\ 0 & 0 & \frac{d^2\delta(Y_1^{N_1}(X(t)))}{dY_1^{N_1}(X(t))^2} \end{pmatrix} \quad (A3)$$




图 A2 内点法与 ICNN 求导结合的解析算法

Fig.A2Analytical algorithm combing IPM and ICNN derivation




图 A3 IEEE 14 节点测试系统

Fig.A3 IEEE 14-bus test system





图 A4 IEEE 118 节点测试系统

Fig.A4 IEEE 118-bus test system

表 A1IEEE 118 节点系统测试结果


Table A1 Test results of IEEE 118-bus system

系统静态电压稳定状态	负荷裕度/%		计算时间/s
	预防控制前	预防控制后	
I 类	3.74	80.42	6.950
	15.01	80.28	6.858
II 类	26.86	80.04	5.466
	37.10	80.18	5.382
	44.16	80.60	5.671
III 类	52.55	80.10	4.620
	65.71	80.50	5.340
	74.05	80.06	5.620



● ICNN ★ 灵敏度方法
■ 非凸NN — 目标

(a)控制后负荷裕度



(b)控制前负荷裕度

图 A5 IEEE 118 节点系统测试结果

Fig.A5 Test results of IEEE 118-bus system

表 A2 不同替代模型对比
Table A2 Comparison of different surrogate models

预防控制前负荷裕度/%	替代模型	性能	
		计算时间/s	预防控制后运行成本/\$
58.32	灵敏度方法	5.250	4.0418×10 ⁵
	非凸 NN	5.714	4.0274×10 ⁵
	ICNN	5.396	4.0243×10⁵
	无(CPF 模型)	86.15	4.0580×10 ⁵
35.64	灵敏度方法	5.603	4.3479×10 ⁵
	非凸 NN	5.680	4.3263×10 ⁵
	ICNN	5.545	4.3257×10⁵
	无(CPF 模型)	78.39	4.3600×10 ⁵
3.736	灵敏度方法	7.018	4.6217×10 ⁵
	非凸 NN	7.400	4.5898×10 ⁵
	ICNN	6.892	4.5807×10⁵
	无(CPF 模型)	82.45	4.8980×10 ⁵