第49卷 第19期 2025年10月10日
DOI：10.7500/AEPS20250213005
电力系统自动化
Automation of Electric Power Systems
Vol. 49 No. 19 Oct. 10，2025

融合模糊神经网络预决策的有源配电网实时随机调度方法

程礼临[1]，罗子杰[1]，李　群[2]，张宁宇[2]，李雅然[2]，臧海祥[1]
（1. 河海大学电气与动力工程学院，江苏省南京市 211100；
2. 国网江苏省电力有限公司电力科学研究院，江苏省南京市 211103）

摘要： 伴随大量分布式资源接入有源配电网，配电网内部不确定性增强。为建立准确的调度模型，将光伏出力的不确定性、负荷的随机性分别描述为对应预测误差的不确定性，并通过数据驱动的方法获得不确定变量的概率分布。考虑到基于二阶锥松弛（SOCR）的潮流模型可能违反松弛条件并造成误差，基于欧拉方程重新推导了潮流模型，进一步建立有源配电网经济、安全的随机优化功率调度模型。针对所提模型的特点，提出一种融合模糊神经网络（FNN）预决策的有源配电网实时随机调度方法。首先，利用FNN对不确定变量的概率分布进行模糊描述，将其输出作为求解器寻优的初值。然后，通过求解器进行加速求解。最后，通过改进的IEEE 33节点系统验证所提模型和方法的有效性。

关键词： 有源配电网；实时随机调度；数据驱动；潮流；模糊神经网络；不确定性

0　引言

为了减少电力行业的碳排放，构建以“零碳排放”的新能源为主体的新型电力系统十分重要[1]。目前，分布式光伏（photovoltaic，PV）正大量接入配电网。可以预见，未来配电网中将出现高比例新能源并网的态势[2]。为应对新能源出力的随机性，大量分散式储能设备也随之接入配电网[3]，这一转变使得传统配电网逐步升级为有源配电网（主动配电网）[4]。配电网优化调度是实现配电网经济、安全运行的必要途径[5]，建立有效的模型和寻找高效的求解方法是目前所面对的挑战[6]。

一方面，建立准确、符合实际的有源配电网调度模型的关键在于使用合适、可靠的潮流模型并准确描述其不确定性。潮流模型的处理方法主要有潮流线性化、半定松弛（semi-definite relaxation，SDR）、二阶锥松弛（second-order cone relaxation，SOCR）等。潮流线性化不考虑无功功率/电压相角且忽略网损，在高阻抗比配电网中不适用；SDR精度高，但计算速度慢[7]；SOCR兼顾精度和计算速度，故得到了广泛应用[8-9]，但可能因为违反松弛条件而产生较大误差[10]。同时，随着优化模型求解技术的发展，有必要对潮流模型进行更新。另外，新能源的间歇性和负荷的高随机性是调度模型中不确定性的来源，准确描述该不确定性是确保调度模型有效的关键[11]，处理方法包括随机优化[12]、鲁棒优化[13]、分布鲁棒优化[14]等。传统随机优化通常假定不确定变量服从给定的概率分布。例如，假设风电预测误差服从正态分布[15]，但由于实际情况复杂多变，假定的概率分布难以反映不确定变量的真实情况[16]，可用数据驱动的方法从历史数据中获取不确定变量的概率分布[17]。鲁棒优化和分布鲁棒优化在不确定变量最恶劣场景下进行决策，其鲁棒性较好，但优化结果较保守。此外，针对各种功率预测模型，文献[18]和文献[19]分别实现了对负荷功率和PV出力的准确预测。目前，针对配电网优化调度的研究中，大多通过功率预测值对PV出力和负荷功率的不确定性进行建模[20]。但是，在功率预测结果较准确的情况下，直接采用其功率预测误差，反而更有利于对不确定性进行更本质、更细致的描述。

另一方面，亟待开发求解速度快、实时性好的求解方法。在优化问题求解上，传统求解器可能存在求解速度较慢的不足[21]。随着深度神经网络的发展，有学者将其用于优化模型的求解。文献[22]利用深度神经网络高效求解交流最优潮流，但存在潮流功率不平衡的问题；文献[23]对此进行了改进，通过预测-重构方法确保满足原模型的约束；文献[24]则采用卷积神经网络对最优潮流进行求解。除求解最优潮流外，神经网络也可用于求解优化调

收稿日期：2025-02-13；修回日期：2025-06-12。
上网日期：2025-07-31。
国家电网公司科技项目（4000-202418061A-1-1-ZN）。

度模型，文献[25]用深度学习的方法预测最恶劣概率分布来高效求解分布鲁棒优化模型；文献[26]融合全连接层神经网络加速了随机优化模型的求解。这些方法能够在牺牲少量准确性的情况下，大大加快优化模型的求解速度，但可能存在训练成本大或预测结果与真实值存在偏差而导致优化模型约束条件不收敛的问题。

综上所述，首先，本文基于欧拉方程重新推导潮流模型，所提模型无需假设条件，同时可用现有的非线性求解器进行高效求解；然后，将负荷和PV功率分解为其预测值和预测误差，其不确定性本质上为预测误差的不确定性；接着，对功率预测误差历史数据进行场景削减，从而得到不确定变量的概率分布；最后，综合考虑网络损耗、调度成本等多种因素，建立经济、安全的有源配电网随机优化功率调度模型，并提出融合模糊神经网络(fuzzy neural network，FNN)预决策的高效求解方法。所提方法使用FNN的隶属度函数来表征随机优化不确定变量的概率分布，通过神经网络的输出对决策变量进行预决策，最终实现在不牺牲模型求解准确度的前提下，加快模型的求解速度。

1 基于数据驱动的有源配电网随机优化功率调度模型

首先，基于欧拉方程重新推导潮流方程，与原始潮流方程等价，但相较于原始潮流方程更易求解；然后，将存在不确定性的PV功率和负荷功率分解为功率预测值和预测误差两部分，功率预测值在实际调度中一般被视为确定值，故不确定性本质上为预测误差的不确定性；接着，通过对其历史数据采取数据驱动的方式进行场景削减，得到不确定变量的概率分布，从而合理表征该不确定性；最后，提出基于数据驱动的配电网随机优化功率调度模型，可由成熟的非线性求解器较快求解。

1.1 潮流模型推导

本文采用的潮流模型为非线性模型，参考文献[27]进行推导。

1)网络损耗

$$P_{mn}^{\mathrm{L}}=I_{mn}^{2}R_{mn}=\frac{(P_{mn}^{2}+Q_{mn}^{2})R_{mn}}{U_{m}^{2}} \tag{1}$$

$$Q_{mn}^{\mathrm{L}}=I_{mn}^{2}X_{mn}=\frac{(P_{mn}^{2}+Q_{mn}^{2})X_{mn}}{U_{m}^{2}} \tag{2}$$

式中：U_m为节点m的电压幅值；P_{mn}、Q_{mn}、I_{mn}分别为流过线路mn的有功功率、无功功率、电流；P_{mn}^{L}、Q_{mn}^{L}、R_{mn}、X_{mn}分别为线路mn的有功功率损耗、无功功率损耗、电阻、电抗。

2)功率平衡

节点功率平衡示意图如附录A图A1所示，故对于节点m存在有功、无功功率平衡，即

$$\sum_{km\in\Omega_{\mathrm{L}}}P_{km}-\sum_{mn\in\Omega_{\mathrm{L}}}(P_{mn}+P_{mn}^{\mathrm{L}})+P_{m,\mathrm{T}}+P_{m,\mathrm{PV}}+P_{m,\mathrm{ESS}}=P_{m,\mathrm{D}} \tag{3}$$

$$\sum_{km\in\Omega_{\mathrm{L}}}Q_{km}-\sum_{mn\in\Omega_{\mathrm{L}}}(Q_{mn}+Q_{mn}^{\mathrm{L}})+Q_{m,\mathrm{T}}+Q_{m,\mathrm{PV}}+Q_{m,\mathrm{SVC}}=Q_{m,\mathrm{D}} \tag{4}$$

式中：$P_{m,\mathrm{T}}$、$P_{m,\mathrm{PV}}$、$P_{m,\mathrm{ESS}}$分别为变电站、分布式PV、分散式ESS注入节点m的有功功率P_m^{dis}；$Q_{m,\mathrm{T}}$、$Q_{m,\mathrm{PV}}$、$Q_{m,\mathrm{SVC}}$分别为变电站、分布式PV、静止无功补偿器(static var compensator，SVC)注入节点m的无功功率Q_m^{dis}；$P_{m,\mathrm{D}}$、$Q_{m,\mathrm{D}}$分别为节点m的负荷有功、无功功率；P_{km}、Q_{km}分别为线路km注入节点m的有功、无功功率；Ω_{L}为线路集合。

3)电压降落

电压降落初始定义公式为：

$$\dot{V}_m-\dot{V}_n=Z_{mn}\dot{I}_{mn}=Z_{mn}\frac{S_{mn}^{*}}{\dot{V}_m^{*}} \tag{5}$$

式中：$Z_{mn}=R_{mn}+\mathrm{j}X_{mn}$为线路$mn$的阻抗；$\dot{V}_m=|V_m|\angle\theta_m$、$\dot{V}_n=|V_n|\angle\theta_n$分别为节点$m$、$n$的电压相量，其中，$\theta_m$、$\theta_n$分别为节点$m$、$n$的电压相位角，$|V_m|$、$|V_n|$分别为节点$m$、$n$的电压幅值；$\dot{I}_{mn}$为线路$mn$电流相量；$S_{mn}^{*}$和$\dot{V}_m^{*}$分别为线路$mn$的视在功率$S_{mn}$和节点$m$的电压相量$\dot{V}_m$的共轭复数。

由于式(5)含有复数项，难以直接求解，故对电压相角进行松弛。首先，对式(5)等号两边同乘$\dot{V}_m^{*}$，即

$$\dot{V}_m^{*}(\dot{V}_m-\dot{V}_n)=Z_{mn}S_{mn}^{*} \tag{6}$$

将$\dot{V}_m$、$\dot{V}_n$、Z_{mn}、S_{mn}^{*}展开，则有：

$$|V_m|^2-\dot{V}_m^{*}\dot{V}_n=|V_m|^2-|V_m||V_n|\angle\theta_{nm}=(R_{mn}+\mathrm{j}X_{mn})(P_{mn}-\mathrm{j}Q_{mn}) \tag{7}$$

式中：θ_{nm}为节点m、n的电压相位角差。

根据欧拉公式对电压相位角差θ_{nm}进行改写，则有：

$$|V_m|^2-(|V_m||V_n|\cos\theta_{nm}+\mathrm{j}|V_m||V_n|\sin\theta_{nm})=(R_{mn}+\mathrm{j}X_{mn})(P_{mn}-\mathrm{j}Q_{mn}) \tag{8}$$

将式(8)的实、虚部分开，则有：

$$|V_m||V_n|\cos\theta_{mn}=|V_m|^2-(R_{mn}P_{mn}+X_{mn}Q_{mn}) \tag{9}$$

$$|V_m||V_n|\sin\theta_{mn}=R_{mn}Q_{mn}-X_{mn}P_{mn} \tag{10}$$

将式(9)的平方和式(10)的平方相加，则有：

$$[|V_m|^2-(R_{mn}P_{mn}+X_{mn}Q_{mn})]^2+$$
$$(R_{mn}Q_{mn}-X_{mn}P_{mn})^2=(|V_m\|V_n|)^2 \quad (11)$$

将式(11)中的平方项展开，等式两边同除$|V_m|^2$，则有：

$$\frac{1}{|V_m|^2}(R_{mn}P_{mn}+X_{mn}Q_{mn})^2-2(R_{mn}P_{mn}+X_{mn}Q_{mn})+$$
$$|V_m|^2+\frac{1}{|V_m|^2}(R_{mn}Q_{mn}-X_{mn}P_{mn})^2=|V_n|^2 \quad (12)$$

因此，线路的电流约束为：

$$I_{mn}^2\leqslant I_{mn,\max}^2 \quad (13)$$

$$\frac{|S_{mn}|^2}{|V_m|^2}\leqslant I_{mn,\max}^2 \quad (14)$$

$$\frac{P_{mn}^2+Q_{mn}^2}{|V_m|^2}\leqslant I_{mn,\max}^2 \quad (15)$$

式中：$I_{mn,\max}$为流过线路mn的电流幅值的上限。

1.2　基于数据驱动的PV功率和负荷功率典型场景构建

本文将PV和负荷的实际功率分解为功率预测值和预测误差两部分[28]，即

$$P_{PV}=P_{PV,pre}(1+\xi_{PV}) \quad (16)$$

$$P_D=P_{D,pre}(1+\xi_{DP}) \quad (17)$$

$$Q_D=Q_{D,pre}(1+\xi_{DQ}) \quad (18)$$

式中：P_{PV}、P_D、Q_D分别为PV功率、负荷有功功率、负荷无功功率的实际值；$P_{PV,pre}$、$P_{D,pre}$、$Q_{D,pre}$分别为PV功率、负荷有功功率、负荷无功功率的预测值；ξ_{PV}、ξ_{DP}、ξ_{DQ}分别为$P_{PV,pre}$、$P_{D,pre}$、$Q_{D,pre}$的预测误差率。

因此，PV和负荷的随机性表现为预测误差的随机性。随机优化以不确定场景下目标函数的数学期望值最优为目标。本文中，不确定变量为功率预测误差，故可对相似日的预测数据进行场景削减，通过预测误差的典型场景来描述其随机性。

考虑到全部历史数据数量繁多，计算所有场景下的数学期望会使模型维数过高，从而难以求解。此外，场景数增多会大幅降低求解速度，故通过场景削减，使用少量的典型场景有效代表所有历史数据场景，兼顾模型求解的准确性和实时性。本文采用文献[29]所提方法，通过改进的K-means聚类算法和基于概率距离的同步回代消除技术对PV功率预测误差百分数和负荷功率预测误差百分数进行联合场景削减，获得不确定变量典型场景。其中，改进的K-means聚类算法通过选择高密度区域中距离最大的点作为初始聚类中心，克服了传统K-means聚类算法随机选择初始聚类中心，易导致聚类结果不稳定的不足[30]。此外，由于直接对预测误差百分数进行场景削减，预测功率被视为确定量，且不确定变量中不再包含PV出力骤降、负荷突增等极端事件，这不仅避免了此类事件对不确定性建模的干扰，也为后续方法的实现提供了便利。

1.3　基于数据驱动的随机优化调度模型

1.3.1　目标函数

综合考虑上级变电站供电成本、配电网网络损耗、分散式ESS调度成本、SVC调度成本[31]，所提模型目标函数为：

$$\min\left(K_TP_T+\sum_{mn\in\Omega_L,S\in\Omega_S}\pi(S)K_LP_{mn}^L+\sum_{m\in\Omega_{ESS}}K_EP_{m,ESS}^2+\sum_{m\in\Omega_{SVC}}K_SQ_{m,SVC}\right) \quad (19)$$

式中：Ω_{ESS}、Ω_{SVC}、Ω_S分别为ESS节点集合、SVC节点集合、数据驱动后典型场景集合；K_T、K_L、K_E、K_S分别为变电站供电成本系数、网络损耗系数、ESS调度系数、SVC调度系数；P_T为变电站有功功率；$\pi(S)$为数据驱动得到的典型场景对应概率。

值得说明的是，本文设置$P_{m,ESS}$结果为正表示放电，为负表示充电[30]，由于ESS充、放电功率共用一个值，故ESS的充、放电约束自然满足。

1.3.2　约束条件

1)潮流约束

潮流约束如式(1)—式(4)和式(12)所示。

2)安全运行约束

安全运行约束包括线路电流约束(式(15))、线路传输功率约束和节点电压约束。线路传输功率约束和节点电压约束分别如式(20)和式(21)所示。

$$P_{mn}^2+Q_{mn}^2\leqslant S_{mn,\max}^2 \quad (20)$$

$$V_m^{\min}\leqslant|V_m|\leqslant V_m^{\max} \quad (21)$$

式中：$S_{mn,\max}$为线路mn载流量的上限；$V_m^{\max}$、$V_m^{\min}$分别为$|V_m|$的上、下限。

3)变电站注入功率约束

变电站注入功率约束如式(22)和式(23)所示。

$$P_T^{\min}\leqslant P_T\leqslant P_T^{\max} \quad (22)$$

$$Q_T^{\min}\leqslant Q_T\leqslant Q_T^{\max} \quad (23)$$

式中：Q_T为变电站无功功率；$P_T^{\max}$、$P_T^{\min}$分别为P_T的上、下限；$Q_T^{\max}$、$Q_T^{\min}$分别为Q_T的上、下限。

4)PV机组运行约束

考虑PV机组一般运行在最大功率点跟踪(maximum power point tracking，MPPT)模式[32]，为充分利用能源，考虑PV机组所发的有功功率全部利用；同时，考虑分布式PV可通过调节其逆变器的功率因数角进行无功调整[33]，其运行约束为：

$$P_{m,\mathrm{PV}}^2+Q_{m,\mathrm{PV}}^2\leqslant S_{m,\mathrm{PV}}^2 \tag{24}$$

式中：$S_{m,\mathrm{PV}}$为节点m的PV容量。

5)ESS运行约束

ESS运行约束如式(25)—式(27)所示。

$$P_{m,\mathrm{ESS}}^{\min}\leqslant|P_{m,\mathrm{ESS}}|\leqslant P_{m,\mathrm{ESS}}^{\max} \tag{25}$$

$$E_{t,m,\mathrm{ESS}}=(1-\eta_{\mathrm{loss}})E_{t-1,m,\mathrm{ESS}}-\eta_{\mathrm{ESS}}P_{m,\mathrm{ESS}} \tag{26}$$

$$E_{m,\mathrm{ESS}}^{\min}\leqslant E_{t,m,\mathrm{ESS}}\leqslant E_{m,\mathrm{ESS}}^{\max} \tag{27}$$

式中：$P_{m,\mathrm{ESS}}^{\max}$、$P_{m,\mathrm{ESS}}^{\min}$分别为节点$m$的ESS充放电功率上、下限；$E_{t,m,\mathrm{ESS}}$为$t$时刻节点$m$的ESS电量；$E_{m,\mathrm{ESS}}^{\max}$、$E_{m,\mathrm{ESS}}^{\min}$分别为节点$m$的ESS电量的上、下限；$\eta_{\mathrm{loss}}$、$\eta_{\mathrm{ESS}}$分别为电量损耗系数、充放电效率。

6)SVC约束

SVC约束如式(28)所示。

$$Q_{m,\mathrm{SVC}}^{\min}\leqslant Q_{m,\mathrm{SVC}}\leqslant Q_{m,\mathrm{SVC}}^{\max} \tag{28}$$

式中：$Q_{m,\mathrm{SVC}}^{\max}$、$Q_{m,\mathrm{SVC}}^{\min}$分别为节点$m$的SVC所补偿的无功功率上、下限。

7)柔性负荷约束

柔性负荷占总负荷的比例有限，其约束为：

$$(1-K_{m,\mathrm{P}})P_{m,\mathrm{D0}}\leqslant P_{m,\mathrm{D}}\leqslant(1+K_{m,\mathrm{P}})P_{m,\mathrm{D0}} \tag{29}$$

$$(1-K_{m,\mathrm{Q}})Q_{m,\mathrm{D0}}\leqslant Q_{m,\mathrm{D}}\leqslant(1+K_{m,\mathrm{Q}})Q_{m,\mathrm{D0}} \tag{30}$$

式中：$P_{m,\mathrm{D0}}$、$Q_{m,\mathrm{D0}}$分别为节点m柔性负荷控制前的原始负荷有功功率、无功功率；$K_{m,\mathrm{P}}$、$K_{m,\mathrm{Q}}$分别为节点m柔性负荷有功功率、无功功率所占比例。

2　融合FNN的模型求解方法

随着配电网复杂性提升，所提基于场景的随机优化方法使用求解器求解可能无法满足实时性要求。FNN兼具神经网络数据挖掘能力与模糊推理系统模糊信息处理能力，可用于处理不确定性变量。本文将FNN纳入不确定性变量的概率信息来加快模型的求解速度。观察1.3节所提模型可知，状态变量中节点电压幅值$|V_m|$为接近1且数量繁多的变量，而P_{T}、Q_{T}、$Q_{m,\mathrm{PV}}$、$P_{m,\mathrm{ESS}}$、$Q_{m,\mathrm{SVC}}$的数量较少且取值范围较大，故以训练好的神经网络进行第1阶段预决策得到P_{T}、Q_{T}、$Q_{m,\mathrm{PV}}$、$P_{m,\mathrm{ESS}}$、$Q_{m,\mathrm{SVC}}$的初值，再代入模型，通过求解器进行修正，从而保证收敛。由于第1阶段耗时极短，而第2阶段比直接求解有所加速，整体上加快了模型的求解速度。

2.1　融合FNN预决策的第1阶段求解

FNN的结构图如附录A图A2所示，其学习过程包括前向传播和反向传播两部分。

前向传播过程：首先，在数据输入层(第1层)，将神经元数量作为输入数据的特征维度。本文输入数据包括预测的PV有功功率$P_{\mathrm{PV,pre}}$、预测的负荷有功功率$P_{\mathrm{D,pre}}$、预测的负荷无功功率$Q_{\mathrm{D,pre}}$及各典型场景下的预测误差ξ_{PV}、ξ_{DP}、ξ_{DQ}，值得注意的是，输入的变量含有不确定性。此外，为避免数据的差异对训练模型的结果产生影响，当将输入数据输入神经网络之前，本文对输入数据按照式(31)进行归一化处理。

$$\tilde{x}_{i,\mathrm{feature}}=\frac{x_{i,\mathrm{feature}}-\min x_{\mathrm{feature}}}{\max x_{\mathrm{feature}}-\min x_{\mathrm{feature}}} \tag{31}$$

式中：x_{feature}为输入数据某一类特征；$x_{i,\mathrm{feature}}$为某一类特征的第i个数据；$\tilde{x}_{i,\mathrm{feature}}$为$x_{i,\mathrm{feature}}$归一化后的结果。

第2层为隶属度函数计算层，每个神经元代表一个模糊量，通过隶属度函数计算输入变量隶属于模糊量的概率，神经元个数为输入变量可能构成的模糊条件数，即模糊集。鉴于不确定变量平滑变化，符合高斯函数特征，而三角形、梯形隶属度函数变化不够平滑且存在突变的部分。因此，选用高斯函数作为隶属度函数更符合本文使用场景，如式(32)所示。

$$u_{ij}=\frac{\mathrm{e}^{-\frac{(x_i-c_{ij})^2}{2b_{ij}^2}}}{\sqrt{2\pi}\,b_{ij}}\qquad i\in[1,n],j\in[1,z] \tag{32}$$

式中：u_{ij}为第i个输入数据的第j个模糊分级输出；x_i为输入数据；c_{ij}为隶属度函数的中心点；b_{ij}为隶属度函数的宽度值；n为输入数据的维度；z为模糊分级数，即典型场景数。为保证神经网络的收敛，参数c_{ij}和b_{ij}通过随机初始化获得，由于输入数据进行了归一化，参数c_{ij}和b_{ij}的初始化范围分别为$[-1,1]$和$[0,1]$。

将数据传递至规则生成层(第3层)，每个神经元代表一条模糊规则，其输出α_j为每条规则的适用度，即

$$\alpha_j=\prod_{j=1}^{z}u_{ij} \tag{33}$$

第4层为归一化层，对规则生成层每条规则的适用度进行归一化，如式(34)所示

$$\beta_j=\frac{\alpha_j}{\sum_{j=1}^{z}\alpha_j}\qquad j\in[1,z] \tag{34}$$

式中：β_j为归一化后的规则生成层每条规则的适用度。

最后，在输出层(第5层)中将数据进行加权处理，进而得到最终的输出结果为：

$$y_i=\sum_{j=1}^{z}w_{ij}\beta_j\qquad i\in[1,k],j\in[1,z] \tag{35}$$

式中：y_i为输出变量；w_{ij}为β_j对应的权重；k为输出变量的个数。需要说明的是，参数w_{ij}通过随机初始化获得，初始化范围为$[0,1]$。

性能指标函数为：

$$E=\frac{1}{2}\sum_{i=1}^{k}(y_{\mathrm{d},i}-y_i)^2 \tag{36}$$

式中：$y_{\mathrm{d},i}$为输出变量y_i的真实值；E为损失函数。

反向传播过程使用负梯度下降算法对隶属度函数的中心点、宽度值以及输出层的连接权值进行优化，直至损失函数达到收敛，具体计算步骤如下。

首先，计算损失函数E对第5层输出层的负梯度$\delta_i^{(5)}$，即

$$\delta_i^{(5)}=-\frac{\partial E}{\partial y_i}=y_{\mathrm{d},i}-y_i \qquad i\in[1,k] \tag{37}$$

从而可计算得到损失函数E对权重w_{ij}的负梯度为：

$$-\frac{\partial E}{\partial w_{ij}}=-\frac{\partial E}{\partial y_i}\frac{\partial y_i}{\partial w_{ij}}=-\delta_i^{(5)}\beta_j=-(y_{\mathrm{d},i}-y_i)\beta_j \tag{38}$$

同理，依次计算损失函数E对归一化层、规则生成层、隶属度函数层的负梯度，可得损失函数E对第2层隶属度函数层的负梯度$\delta_{ij}^{(2)}$为：

$$\delta_{ij}^{(2)}=\frac{\prod_{i=1,i\neq j}^{n}u_{ij}\sum_{i=1}^{z}(y_{\mathrm{d},i}-y_i)w_{ij}\sum_{i=1,i\neq j}^{z}\alpha_i}{\left(\sum_{i=1}^{z}\alpha_i\right)^2} \tag{39}$$

损失函数E对中心点c_{ij}和宽度值b_{ij}的负梯度为：

$$-\frac{\partial E}{\partial c_{ij}}=-\frac{\partial E}{\partial u_{ij}}\frac{\partial u_{ij}}{\partial c_{ij}}=\delta_{ij}^{(2)}u_{ij}\frac{2(x_i-c_{ij})}{b_{ij}^2} \tag{40}$$

$$-\frac{\partial E}{\partial b_{ij}}=-\frac{\partial E}{\partial u_{ij}}\frac{\partial u_{ij}}{\partial b_{ij}}=\delta_{ij}^{(2)}u_{ij}\frac{2(x_i-c_{ij})}{b_{ij}^3} \tag{41}$$

最后，得到的参数调整算法为：

$$w_{ij}^{r+1}=w_{ij}^{r}-\eta\frac{\partial E^r}{\partial w_{ij}^r} \qquad i\in[1,k],j\in[1,z] \tag{42}$$

$$c_{ij}^{r+1}=c_{ij}^{r}-\xi\frac{\partial E^r}{\partial c_{ij}^r} \qquad i\in[1,n],j\in[1,z] \tag{43}$$

$$b_{ij}^{r+1}=b_{ij}^{r}-\psi\frac{\partial E^r}{\partial b_{ij}^r} \qquad i\in[1,n],j\in[1,z] \tag{44}$$

式中：η、ξ、ψ分别为w_{ij}、c_{ij}、b_{ij}的学习率；上标r为迭代次数。

在实际应用中，使用历史数据学习$P_{\mathrm{PV,pre}}$、$P_{\mathrm{D,pre}}$、$Q_{\mathrm{D,pre}}$、$\boldsymbol{\xi}_{\mathrm{PV}}$、$\boldsymbol{\xi}_{\mathrm{DP}}$、$\boldsymbol{\xi}_{\mathrm{DQ}}$与$P_{\mathrm{T}}$、$Q_{\mathrm{T}}$、$Q_{m,\mathrm{PV}}$、$P_{m,\mathrm{ESS}}$、$Q_{m,\mathrm{SVC}}$的映射关系。后续对于训练好的神经网络，只要输入当前时刻的$P_{\mathrm{PV,pre}}$、$P_{\mathrm{D,pre}}$、$Q_{\mathrm{D,pre}}$、$\boldsymbol{\xi}_{\mathrm{PV}}$、$\boldsymbol{\xi}_{\mathrm{DP}}$、$\boldsymbol{\xi}_{\mathrm{DQ}}$，进行归一化、FNN输出、反归一化后就能对$P_{\mathrm{T}}$、$Q_{\mathrm{T}}$、$Q_{m,\mathrm{PV}}$、$P_{m,\mathrm{ESS}}$、$Q_{m,\mathrm{SVC}}$进行预决策。

2.2　使用求解器进行第2阶段求解

对于优化模型，给定的初值越接近最优解，寻优过程的迭代次数越少、时间越短，在复杂模型中更明显。因此，本文将第1阶段预决策的P_{T}、Q_{T}、$Q_{m,\mathrm{PV}}$、$P_{m,\mathrm{ESS}}$、$Q_{m,\mathrm{SVC}}$作为初值代入原模型，用求解器加速求解，保证求解正确性的同时加快求解速度。

融合FNN预决策的求解算法系统图如附录A图A3所示。首先，使用历史数据对FNN进行离线训练，第1阶段向训练好的神经网络输入实时的功率预测数据$P_{\mathrm{PV,pre}}$、$P_{\mathrm{D,pre}}$、$Q_{\mathrm{D,pre}}$以及数据驱动得到的典型场景误差$\boldsymbol{\xi}_{\mathrm{PV}}$、$\boldsymbol{\xi}_{\mathrm{DP}}$、$\boldsymbol{\xi}_{\mathrm{DQ}}$，神经网络基于历史数据之间的关系快速输出调度变量估计值$\hat{P}_{\mathrm{T}}$、$\hat{Q}_{\mathrm{T}}$、$\hat{Q}_{m,\mathrm{PV}}$、$\hat{P}_{m,\mathrm{ESS}}$、$\hat{Q}_{m,\mathrm{SVC}}$，并将其作为预决策值；第2阶段将预决策值作为求解器寻优的初始点，加速对调度变量进行修正以保证结果的准确性。

3　算例分析

本文使用修改的IEEE 33节点系统进行算例测试，PV接入节点和容量如表1所示，ESS和SVC参数如表2和表3所示。为了生成多个时刻的PV机组输出功率和负荷功率预测值，分别在PV机组额定功率的10%～90%范围内、负荷功率的80%～100%范围内按递增顺序进行均匀采样，总采样点数与需要生成的总时刻数一致，并将采样结果作为功率预测值。通过蒙特卡洛模拟法生成功率预测相似日的预测误差历史数据，对历史数据进行场景削减得到功率预测误差典型场景。本文设定变电站供电成本系数K_{T}为0.8元/kW；网络损耗系数K_{L}为1.2元/kW；ESS调度系数K_{E}为0.000 6元/kW^2；SVC调度系数K_{S}为1.2元/kvar[34]。本文使用Pyomo建模，由于是非线性优化问题，传统求解器使用内点法优化器（interior point optimizer，IPOPT）进行求解。

表1　PV机组参数
Table 1　Parameters of PV unit

PV机组编号	接入节点序号	容量/(kV·A)	PV机组编号	接入节点序号	容量/(kV·A)
PV1	3	150	PV2	7	150
PV3	10	100	PV4	16	200
PV5	18	100	PV6	19	150
PV7	22	200	PV8	25	100
PV9	28	100	PV10	33	150

3.1　所提随机优化调度方法的有效性分析

3.1.1　场景削减结果分析

以从2 000组功率预测误差历史数据中削减得

表2　ESS参数
Table 2　Parameters of ESS

ESS编号	所在节点	电量上限/(kW·h)	充放电功率/kW
ESS1	1	200	100
ESS2	12	1 600	800
ESS3	20	400	200
ESS4	24	2 000	1 000
ESS5	27	600	300
ESS6	30	2 000	1 000

表3　SVC参数
Table 3　Parameters of SVC

SVC编号	接入节点	补偿功率/kvar	SVC编号	接入节点	补偿功率/kvar
SVC1	2	400	SVC6	23	120
SVC2	4	120	SVC7	25	200
SVC3	7	400	SVC8	29	200
SVC4	14	200	SVC9	30	200
SVC5	19	200	SVC10	32	200

到的10个场景为例，多时刻下功率预测误差典型场景及概率如图1和图2所示。由于各PV机组安装位置的天气状况等物理条件和各节点负荷的复杂情况不尽相同，其功率预测误差有所差异，故场景削减时使用本地的历史数据进行数据驱动较为合理。从图1中也可看出，使用历史数据功率预测误差基本处于−15%～15%之间，在现有技术条件下能够实现，与实际情况相符。

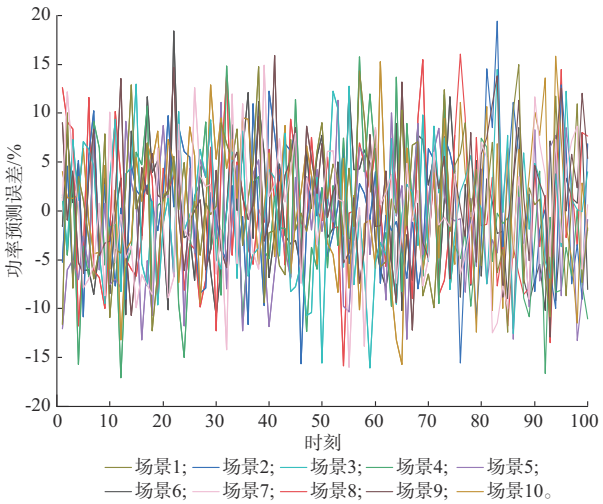

图1　典型场景的功率预测误差
Fig. 1　Power prediction errors in typical scenarios

3.1.2　数据驱动得到的典型场景数量对优化结果的影响

附录A图A4对比了100个时刻下典型场景数为5、10、20、30的目标函数值和求解时间。图A4显示，在典型场景数为10、20、30时，100个时刻(时间断面)下的目标函数值均趋于稳定，目标函数值相差基本在±100元以内，可见，再增加典型场景的数量，目标函数值也会稳定在该区间内，说明典型场景能够代表原始数据。但是，随着典型场景的增加，模型总求解时间分别为546、1 146、3 243、12 941 s，求解时间大幅增加，求解速度变慢，这充分证明了从历史数据中获取典型场景的必要性和有效性。

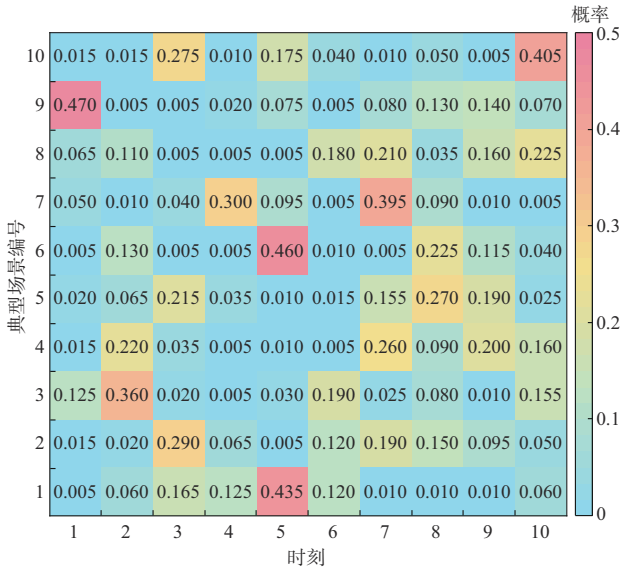

图2　典型场景概率
Fig. 2　Probability of typical scenario

3.1.3　重新推导的潮流方程准确性和高效性分析

本节基于本文重新推导的潮流模型和基于SOCR的潮流模型分别建立随机优化调度模型，图3对比了100个时刻下2种模型的目标函数值和求解时间。2种模型的区别仅在潮流模型的差异上，具体潮流模型的对比如附录B所示。

从图3中可以看出，不同典型场景数下，2种模型的目标函数值变化趋势及大小基本一致，说明了本文潮流模型的最优性。此外，当使用IPOPT求解2种模型时，本文重新推导的潮流模型与基于SOCR的潮流模型相比，当典型场景数为5、10、20、30个时，求解速度分别提升了33.90%、34.63%、37.83%、40.88%。这是因为本文重新推导的潮流模型减少了中间变量以及SOCR约束，从而减小了随机优化调度模型的规模，提高了求解速度。

3.1.4　所提不确定性处理方法有效性分析

附录A图A5对比了100个时刻下本文随机优化调度模型(20个典型场景)与确定性优化模型、鲁棒优化模型的目标函数以及求解时间。可以看出，

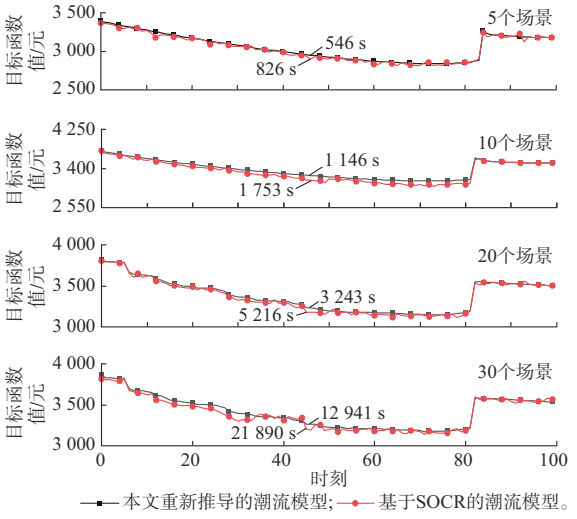

图3　潮流模型的效果对比

Fig. 3　Comparison of performance of power flow model

由于确定性优化模型未考虑不确定变量的随机性，优化成本较小、求解时间短，但与实际情况相差较大。鲁棒优化模型考虑了不确定变量最恶劣条件下的场景，优化成本过于保守，经济性较差。同时，鲁棒优化模型在优化过程中要不断迭代以寻找不确定量最恶劣场景下的概率分布，求解速度较慢。本文所提随机优化方法则在较快的求解速度下兼顾了优化的有效性和经济性。

3.1.5　所提模型优化结果分析

综合考虑求解速度和求解效果，本文选取典型场景数为20时，100个时刻的优化结果展开分析。变电站无功出力接近0，附录A图A6、图A7、图A8分别展示了PV无功出力、变电站有功出力（图中编号为0）及ESS充放电功率（图中编号为1-6）、SVC无功出力。电网中的有功功率来源包括变电站出力、PV机组有功出力和ESS的充放电量。当PV机组出力较多时，ESS充电储能；当PV机组出力较少时，ESS放电供电，从而平抑PV的波动性。由于分布式PV机组和SVC的无功功率调节，为减少电网中功率流动并降低网络损耗，变电站基本不供应无功功率，无功功率实现就地平衡。在算例中，分布式PV机组的有功功率递增，提供的有功功率增多，故变电站有功功率和ESS的放电功率基本呈现减小趋势，优化的目标函数值降低。同时，受分布式PV机组运行约束式（24）的限制，分布式PV机组提供的无功功率逐渐减少，当无功功率不足时，为维持无功功率平衡，需要SVC提供无功功率支撑，导致SVC调度成本增加，故在时刻80附近，优化的目标函数值增加。当分布式PV机组有功功率增加带来的效益高于SVC调度成本时，目标函数值下降。

3.2　所提求解方法计算性能分析

3.2.1　所提方法计算效率分析

为验证本文所提融合FNN的求解方法在计算效率方面的提升效果，以直接采用求解器求解原问题作为对比基准。同时，为了减少计算机性能对计算时间造成的随机影响，均对100个时刻（时间断面）进行求解，统计总求解时间。在不同典型场景数下的仿真结果如表4所示。表中：T_0为直接使用求解器求解所需时间；T_1为FNN预决策时间；T_2为求解器第2阶段修正所需时间；T_{total}为融合FNN求解方法所需总时间。加速比α为：

$$\alpha=\frac{T_0-T_{\text{total}}}{T_0}\times 100\% \tag{45}$$

表4　不同典型场景数下计算时间对比

Table 4　Comparison of computation time with different numbers of typical scenarios

场景数	计算时间/s				α/%
	T_0	T_1	T_2	T_{total}	
5	546.72	16.02	368.49	384.51	29.67
10	1 146.18	16.27	765.79	782.06	31.77
20	3 243.35	17.54	2 206.70	2 224.24	31.42
30	12 941.38	16.89	8 320.96	8 337.85	35.57

由表4可知，在场景数为30时，直接用求解器求解所提模型每次求解耗时为129.41 s，而实时调度的时间尺度为300.00 s，时间裕度较小，考虑功率预测所需时间、通信延迟等，有必要提升求解实时性。所提融合FNN的求解方法每次求解耗时为83.38 s，能够更好地满足实时调度的要求。同时，各典型场景数下，所提方法的加速效果均超过30%，尤其当典型场景数为30时，求解总时间缩短了4 604.53 s，加速效果更明显。此外，随着典型场景数增加，原优化问题更加复杂，使用求解器直接求解的时间大幅增加；而本文所提方法所需的时间基本不变，第2阶段修正时间增加，但整体加速比提高，说明所提方法对复杂系统求解效率的提升更为明显。

3.2.2　FNN优越性分析

为说明所用FNN的优越性，将FNN与反向传播（back propagation，BP）神经网络预决策的性能进行对比，在二者损失函数均达到收敛的情况下，计算预决策值与真实值的均方根误差（root mean square error，RMSE）、平均绝对误差（mean absolute error，MAE）、平均绝对误差百分数（mean absolute percentage error，MAPE）进行对比，将这3个变量作为衡量神经网络性能的指标，即

$$e_{\mathrm{RMSE}}=\frac{1}{N}\sqrt{\sum_{k=1}^{N}(\hat{o}_k-o_k)^2} \tag{46}$$

$$e_{\mathrm{MAE}}=\frac{\sum_{k=1}^{N}|\hat{o}_k-o_k|}{N} \tag{47}$$

$$e_{\mathrm{MAPE}}=\frac{1}{N}\sum_{k=1}^{N}\frac{|\hat{o}_k-o_k|}{o_k}\times 100\% \tag{48}$$

式中：N为样本的总数；$\hat{o}_k$为预测值；o_k为真实值。

本节设置样本数为100，其中，测试集和训练集样本的比例为2∶8，在不同的典型场景数下得到的性能对比结果如表5所示。

表5　FNN与BP神经网络性能对比

Table 5　Performance comparison between FNN and BP neural networks

场景数	RMSE/(kV·A)		MAE/(kV·A)		MAPE/%		α/%	
	BP神经网络	FNN	BP神经网络	FNN	BP神经网络	FNN	BP神经网络	FNN
5	17.83	15.40	18.58	15.63	4.17	3.68	20.87	30.12
10	17.82	15.83	17.54	15.03	4.65	3.76	23.70	31.55
20	16.64	16.22	17.06	17.60	4.44	4.32	29.58	31.27
30	18.66	15.83	17.87	16.39	5.88	3.48	25.19	35.53

由表5可知，各典型场景数下，由于FNN使用隶属度函数来描述不确定变量隶属于各场景的概率，而BP神经网络仅依靠数据拟合，未涉及物理信息，故FNN预决策误差更小，预决策值更接近优化问题的最优点，加速性能更好。此外，预决策值与真实值之间的误差是影响加速效果的关键，误差越小，预决策值越靠近实际最优解，第2阶段求解所需迭代的次数和时间更少。

3.2.3　融合FNN预决策效果分析

以典型场景数为10、样本数为500为例，图4显示了隶属度函数层对不确定变量的模糊分级情况。由图4可以看出，不确定变量分布不满足单一的高斯分布，分布呈现非对称、多峰的特征，但由于在FNN的隶属度函数计算层进行了模糊分级，各级隶属度函数仍能较好地学习不确定变量的概率信息，为预决策提供了较好的基础。鉴于神经网络学习的样本数较少，部分功率预测误差的概率信息与隶属度函数计算结果存在偏差是可以接受的。

以典型场景数为20、样本数为500为例，图5为测试集中FNN预决策值与真实值的散点图。由图5可知，数据点大致位于斜率为1的直线附近，预决策值与真实值的线性相关系数R为0.999 89，决定系数R^2为0.999 78，表明预决策值能够较好地反映真实值，融合FNN预决策性能良好。

3.2.4　样本数对所提方法的影响

配电网结构改变频繁，例如，重构拓扑、扩建、新增PV机组等。对于神经网络，一旦配电网结构发生改变，神经网络就要重新训练，若训练样本难以大量获取，可能会导致效果不佳。典型场景数为20时，本节对比分析了不同样本数下FNN预决策的性能，结果如表6所示。由表6可知，随着样本数增加，

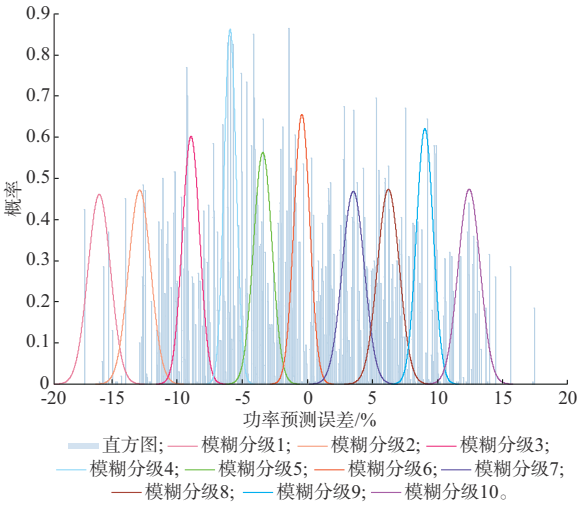

图4　隶属度函数对不确定变量的模糊分级情况

Fig. 4　Fuzzy classification of uncertain variables by membership functions

神经网络预决策误差减小。当样本数为500时，误差最小，加速性能超过35%，这是由于更多的样本数使神经网络更好地学习到数据中的特征信息，反向传播能获得更精准的参数，实现更好的效果。相较于其他需要大量样本的神经网络，本文所提方法在几百样本数下能够加速30%以上，更适合灵活多变的配电网，且克服了样本获取难、训练耗时的缺点。

3.2.5　大规模配电网络扩展测试

为验证所提方法对大规模系统的适用性，采用修改的IEEE 69节点配电网进行仿真分析，共接入20台分布式PV、12台分散式ESS、20台SVC。附录A图A9对比了100个时刻、各典型场景数下的目标函数值和求解时间，显示在典型场景数为10、20、30时，100个时刻下的目标函数值基本稳定，表明数

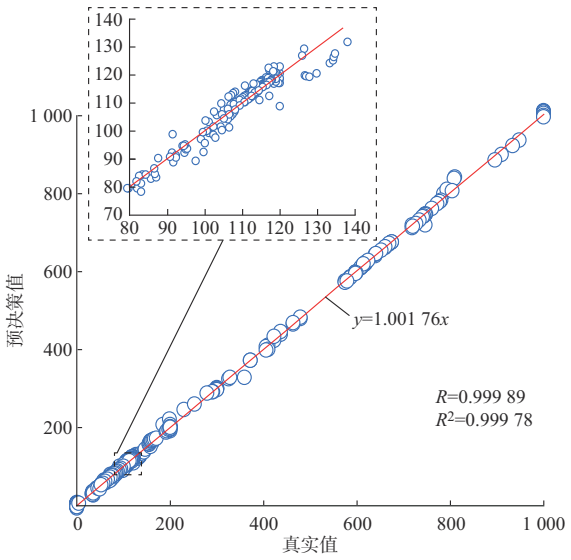

图5　预决策值与真实值对比
Fig. 5　Comparison between pre-decision value and actual value

表6　样本数对所提方法的影响
Table 6　Impact of sample numbers on proposed method

样本数	RMSE/(kV·A)	MAE/(kV·A)	MAPE/%	α/%
100	16.22	17.60	4.32	31.27
200	15.98	17.36	4.12	32.86
300	15.92	17.08	4.05	33.05
400	15.37	15.54	3.99	33.73
500	13.65	14.09	3.66	35.02

据驱动得到的典型场景能够有效代表不确定变量历史数据。附录A表A1展示了所提方法的加速效果，所提方法在IEEE 69节点系统中的加速效果达34%以上，优于在IEEE 33节点系统中的加速效果，且能够满足30典型场景下的实时调度要求，说明该方法适用于复杂系统。

4　结语

本文综合考虑网络损耗、调度成本等多种因素，提出了经济、安全的有源配电网随机优化功率调度模型，并提出了融合FNN预决策的高效求解方法。本文通过修改的IEEE 33节点和IEEE 69节点测试系统对所提模型和方法进行了仿真测试，并得出了以下结论：

1）随着不确定变量典型场景数的增加，随机优化模型的目标函数值将趋于稳定，但求解时间大幅增加。

2）FNN通过隶属度函数对不确定变量的概率分布进行描述，预决策性能优于仅依靠数据驱动的BP神经网络。

3）与直接求解随机优化模型相比，融合FNN预决策的求解方法可有效提升模型的求解速度，且在样本数较少时，依然具有不错的效果。

本文提出的随机优化功率调度模型和融合FNN的求解方法是针对数据驱动得到不确定变量概率分布的情况，对于难以或无法得到不确定变量概率分布的情况，如何建立有效的模型和提出高效的求解方法，未来需要进一步研究。

附录见本刊网络版，点击http://www.aeps-info.com/aeps/article/abstract/20250213005，或扫描英文摘要后二维码，可阅读全文。

参考文献

[1] 陈胜，卫志农，顾伟，等．碳中和目标下的能源系统转型与变革：多能流协同技术[J]．电力自动化设备，2021，41(9)：3-12.
CHEN Sheng，WEI Zhinong，GU Wei，et al. Carbon neutral oriented transition and revolution of energy systems：multi-energy flow coordination technology [J]. Electric Power Automation Equipment，2021，41(9)：3-12.

[2] 鞠平，姜婷玉，黄桦．浅论新型电力系统的“三自”性质[J]．中国电机工程学报，2023，43(7)：2598-2608.
JU Ping，JIANG Tingyu，HUANG Hua. Brief discussion on the “three-self” nature of the new power system [J]. Proceedings of the CSEE，2023，43(7)：2598-2607.

[3] 孙旭，邱晓燕，张志荣，等．基于数据驱动的交直流配电网分布鲁棒优化调度[J]．电网技术，2021，45(12)：4768-4778.
SUN Xu，QIU Xiaoyan，ZHANG Zhirong，et al. Distributed robust optimal dispatching of AC/DC distribution network based on data driven mode [J]. Power System Technology，2021，45(12)：4768-4778.

[4] SHEN X W，SHAHIDEHPOUR M，ZHU S Z，et al. Multi-stage planning of active distribution networks considering the co-optimization of operation strategies [J]. IEEE Transactions on Smart Grid，2016，9(2)：1425-1433.

[5] RATHORE A，PATIDAR N P. Optimal sizing and allocation of renewable based distribution generation with gravity energy storage considering stochastic nature using particle swarm optimization in radial distribution network [J]. Journal of Energy Storage，2021，35：102282.

[6] TANG Y J，DVIJOTHAM K，LOW S. Real-time optimal power flow [J]. IEEE Transactions on Smart Grid，2017，8(6)：2963-2973.

[7] 赵飞，樊雪君，李亚楼，等．基于迭代隐式线性化的网状配电网潮流计算及其最优潮流模型[J]．中国电机工程学报，2024，44(6)：2197-2208.
ZHAO Fei，FAN Xuejun，LI Yalou，et al. Iterative implicit linearization based power flow calculation and optimal power flow model for meshed distribution networks [J]. Proceedings of the CSEE，2024，44(6)：2197-2208.

[8] 李晓波，谢剑锋，张世乐．基于集群划分的主动配电网电压无功两阶段鲁棒控制策略[J/OL]．中国电机工程学报[2025-01-01]. http://kns. cnki. net/kcms/detail/11.2107. tm. 20240930.1418.

003.html.
LI Xiaobo, XIE Jianfeng, ZHANG Shile. A two-stage robust strategy for voltage/var control in active distribution networks based on cluster partitioning [J/OL]. Proceedings of the CSEE [2025-01-01].http://kns.cnki.net/kcms/detail/11.2107.tm.20240930.1418.003.html.

[9] CHOWDHURY M M, KAMALASADAN S, PAUDYAL S. A second-order cone programming based optimal power flow model with cyclic constraints for power transmission systems[J]. IEEE Transactions on Power Systems, 2023, 39(1): 1032-1043.

[10] 肖遥,别朝红,黄格超,等.基于二阶锥最优潮流的机会约束分布鲁棒优化研究[J].电网技术,2021,45(4):1505-1518.
XIAO Yao, BIE Zhaohong, HUANG Gechao, et al. Chance-constrained distributional robust optimization based on second-order cone optimal power flow[J]. Power System Technology, 2021, 45(4): 1505-1518.

[11] 郑晓东,陈皓勇,段声志,等.基于场景概率驱动的输电网和储能分布鲁棒规划[J].电力自动化设备,2022,42(6):170-178.
ZHENG Xiaodong, CHEN Haoyong, DUAN Shengzhi, et al. Distributionally robust planning of transmission network and energy storage based on scenario probability-driven[J]. Electric Power Automation Equipment, 2022, 42(6): 170-178.

[12] SHANG Y W, WU W C, LIAO J W, et al. Stochastic maintenance schedules of active distribution networks based on Monte-Carlo tree search [J]. IEEE Transactions on Power Systems, 2020, 35(5): 3940-3952.

[13] 王善磊,孙国强,吴晨,等.基于集中-分散交易机制的多产消者两阶段鲁棒优化模型[J].电力自动化设备,2022,42(5):175-182.
WANG Shanlei, SUN Guoqiang, WU Chen, et al. Two-stage robust optimization model of multiple prosumers based on centralized-decentralized trading mechanism[J]. Electric Power Automation Equipment, 2022, 42(5): 175-182.

[14] LI P S, ZHANG C, WU Z J, et al. Distributed adaptive robust voltage/var control with network partition in active distribution networks[J]. IEEE Transactions on Smart Grid, 2020, 11(3): 2245-2256.

[15] 叶林,李智,孙舶皓,等.基于随机预测控制理论和功率波动相关性的风电集群优化调度[J].中国电机工程学报,2018,38(11):3172-3183.
YE Lin, LI Zhi, SUN Bohao, et al. Optimal dispatch of system integrated wind farm clusters based on stochastic model predictive control considering temporal correlation of wind power [J]. Proceedings of the CSEE, 2018, 38(11): 3172-3183.

[16] 鲁卓欣,徐潇源,严正,等.不确定性环境下数据驱动的电力系统优化调度方法综述[J].电力系统自动化,2020,44(21):172-183.
LU Zhuoxin, XU Xiaoyuan, YAN Zheng, et al. Overview on data-driven optimal scheduling methods of power system in uncertain environment [J]. Automation of Electric Power Systems, 2020, 44(21): 172-183.

[17] 赵书强,赵蓬飞,韦子瑜,等.数据驱动下考虑多预测误差带信息的多场景随机优化调度[J].电力自动化设备,2024,44(11):52-59.
ZHAO Shuqiang, ZHAO Pengfei, WEI Ziyu, et al. Multi-scenario stochastic optimal scheduling considering multi-prediction error band information under data-driven[J]. Electric Power Automation Equipment, 2024, 44(11): 52-59.

[18] CHENG L L, ZANG H X, XU Y, et al. Probabilistic residential load forecasting based on micrometeorological data and customer consumption pattern[J]. IEEE Transactions on Power Systems, 2021, 36(4): 3762-3775.

[19] CHENG L L, ZANG H X, WEI Z N, et al. Short-term solar power prediction learning directly from satellite images with regions of interest [J]. IEEE Transactions on Sustainable Energy, 2022, 13(1): 629-639.

[20] 巨云涛,康晓帆,刘文武,等.基于分布鲁棒优化的分布式配-微协同日前调度方法[J].电力系统自动化,2024,48(20):48-58.
JU Yuntao, KANG Xiaofan, LIU Wenwu, et al. Distributed coordinated day-ahead scheduling method for distribution network and microgrid based on distributionally robust optimization[J]. Automation of Electric Power Systems, 2024, 48(20): 48-58.

[21] ZHANG L, CHEN Y Z, ZHANG B S. A convex neural network solver for DCOPF with generalization guarantees[J]. IEEE Transactions on Control of Network Systems, 2021, 9(2): 719-730.

[22] HUANG W J, PAN X, CHEN M H, et al. DeepOPF-V: solving AC-OPF problems efficiently[J]. IEEE Transactions on Power Systems, 2022, 37(1): 800-803.

[23] PAN X, CHEN M H, ZHAO T Y, et al. DeepOPF: a feasibility-optimized deep neural network approach for AC optimal power flow problems [J]. IEEE Systems Journal, 2023, 17(1): 673-683.

[24] JIA Y J, BAI X Q, ZHENG L Q, et al. ConvOPF-DOP: a data-driven method for solving AC-OPF based on CNN considering different operation patterns[J]. IEEE Transactions on Power Systems, 2023, 38(1): 853-860.

[25] 卫志农,徐昊,陈胜,等.基于深度学习的直流配电网分布鲁棒优化调度方法[J].电力自动化设备,2023,43(10):87-94.
WEI Zhinong, XU Hao, CHEN Sheng, et al. Distributionally robust optimal dispatching method of DC distribution network based on deep learning [J]. Electric Power Automation Equipment, 2023, 43(10): 87-94.

[26] 陈远扬,谭益,李勇.融合深度神经网络的电力系统经济-环保随机调度方法[J].电网技术,2025,49(5):1993-2003.
CHEN Yuanyang, TAN Yi, LI Yong. Power system stochastic economic-environmental dispatch method integrated with deep neural networks [J]. Power System Technology, 2025, 49(5): 1993-2003.

[27] VERGARA P P, LÓPEZ J C, RIDER M J, et al. Optimal operation of unbalanced three-phase islanded droop-based microgrids[J]. IEEE Transactions on Smart Grid, 2017, 10(1): 928-940.

[28] 吕闫,李理,孙略,等.基于抽样概率区间修正的典型源荷时序场景生成方法[J].电力系统自动化,2024,48(17):141-150.
LYU Yan, LI Li, SUN Lüe, et al. Typical source-load temporal scenario generation method based on modification of sampling probability interval[J]. Automation of Electric Power

Systems, 2024, 48(17): 141-150.
[29] 要金铭，赵书强，韦子瑜，等.基于场景分析的电力系统日前调度及其快速求解方法[J].电力自动化设备，2022，42(9)：102-110.
YAO Jinming, ZHAO Shuqiang, WEI Ziyu, et al. Day-ahead dispatch and its fast solution method of power system based on scenario analysis [J]. Electric Power Automation Equipment, 2022, 42(9): 102-110.
[30] 石文超，吕林，高红均，等.考虑需求响应和电动汽车参与的主动配电网经济调度[J].电力系统自动化，2020，44(11)：41-51.
SHI Wenchao, LYU Lin, GAO Hongjun, et al. Economic dispatch of active distribution network with participation of demand response and electric vehicle[J]. Automation of Electric Power Systems, 2020, 44(11): 41-51.
[31] 徐熙林，宋依群，姚良忠，等.主动配电网源-荷-储分布式协调优化运行(一)：基于一致性理论的分布式协调控制系统建模[J].中国电机工程学报，2018，38(10)：2841-2848.
XU Xilin, SONG Yiqun, YAO Liangzhong, et al. Source-load-storage distributed coordinative optimization of AND (part Ⅰ): consensus based distributed coordination system modeling [J]. Proceedings of the CSEE, 2018, 38(10): 2841-2848.
[32] 彭志辉，姜锐，和军平，等.一种新型光伏系统最大功率点跟踪研究[J].太阳能学报，2013，34(6)：991-996.
PENG Zhihui, JIANG Rui, HE Junping, et al. Research on novel maximum-power-point tracking for pv generation system [J]. Acta Energiae Solaris Sinica, 2013, 34(6): 991-996.
[33] 孟晓丽，高君，盛万兴，等.含分布式电源的配电网日前两阶段优化调度模型[J].电网技术，2015，39(5)：1294-1300.
MENG Xiaoli, GAO Jun, SHENG Wanxing, et al. A day-ahead two-stage optimal scheduling model for distribution network containing distributed generations [J]. Power System Technology, 2015, 39(5): 1294-1300.
[34] 郑能，丁晓群，管志成，等.基于场景法的配电网有功-无功协调优化[J].电网技术，2019，43(5)：1640-1651.
ZHENG Neng, DING Xiaoqun, GUAN Zhicheng, et al. Coordinated optimization of active power and reactive power in distribution network based on scenario method [J]. Power System Technology, 2019, 43(5): 1640-1651.

程礼临(1995—)，男，博士，讲师，主要研究方向：电力系统人工智能、新能源发电。E-mail：straw@hhu.edu.cn

罗子杰(2000—)，男，硕士研究生，主要研究方向：电力系统人工智能、基于数据驱动的配电网优化。E-mail：231606030034@hhu.edu.cn

李　群(1967—)，男，博士，研究员级高级工程师，主要研究方向：大电网安全稳定分析与控制、新能源发电技术。E-mail：qun_li@sina.com

臧海祥(1986—)，男，通信作者，教授，博士生导师，主要研究方向：电力系统规划与运行分析、新能源发电技术、人工智能在电力系统中的应用。E-mail：zanghaixiang@hhu.edu.cn

（编辑　冯慧敏）

Real-time Stochastic Dispatch Method for Active Distribution Network Using Fuzzy Neural Network Pre-decision

CHENG Lilin[1], *LUO Zijie*[1], *LI Qun*[2], *ZHANG Ningyu*[2], *LI Yaran*[2], *ZANG Haixiang*[1]
(1. School of Electrical and Power Engineering, Hohai University, Nanjing 211100, China;
2. Electric Power Research Institute of State Grid Jiangsu Electric Power Co., Ltd., Nanjing 211103, China)

Abstract: With the large-scale integration of distributed resources into the active distribution network, internal uncertainties of the active distribution network increase. To establish an accurate dispatch model, the uncertainty of photovoltaic output and the randomness of load are described as the uncertainty of corresponding prediction errors, and the probability distribution of uncertain variables is obtained through data-driven methods. Considering that the power flow model based on second-order cone relaxation (SOCR) may violate relaxation constraints and introduce errors, the power flow model is re-derived based on the Euler equations, thereby further establishing a stochastic optimal power dispatch model for active distribution networks that is both economical and secure. Aiming at the characteristics of the proposed model, this paper presents a real-time stochastic dispatch method for active distribution networks using fuzzy neural network (FNN) pre-decision. First, the FNN is employed to provide a fuzzy description of the probability distribution of uncertain variables, and its output is used as the initial value for solver optimization. Then, the solver is utilized to accelerate the solution process. Finally, the effectiveness of the proposed model and method is validated through a modified IEEE 33-bus system.

This work is supported by State Grid Corporation of China (No. 4000-202418061A-1-1-ZN).

Key words: active distribution network; real-time stochastic dispatch; data-driven; power flow; fuzzy neural network; uncertainty