生成式人工智能与量子计算时代下一代网络的单目标与多目标随机优化

Trinh Van Chien，*IEEE*会员，Bui Trong Duc、Nguyen Xuan Tung、Van Duc Nguyen、Waqas Khalid，*IEEE*会员，Symeon Chatzinotas，*IEEE*会士，以及Lajos Hanzo，*IEEE*终身会士

arXiv:2601.02175v1 [cs.IT] 5 Jan 2026

摘要——**下一代（NG）网络不再只是连接设备，而是致力于构建互联智能生态系统，生成式人工智能（AI）和量子计算为此提供了有力支持。预计这些系统将能够应对大规模部署和高密度网络，并支持多种功能。因此，人们越来越需要能够在传播环境和网络系统的不确定性下运行的高效智能算法。传统优化方法往往依赖准确的数据传输理论模型，但在真实的下一代网络场景中，这些方法在大规模环境下会面临较高的计算复杂度。随机优化（SO）算法专为适应极高密度和大规模网络可扩展性而设计，已成为优化无线网络的有效方案。这类算法涵盖多种类别，从基于模型的方法到基于学习的方法。这些技术能够在可行的时间范围内收敛，同时解决复杂的大规模优化问题。然而，目前关于将随机优化应用于下一代网络的研究仍然有限，尤其是面向即将到来的第六代（6G）网络。在这篇综述中，我们通过八个开放性问题，探讨下一代系统与随机优化之间的关系，涉及背景、关键特征和经验教训。总体而言，我们首先详细概述这两个领域，涵盖基础且广泛应用的随机优化技术，范围从单目标到多目标信号处理。接下来，我们探讨不同算法如何解决下一代网络面临的挑战，例如负载均衡、能效优化、提升频谱效率，或处理多个性能权衡。最后，我们指出当前研究面临的挑战，并为未来研究提出新的方向。**

索引词—**下一代网络、随机优化、生成式人工智能、量子计算（QC）。**

术语表

缩略语定义

5G 第五代移动通信 6G 第六代移动通信 ABC 人工蜂群算法 ACO 蚁群优化 AI 人工智能 ANN 人工神经网络 AoI 信息年龄 AUV 自主水下航行器

Trinh Van Chien 和 Bui Trong Duc 任职于越南河内河内国立大学信息与通信技术学院，邮编 100000。（电子邮箱：chientv@soict.hust.edu.vn、duc.buitrong@hust.edu.vn）。

Nguyen Xuan Tung 任职于 PHENIKAA大学跨学科数字技术学院，地址：越南河内市河东郡Yen Nghia，邮编 12116（电子邮箱：tung.nguyenxuan@phenikaa-uni.edu.vn）。

Van Duc Nguyen 任职于越南河内 100000 的河内科学技术大学电气与电子工程学院（电子邮箱：duc.nguyenvan1@hust.edu.vn）。

Waqas Khalid 任职于韩国世宗 30019 的高丽大学工业技术研究所。（电子邮箱：waqas283@gmail.com）。

Symeon Chatzinotas 任职于卢森堡 L-1855 卢森堡大学跨学科安全、可靠性与信任中心（SnT）。（电子邮箱：symeon.chatzinotas@uni.lu）。

Lajos Hanzo 任职于英国南安普顿大学电子与计算机科学学院，地址为英国南安普顿 SO17 1BJ（电子邮箱：lh@ecs.soton.ac.uk）。

AWGN	加性白高斯噪声
BCD	块坐标下降
BSs	基站
CPU	中央处理器
DDPG	深度确定性策略梯度
DDQN	双重深度Q网络
DE	差分进化
DNN	深度神经网络
DQN	深度Q网络
DRL	深度强化学习
EA	进化算法
EE	能效
EP	进化编程
ES	进化策略
FL	联邦学习
GA	遗传算法
GP	遗传编程
GPU	图形处理器
GSP	基于遗传模拟退火的粒子群优化
GWO	灰狼优化器
HT-PSO	双曲正切粒子群优化
IoT	物联网
ISAC	一体化感知与通信
KPIs	关键绩效指标
LLM	大语言模型
LMEA	大语言模型驱动的进化算法
LS	局部搜索
LSTM	长短期记忆
MADDPG	多智能体深度确定性策略梯度
MARL	多智能体强化学习
MDP	马尔可夫决策过程
MEC	移动边缘计算
ML	机器学习
毫米波	毫米波
MODE	多目标差分进化
多目标粒子群优化	多目标粒子群优化
多用户多输入多输出	多用户多输入多输出
NFV	网络功能虚拟化
NG	下一代
NISQ	含噪中等规模量子
NOMA	非正交多址接入
NSGA-III	非支配排序遗传算法 III
NSGA-II	非支配排序遗传算法 II
PPO	近端策略优化
PQCs	参数化量子电路
PSD	功率谱密度
PSO	粒子群优化
QA	量子退火
QC	量子计算
QIGA	量子启发式遗传算法
QIM	量子启发式元启发式算法
QoE	体验质量
QoS	服务质量
QRL	量子强化学习
QUBO	二次无约束二元优化
RAN	无线接入网
RE	资源效率
RIS	可重构智能表面
RL	强化学习
SAC	软演员-评论家
SARSA	状态–动作–奖励–状态–动作
SA	模拟退火

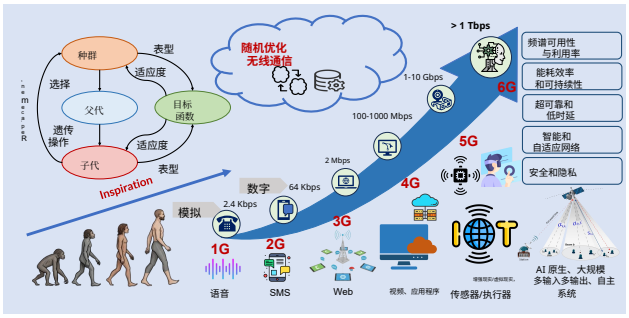

图 1：下一代无线网络与进化算法（EA）的演进。

SDN 软件定义网络 SE 频谱效率 SGD 随机梯度下降 SINR 信号与干扰加噪声比 SI 群体智能 SNR 信噪比 SoA 最先进水平 SO 随机优化 SPSO 球形向量粒子群优化 SWIPT 同时无线信息与功率传输 Tbps 每秒太比特 TS 禁忌搜索 UASNs 水下声传感器网络 UAV 无人机 URLLC 超可靠低时延通信 UUV 无人水下航行器 VQCs 变分量子电路 WSNs 无线传感器网络

I. 引言

鉴于革命性技术的兴起，以及对多媒体内容和数据流量日益增长的依赖，增强当代通信系统的需求也在不断增加 [1], [2]。下一代网络的部署可能会因数据需求的急剧增长而面临挑战，包括需要提高系统容量和移动性，同时仍保持较低的能耗水平[3]。与前几代相比，预计6G将在传输速率、数据容量、可靠性、时延和能效方面实现改进，并增添互联智能等特性 [2]。在下一代通信中，峰值数据速率预计将达到每秒太比特（Tbps）级别[4]。下一代网络还预计将显著提升容量，从而支持更多无线电设备和应用的连接 [5], [6]。在时延方面，预计6G网络将通过将传输时延降低至1毫秒以下而超越第五代移动通信（5G） [3], , 这将支持自动驾驶汽车、远程手术和智慧城市技术等需要近实时响应和高精度的新应用[7]。下一代网络架构预计将促进先进技术的发展，包括天地空海一体化通信和云端解决方案。在下一代海事网络中，无人水下航行器（UUV）、浮标和船舶等水下设备可能利用声学链路与水面节点和空中中继建立连接。这种融合将实现实时海洋监测、自适应自主水下航行器（AUV）群体，以及覆盖海洋、空中和太空的扩展覆盖等新服务。该网络将构建高度可扩展、无缝且广泛的连通性。此外，通过引入太赫兹、可见光和免许可频段，该架构将支持蓝色全范围的频率，以实现更优的性能。其他关键创新，包括量子通信和大规模多用户多输入多输出（MU-MIMO）通信，也正在推动下一代网络的演化 [8]。

未来移动技术的进步有望支持更可靠的连接，并改善偏远地区的覆盖，即使传播条件恶劣也是如此。更高的可靠性对于关键应急服务、工业自动化和医疗保健至关重要。此外，下一代系统预计将比前几代更加节能，旨在减少碳足迹 [9], , 以应对无线接入需求高涨的局面 [10]。许多挑战亟待探索，例如资源分配、频谱管理和网络安全。因此，有效的优化技术对于下一代网络至关重要。这些技术包括数学建模、强大的算法，以及用于寻找最优解集的具体措施。凸优化问题具有数学性质，因此可借助成熟的方法和现有求解器获得最优解。然而，现实世界中的优化问题往往具有非凸性，因此难以保证获得全局最优解。

A. 下一代网络中的随机优化

机器学习、深度学习和博弈论等多种强大的基于学习的方法 [11], 已被证明能够应对这些非凸挑战。在许多场景中，例如大规模物联网网络 [12],、大规模多用户大规模多输入多输出系统或可重构智能表面辅助通信，问题会变得极其复杂，呈现出多个局部最优解和不可微的目标函数。此外，现实环境具有动态性，这意味着最优解必须迅速适应流量模式、干扰水平和资源可用性的变化。现有许多种类繁多的优化算法并不需要此类数据。然而，在处理大规模多目标问题时，这些优化求解器往往会变得过于复杂。因此，实时决策更具挑战性，也不太适用于对时间敏感的场景。在这些情况下，研究人员通常倾向于采用启发式算法，因为这类算法计算复杂度低，能够以适中的复杂度找到次优解。

作为人工智能领域一部分的随机优化算法，因能够以计算上可行的方式提供高质量解，同时保持鲁棒性并确保收敛，而在研究中日益受到关注。如图 1 所示，这些算法相较于传统方法具有多项优势，并且与无线网络代际的演进十分契合。它们易于实现，有助于实现全局优化，能够解决多种多样的问题、处理约束，并支持高效的并行处理。许多算法受到自然过程的启发，并以进化算法和群体智能的广泛原理为基础。这些算法往往取法自然，借鉴生物学、物理学或动物行为等领域。它们具有随机性，包含随机因素，通常还包含需要针对具体问题调整的参数。进化算法利用交叉和变异等遗传技术模拟自然选择，逐步改进解。另一方面，基于群体的方法从群居动物的集体行为中汲取灵感，以应对优化挑战。随机优化方法通常需要通过试错来选择合适的算法参数，例如种群规模、变异率、惯性权重，以及

这些参数的调优过程可能会显著影响性能。然而，与许多依赖大型训练数据集和大量训练时间的人工智能技术不同，随机方法通常更加轻量且不依赖数据，因此在资源受限场景或实时优化场景中更为实用。

B. 我们的主要贡献

下一代无线技术、生成式人工智能和量子计算的兴起，既带来了机遇，也带来了重大挑战。深入回顾下一代网络资源分配随机优化领域的最新进展，并应对安全和隐私方面的顾虑，至关重要。我们对最新随机优化技术及其在下一代通信中的作用，以及它们在解决现实问题中的应用进行了批判性评估。我们介绍了一系列强大的算法和实际应用场景。此外，我们还重点指出现有的研究挑战，并提出未来研究方向，从而为专注于下一代系统随机优化的研究人员提供参考。我们的主要贡献围绕以下八个开放性问题和未来研究方向展开：

- 我们清晰阐释了下一代网络随机特征的基础知识、定义、分类和应用，以及随机算法，并探讨了其中几种值得关注的算法。
- 我们提供了设计指南，说明如何应用随机优化技术来应对下一代网络资源分配、安全和隐私方面的挑战。
- 我们重点介绍了关键挑战，并为该领域未来的研究与开发提出了潜在方向。此外，我们还对随机优化算法与传统的确定性优化技术（例如块坐标下降（BCD））进行了批判性比较，以阐明它们各自的优缺点。
- 最后，我们在表 I 中详细比较了本研究与该领域最新研究成果。我们讨论了一系列尚待解决的问题、挑战，以及面向 NG 网络资源分配的随机优化设计指南。

本文的结构如图 2 所示，全面概述了当前 NG 无线系统中随机优化算法的研究。第二节介绍了 NG 网络的随机特性，并提供了相关背景

用于实现应用于资源分配的优化算法。第三节将详细概述随机优化算法系列。第四节介绍随机优化在下一代网络资源分配中的应用。第五节讨论在生成式人工智能和量子计算时代，随机优化与下一代网络的内在融合。最后，第六节将给出设计指南、要点信息和主要结论。II

. $S_{\text{随机}}$ $P_{\text{性质}}$ & RADIO $R_{\text{资源}}$
下一代网络的资源分配

本节介绍下一代无线网络固有的随机性。在随机条件下，资源分配问题应以能够考虑影响系统性能的随机因素的方式进行建模和求解。

开放性问题一：哪些特征促成了下一代网络的随机性？

1) 背景：在下一代系统中，随机特性表明，网络性能会受到各种不确定性来源的影响

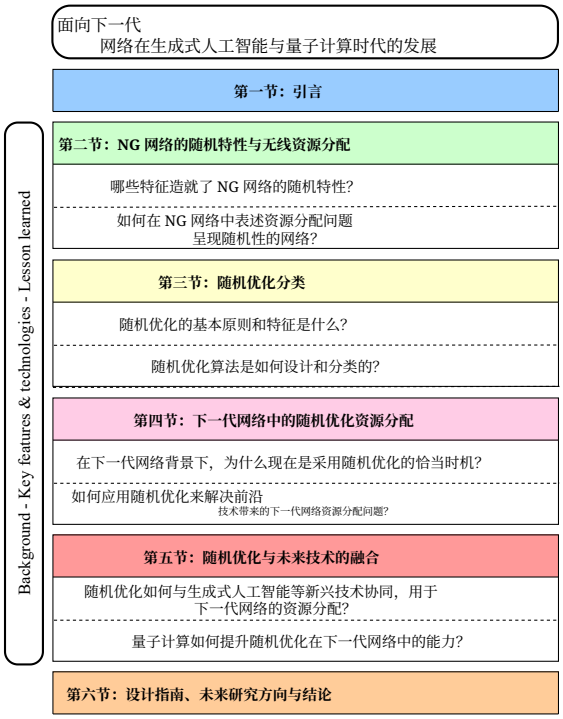

图2：教程和综述的主要内容

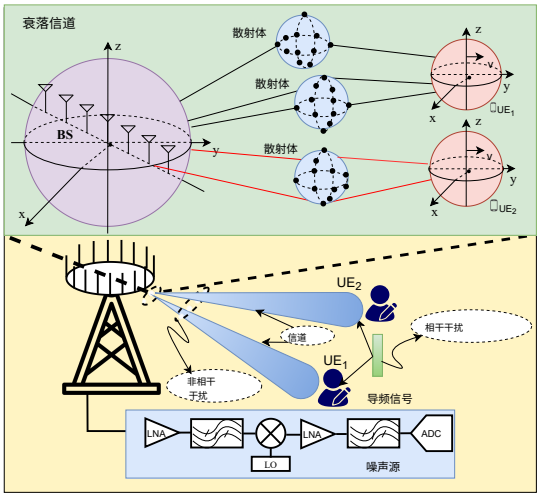

图3：下一代无线网络中随机特征的来源：信道衰落、噪声和相互干扰。

这些不确定性源自随机传播条件、噪声与干扰，以及用户动态移动性 [25]。在典型传播环境中，这些不确定性可能无法完全消除。因此，在设计和管理无线电资源时，相同的输入条件可能会导致不同的解决方案和策略 [26]。这一随机特性挑战了传统网络的乐观确定性假设，因此需要进行概率建模 [27]。请注意，不确定性可能遵循多种概率分布 [28]。用户移动性会使信道脉冲响应随时间变化，从而以不可预测的方式影响系统性能 [29], [30]。来自附近用户的噪声和相互干扰，以及剧烈的接收信号波动，会进一步加剧其非确定性特征 [31]。

2) 关键特征与考量因素：我们介绍下一代无线通信具有随机性的主要原因及相关数学建模，如图 3 所示：

Tabl表 I：不同近期综述中系统与随机优化主题的比较 s.

参考文献		[13]	[14]	[15]	[16]	[17]	[18]	[19]	[20]	[21]	[22]	[23]	[24]	**Our**
年份		2020	2021年	2021年	2022年	2023年	2023年	2024年	2024年	2024年	2025年	2025年	2025年	2026年
目标	单一			✓	✓	✓	✓		✓	✓	✓	✓	✓	✓
	多个	✓	✓		✓	✓	✓	✓	✓	✓	✓	✓	✓	✓
优化	基于局部搜索的算法	✓		✓		✓	✓		✓	✓				✓
	EAs	✓	✓		✓	✓	✓	✓	✓	✓				✓
	SI	✓	✓	✓	✓	✓	✓	✓	✓	✓			✓	✓
	协作式协同进化算法			✓	✓									✓
	强化学习（RL）	✓	✓	✓	✓	✓	✓		✓	✓	✓	✓	✓	✓
	混合算法		✓	✓	✓		✓	✓	✓	✓		✓		✓
应用场景	RIS			✓		✓	✓		✓	✓	✓	✓		✓
	大规模多用户多输入多输出			✓	✓	✓	✓		✓	✓	✓	✓		✓
	卫星			✓	✓	✓			✓	✓	✓	✓	✓	✓
	无人机	✓		✓	✓	✓	✓		✓	✓	✓	✓	✓	✓
	感知与通信	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓
	边缘计算	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓	✓
	水下通信			✓						✓	✓	✓		✓
	QC			✓	✓				✓	✓	✓			✓
	大语言模型（大语言模型）											✓	✓	✓

i）噪声本质上源于接收机中电子的布朗运动，如图 3 所示。这在各种通信环境中带来了多方面的挑战，包括太空、地面和水下[32]。宇宙辐射、大气条件和硬件损伤会加剧卫星通信中的性能退化 [33]。基于无人机的通信会因放大器、混频器、振动，以及电机和螺旋桨产生的电磁辐射而引入额外噪声[34]。地面下一代系统可能运行于毫米波和太赫兹频段，并因带宽极高而遭受严重的热噪声影响 [35]。这些噪声源可用具有平坦功率谱密度（PSD）的加性白高斯噪声（AWGN）分布建模 [36]。在下一代网络中纳入水下声通信会引入非白（有色）噪声，其成因包括海洋生物、水体运动和航运。水下噪声的功率谱密度会随频率波动[37]。请注意，必须设计并优化低噪声放大器、数字滤波器和稳健的噪声抑制算法，以减轻噪声影响，从而提高信噪比（SNR） [38]。然而，由于有色噪声的功率取决于频率，抑制它需要付出额外努力，且成效取决于能否准确估计其频谱形状[37]。

ii) 衰落信道会受到时域和频域中随机物理现象的影响 [39]。这些现象包括多径传播：信号被建筑物、地形或其他物体反射（如图 3 中的散射体所建模），从而造成时变时延和相位 [40]。由于传播环境的确切位置和属性未知或不断变化，传输信号的变化通常采用统计方法建模 [41]。发射机、接收机或附近物体的移动会引入多普勒频移，并使信道特性迅速变化 [42]。不规则表面的散射和反射会进一步增加接收信号的随机性，如图 3 所示。该现象的技术细节将依据文献 [43]提出的基于几何的随机模型进行讨论。天气、温度和障碍物等环境因素，也会不可预测地变化，进一步凸显了概率建模的必要性。因此，所谓的频率平坦衰落通常采用准静态模型来描述 [44]。在卫星通信中，对流层闪烁在较高频率（如 Ka波段）下更为显著，并且温度和压力波动所引起的湍流涡旋也会造成额外的性能劣化 [45]。空间通信也日益受到低地球轨道（LEO）中的动态频移、卫星结构造成的自遮蔽，以及气候变率和密集星座导致的加剧雨衰的影响 [46]，[47]。在水下环境中，温度和盐度波动、表面气泡云以及自主车辆的运动会形成复杂的时变多径和多普勒引起的衰落[48]。此外，人造水下结构和生物活动也会导致频率选择性衰落。

iv) 相互干扰是指在相同或相邻频段运行的发射机之间发生的不必要交互，尤其是在多个设备同时传输时，会进一步降低信号质量和可靠性 [49]。相互干扰在密集的下一代网络中尤为关键，例如具有有限共享带宽的无蜂窝网络和机器型通信网络 [50]。当干扰信号与期望信号具有一致的相位关系时，便会产生相干干扰，这通常是由同步信号源或同一信号的反射造成的，并会严重影响信号完整性。在下一代网络中，导频污染是一项关键挑战：相同或高度相关的非正交导频信号在多个小区间重复使用，导致信道估计过程中出现高度相干的干扰，从而降低系统性能[51]。另一方面，非相干干扰源于与期望信号在相位或调制方面几乎完全不相关的信号源。这类干扰通常表现为随机噪声，因此常被建模为加性白高斯噪声。前沿的下一代技术通常致力于通过动态控制传播路径的出现与消失、采用智能导频分配，以及在用户附近部署分布式天线，来减轻相干和非相干干扰 [52]。此外，基于学习的干扰预测

以及可重构频谱接入技术已被开发出来，用于管理高动态网络环境中的干扰[53]。

3）经验教训：下一代网络固有的随机性由设备移动性以及随时间和频率变化的信道条件所致，给评估系统效率和实施有效的资源管理带来了重大挑战。多个来源的不可预测性促使我们观察多个连续相干区间内的平均系统性能，并考察小尺度衰落系数的多次实现以及设备位置。随机性特征也使频谱、功率和计算能力等关键资源的优化变得更加复杂。传统的确定性分配方案往往无法应对这些不确定性，导致系统性能欠佳，服务质量（QoS）保障受损。此外，为满足条件各异的异构应用需求，随机条件下的资源分配复杂度进一步增加。

开放问题二：具有随机特性的下一代网络中，如何对资源分配问题进行建模？

1）背景：资源分配被视为提升下一代系统效率的关键方法，可用于应对无线电资源有限且存在随机行为的情况，[54]。这涉及在网络中的不同用户及其设备之间合理分配资源。其主要目标是在满足设备多种需求的同时最大限度地提升性能，例如吞吐量、频谱效率和能效等。此外，为了在严苛的网络条件和用户需求下实现实时部署，还需要高性能、低复杂度且节能的算法。将优化技术融入下一代无线系统，旨在实现敏捷的资源分配，从而通过更智能、更具适应性的管理来满足关键绩效指标（KPIs） [55]。

2）关键特征和考量因素：优化问题是一种数学建模，旨在根据特定准则 [56]，从一组可行方案中找出最佳解。它涉及在满足某些约束的条件下，最大化或最小化一个或多个目标函数
定义可行域的约束集合。

预备知识： 为了对各种算法类别及其应用进行批判性评估，我们首先从最大化形式出发，构建一个一般的单目标优化问题，即

$$\begin{aligned} \underset{\mathbf{s}\in\mathcal{D}}{\text{maximization}} \quad & f_0(\mathbf{s}) \\ \text{subject to} \quad & f_i(\mathbf{s}) \le 0, \quad i = 1, 2, \ldots, m, \\ & h_j(\mathbf{s}) = 0, \quad j = 1, 2, \ldots, r, \end{aligned} \tag{1}$$

其中，$\mathbf{s} = [s_1, \ldots, s_N]^T$包含 N优化变量；集合 $\mathcal{D}$ 定义了该优化问题的可行域；$f_0(\mathbf{s})$称为目标函数，也称为代价函数或适应度函数；集合 $\{f_i(\mathbf{s})\}_{i=1}^m$ 和 $\{h_j(\mathbf{s})\}_{j=1}^r$分别表示不等式约束和等式约束。需要强调的是，目标函数和约束包含了下一代无线网络的随机特征，例如大尺度和小尺度衰落效应 [57]。因此，在实际应用中，可行集 $\mathcal{D}$ 未必总是显式定义的，但可以通过预言机（例如用户提供的软件工具）确定。$\mathbf{s}$中的优化变量

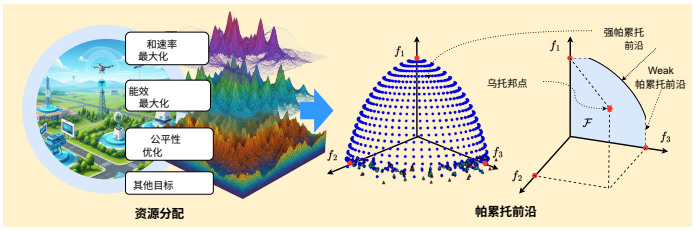

图 4：相互冲突的目标函数促成多目标优化问题。

如果$\mathbf{s} \in \mathcal{D}$ 并满足所有给定的不等式和等式约束，则被视为可行。若$\mathbf{s}_{\text{best}}$ 满足 $f_0(\mathbf{s}_{\text{best}}) \le f_0(s)\ \forall \mathbf{s} \in \mathcal{D}$，则该解是全局最优解。相反，若存在一个较小的正数$\epsilon > 0$，使得 $f_0(\bar{\mathbf{s}}) \le f_0(\mathbf{s})\ \forall \mathbf{s} \in \mathcal{D}$ 满足 $\|\mathbf{s} - \bar{\mathbf{s}}\| \le \epsilon$，则可行向量 $\bar{\mathbf{s}}$ 是局部最优解。优化问题通常可分为凸问题和非凸问题，各自需要采用不同的求解方法 [58]。凸优化是在满足凸约束的条件下最大化凸目标函数。这些技术在工程应用中发挥着关键作用，因为在凸问题中，任何局部最优解同时也是全局最优解 [24]。

在下一代网络中，我们通常有多个目标f_{01}（s）.....， f_{0M}（s），其中 M 为目标的数量。一个基本假设是，这些 M 目标彼此无序，因此在不带偏见或预设偏好的情况下进行分析，从而能够考虑所有可能的结果。我们可能希望同时最大化这些 M 目标，即

$$\begin{aligned} \underset{\mathbf{s}\in\mathcal{D}}{\text{maximization}} \quad & \mathbf{f}_0(\mathbf{s}) = [f_{01}(\mathbf{s}), \ldots, f_{0M}(\mathbf{s})]^T \\ \text{subject to} \quad & f_i(\mathbf{s}) \le 0, \quad i = 1, 2, \ldots, m, \\ & h_j(\mathbf{s}) = 0, \quad j = 1, 2, \ldots, r, \end{aligned} \tag{2}$$

其中，粗体记号$\mathbf{f}_0(\mathbf{s})$强调了目标函数的向量值性质。(2)中的 M 目标本质上相互冲突；由于向量值目标之间不存在排序，通常不存在全局最优解。由于只能得到主观意义上的最优解，因此无法从全局最优的意义上求解多目标问题(2)。我们将可达目标集记为$\mathcal{F} = \{\mathbf{f}_0(\mathbf{s}) : \mathbf{s} \in \mathcal{D}\}$，其中包含了目标值的所有可能取值。集合 $\mathcal{F}$ 通常是紧致的，即$\mathbf{f}_0 \in \mathcal{F}$ 会导出 $\alpha\mathbf{f}_0 \in \mathcal{F}, \forall \alpha \in [0, 1]$。集合 $\mathcal{F}$ 中的大多数点都是严格劣解；具体而言，位于 $\mathcal{F}$ 内部的任何点都可以排除，因为 $\mathcal{F}$ 中存在其他点，在所有 M 目标上均优于该点。就所有目标而言都无法被超越的点构成帕累托边界，其示意见图 4。帕累托边界上的任何解都无法在不损害至少一个其他目标的情况下得到改进。

定义 1. 强帕累托边界由所有满足以下条件的点组成：$\tilde{}$属于$\mathbf{f}_0 \in \mathcal{F}$，且不存在可行点$\mathbf{f} \in \mathcal{F} \setminus \{\mathbf{f}_0\}$ 满足 $\tilde{f}_{0m} \ge f_{0m}, \forall m \in \{1, \ldots, M\}$。

强帕累托边界由所有无法从目标角度排除的可行点构成，因为改善任一目标必然会使至少一个其他目标恶化。显然，任何不位于强帕累托边界上的点都是次优的，因为存在其他点在所有目标上都优于或至少同样有效。在多目标优化中，强帕累托边界代表了对全局最优性的最接近逼近。

强帕累托边界是 $\mathcal{F}$上边界的子集。完整的上边界称为弱帕累托边界，也包括这样一些点：可以改善某些（但非全部）目标，而不损害其他目标。乌托邦点定义为$\mathbf{s}_{\text{utopia}} = [\max_{\mathbf{s}\in\mathcal{D}} f_{01}(\mathbf{s}) \ldots, \max_{\mathbf{s}\in\mathcal{D}} f_{0M}(\mathbf{s})]^T$，它同时最大化所有 M 目标，图4展示了一个具有代表性的简单示例。如果$\mathbf{s}_{\text{utopia}} \in \mathcal{F}$，那么多目标优化问题就是平凡的，因为强帕累托边界就是乌托邦点，也就是全局最优解。在NG网络中，具有多个冲突目标的多目标优化问题并非易解，而且当$\mathbf{s}_{\text{utopia}} \notin \mathcal{F}$时，全局最优解并不存在。由于帕累托边界包含所有潜在的最优工作点，因此网络应进行优化，以表征这些点。

定义 2. 如果可行点 $\mathbf{s}^* \in \mathcal{D}$ 满足 $\mathbf{f}_0(\mathbf{s}^*)$ 属于强帕累托边界，则该点为帕累托最优点。

我们强调，在 $\mathcal{D}$ 中，多个可行点可能对应完全相同的目标点，因此多目标函数并非双目标函数。下一代网络的设计预计需要应对随机性带来的非凸非光滑优化问题。

关键特征与当代问题：例如，可利用凸优化来最小化总功耗，同时确保收敛到唯一的全局最优解。这确定了最优功率分配策略，同时满足每个接收机 [59] 的特定信干噪比（SINR）阈值。现代系统的进步显著改变了系统设计背后的数学优化问题。这些变化带来了重大挑战，使得理解、分析和求解这些优化问题变得更加困难。许多单目标和多目标优化问题都很复杂，通常具有非凸性和非确定性 [60]。此外，设计变量的类型可能差异很大，从连续型到整数型，甚至混合型。这些新兴的复杂性推动了先进优化理论、算法和技术的发展，以改进次优解，并引导其趋近全局最优解 [61]。

非凸问题会带来额外的困难，因为它们可能无法收敛到单个全局最优解。相反，由于无线网络固有的非线性动态特性，它们通常会出现多个局部最优 [62]。这进一步增加了优化过程的复杂性，需要采用专门技术来有效探索复杂的解空间。为解决非凸问题而设计的传统算法通常会消耗大量资源，计算成本也很高。它们通常依赖通过凸形式进行迭代近似 [63]。另一种方法是将原问题分解为更小、更易处理的子问题，例如采用块坐标下降 [64]。尽管这些方法应用广泛，但仍存在固有局限，包括收敛速度慢、计算复杂度高，以及无法保证全局最优性。因此，近似方法应运而生，成为一种实用的替代方案，能够在合理的时间内提供高质量解[65]。非凸问题常见于导频分配 [66] 或波束成形设计 [67],等优化任务，其中目标函数是其参数的复杂非线性函数。

在小规模优化问题领域，穷举（或蛮力）搜索算法能够解决非凸和确定性问题，因为它们可以系统地探索所有可能的解。这些方法通过评估每个可行选项，确保找到最优解，因此尤其适用于能够可靠识别全局最优解的优化问题 [68]。例如，蛮力算法可以与通用求解器结合，用于解决确定性优化问题；尽管计算成本会随着网络规模呈指数级增长，这种方法仍能给出准确结果 [69]。更具体地说，这些算法的效率受问题规模限制，因此不适用于复杂的大规模场景。正因如此，传统穷举搜索方法由于计算成本过高、时间需求过大而不切实际。此外，正如权威研究所指出的，许多下一代无线网络的优化问题都是 NP难问题 [21] ，且运行于不确定环境中 [70]–[72]。因此，穷举搜索算法面临显著局限，必须采用随机算法。这些随机方法对于高效应对下一代系统动态、多变且异构的特性至关重要，而这类系统预计将支持大规模超高密度网络。正如 [73], 中的框架所示，专为协同管理、拥塞控制和调度而设计的随机算法可以轻松提升 NG网络性能。这种方法旨在通过整合多层优化策略来提高网络效率并降低时延，同时最大化网络效用并采用 SO方法。这些特性有助于动态网络快速收敛并实现长期优化。同样，分布式机器学习技术通常依赖 SO，在大规模优化领域也颇受欢迎，能够提供近最优性能和较高的计算效率 [11]。

3) 经验教训：在随机特征下进行资源分配会给网络性能带来显著的不确定性。单目标优化技术通常旨在最大化某个特定指标，同时可能需要满足一些约束。在定义明确的场景中，单目标方法往往有效；但在复杂环境中，多个性能准则必须同时满足，这类方法常常无法权衡这些准则之间的取舍。另一方面，多目标优化通过考虑冲突目标，提供了一个更灵活的框架。然而，随机性使帕累托最优解的识别更加困难，因此需要能够动态适应时变条件的鲁棒算法。应对这些挑战对于确保下一代网络高效运行至关重要。

III. 随机优化分类体系

本节通过阐述随机优化的核心原理，概述其基础分类体系。首先，我们说明随机优化区别于确定性方法的基本特征，强调随机性在优化问题建模中的作用（开放问题三）。随后，我们对算法格局进行分类，回顾从基于种群的元启发式方法到学习驱动框架的各种设计方法（开放问题四）。

开放问题三：随机优化的基本原则和特征是什么？

1）背景：SO 指一类将随机性纳入

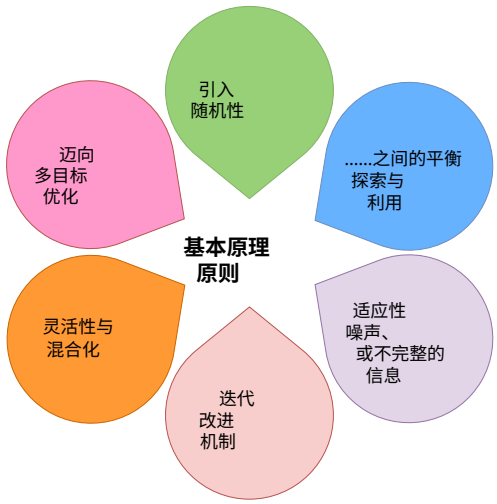

图 5：随机优化的基本原则。

优化过程以解决具有不确定性、噪声或不完整信息等特征问题的数学与计算技术 [74]。对于复杂的非确定性问题，传统确定性优化方法会因存在未知参数或数据而面临挑战，因此这种方法尤为实用 [75]。图 6 展示了不同特征下各类算法的交集，包括元启发式算法、强化学习，以及随机梯度下降（SGD）、近似算法和创新性地结合多种策略的混合方法等。具体而言，元启发式算法是高层策略，能够有效引导搜索过程，高效探索解空间并寻找最优或近似最优解 [76]。这些算法通常分为两类：基于种群的算法会探索多种候选解，以促进全局搜索空间的探索；基于轨迹的算法则沿着单一解路径搜索，侧重于局部细化。相比之下，强化学习是机器学习（ML）的一个分支，专注于训练智能体通过与运行环境交互来进行一系列决策 [77]。智能体旨在通过试错学习最大化累积奖励。强化学习算法分为三类：基于价值的方法、基于策略的方法，以及行动者-评论家/混合方法。由于探索策略和环境的不确定性，这些方法本质上具有随机性。

2）关键特征与考量因素：随机优化依赖于图 5 所示的基本原则，具体阐释如下：

i) 引入随机性。确定性算法从相同的起点出发会产生一致的解，而随机优化会在优化过程的不同阶段引入随机性，例如在解初始化时，或通过迭代更新中的随机扰动来引入随机性 [78]。随机因素会在搜索过程中有意引入扰动，使优化器能够跳转到此前未探索过、可能包含更优解的区域。在复杂的高维景观中，这一机制至关重要，因为通过确定性方法很难避开局部陷阱。此外，随机性还能降低对建模不准确性和噪声观测的敏感度，从而增强鲁棒性；确定性方法则可能受到不完美信息的影响。因此，随机性是使搜索多样化、并让算法在优化过程中持续生成新候选解的关键组成部分[79]。

ii)探索与利用之间的平衡。这种能力在解搜索过程中，需要权衡探索与利用 [80]。探索是指算法考察解空间中多样且此前未访问区域的能力，从而提高发现全局最优解或近似最优解的可能性。相较之下，利用侧重于深入改进已识别出的高质量候选解，以便在有希望的区域实现局部改进并加快收敛。我们强调随机优化（SO）中各因素之间的平衡：过度探索可能导致效率低下和收敛缓慢，而缺乏策略性利用则可能导致过早收敛到局部最优。SO方法会纳入随机机制，在整个优化过程中自适应地调节搜索行为。在元启发式框架中，采用随机变异算子促进探索，而选择和强化机制则引导利用转向有希望的解区域[81]。在强化学习（RL）中，通常采用 ε-贪心或策略梯度方法，通过策略明确管理探索与利用之间的权衡，在学习新策略与利用已知的高奖励动作之间取得平衡 [82]。同样，其他随机算法，例如基于随机梯度的方法和贝叶斯优化，也会纳入概率规则或噪声，以跳出局部最优并促进鲁棒的搜索动态。因此，SO方法的鲁棒性和效率，在很大程度上取决于其能否在不确定性和问题复杂度的影响下，于搜索的不同阶段自适应地平衡探索与利用。

iii) 适应噪声、不确定性或不完整信息。随机优化能够利用自适应机制处理不确定性，因此尤其适用于现实的实际场景。确定性方法通常假设信息完整且准确，而随机优化则依赖概率模型，例如对噪声进行建模、从概率分布中采样，或通过重复试验评估解。这可以减轻异常值或目标评估波动的影响 [74]。某些技术（如蒙特卡洛采样）可使算法随时间形成稳定的解质量估计，从而避免因数据不完整而导致过早收敛 [83]。在进化算法、群体智能和随机梯度方法中，鲁棒性通过随机算子、自适应采样或基于集成的评估融入算法设计。对于强化学习，随机策略和奖励估计器通过从多样化轨迹及可变反馈中学习来提升策略鲁棒性。此外，随机优化往往优先考虑期望性能或风险感知型目标，而非针对单一确定性场景进行优化。这使所得解能够更好地应对未来变化或知识不完整的情况。

iv) 迭代改进机制。SO 通常采用迭代改进机制，逐步逼近最优解 [78], [81]。搜索过程可以从单个解开始，也可以从通过随机化或启发式策略生成的多样化候选解种群开始，以促进无偏探索。在每次迭代中，都会使用目标函数评估候选解，并通过随机扰动、重组或概率选择生成新解。随后利用评估反馈自适应地引导后续更新，使搜索逐渐聚焦于解空间中有希望的区域，同时保持足够的

多样性以避免过早收敛。评估与自适应的循环过程模拟了一种引导式试错方法：表现不佳的解会被改进或舍弃，而较优的解则会被保留并进一步开发。这种迭代优化框架应用于许多著名的元启发式算法。具体而言，遗传算法（GA）通过选择、交叉和变异演化种群，在各代之间平衡探索与开发 [81]。模拟退火（SA）对单个解进行迭代扰动，并采用基于温度的概率函数，在早期接受较差解；随着温度降低，逐渐转向开发 [84]。对于群体智能（SI），粒子群优化（PSO）和蚁群优化（ACO）利用种群层面的动态过程和随机交互，依据个体与集体经验迭代改进候选解 [85]。此外，随机梯度方法和强化学习（RL）会利用环境观测反馈来调整模型参数或策略 [86]。只要运行时间和多样性充足，这些算法的迭代特性便能提高其收敛至最优或近似最优解的可能性；同时，还可根据收敛行为、计算预算或特定应用需求灵活设置停止条件。

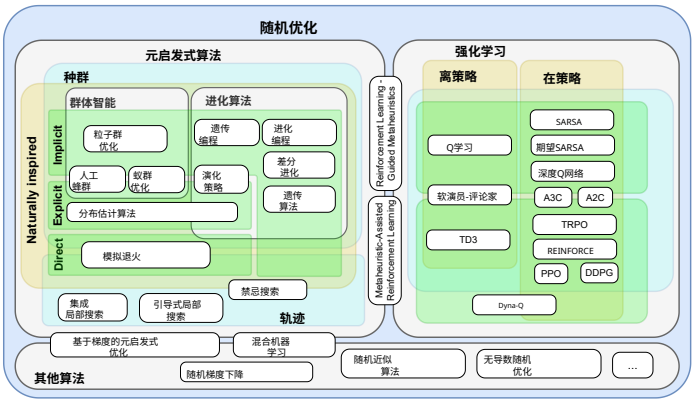

图 6：随机优化的分类。

v)灵活性与混合化。 SO在算法设计和实现方面都展现出高度的灵活性。 这种灵活性源于其与问题无关的模块化结构，使SO能够轻松适应特定领域的需求。SO的关键组件可以进行修改或扩展，而无需改变其核心搜索范式 [76]。此外，还可以调整参数以适应特定的问题特征，同时通过定制算子或初始化策略注入领域知识 [87]。此外，还可以将特定约束无缝地定制并集成到解的评估或生成过程中。我们强调混合化的一项重要扩展，即结合多个优化技术以增强其鲁棒性。将进化算法与局部搜索（LS）或统一的群体智能（SI）技术相结合，可以构建混合元启发式算法，并将其设计为模因

用于解决不同优化问题的算法 [8], [88]。这些混合设计能够平衡全局探索与局部开发，从而提高鲁棒性、收敛速度和解的质量。对于强化学习和机器学习而言，结合元启发式算法与基于梯度的优化的混合技术已成为解决非凸或不可微问题的强大方案。这些方法利用元启发式算法的全局搜索能力，并结合基于梯度的优化或策略学习调整的精确性，通常能够取得更优结果。

vi) 迈向多目标优化。随机优化算法具有很强的适应性，可扩展用于有效解决多目标优化问题。这类问题旨在确定一组帕累托最优解，其中，改善一个目标必然会与其他目标产生权衡 [87]-[89]。这种灵活性使得探索多个相互冲突的目标成为可能。

3）经验教训：对随机优化（SO）的全面研究凸显了这一范式在应对下一代网络中的广泛资源分配挑战方面的巨大潜力。首先，引入随机性能够增强算法抵御噪声和不确定性的鲁棒性，同时提升全局探索能力，从而降低过早收敛的风险。其次，随机优化在探索与利用之间实现了权衡。变异、策略变化和随机采样等机制能够帮助算法有效地遍历复杂的解空间。此外，随机优化对噪声较大、数据不完整的环境所具备的适应性，展现了其在复杂问题上的效率。种群进化、随机扰动和基于强化的更新等迭代机制，在引导算法收敛至最优解方面发挥着关键作用。随机优化的模块化和混合特性使其能够无缝融合领域知识与多种策略，从而提升其在不同问题领域中的性能。此外，随机优化作为一种稳健且有原则的框架，能够应对多目标问题，这体现了其处理冲突目标并生成帕累托最优解的灵活性。

开放问题四：随机优化算法是如何设计和分类的？

1）背景：随机优化算法依据多种标准进行设计和分类，包括搜索策略、对梯度信息的依赖程度以及学习范式。这些算法可分为三大类：1）元启发式算法，2）强化学习，以及 3）其他随机方法，如图 6 所示。每一类都包含针对不同优化挑战的多种原理和机制。根据探索搜索空间的方式，元启发式算法通常分为基于种群的方法和基于轨迹的方法 [90]。基于种群的元启发式算法会同时维护并演化一组候选解。这一类包括模拟自然进化的进化算法，以及受动物群体所表现出的动物群体行为启发的群体智能算法，例如觅食和狩猎行为，如粒子群优化、蚁群优化。另一方面，基于轨迹的元启发式算法通过探索单个候选解的邻域，逐步改进该候选解，其中包括模拟退火 [84],禁忌搜索（TS）[91],以及一系列其他算法。另一方面，元启发式算法也根据搜索类型分为：1）隐式搜索，2）显式搜索，以及 3）直接搜索。隐式搜索方法依赖概率转移或随机选择等间接机制，在不显式计算梯度或方向性移动的情况下探索解空间。相比之下，显式搜索算法利用由启发式方法或学习得到的模型指导的明确定义算子生成候选解。最后，直接搜索算法通过评估采样点处的目标函数值来运行，并仅依据这些值引导搜索，无需导数或概率模型。

强化学习算法主要分为三类：基于价值的方法、基于策略的方法和混合方法。基于价值的强化学习会学习不同状态或状态-动作对的期望回报（价值函数）估计，并通过选择使这些价值最大化的动作来间接得出策略 [92]。基于策略的方法通过参数化函数直接优化策略，通常采用期望回报的梯度上升 [93]。混合方法结合价值学习和策略学习，发挥两者的优势，例如软演员-评论家（SAC）、异步优势演员-评论家（A3C）和优势演员-评论家（A2C） [94]。强化学习还可根据算法与环境的交互方式进一步分类：离策略与在策略，或基于模型与无模型。在策略算法仅从当前正在优化的策略所收集的数据中学习，促成稳定但有时样本效率较低的学习（例如，状态–动作–奖励–状态–动作（SARSA））。离策略方法从不同的行为策略生成的数据中学习，从而提高样本效率，但代价是复杂度增加（例如，Q学习）。基于模型的强化学习采用显式模型或学习得到的环境动态模型来规划或模拟未来状态，从而有望加快学习；而无模型强化学习则完全依赖直接交互。

此外，其他SO方法还包括随机算法，例如：1）随机梯度下降变体，2）随机近似算法，以及3）马尔可夫链蒙特卡罗方法；还包括混合算法，这类算法通常结合元启发式算法与强化学习，从而在噪声较大或复杂的解空间中提供更强的鲁棒性。具体而言，强化学习可用于在元启发式算法框架内初始化解或调整参数，从而提高收敛速度和解的质量。反过来，元启发式算法能够控制超参数，或引导强化学习或机器学习模型中的探索策略，帮助优化器逃离局部最优，或动态适应不断变化的环境。这类协同设计支持更加灵活且具有韧性的优化框架，以应对现实问题中多方面的挑战。

2）关键特征与考量因素：元启发式算法是为解决复杂问题而设计的高层次优化框架

对于非线性、不连续、搜索空间庞大或缺乏梯度信息的问题，传统方法往往难以适用 [90]。元启发式算法通过运用随机算子探索解空间，在计算复杂度高到难以承受时，为穷举搜索提供了一种高效的替代方案 [8], [81]。其有效性很大程度上源于能够平衡探索与利用，从而提高获得高质量近似最优解的可能性。

进化算法的一般框架如图7所示，由两个关键步骤组成：1）繁殖；2）自然选择。繁殖通过基因交叉使有利特征从父代遗传给子代，而变异则引入随机变化，以保持遗传多样性。自然选择确保适应性更强的个体，即更能适应其环境的个体，更有可能存活并传递其特征，而较弱的个体则会逐渐被淘汰。通过模仿这些机制，进化算法在连续多代中迭代提升解的质量，使其成为解决复杂优化问题的强大范式。进化算法的一个核心组成部分是解的表示。每个个体都以针对问题定制的专用结构编码一个候选解，而由多个

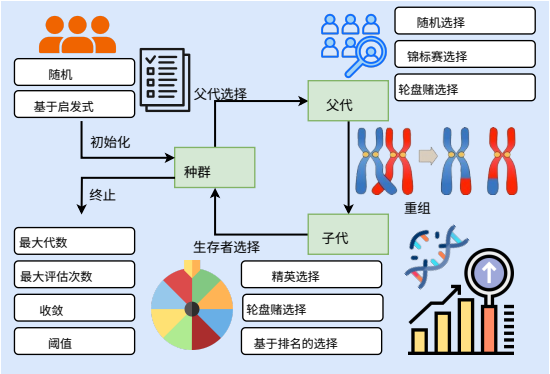

图 7：进化算法的框架。

个体组成种群。这种编码结构称为基因型，经译码后得到相应的表型，可根据问题目标对其进行评估。例如，个体可以编码为用于RIS优化的相移矩阵，译码后得到能够直接提升系统性能的无源波束成形配置 [75]。同样，在无人机使能系统中，个体可以表示飞行计划或轨迹，其中每个基因组编码任务分配或用于协同无人机作业的航路点序列 [80], [95]。

父代选择机制决定选择哪些个体进行繁殖。因此，父代选择通常会偏向适应度较高的个体，以利用有前景的解，同时保留一定程度的随机性，以维持种群多样性。随后，通过交叉和变异等遗传算子创建新解 [96]。交叉将父代的信息结合起来，生成能够继承双方优势特征的子代；变异则引入随机改动，以保持遗传多样性，并探索新的解空间区域。

下一步是生存者选择，由某种策略决定哪些个体能够进入下一代。常见方法包括精英保留策略 [87],，即原样保留最优个体；代际替换，即替换整个种群；以及稳态替换，即仅更新一部分个体。最后，演化过程会持续进行，直至满足特定的终止条件。终止条件可以设定为固定的代数、种群收敛（例如迭代过程中改进幅度很小），或达到预期的适应度阈值。在多目标优化问题中，终止条件还可以取决于帕累托前沿的稳定情况 [97]。

借助进化算法的一般框架，遗传算法继承了个体表示和适应度评估等核心组件，但通过设计更有效的遗传算子和选择机制而脱颖而出。为应对不同的问题结构，人们开发了多种交叉策略：洗牌单点交叉和多点交叉[98]；循环交叉可确保保留较优的亲代信息；顺序交叉和部分匹配交叉广泛应用于基于排列的问题；模拟二进制交叉则已证明对实数表示有效 [99]。变异算子引入随机变异，以防止过早收敛并维持遗传多样性。最常见的形式是针对二进制编码解的位翻转变异，而连续值向量通常采用高斯变异或多项式变异。

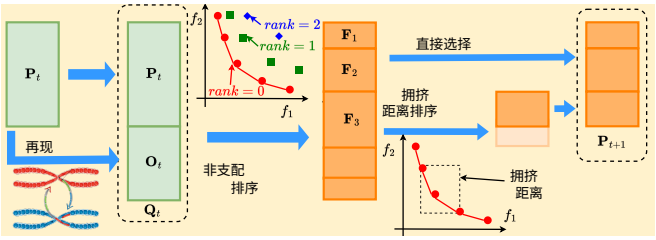

图 8：NSGA-II 流程图。

此外，根据表示方式，还可以设计针对特定问题的交叉算子和变异算子，利用编码的特定结构特征，例如用于虚拟网络功能放置的交换变异和基于交换的变异 [100]。在遗传算法中，子代与父代种群合并，随后通过选择确定下一代的幸存者。

尽管单目标遗传算法广受欢迎，但许多无线通信问题本质上属于多目标问题，需要同时优化相互冲突的准则，因此多目标遗传算法的概念变得不可或缺。基于帕累托的方法，包括非支配排序遗传算法 II (NSGA-II) [101],和非支配排序遗传算法 III (NSGA-III)[102]，，通过整合非支配排序和多样性保持机制扩展了遗传算法，从而高效地逼近帕累托前沿。这些算法会生成一组权衡解。如图 8 所示，标准遗传算法与 NSGA-II 的关键区别在于其幸存者选择策略。不同于仅依据适应度评估个体，父代—子代种群会被划分为多个非支配前沿；优先保留等级较低的前沿，而最后一个可接纳的前沿则使用所谓的拥挤距离度量进行截断，以保持解的多样性。这一机制确保了帕累托前沿在多个目标间均匀分布。然而，当目标数量超过三个时，NSGA-II 往往难以应对，因为拥挤距离在高维空间中保持多样性的效果会下降。为解决这一局限，NSGA-III [102] 引入参考点作为一种多样性保持机制。这些参考点预先设定，或沿目标空间中的归一化超平面自适应生成。在选择过程中，如果最后一个前沿中的个体数量超过种群上限，则根据候选项与这些参考点的接近程度进行选择，从而确保所有目标上的种群多样性。

差分进化（DE） [75] 已成为另一种强大的基于种群的进化算法，尤其适用于连续值优化问题 [75], [103]。DE 通过差分变异过程生成子代，即利用种群中随机选取成员之间的缩放差异扰动现有个体，从而创建新的候选解。现已提出多种常用的变异策略，例如 DE/rand/1、DE/best/1 和 DE/current-to-best/1，它们在探索与利用之间实现了不同的平衡 [104]。DE 的关键优势之一在于其处理实值搜索空间时的简洁性和效率，因为其变异机制能够自然适应问题的尺度，并促进稳健的全局搜索。DE 的另一项显著特征是其选择机制，即 DE 采用一对一比较，每个子代直接与其父代竞争，只有两者中表现更好的个体才能存活并进入下一代。这种有效的贪婪策略确保种群持续改进，同时保持计算效率

多目标差分进化（MODE） [105] 通过整合受帕累托支配和多样性保持启发的选择机制，扩展了差分进化框架。MODE 通过非支配排序评估解，根据帕累托前沿分配等级，并采用拥挤距离或 ϵ-支配等额外的多样性度量，以维持分布均匀的权衡解集合。还可以融入基于参考点的技术，使决策者能够引导搜索朝向帕累托前沿中偏好的区域，同时保留差分进化灵活的变异策略 [106]。一种值得注意的变体通过结合即时父代替换和外部种群档案，进一步增强了这一框架 [107]。如果试验解支配其父代，则直接替换父代以加速收敛，同时将被替换的解存入档案；否则，将试验解存入档案。在每一代中，将当前种群与档案合并，再采用受 NSGA-II 启发的精英保留与多样性保持策略进行截断。这种设计可避免过早丢弃虽被支配但仍有潜在价值的解，从而在收敛压力与多样性保持之间取得平衡，并更有效地探索帕累托前沿 [99]。

除了遗传算法和差分进化，进化算法家族中的其他范式还包括遗传编程、进化策略和进化编程，它们各自具有不同的表示方式和变异机制 [108]。遗传编程对以树结构表示的解进行演化，这些解是计算机程序或符号表达式，能够同时自适应结构和参数。因此，遗传编程尤其适用于符号回归和自动化设计等具有挑战性的任务。相比之下，进化策略主要针对连续值优化而开发，其特点是对变异参数，尤其是步长，进行自适应控制。与遗传算法侧重于重组不同，进化策略主要依赖高斯变异，并采用 $(\mu,\ \lambda)$ 或 $(\mu + \lambda)$ 选择方案来平衡探索与开发，同时动态调整搜索过程。此外，进化编程最初受到人工智能应用的启发，它完全摒弃交叉，并将变异作为唯一的变异算子。其个体通常建模为有限状态机或实值向量，并通过随机扰动与锦标赛选择相结合来推动演化进程。

与进化算法并行，基于种群的元启发式算法的第二大分支是群体智能，其驱动力来自智能体（如粒子、蚂蚁和蜜蜂）的集体行为。具体而言，群体智能利用智能体之间的自组织和局部交互来实现全局问题求解 [89], [109]。智能体交换启发式信息，协同引导优化过程。群体智能的灵感源于鸟群、蚁群和鱼群等自然现象，其本质上是去中心化和自组织的，智能并非来自中央控制器，而是从智能体与其环境之间的分布式交互中涌现出来。在实际运作中，群体系统通常由遵循基本行为规则（如吸引或排斥）并在没有全局知识的情况下进行局部交互的简单智能体构成。尽管每个智能体本身都很简单，但它们的集体交互会产生涌现智能行为，使群体能够执行复杂任务，例如发现最优路径或形成高效的群体

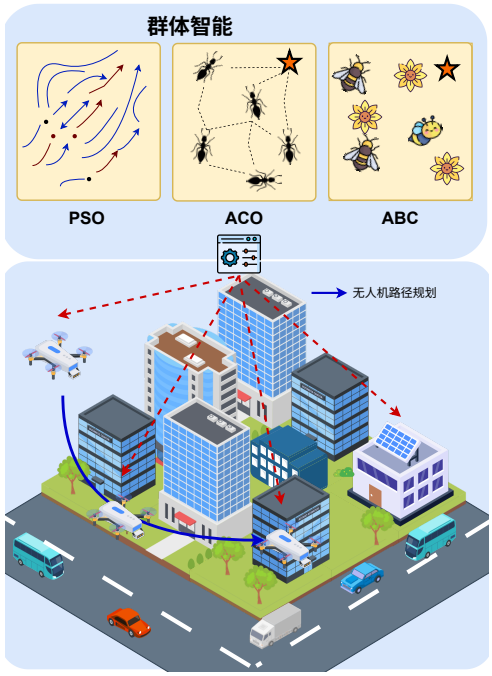

图9：群体智能的应用。

结构。这种自下而上的范式凸显了自组织的力量，并被形式化为种类繁多的算法，例如粒子群优化 [79], 蚁群优化 [89], 和人工蜂群算法（ABC）。这些方法都利用群体的集体行为和局部交互，解决不同领域中的各种优化问题。

粒子群优化（PSO）将候选解表示为粒子，粒子依据个体最优经验以及其他粒子分享的信息在搜索空间中移动 [79], [109]。位置更新由速度方程控制，这些方程结合了惯性、认知分量和社会分量，从而在探索与利用之间取得平衡。为改善粒子群优化的收敛表现、降低停滞风险，人们提出了多种扩展方法。与排序粒子相结合的混合范式通过整合多样化的搜索策略来提升优化性能；自适应方案则会在各次迭代中动态调整范式比率和收缩系数，以平衡探索与利用。完全信息搜索策略将每一代中的全局最优解信息纳入考量，并通过鼓励算法摆脱局部最优，进一步缓解过早收敛问题 [79]。此外，已有研究提出将领导者自适应粒子群优化与降维结合，以提升其在高维问题中的可扩展性 [110]。多目标粒子群优化（MOPSO）引入了包含帕累托最优解的外部档案，以及保持多样性的选择策略 [111]。MOPSO 不会收敛到单一最优解，而是保留一组权衡解，并依据拥挤距离、聚类或基于网格的方法从档案中选取全局示例。这些进展拓展了粒子群优化及其变体在单目标和多目标优化问题中的适用范围。除此之外，蚁群优化受到蚂蚁集体觅食行为的启发：人工智能体根据其信息素轨迹和启发式信息，以概率方式构建解 [87]。信息素水平通过蒸发和沉积进行更新，从而强化与高质量解相关的组成部分 [89]。

在多目标场景中，扩展方法会采用多个

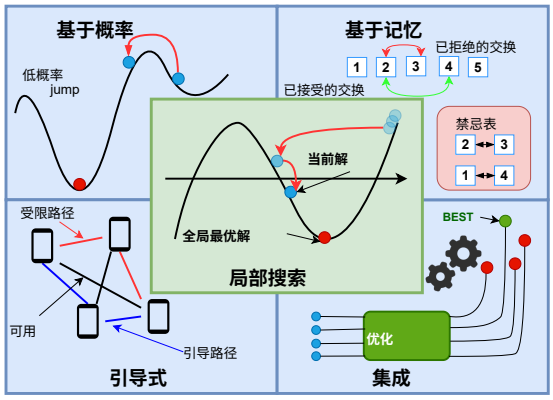

图10：局部搜索策略。

信息素矩阵 [112] 或聚合策略来近似帕累托前沿 [113]。类似地，人工蜂群算法将种群划分为雇佣蜂、跟随蜂和侦察蜂，以搜索解空间 [114]。雇佣蜂改进已知食物源，跟随蜂以概率方式选择有希望的候选项，而侦察蜂则引入随机解以保持多样性。扩展方法着重于改进邻域搜索，或引导探索转向高质量区域；多目标变体则纳入帕累托支配，以处理冲突目标。

基于轨迹的算法是单解元启发式算法，通过沿由邻域结构和接受准则定义的引导式轨迹迭代变换当前解来探索搜索空间 [85], [115], [116]。这些算法一次仅维护和改进一个解。代表性方法包括模拟退火（SA），其采用概率接受机制来逃离局部最优 [85]；禁忌搜索（TS），其利用基于记忆的机制防止循环；迭代局部搜索（ILS），其交替执行局部搜索和解扰动 [115]；以及引导式局部搜索（GLS），其动态惩罚频繁访问的次优特征 [116]。当利用局部结构并避免过早收敛至关重要时，这些方法对于组合优化和数值优化问题十分有效。

具体而言，模拟退火（SA）通过引入概率接受准则对局部搜索框架进行改进，从而能够更有效地逃离局部最优。SA 以一定概率接受较差的解，该概率随着算法推进而降低，并由温度参数控制 [117]。这一改进使 SA 能够探索更广阔的解空间，并有可能找到全局最优解。SA 与局部搜索之间的一个关键区别在于它们具体的邻居选择和接受准则。局部搜索遵循确定性策略，选择改进幅度最大的解；而 SA 使用梅特ropolis准则 [118]，以概率方式接受较差的解，从而增强探索能力。

对于基于记忆的算法，禁忌搜索通过结合自适应记忆结构的确定性规则来引导搜索过程。禁忌搜索通过采用基于记忆的约束和历史搜索信息，克服了陷入局部最优区域等关键局限。具体而言，禁忌表用于暂时禁止最近访问过的解或禁忌移动，从而避免循环并促进对新解区域的探索 [119]。禁忌搜索中的记忆机制通常具有层次性和自适应性，包括短期记忆（如禁忌表）、用于强化和多样化的长期记忆，以及在解足够有前景时允许解除禁忌限制的特赦准则，

解 [91], [119]。这些特性使禁忌搜索能够根据搜索历史和特定问题的约束动态调整邻域结构。总之，表 II 展示了针对资源分配（可能应用于无线通信）而实施的创新元启发式策略。

强化学习近年来已成为一类颇具潜力的随机优化技术，可用于解决下一代网络中的高动态资源分配问题。强化学习方法被设计为一种动态、自适应的框架，自然契合随机优化方法，尤其适用于不确定性下的序贯决策问题 [94]。在强化学习中，智能体与环境交互，通过试错学习策略，以最大化长期累积奖励，因此非常适合用于时变无线系统中的在线自适应优化。强化学习的基础可建模为马尔可夫决策过程（MDP），由一个元组 $(\mathcal{S},\ \mathcal{A},\ P,\ R,\ \gamma)$ 定义，其中 $\mathcal{S}$ 是状态集合； $\mathcal{A}$ 是动作集合； $P(s'|s,\ a)$ 表示在状态 s 下执行动作 a 后转移至状态 s' 的概率； $R(s,\ a)$ 表示期望即时奖励； $\gamma \in [0,1]$ 是折扣因子，反映未来奖励的重要性。此外，策略 $\pi(a|s)$ 通过定义动作上的概率分布来指定智能体的行为。目标是找到一个最优策略 π^* ，使期望回报最大化

$$G_t = \sum\nolimits_{k=0}^{\infty} \gamma^k R_{t+k+1}, \tag{3}$$

其中， G_t 表示时间步 t 的回报， R_{t+k+1} 是提前 $(k+1)$ 步收到的奖励，而折扣因子 γ 控制即时奖励与长期奖励之间的权衡：较小的值偏向短期收益，较大的值则更重视未来回报。此外，价值函数用于评估策略的性能。状态价值函数 $V_\pi(s)$ 表示在策略 π 下从状态 s 出发的期望回报，而动作价值函数 $Q_\pi(s,\ a)$ 表示在状态 s 下采取动作 a 并随后遵循 π 所获得的期望回报。这些量可以利用贝尔曼方程递归计算，具体如下： [94]

$$V_\pi(s) = \mathbb{E}_\pi \left\{ \sum\nolimits_{k=0}^{\infty} \gamma^k R_{t+k+1} | S_t = s \right\}, \tag{4}$$

$$Q_\pi(s,a) = \mathbb{E}_\pi \left\{ G_t | S_t = s, A_t = a \right\}. \tag{5}$$

这里， S_t 和 A_t 分别表示时间步 t 的状态和动作。最优状态价值函数 $V^*(s)$ 是在所有策略中从状态 s 出发可达到的最大期望回报，并满足贝尔曼最优方程。该方程将状态价值表示为即时奖励与后续状态折扣价值之和的最大值： [94]

$$V_\pi^*(s) = \max_{a \in \mathcal{A}} \left[R(s,a) + \gamma \sum\nolimits_{s' \in S} P(s'|s,a) V^*(s') \right]. \tag{6}$$

另一方面，最优动作价值函数 $Q^*(s,\ a)$ 估计期望回报的最大值。$Q^*(s,\ a)$ 与未来奖励之间的关系正式基于贝尔曼最优方程，其定义如下 [94]

$$Q^*(s,a) = R(s,a) + \gamma \sum\nolimits_{s' \in S} P(s'|s,a) \max_{a' \in \mathcal{A}} Q^*(s',a'). \tag{7}$$

对于基于价值的方法，例如 Q 学习、SARSA 和深度Q网络（DQN），其重点是估计动作价值函数，并据此推导出最优策略。这些方法利用贝尔曼方程随时间更新价值函数，逐步改进对长期奖励的估计。无线环境的随机性体现在衰落信道或用户移动性引起的随机状态转移上，可通过对多次经验取平均来获得稳健的价值估计。例如，Q 学习已应用于动态频谱接入和发射功率控制 [123], ，其中信道条件按概率变化，智能体必须在不了解系统模型的情况下学习最优策略 [82]。然而，基于价值的方法往往难以应对连续动作空间，可能需要进行离散化，从而限制其在波束成形或功率分配等细粒度控制任务中的性能。基于策略的方法，包括 REINFORCE[124], 、双延迟深度确定性策略梯度（TD3）、深度确定性策略梯度（DDPG） [94], 、信赖域策略优化（TRPO） [125],和近端策略优化（PPO） [126], ，直接对策略函数进行参数化和优化，因此在建模随机策略方面尤为有效；在这类策略中，动作依据状态依赖随机策略选取。此外，强化学习方法具有自适应性，可根据问题背景进行调整，如表 III 所示。

3) 经验教训：没有哪一种随机优化算法能够普遍适用于所有问题；其性能在很大程度上取决于问题特征。遗传算法尤其适用于离散或混合优化问题，因为它们能通过交叉和变异有效探索大型搜索空间。差分进化和粒子群优化非常适合连续优化问题，尤其是具有非线性目标函数和多个局部最优的问题；二者可以结合以提升搜索效率，同时加快收敛。其他群体智能算法适用于需要协作行为的优化任务，例如网络路由，并且可以通过结合全局搜索策略加以增强。此外，基于局部搜索的算法适用于明确定义了邻域结构的情况，因为它们能系统地利用局部信息来改进解，并通过自适应探索摆脱较差的局部最优。强化学习算法适用于动态决策问题，并可与进化算法集成，以适应不断变化的环境。因此，算法编排取决于问题特征，而采用自适应方法可以显著提升解的质量和计算效率。

IV. 随机优化在下一代网络资源分配中的应用

本节探讨随机优化技术在下一代网络中的战略应用，并聚焦两个关键问题。首先，我们考察当前采用随机优化的驱动因素，分析下一代环境日益加剧的复杂性和异构性为何要求转向随机方法这一范式（开放问题五）。其次，我们探究这些技术在解决尖端下一代技术所带来的复杂资源分配挑战方面的实际效率（开放问题六）。

开放问题五：为什么现在是采用随机优化应对下一代网络的恰当时机？

1) 背景：在高度动态且非平稳的条件下，下一代网络需要高效分配频谱、功率、时间和计算资源 [81], [92]。波动的信道条件、用户移动性、时变流量和节点间干扰共同构成了一个概率环境，给传统确定性优化方法带来挑战 [8]。

表 II：元启发式算法中的创新策略

		算法改进	
Metaheuristic	EAs	GA	- 基于标量化的多目标问题向单目标形式的转换 [120] - 使用无效解过滤和无参数惩罚机制的约束感知适应度评估 [76] - 通过条件随机采样的问题驱动的种群初始化 [96]以及聚类感知分配策略 [121]
		DE	- 结合算子选择的自适应变异和交叉策略 [75] 以及由种群适应度引导的参数控制 [104] - 基于加权和的标量化，用于处理多目标优化 [103]
	SI	PSO	- 分布感知粒子初始化，以改善早期探索 [95], - 融合进化算子的混合粒子群优化框架，以增强全局探索和精细搜索 [95], [109] - 通过无参数惩罚式适应度评估处理约束 [109] - 使用加权和向量进行基于标量化的多目标优化 [79] - 兼顾多样性保持与精度感知扰动的分组—合并粒子更新机制 [79]
		ACO	- 结合学习辅助启发式方法的异构信息素建模，用于自适应解构造和信息素更新 [87], , 并使用神经网络启发式 [89]
	LS	SA	- 利用基于神经网络的代理建模实现学习辅助参数自适应 [122] - 结合模拟退火、禁忌机制和基于交叉熵的邻域探索的混合局部搜索框架 [117]; - 通过二次无约束二元优化（QUBO）建模实现量子启发式优化，并采用解析推导的惩罚界和缩放策略。 [118]
		TS	学习辅助初始化、概率引导的邻域移动及早停准则 [119]

表 III：强化学习中的创新策略

		算法	改进
RL	Value-based	Q学习	- 利用信道相关信息进行问题感知状态抽象和时延驱动的奖励设计 [127] - 通过资格迹、多目标奖励构建和自适应学习率控制增强时序差分学习 [128] - 使用长短期记忆（LSTM）进行Q值估计，以实现快速收敛 [129]
		SARSA	- 采用深度神经网络（DNN）和经验回放进行深度函数逼近，并结合资格迹进行多步时序差分更新，以提高缓冲区，以提升收敛稳定性 [130]
		期望SARSA	- 通过对动作分布求期望，实现方差缩减价值更新 [94]
		DQN	- 采用经验回放和目标网络进行深度价值函数近似，并通过双重深度Q网络缓解过高估计 [131]
	Policy-based	PPO	- 采用基于聚类的交互削减，提高多智能体场景中的可扩展性 [95] - 采用集中式训练与分布式执行的多智能体机制，并结合全局奖励和状态归一化实现协作学习 [128] - 通过基于李雅普诺夫的分解和分层PPO，实现稳定性感知策略优化 [125]
		DDPG	- 采用预测辅助连续控制，并进行服务质量和能量感知奖励设计 [132] - 通过深度神经网络预测车载用户和窃听者的未来位置，实现预测定位 [133]
		TD3	- 结合 LSTM 和动作空间正则化的历史感知演员建模 [134] - 采用延迟更新和目标策略平滑的轨迹感知演员—评论家优化 [135]
		Dyna-Q	- 基于模型的规划与无模型强化学习相结合。
	Actor-Critic	SAC	- 结合隐私感知奖励建模的熵正则化演员-评论家学习 [136]
		A3C	- 面向可扩展训练的异步并行演员-评论家学习
		A2C	- 采用批量梯度更新的同步演员-评论家学习 [94]

随机优化通过纳入随机性、概率建模以及从历史和实时观测中学习，为自适应、数据驱动的决策提供了原则性框架，从而增强资源分配的鲁棒性和灵活性。计算能力和网络智能方面的现代进展，使随机方法在下一代网络中的应用日益实用且可扩展。随着网络向超可靠低时延通信（URLLC）、增强型移动宽带和海量机器类通信演进，随机优化已成为下一代时代确保稳定性、效率和智能资源管理的关键工具。

2）关键特征与考量因素：随着下一代无线网络在规模、密度和服务多样性方面不断扩展，有若干因素使采用计算高效的随机优化不仅恰逢其时，而且对实现高性能和快速适应性至关重要。表 IV 突显了下一代网络中资源分配面临的挑战以及随机优化带来的益处，包括：

可扩展性是阻碍 SO 在大规模系统中应用的一项根本因素。NG 网络预计将支持超密集部署中的数百万台设备，从而产生维度高且复杂度迅速增加的优化问题 [137], [138]。与计算上变得难以处理的集中式方法相比，分布式随机优化算法具有鲁棒性，即使网络规模前所未有，也能保持出色的收敛性质。先进的分布式随机优化框架利用基于共识的机制，使网络节点能够协作解决全局优化问题，而无需集中式协调 [139]。这些技术在通信时延和链路故障情况下仍能保持可靠的收敛保证，因此非常适合无法实现完美同步的大规模部署 [140]。现代随机优化技术的可扩展性和鲁棒性，使复杂的全网优化问题能够分解为易于处理的子问题。这种分解确保计算复杂度随网络规模呈多项式增长，而非指数增长，同时保持性能保证 [141]。

部分可观测性和不确定性下的学习给下一代网络优化带来了重大挑战，因为受测量限制、估计误差和通信时延的影响，往往无法获取完整的系统状态信息[142]。随机优化通过将不确定性明确纳入优化框架，对部分可观测性具有内在的鲁棒性，从而能够在信息不完整的情况下有效决策。这些方法通过明确建模不确定性并为优化结果提供概率保证，维持稳健的性能。这种鲁棒性可确保随着可观测性降低，网络性能逐步下降，而非发生灾难性故障。与随机优化相结合的机器学习技术使无线电网络能够在未知的系统动态下，通过探索与利用来学习有效的资源分配策略 [143]。

非凸性与收敛保证：由于干扰模式难以预测、离散资源分配约束以及复杂的目标函数，非凸优化问题是无线网络中的基础问题 [144], [145]。传统优化方法往往会陷入局部

表 IV：NG网络中的设计考虑因素与 SO 的作用

设计考虑因素	下一代网络挑战	SO 的作用	示例技术
可扩展性	海量 设备连接 in 超密集部署	随机优化通过分布式计算和在高维空间中进行近似，	遗传算法、粒子群优化、深度 Q 学习，分散式多智能体强化学习（MARL）
部分可观测性	由于反馈有限或延迟受限控制信道，反馈有限或延迟	SO 利用随机观测得出近乎最优的决策，无需完整状态信息	汤普森采样、贝叶斯优化
非凸性	用户关联、功率控制和波束成形的联合优化	随机优化探索非凸空间，以寻找可行的高质量解，突破确定性方法的局限	进化算法、模拟退火、采用探索策略的深度强化学习
实时约束	超低延迟要求	随机优化支持快速收敛和在线自适应，以满足严格延迟预算	无模型强化学习、在线镜像下降、元结合提前停止的启发式方法
多目标权衡	相互冲突的关键绩效指标	随机优化近似帕累托前沿，以平衡权衡在多个目标之间动态	NSGA-II、NSGA-III
与 AI 模型集成	AI 原生 NG 网络需要运行时适应性和韧性	随机优化为训练、推理和部署提供应对不确定性的鲁棒优化层	随机梯度朗之万动力学、班迪特算法、用于大语言模型流水线调优的随机优化
动态拓扑	具有更多移动性的非平稳网络移动用户、无人机和边缘节点	glsso使策略和资源分配适应不断变化的网络拓扑	自适应强化学习、带漂移检测的在线学习、上下文老虎机
有限/先验知识 已标注 数据 /	新兴地区的稀疏测量或部署不足的区域	随机优化利用先验分布和样本高效学习——以适应反馈有限或延迟的情况。	贝叶斯强化学习、基于随机优化先验的迁移学习、高斯过程

最优解，从而限制其在复杂且时变的无线环境中的有效性。借助精细的方差缩减和动量方法等先进技术，即使面对非凸问题，鲁棒的随机优化算法也能提供理论上的收敛保证 [146]。这些算法能够跳出局部最优，并以较高概率收敛到全局最优或近似最优解，从而确保在各种运行条件下性能稳定。在非凸情形下，采用方差缩减技术的随机梯度下降表现出稳健的收敛性质。即使梯度估计受到噪声影响，其收敛速度仍保持稳定 [147]。这种鲁棒性对于下一代无线应用至关重要，因为梯度计算往往会受到信道噪声或干扰的影响。

实时约束和计算效率：实时约束要求优化算法能够在严格的时限内给出解；对于关键应用而言，时限通常以毫秒计 [148]。随机优化算法的计算鲁棒性使其即使在严苛的时间约束下也能得出近似最优解，因此非常适用于对时间敏感的无线应用。在线随机优化算法能够实时适应时变网络条件，同时维持稳健的性能保证 [85]。这种鲁棒性确保即使无线环境偏离设计假设，性能仍能保持稳定。

多目标权衡与帕累托优化：同样，无线网络的多目标优化需要在相互冲突的目标之间取得平衡，例如能效、时延、吞吐量和可靠性 [149]。鲁棒随机优化为处理多目标权衡提供了数学框架，同时确保所有目标均能维持性能保证。基于帕累托的优化能够识别相互竞争目标的非支配前沿，同时对目标权重和约束中的不确定性保持鲁棒性 [101]。

动态拓扑与自适应算法：用户移动、节点故障和时变连接会驱动无线网络中的动态拓扑变化，给优化算法带来重大挑战 [150]。作为应对之策，稳健的随机优化算法能够实时适应拓扑变化，同时保持收敛保证并展现稳定的性能。

3) 经验教训： 与依赖静态或平均情况假设且容易陷入局部最优的确定性方法不同，随机优化通过概率建模、随机性和数据驱动自适应，在波动信道、不可预测的移动性以及动态干扰下保持稳定性能，分布式和基于分解的随机优化框架通过多项式复杂度增长以及在不完美同步条件下实现稳健收敛，应对超密集下一代部署中的可扩展性挑战。随机优化还通过显式不确定性建模和基于学习的方法，进一步缓解部分可观测性问题，使系统能够利用不完整或延迟的系统信息进行知情决策。对于无线环境中常见的非凸优化问题，方差缩减和基于动量的方法等先进随机优化技术有助于快速摆脱局部最优，并促成近似全局解。此外，在线随机优化算法的计算效率能够在毫秒级时延预算内提供近似最优解，从而满足严格的实时约束。最后，随机优化通过帕累托优化平衡多目标权衡的能力，以及其对动态网络拓扑的适应性，凸显了其作为下一代系统中确保稳定性、效率和智能资源管理这一关键工具的作用。

开放问题六：如何应用随机优化，应对下一代网络前沿技术带来的资源分配问题？

4）背景：尽管前沿技术能够显著提升网络容量、覆盖范围和灵活性，但也带来了高度动态且具有随机性的资源分配挑战。例如，可重构智能表面辅助系统需要在信道信息不完整且随时间变化的情况下优化反射系数，从而形成高度非凸问题。大规模和无蜂窝大规模多用户多输入多输出需要对功率控制和用户关联进行大规模随机优化，以适应动态信道和用户移动性。采用无人机和卫星的空天地网络面临快速变化的拓扑，因此需要对调度、覆盖和切换进行实时随机决策。在移动边缘计算（MEC）中，无线链路、服务器容量和用户移动性的不确定性，使时延敏感型服务的任务卸载决策更加复杂。由于信道变化剧烈、时延长且能量受限，水下声通信也进一步加大了资源分配的难度。这些特性使随机优化成为在高度动态且不确定的下一代网络中实现高效资源管理的关键。下一代网络中随机优化的应用总结见表 V。

5）关键特征与考量因素：

RIS：随机优化主要用于有源-无源联合资源分配问题，这类问题具有非凸目标函数、单位模约束和不完美信道状态

表 V：随机优化在下一代网络中的应用

NG 网络	Ref.	Year	Obj.	Var.	算法贡献
RIS	[75]	2022	单一	连续	轮盘赌法根据权重向量，从三个变异算子中选择一个， 根据最优个体的适应度进行更新
	[104]	2023	单一	连续	使用多个变异算子，并根据搜索行为动态调整变异算子和交叉算子的控制参数 会根据搜索行为动态调整
	[117]	2024	单一	混合	混合型 元启发式算法组合 改进的禁忌搜索， 模拟 退火， and 交叉- 基于熵的邻域探索，用于解耦RIS优化
	[103]	2024	多个	离散	使用加权和向量将多目标优化转换为单目标；每个个体- 由量子向量表示，并由此生成二进制向量，每个二进制 然后将字符串解码为对应的十进制值
大规模多用户多输入多输出	[149]	2022	多个	连续	提出一种基于目标的适应度函数，并使用 K均值聚类将差分 进化种群划分为三个组，每组采用不同的变异算子
	[151]	2022	单一	混合	将问题分解为三个子问题：采用K均值聚类进行无人机部署 和用户配对，采用粒子群优化进行混合波束成形以最大化命中概率，以及采用遗传算法实现最优 功率分配
	[137]	2023	单一	连续	分布式协作多智能体强化学习框架，其中每个用户都作为 学习智能体，仅利用局部信息进行联合资源分配
	[152]	2023	单一	连续	该问题被建模为随机时变信道下的 MDP，而深度 采用确定性策略梯度算法优化联合协方差矩阵 设计（位于基站）和无源波束成形设计
	[138]	2025	单一	连续	提出一种改进的遗传算法，采用多点随机交叉，并结合 围绕当前种群最优解实施强制局部变异机制
卫星-无人机	[153]	2023	单一	离散	采用单点交叉、位翻转变异和轮盘赌选择的二进制编码遗传算法
	[95]	2023	单一	连续	初始化过程采用正态分布，并将遗传算法的交叉操作、差分进化的 变异和自然选择机制融入粒子群优化中，以摆脱局部最优
	[109]	2024	单一	混合	将遗传算法集成到每次粒子群优化迭代中，以优化所选粒子，并使用无参数惩罚 函数
	[87]	2024	多个	离散	引入具有不同目标偏好的异构蚁群，每个蚁群使用五对信息素矩阵 ；设计用于解构造的可行解生成方法、用于解划分的 质量改进方法，以及用于自适应信息素更新的信息素更新方法
	[89]	2025	多个	离散	蚁群优化利用神经网络启发式来指导路由；蚂蚁通过状态转移探索路径，并更新 基于成本-质量的信息素，并迭代改进基于Transformer的VNF 嵌入
	[118]	2025	单一	连续	采用量子退火（QA）求解 QUBO模型，并通过推导惩罚界加以改进 并利用泰勒近似优化缩放参数，以及混合整数线性分式 规划，避免启发式调参
感知与通信	[120]	2021	多个	离散	使用加权和向量将多目标优化转换为单目标优化；二进制 编码遗传算法，采用单点交叉、位翻转变异和无效个体移除
	[76]	2024	单一	混合	混合遗传算法–粒子群优化，每次粒子群优化迭代中，种群的一部分由遗传算法进行优化。该 适应度通过无参数惩罚函数进行评估，以处理约束
	[96]	2022	单一	离散	个体以二维拼接矩阵表示，并通过以下方式进行初始化 采用条件随机搜索，而非纯粹随机生成
	[121]	2025	单一	离散	生成初始种群，更有可能将提供方分配给请求方 在同一簇内，并采用具有更大锦标赛规模的锦标赛选择策略
水下通信	[154]	2022	单一	混合	融合粒子群优化、非均匀聚类和簇大小的自适应更新
	[155]	2024	多个	离散	通过基于标记树的编码方案、转向角先验信息，增强 NSGA-II， 以及基于哈希的记忆搜索机制
	[156]	2025	单一	混合	结合基于模型的优化（二分法和拉格朗日对偶）与深度确定性策略梯度进行频谱 分配
其他	[150]	2024	多个	连续	基于温度的扰动、领域特定调优
	[122]	2023	多个	连续	训练神经网络以建模几何结构与S参数的关系；模拟退火通过人工神经网络代理模型优化几何结构 参数，以拓宽带宽，同时保持所需的中心 频率
	[119]	2024	单一	连续	DeepEigNet 初始化、概率引导移动和早停机制
	[79]	2025	多个	连续	使用加权和向量将多目标优化转换为单目标优化；集成 一种分组与合并策略，通过允许.....来增强信息共享和多样性 粒子在各组内学习，并定期以受控方式合并；精度匹配 引入扰动以维持搜索动量

信息。具有代表性的一类研究针对以吞吐量或公平性为导向的目标，构建联合波束成形与相移设计问题。例如，Zhi 等 [157]研究了RIS辅助的大规模多用户多输入多输出上行链路系统中的和速率最大化和最大最小速率最大化问题，并采用一种新型遗传算法，在耦合的有源波束成形向量和RIS相位配置空间中进行搜索。针对高频场景，研究者采用群体智能方法应对严重的路径损耗和阻塞效应。在 [158], 中，研究了RIS辅助的毫米波大规模多用户多输入多输出上行链路，并采用粒子群优化联合设计波束成形器和RIS相移。该问题被建模为在发射功率、波束成形结构和RIS相位范围等实际约束下的可达速率最大化问题，并由粒子群优化对耦合的有源和无源波束成形变量进行搜索。具体而言，RIS相移被视为粒子位置这些粒子根据各自的个体最优性能以及群体的全局最优性能进行迭代更新。采用粒子群优化进行优化的可重构智能表面能够减轻无线传播环境带来的有害干扰效应。

在明确考虑网络动态和移动性的情况下，引入基于学习的 SO 技术来处理复杂的决策空间。Mei 等人 [82]提出了一种深度强化学习（DRL）框架，用于联合优化无人机轨迹和 RIS 相移，以最小化 RIS 辅助无人机通信系统中无人机在所有时隙内的总体推进能耗。该系统中，无人机借助部署在建筑物上的 RIS 为地面终端提供服务，以克服遮挡。作者采用双重深度 Q 网络（DDQN）处理离散的无人机动作，并采用 DDPG 进行连续控制，二者均结合了 RIS 相位自适应。可靠性导向设计进一步扩展了

SO 应用的范围，使其超越基于速率的目标。Chien 等人 [8] 研究了 RIS 辅助多用户多输入多输出系统中通信可靠性的优化，并将其视为 RIS 引入的相移与基站波束成形向量的多变量函数。为解决这一问题，作者提出了一种差分进化算法，并在每一代结束时采用局部搜索技术，从而有效处理非凸的符号错误率（SER）优化问题，避免陷入局部最优。

总体而言，现有基于SO的可重构智能表面辅助网络研究大致可分为两类：一类是在单位模约束下联合优化有源–无源波束成形的元启发式驱动方法；另一类是面向动态场景的基于学习的框架，涉及移动性、离散–连续混合决策以及长期性能目标。

大规模多用户多输入多输出/无蜂窝大规模多用户多输入多输出：SO 技术被广泛用于解决涉及通信、计算和能源管理的大规模、时变资源分配问题。Tilahun 等人 [137]提出了一个联合通信与计算优化问题，旨在严格时延约束下，最小化无蜂窝大规模多用户多输入多输出辅助移动边缘计算网络中用户的总能耗。任务到达和无线信道状态均被建模为随机过程。为实现可扩展的实时决策，作者提出了一种采用集中式训练和分散式执行的多智能体强化学习框架，使分布式智能体能够协调资源分配决策，同时避免过多的信令开销。Kurma等人 [152]研究了 RIS 辅助全双工多用户多输入多输出系统中的资源效率优化，该系统由多天线基站、上行链路和下行链路用户以及分布式可重构智能表面组成。优化目标是在功率约束和 RIS 相移的单位模约束下，最大化资源效率；资源效率定义为频谱效率与能效的加权组合。针对这一非凸联合优化问题，研究采用了基于策略梯度的深度强化学习框架，在动态信道条件下结合行动者–评论家架构与经验回放进行求解。作为进一步拓展，Chen等人[138] 研究了毫米波多用户大规模多用户多输入多输出系统中可重构天线子阵列的极化混合波束成形。该波束成形设计被建模为掩码矩阵选择问题，通过移相器实现的极化分布、数字波束成形和模拟波束成形均被联合优化，以最大化和速率。为解决该问题，作者比较了随机掩码采样、传统遗传算法以及结合定向扰动策略的增强型遗传算法，凸显了进化搜索在探索大型组合波束成形空间中的作用。最后，Chien 等人 [159] 采用增强型差分进化，对无蜂窝大规模多用户多输入多输出信道估计中的 RIS 相移进行优化。该方法通过向精英候选解注入定向扰动，在减轻过早收敛的同时，最小化归一化均方误差。

大规模和无蜂窝大规模多用户多输入多输出系统中的随机优化主要由可扩展性和协调需求驱动。基于学习的方法，尤其是多智能体和策略梯度强化学习，被用于实现天线、用户和边缘资源之间的分布式决策；进化算法和群体智能方法则用于处理高维、混合整数且梯度难以计算的波束成形与配置问题。

空中通信：优化资源使用

空天地通信涉及颇具挑战性的路径规划问题，其特点是复杂的三维环境、动态障碍物和能量约束。在 [85], Yu 等人中，他们将无人机轨迹规划任务表述为一个 NP难优化问题，旨在最小化加权路径代价，其中考虑了传播距离、避障、偏航角和俯仰角以及高度约束。为应对这一问题的非凸性和多目标特性，作者采用了混合粒子群优化框架，并结合模拟退火以跳出局部最优，同时运用维度学习策略改善收敛行为。此方法旨在平衡探索与开发，从而实现高质量的无人机轨迹规划。从网络层角度看，空中通信在较高协议层同样面临资源分配挑战，尤其是在动态需求和有限机会下的内容传输与缓存方面。研究 [160] 考察了一种融合卫星、地面基站和飞机辅助缓存的三层空中通信架构。研究将内容放置问题表述为最小化端到端传输时延，同时考虑随时间变化的内容流行度、异构缓存容量以及受限的通信时长。为解决这一问题，作者将内容放置与传输建模为马尔可夫决策过程，并采用基于深度强化学习的方法，在动态空中环境中学习自适应缓存策略。

空中通信网络中的随机优化主要应用于两个层面：轨迹级优化，用于应对移动性和环境不确定性；网络层资源管理，用于根据动态需求和连接约束调整内容传输与缓存决策。

卫星通信：随机优化方法用于优化下一代卫星的星座布局、动态调整波束指向，并在链路条件不确定的情况下合理分配频谱和功率，以最大化覆盖范围和吞吐量。Song 等人 [161] 将问题建模为混合整数优化任务，以最大化探测收益，从而研究一组电磁探测卫星的任务调度。为解决该问题，他们将遗传算法与基于学习的自适应机制相结合，在策略梯度强化学习策略的指导下，利用循环神经网络动态调整交叉和变异参数。这种混合设计使系统能够在不断变化的大规模卫星调度场景中自适应地进行搜索。除调度之外，基于学习的随机优化框架也已用于天地一体化系统中的联合资源分配与缓存。在 [162],Li 等人提出了一种基于多智能体深度确定性策略梯度（MADDPG）的多智能体强化学习框架，用于联合优化卫星辅助非正交多址接入（NOMA）网络中的用户关联、功率控制和缓存放置。该问题被建模为受约束的能效最大化任务，不同智能体通过协调来管理通信和缓存决策。除以吞吐量为导向的目标外，信息新鲜度也已成为卫星支持的物联网网络中的一项重要性能指标。

卫星通信中的随机优化主要用于处理动态、大规模和异构环境中的混合整数调度与长期资源协调，从而能够在时变流量需求、多样化链路条件和复杂系统架构下进行自适应决策。

一体化感知与通信（ISAC）：采用随机优化来管理移动性、不确定性和动态

交通状况下高度耦合的感知通信资源分配。典型挑战包括高动态环境中的联合带宽分配、功率分配、基础设施激活以及时延与感知权衡。Zhang等 [163]研究了车联网基础设施系统中的ISAC优化，通过最大化多个基站和时间段内的雷达感知速率总和来实现优化。该问题涉及随机网络状况下的基站激活与带宽分配联合优化。随后，作者采用基于双重深度Q网络的强化学习方法，同时学习最优带宽分配和基站选择。该方法能够在感知和通信维度上实现自适应决策。在车联网场景中，Liu 等 [164]考虑了频谱稀缺条件下的ISAC-enabled多基站系统。资源分配问题被分解为两个阶段：首先，基于车辆位置，采用深度确定性策略梯度框架动态分配传输功率和信道，以最大化频谱效率；随后，采用深度Q网络分配带宽，在满足感知约束并适应不断变化的业务负载的同时，进一步协调通信性能。ISAC优化也已在无人机辅助高速铁路系统等高移动性场景中得到研究。Qiao 等 [165] 构建了一个混合整数非线性优化问题，旨在满足雷达感知约束的条件下最大化乘客的公平总速率。随后，采用混合粒子群优化—遗传算法方法，将粒子群优化的收敛能力与遗传算法强大的全局搜索能力相结合。在粒子群优化阶段，粒子根据自身的个体最优解和群体全局最优解调整位置，在搜索空间中移动。

移动边缘计算：SO方法已展现出巨大潜力，能够在需求不稳定且不可预测地波动的情况下，高效管理任务分配和资源调度。Goudarzi等 [80] 研究了一种由云中心、搭载于无人机上的移动边缘服务器，以及通过软件定义网络（SDN）控制协调的移动用户组成的无人机辅助移动边缘计算架构。为克服可访问性受限和能耗高等问题，作者提出了一种协同进化算法，在能耗和通信约束下联合优化任务卸载与带宽分配。多目标任务卸载也已

已在移动边缘计算系统中得到广泛研究。Wang 等人 [166]提出了一种全面的多目标优化框架，用于多用户、多服务器移动边缘计算系统中的任务卸载、功率分配和资源调度。每项卸载决策都必须在三个相互冲突的目标之间取得平衡：最小化响应时间、能耗和使用成本，同时满足服务器资源有限、设备功率预算受限等约束。为此，作者开发了一种基于分解的改进型多目标进化算法，将决策编码为染色体，并采用有效的约束处理策略、交叉/变异操作以及用于解选择的决策方法，例如简单加权法或多准则决策。研究还考虑了部分计算卸载，以提高能效。Bi等人 [88]设计了一种适用于支持智能移动设备的移动边缘计算系统的能效部分计算卸载策略，旨在通过联合优化卸载比例、中央处理器速度、带宽分配和传输功率来最小化总能耗，同时满足时延、资源和能耗约束。随后，作者提出了一种新型混合元启发式算法，即基于遗传模拟退火的粒子群优化（GSP）。具体而言，该算法采用遗传算法的交叉和变异操作来产生更优

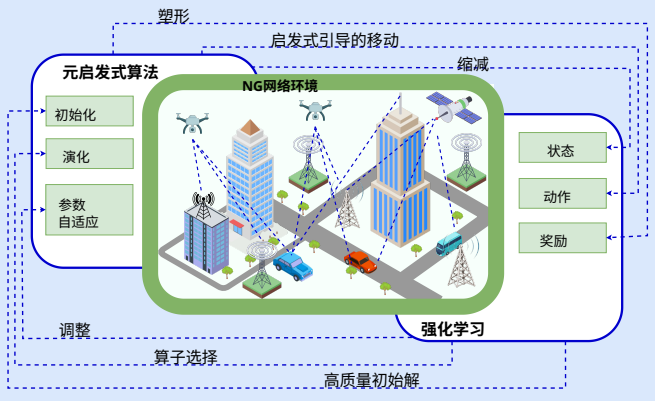

图 11：元启发式算法与强化学习的混合化。

粒子，并增强粒子群优化的全局搜索能力。此外，在更新粒子位置时采用模拟退火的 Metropolis 接受准则，使算法能够跳出局部最优。

水下声通信： 随机优化在克服严苛的能量约束、恶劣的时变信道条件以及多跳路由挑战方面发挥着关键作用。Hou 等[154]通过构建网络寿命最大化问题，研究了三维水下声传感器网络（UASNs）中的能量感知聚类与路由，该问题旨在平衡各传感器节点的能耗。优化重点在于联合进行簇头选择、簇大小配置和路由路径规划，目标函数则纳入剩余能量、通信距离和负载分布等因素。研究采用基于粒子群优化的方法，在动态拓扑条件下迭代探索可行的聚类与路由配置。

水下环境中的频谱与功率联合分配问题也得到了研究。Tang 等 [156] 针对水下声传感器网络中的资源分配提出了一套全面的解决方案。在该网络中，传感器节点通过恶劣的水下声信道向中心汇聚节点传输数据。其目标是在满足功率分配和部分频谱共享约束的前提下，最大化所有用户的最小速率。由于缺乏频谱分配模型的闭式解，且存在非凸干扰耦合，作者将遗传算法用于粗略频谱分配，并结合基于深度确定性策略梯度的深度强化学习方法，以数据驱动的方式细化功率与频谱决策。首先使用遗传算法近似全局最优解，再采用基于深度强化学习的方法高效探索整个解空间，实现最优资源分配。能量采集和移动性进一步增加了水下资源管理的复杂性。Han 等 [167] 研究了采用能量采集供电、配备移动中继的协作式上行水下声传感器网络。研究构建了一个联合优化中继选择与传输功率的问题，旨在电池和功率约束下最大化长期上行链路容量。该问题的主要挑战在于其离散与连续变量相耦合的特性，而能量采集的随机性、节点移动性以及有限的信道信息又使问题更加复杂。为应对这些挑战，作者采用了基于深度强化学习的分治方法：使用深度Q网络进行中继选择，使用深度确定性策略梯度进行功率分配，并重构状态空间，设计自适应奖励机制，在短期吞吐量与长期能源可持续性之间取得平衡。

性能结果：图13中，我们考虑一个大规模多用户 MIMO 系统，其中一个最多配备 100 根天线的基站为

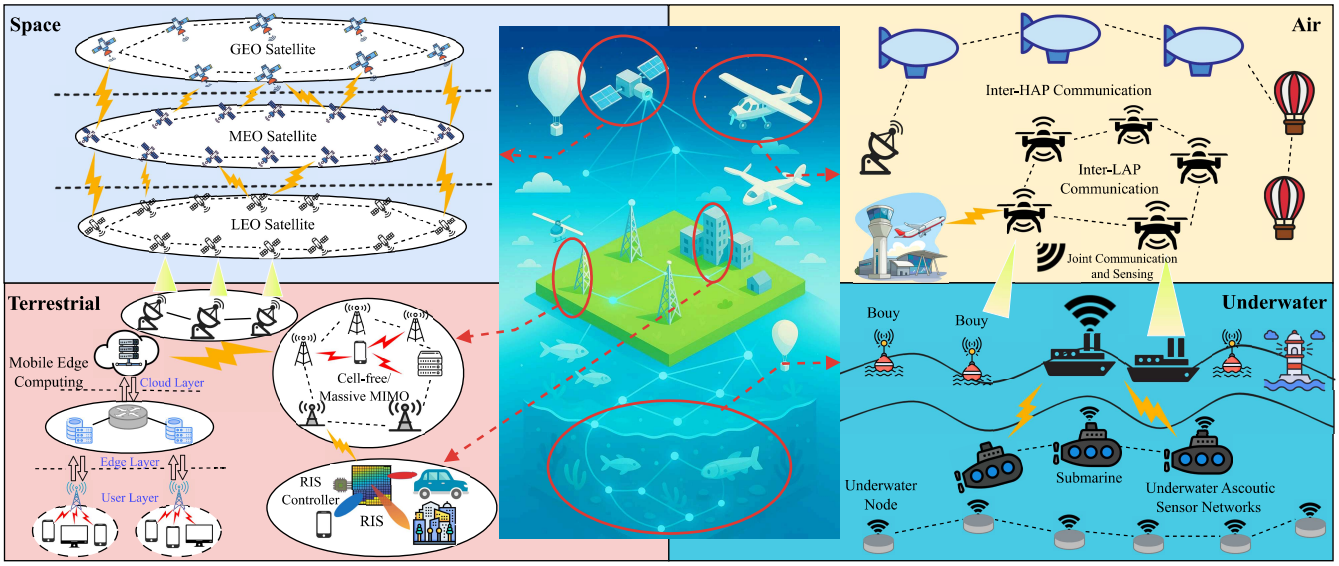

图 12：集成于下一代无线网络中的前沿技术，分为太空、空中、地面和水下四个层面。

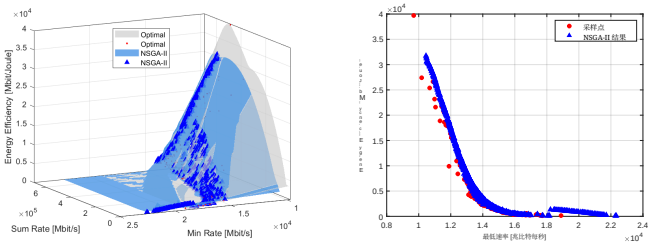

(a) 三维帕累托前沿　　(b) 二维帕累托前沿

图 13：针对三个不同目标，采用 NSGA-II 得到的 RIS单元与基站天线数量联合设计的帕累托前沿。

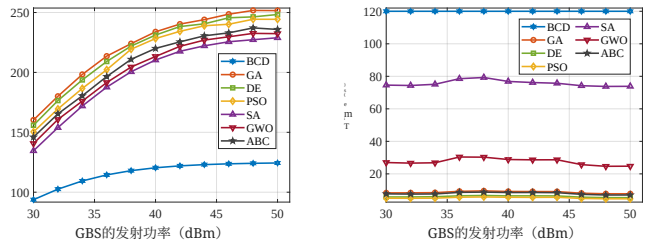

(a)　　(b)

图 14：双无人机辅助系统中联合轨迹与动态时间分割比的随机优化与确定性优化对比。

均匀分布在 $0.5 \times 0.5\,\mathrm{km}^2$ 区域内的 50 个用户提供服务。为提升通信性能，我们在覆盖区域内部署了一个含有 256 个单元的可重构智能表面，并按照 [8]对信道信息进行建模。一个多目标优化问题联合设计有源基站天线数量和可重构智能表面单元配置，以同时最大化三个目标：和速率、最小速率和能效。图13a展示了 NSGA-II 算法的收敛性能，其种群规模设为 100，迭代 100 代。经过约 10,000 次适应度评估后，得到的帕累托前沿与真实前沿非常接近。能效与最小速率之间的二维帕累托前沿展示了 NSGA-II 在捕获各目标间权衡方面的鲁棒性和多样性保持能力。

在图 14 中，我们考虑这样一个网络：地面基站与配备反向散射设备的无人机进行通信，由无人机将信息中继给终端用户。我们针对在不完美信道状态信息下联合确定动态时间分割比和无人机飞行轨迹，构建了一个新型优化问题，同时考虑无人机飞行时长、高度和传输功率等关键因素。在不同地面基站发射功率水平下，对确定性的基于块坐标下降的算法与包括遗传算法、差分进化、粒子群优化、模拟退火、灰狼优化器（GWO）和人工蜂群算法在内的各种随机优化算法进行了性能比较。定量来看，对于所有方法，可达速率均随着地面基站发射功率的增加而持续提升，其中随机优化算法显著优于基于块坐标下降的基准算法。具体而言，随机优化技术带来的速率提升范围为 73.79% 至 95.89%，而计算时间最多可减少 15.78% 至 95.47%。此外，遗传算法实现了最高的可达速率。与其他随机优化方法相比，模拟退火和灰狼优化器需要更长的执行时间。相比之下，差分进化和粒子群优化在解的质量与计算成本之间实现了较好的权衡。

6）经验教训：大规模/无蜂窝多用户多输入多输出、联合通信与感知以及可重构智能表面等前沿技术，在动态不确定环境中可能会引入复杂的频谱效率表达式，因此，随机优化凭借其适应实时变化的灵活性，展现出重要价值。在处理不可预测的信道条件、移动性和干扰时，它能够胜过静态或确定性方法。总之，随机优化对于下一代技术带来的复杂且不确定的环境颇具吸引力，但其持续发展必须着重关注可扩展性、适应性和实际应用价值。这些见解对于设计具有韧性且高效的下一代无线系统至关重要。

五、随机优化与未来技术的融合

开放问题七：随机优化如何与生成式人工智能等新兴技术协作，以实现下一代网络的资源分配？

1) 背景：向 6G 的演进以分布式系统 [138], 生成式人工智能 [168],的融合为基础

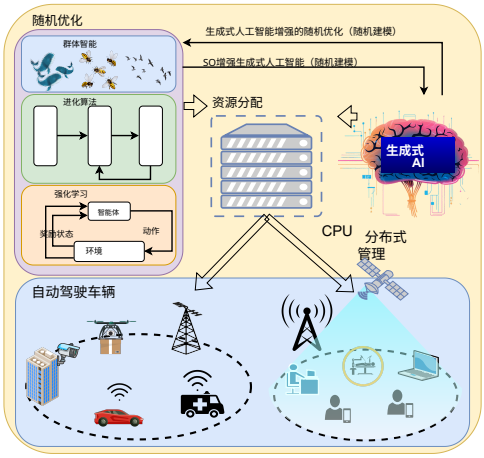

图 15：随机优化与下一代无线网络中新兴技术的结合。

[169]，和自动化框架 [170]。尽管分布式架构增强了可扩展性 [171]，，但其效能受到固有网络随机性的影响而降低，使集中式确定性控制难以胜任。同时，生成式人工智能模型，包括大语言模型 [172]，、扩散模型 [173]，和生成对抗网络（GAN） [168]，，推动了智能化运营 [169]，[174] ，但在边缘侧面临严峻的集成挑战，包括能量约束和非平稳数据分布。与此同时，网络自动化对于通过基于意图的网络和零接触管理 [175]等框架应对复杂性至关重要。通过将高层用户意图（例如，最大化体验质量（QoE））转化为自主决策，这些系统提升了多业务环境中的可扩展性。然而，在下一代网络中，其效能受到随机性和部分可观测特性的挑战；模糊的意图与延迟反馈使实时控制更加复杂。在这些技术领域中，随机性的主导地位使确定性优化从根本上难以胜任。相反，随机优化提供了应对不确定性的必要数学支撑（见图 15）。随机优化能够在噪声和部分信息条件下实现鲁棒决策，并促进非平稳环境中的无模型学习，因此成为分布式系统、大语言模型驱动的智能以及下一代网络中自主编排的基础赋能技术。

2) 关键特征与考量因素：

分布式实现：分布式系统的典型代表包括移动边缘计算、联邦学习、无蜂窝大规模多用户多输入多输出以及可重构智能表面集群等。这些系统运行于固有的去中心化架构中，必须应对动态约束，而此类约束往往会破坏凸性假设，并限制集中式优化方法的可行性。因此，决策通常基于异步、局部且非平稳的反馈，而基于种群的随机优化方法能够可靠地处理这类反馈。

- 群体智能 以粒子群优化和蚁群优化为例，其本质上是去中心化的，因此非常适合分布式优化。这些算法依赖局部交互和有限的信息交换，使智能体（例如边缘设备、无人机、RIS单元）能够根据自身的局部观测和共享的当前最优解独立进行自适应。这使其通信开销低、可扩展性高，这对大规模动态网络至关重要。
- 进化算法作为无需梯度且基于种群的方法，本质上支持通过在分布式节点上局部演化候选解来实现并行计算（例如，岛屿模型）。这种架构能够适应节点能力和链路质量各异的异构环境。例如，Li等人 [176] 提出了一种采用三层架构的完全分布式差分进化框架，用于并行适应度评估和自适应迁移，从而显著加快了资源分配任务的收敛速度。
- 强化学习 通过局部环境交互优化长期目标，从而促进分布式系统中的自主、异步决策。这一能力对于受部分可观测性限制的任务至关重要，例如分布式缓存 [177] 或联邦学习 [41]。此外，强化学习能够实现对随机动态的无模型自适应[178]，，而均场近似和参数共享等先进技术则有助于在连续动作空间中实现可扩展协作 [179]。
- 其他随机优化框架： 梯度下降和对偶分解等随机框架与分布式架构相契合：它们将全局目标划分为相互解耦的局部子问题，并通过消息传递或共享对偶变量来协调。在含噪梯度下具有稳健的收敛性质，使其成为管理移动边缘计算和联邦学习中计算与时延权衡不可或缺的工具，从而促进实时自适应控制。

生成式人工智能与随机优化：将涵盖大语言模型、扩散模型和生成对抗网络的生成式人工智能模型集成到网络优化流程中，需要具备可扩展性且能抵御不确定性的决策机制。在此，随机优化为实现样本高效搜索、鲁棒适应和多目标权衡处理提供了天然框架。随机优化与基于生成式人工智能的智能之间的相互作用主要体现在以下几个方面：

- 群体智能 与生成式人工智能融合，构建了一个双重功能框架。粒子群优化等经典算法可作为外部优化器，优化生成式输出，使其满足时延和能耗等严格的服务质量约束 [180]。反过来，生成式人工智能智能体（尤其是大语言模型）本身也可应用于类似群体的架构中，形成能够解读局部上下文并通过提示驱动协议进行协作的分布式决策实体。在这一范式下，群体智能原理为分布式大语言模型智能体提供协调框架，使其能够在复杂的多智能体环境中实现去中心化协商和涌现式策略合成 [181]。
- 进化算法与生成式人工智能相结合，在生成能力（例如，生成对抗网络中的分布建模 [169]）与全局搜索 [182]之间形成强大的协同效应。与此同时，进化算法增强的生成式人工智能利用进化算法优化模型的输入（提示/噪声向量）、参数或推理轨迹，尤其是在无法访问模型内部机制（黑箱）或需要针对多个目标进行优化时。例如，Liu等人 [183] 提出了大语言模型驱动的进化算法（LMEA），通过提示工程利用大语言模型执行交叉和变异操作。反过来，生成式人工智能增强的进化算法是指利用模型辅助进化搜索过程。生成对抗网络能够生成高质量的初始种群或代理模型，以加速收敛 [168]，[169]，；大语言模型则凭借解读复杂问题情境 [184]的能力，展现出语义优势。这种双向协同有助于采用更具适应性的方法进行随机优化，兼顾结构化搜索

与生成式推理。

- 强化学习 与生成式人工智能相结合，构成了一个稳健的闭环框架。生成模型通过合成训练轨迹或提炼非结构化状态来增强强化学习智能体，例如在 O- 无线接入网（RAN）切片中进行大语言模型引导的策略更新 [185]。反过来，强化学习也能优化生成模型的部署。例如，利用强化学习确定边缘层级中的分割点，以尽可能降低时延和能耗 [186]。总体而言，这种结合将结构化策略学习与灵活的生成能力融为一体，为自主的下一代网络控制铺平了道路。

- 其他 *SO* 框架： 除大语言模型外，扩散模型和变分自编码器（VAE） [173], [187]也能与零阶优化和贝叶斯优化协同作用，以应对黑盒不确定性。具体而言，深度生成式模拟器能够稳健地建模时空信道随机性 [188]。例如，利用深度生成式模拟器（如扩散模型）的鲁棒优化框架，为建模和处理无线信道中的时空随机性提供了系统化方法[189]。与此同时，贝叶斯优化能够实现样本高效的超参数调优，例如在边缘环境中采用提示引导的大语言模型部署 [190]。

自动化中的SO： 随着下一代网络迈向完全自治，面对高维不确定性，SO为自配置、自优化和自愈提供了必不可少的算法支撑。通过在随机流量和拓扑变化下实现反应式适应与主动式意图管理，SO赋能多层自动化栈。

- 群体智能算法（如粒子群优化和蚁群优化）通过局部交互实现自适应行为，从而支持在动态波动且不确定的条件下进行可扩展决策。Conforth 和 Meng [191]提出了一种基于群智能的强化学习框架，用于训练人工神经网络（ANN），并结合蚁群优化与粒子群优化来确定ANN拓扑及相应的连接权重。该方法通过机器人定位任务进行了验证，展示了群智能与强化学习协同用于分布式控制应用的有效性。

- 进化算法通过基于种群的搜索和自适应算子，在不依赖梯度的情况下演化自适应策略与配置，从而支持下一代网络中的自动化。借助岛模型进化等机制，它们有助于实现从意图到策略的自动化转换和分布式决策。这些能力使进化算法天然适用于零接触管理，支持系统自优化并适应动态、不确定的环境。例如，Li 等人[176]提出了一种自动化的分布式差分进化框架。其中，多个差分进化种群执行进化搜索，同时通过由性能驱动的适应度评估分配实现自动化。这使系统能够自主管理计算资源并加快收敛。

- 强化学习 已成为闭环自动化的重要支柱，使系统能够通过与网络环境交互来学习最优策略。在下一代网络中，强化学习支持路由、频谱分配、能源管理等方面的自主决策。多智能体强化学习进一步支持异构节点之间的协同，而在线强化学习技术则能够在实际部署中实现连续自适应，以应对频繁变化的条件。Farzanullah等人在 [192] 中采用多智能体强化学习进行工厂自动化网络的资源分配，以满足超可靠低时延通信需求，实现去中心化决策、提升通信可靠性并支持实时工业自动化。

- 其他 *SO* 框架： 贝叶斯优化、零阶优化和生成模型等互补技术，对于梯度不可用情况下的黑盒自动化至关重要。贝叶斯优化擅长样本高效的超参数调优，例如利用它引导多智能体深度强化学习，实现自动化且能效高的无人机协调 [193]。同样，零阶优化有助于在含噪无模型环境中进行在线配置，对于自适应负载均衡和实时传感器管理等梯度无关任务尤其有效[194]。

表 VI 概述了各种随机优化方法在分布式系统、生成式人工智能模型以及下一代网络自动化中的应用，重点介绍了其主要特征、任务和实际应用。

3）经验教训： 随机优化与分布式架构、生成式人工智能和自动化的结合，为自演进下一代网络的设计提供了重要启示。随机优化通过群体智能和进化算法实现去中心化决策，并增强分布式系统在动态条件下的鲁棒适应能力。此外，随机优化与生成式人工智能之间存在双向协同。大语言模型、扩散模型和生成对抗网络等模型通过语义推理、潜在状态抽象和合成数据增强来提升随机优化。反过来，随机优化为这些生成式输出提供依据，充当严格的反馈机制，以优化提示、改进黑盒推理轨迹并施加物理约束。在网络自动化方面，随机优化和强化学习能够针对不断变化的条件实现自优化和自愈，从而提升能效和服务质量。然而，仍面临一些挑战，例如边缘计算与能量约束，以及动态环境中的部分可观测性。分布式系统资源有限，因而难以实现实时适应和可扩展性。要应对这些挑战，需要转向轻量级无模型优化和联邦学习范式，以协调算法复杂度与分布式资源限制。

开放问题八。量子计算如何提升下一代网络中随机优化的能力？

1) 背景：随着多智能体协调、大规模设备种群以及多目标权衡推动 NG 网络问题日益复杂，经典 SO 算法愈发受到四大主要局限的影响，包括 i) 计算复杂度呈指数增长：可重构智能表面配置、任务卸载或轨迹控制等问题具有组合性质，导致搜索空间随变量数量呈指数级增长，使经典中央处理器（CPU）/图形处理器（GPU）难以实现全局优化； ii) 收敛效率低下：基于种群的算法和深度强化学习需要大量迭代和大量采样才能达到可接受的性能，实际应用中往往违反时延约束； iii)不确定性下的采样效率低下：在部分可观测的非平稳环境中，经典 SO 的探索能力有限，难以适应未见过的条件或环境变化；以及 iv) 能量与硬件效率低下：

表 VI：SO 与分布式系统、生成式人工智能和自动化任务的集成：关键方法、特性及应用概述。

技术	方法	关键特性	协同效应与应用
分布式系统 and edge 智能	SI	去中心化协调；局部反馈自适应；具备可扩展性和抗.....能力噪声。	分布式资源分配 [195]。
	EAs	可并行化；对移动性和衰落具有鲁棒性；混合变量优化。	分布式差分进化资源分配 [176]。
	RL	异步局部决策；可处理非平稳动态。	协作式边缘缓存 [177], 联邦学习 [41], 无人机路径规划 [196]。
	其他群智能优化	随机梯度下降、对偶分解、随机逼近。	能耗和时延约束下的移动边缘计算/联邦学习自适应。
生成式 AI	SI	优化生成式输出（例如大语言模型/扩散模型）或协调智能体。	推理增强 [180],群体大语言模型 [181]。
	EAs	生成式种群初始化（生成对抗网络）；大语言模型增强算子。	生成对抗网络辅助优化 [168], [169], LMEA [182],进化算法引导式切片 [184]。
	RL	基于生成式人工智能的状态抽象/增强；用于模型部署的强化学习。	提示增强强化学习策略 [185],大语言模型分割计算 [186]。
	其他群智能优化	生成式模拟器（扩散模型/变分自编码器）；稳健的零阶求解器。	基于扩散的信道建模 [173], [188], 基于VAE的设计 [187], LLM增强的贝叶斯优化 [190]。
自动化	SI	智能体协调；动态自适应行为。	群体智能增强的模型训练 [191]。
	EAs	长期规划和策略演化。	自适应资源分配 [176]。
	RL	闭环控制、多智能体强化学习、在线学习。	URLLC工厂场景中的多智能体强化学习 [192]。
	其他群智能优化	贝叶斯优化、零阶调优、生成模型。	基于贝叶斯优化的无人机卸载 [193],传感器管理 [194]。

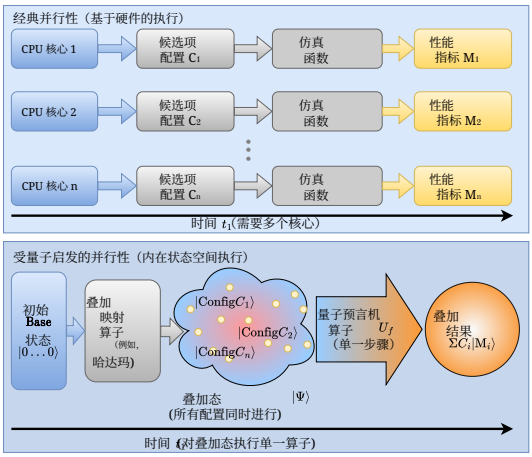

图16：经典硬件并行（上）与通过叠加映射实现的量子启发式内在并行（下）的概念性对比。

经典处理器在大型网络场景中扩展 SO 时会消耗大量能量，引发了对可持续性的担忧，尤其是在边缘侧。

这些局限性要求我们转向量子计算范式[197], [198]。通过利用叠加、纠缠和隧穿，量子计算可实现内在并行探索，从而降低随机优化的计算复杂度，使其达到经典硬件加速无法企及的水平。

2）关键特征与考量因素：现在，我们将探讨量子计算如何增强各类随机优化技术，包括基于种群的元启发式算法、强化学习、黑箱框架和基于采样的框架，并讨论硬件和算法层面的实现权衡。

量子启发式元启发式算法（QIM）： 量子启发式元启发式算法将量子原理融入遗传算法、粒子群优化或蚁群优化等经典算法。如图17所示，基于量子启发式元启发式算法的随机优化在初始化期间采用概率量子比特表示，从而最大限度地提高多样性。随后，旋转门或相移等量子启发式算子会动态更新这些状态，使其能够产生类似干涉的行为并跳出局部最优。因此，这种融合加快了收敛速度，并提升了高维多目标无线优化任务的性能。为阐明量子原理在我们框架中的内在融合方式，图16展示了其基本运行机制上的区别。经典算法（上图）依赖串行处理或基于硬件的并行处理。相比之下，下图展示了所提出的量子启发式机制如何充当量子协处理器。具体而言，叠加映射算子（例如哈达玛算子）将经典信息转换为单一叠加态（$|\Psi\rangle$） [199]。该机制利用内在的状态空间并行性，通过量子预言机（U_f）在单一步骤中评估整个解空间，从而加速对高维下一代网络配置 [199] 的搜索。其详细特征包括

- 用于丰富搜索表示的量子编码：在经典元启发式算法（例如遗传算法、粒子群优化）中，解表示是固定且明确的，因此每个候选项只能对应搜索空间中的一个确定性点，无法体现概率叠加。相比之下，量子启发式元启发式算法采用量子比特编码，将决策变量表示为状态叠加。这种方式能够对整个搜索空间进行概率映射，从而同时探索多个潜在解。例如，量子行为粒子群优化 [200] 采用相位角编码和基于量子吸引子的随机采样来表示粒子位置，从而实现更广泛的概率探索。

- 量子启发式算子：经典算子（如交叉）依赖静态启发式方法，而量子启发式框架则采用旋转门和相移等自适应机制。这些算子通过基于成功结果的调整来更新概率幅度，利用量子干涉动态引导搜索。例如，量子启发式遗传算法（QIGA）会应用旋转门、哈达玛变换和量子变异（如泡利X门）等量子算子，以概率方式演化基于量子比特的解。这使其能够在复杂的高维空间中进行无需梯度的自适应搜索。Saad等人 [201] 证明，QIGA利用叠加态和基于量子门的更新，高效优化资源受限调度。这种方法尤其适用于下一代网络任务，例如卸载和路由，并能有效应对不可微或依赖仿真的目标。

- 利用干扰和量子隧穿逃离局部最优：经典元启发式算法面临的一项主要挑战是过早收敛到局部最优，尤其是在非凸优化景观中。量子启发式元启发式算法整合量子隧穿和波干涉原理

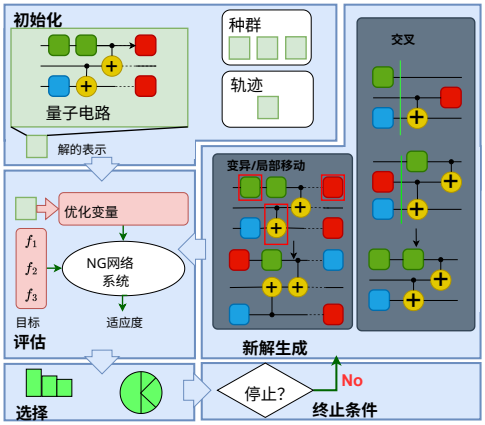

图 17：基于量子计算的随机优化。

以实现从局部陷阱中逃逸。在实践中，这可以通过概率重新初始化方案或非局部更新算子来实现，使解能够在搜索空间的不同区域之间“跳跃”。值得注意的是，量子退火框架（例如由 D-Wave 系统实现的框架）利用量子隧穿穿越势能景观中局部最优和全局最优之间的能垒，而量子启发算法则可以通过概率扰动或混合退火调度来模拟这一过程。

- 通过量子协处理器范式进行并行评估：与按顺序评估解决方案或依赖硬件复制的经典优化器不同，量子计算利用叠加，同时编码和处理大量候选状态。这体现了一种适用于含噪中等规模量子（NISQ）时代的量子-经典混合工作流，其中量子模块充当量子协处理器。正如近期框架所展示的那样 [202], ，这种协作是双向的：经典算法用于微调量子电路的参数（例如旋转角度 θ），而量子协处理器则通过叠加并行执行多个配置的计算密集型评估。例如，量子退火器（如 D-Wave）利用这一特性评估 QUBO 问题的全局能量状态，以显著缩短运行时间实现接近最优的和速率性能。

量子强化学习（QRL）： 强化学习常用于动态频谱接入、移动性管理、能效控制和意图驱动编排。然而，在高度随机且多目标的环境中，经典强化学习存在收敛缓慢、样本效率低和陷入局部策略陷阱等问题。在下一代网络中，量子强化学习带来了显著改进：

- 通过量子编码实现更丰富的策略和状态表示：量子编码利用量子比特，从根本上增强了强化学习对环境的表示能力。与二进制比特不同，量子比特处于叠加状态，因此能够捕捉连续的概率配置 [203]。这种能力使得只用较少的物理单元，就能高效编码规模大得多的状态-动作空间。此外，纠缠的量子比特配置能够高效建模复杂的依赖关系，例如时空相关性。这为高维度的NG网络状态提供了紧凑且信息丰富的表示，使智能体能够更细致地评估多种策略 [204]。

- 用于自适应学习的量子启发式算子：量子强化学习以参数化门和变分量子电路（VQCs）取代神经网络作为函数逼近器，通过利用可训练旋转与纠缠，这些算子以显著更少的参数实现了高表达能力，从而生成能够适应高维控制任务的紧凑型稳健模型。在实际的NG网络场景中，例如移动边缘计算（MEC） [205]或感知与通信一体化系统 [206]，这些量子增强型更新机制使智能体能够快速调整策略，并表现出更高的稳定性和更好的收敛特性。

- 利用量子叠加并行评估策略：量子叠加使得多个策略轨迹能够在单一状态下同时接受评估 [207], [208]。这种内在并行性显著提升了搜索效率，使每次迭代都能进行更广泛的探索，而无需增加额外的计算开销。在密集物联网协调等场景中，这种并行性显著加快了学习速度并提升了样本效率。因此，量子强化学习比经典方法更快地收敛到最优策略，满足下一代网络的关键时间约束。

- 减少训练参数和模型复杂度： QRL 利用希尔伯特空间的指数级表达能力，通过紧凑的参数化量子门来近似复杂策略[204]。这种大幅减少参数化的做法降低了内存和计算开销，从而加速策略优化 [208]。在资源受限环境中，这种效率优势尤为突出 [203], [205],[209]，因为受硬件限制，传统深度强化学习模型可能不切实际。通过使学习性能符合严格的资源约束，QRL 为在下一代网络环境中实现可扩展部署提供了一个颇具前景的框架。

为充分发挥量子强化学习的潜力，研究者提出了多种架构变体，各自具有不同优势，如表 VII 所示。

硬件与算法考量： 要在实践中采用量子增强随机优化，必须同时考虑硬件可行性和算法鲁棒性。这些考量决定了某种技术能否应用于近期混合系统，还是需要容错量子计算。

- 编码约束和嵌入开销： 量子硬件对问题的编码方式有严格限制。例如，量子退火器（如 D-Wave）要求将问题表述为 QUBO 或伊辛模型。相比之下，基于量子门的量子计算机则需要采用参数化量子电路（PQCs）的变分形式。此外，当逻辑变量必须映射到连通性有限的物理量子比特上时，就会产生嵌入开销。用户关联、联合功率与带宽分配或可重构智能表面相位控制等复杂问题通常需要数千个变量，远超当前硬件能力，除非采用激进的降维或聚类方法。例如，Dinh 等人 [210]将量子退火应用于卫星波束部署，并采用哈密顿量约简，将问题分解为符合 D-Wave 硬件限制的子实例。

- 量子-经典混合集成： 鉴于当今量子处理器具有含噪中等规模量子（NISQ）的特性，大多数实际应用都需要采用混合工作流，由量子例程增强经典优化组件。常见的结构是使用量子模块（例如利用量子退火（QA）进行搜索、采样或策略生成），同时由经典模拟器或数字孪生来完成目标函数

Ta表 VII：推动下一代网络性能的量子专用架构比较

架构	结构	优势	代表性应用
混合式 量子-经典 non-顺序架构	经典前馈层 用于输入/输出，包含多个非顺序中间层中的变分量子电路。	实现对量子比特更精细的控制，减小纠缠开销，提高量子-经典系统中的泛化能力和可扩展性。系统。	移动边缘计算环境中的联合任务卸载与资源分配移动边缘计算环境 [205], [207], 低地球轨道卫星路由 [209]。
逐层量子深度强化学习	每层采用 RX/RY/CZ 门的深度量子网络，并进行局部损失计算而非单一量子层全局损失。	避免贫瘠高原，支持更深的量子网络，实现更快的收敛——并以更少的开销实现稳定训练内存开销。	无人机轨迹和功率分配优化——在能效约束下的优化 [203]。
多智能体 量子 强化学习	去中心化智能体各自 采用相互独立的量子策略网络使用 VQCs，并根据局部观测和奖励进行训练。	可扩展的多智能体协调；降低通信开销；对部分局部可观测性；适用于大规模系统。	非规则重复时隙ALOHA-NOMA自适应传输 [204]。
量子演员-评论家与子策略电路 量子	建模演员网络和/或评论家网络采用参数化量子电路；可以使用共享编码器和混合经典输出层。	适用于连续动作控制；实现富有表现力的策略近似使用更少的参数并提升收敛速度。	联合到达方向（DoA）估计以及基于通感一体化的6G系统中的任务卸载 [206]。

评估并提供奖励反馈 [211]。

• 噪声、退相干和容错性：用于SO的量子算法必须应对硬件诱发的量子噪声 [212],[213], ，例如退相干、串扰和量子门不保真度；这些因素会降低性能，尤其是在反馈密集型无线应用中。为减轻这些影响，包括噪声梯度训练和测量误差缓解在内的误差感知策略能够增强鲁棒性。此外，冗余电路编码可以平均化随机故障。尽量降低量子—经典通信延迟，对于满足下一代网络控制的实时需求也至关重要。

• 量子加速基准测试：要证明量子计算集成的合理性，就必须在算法维度和硬件维度上，针对经典基线（例如DE、PSO）进行严格的基准测试。关键指标包括收敛率、多目标帕累托覆盖度，以及对动态网络条件的鲁棒性；同时，硬件评估必须量化量子处理器相对于中央处理器/图形处理器的实际运行延迟和能效。在无人机调度中，Jeong 等 [202]证明，与经典聚类相比，量子退火在不同用户密度下的收敛性和吞吐量均更优，从而为无线场景中的量子优势提供了关键的实证验证。

3）经验教训：量子计算为下一代网络中的随机优化带来了变革性潜力，但要充分发挥这一潜力，必须谨慎协调算法设计、硬件限制和网络特定需求。主要经验教训如下：

• 即使无法使用容错量子硬件，量子启发算法（例如量子启发式遗传算法、量子行为粒子群优化）也能立即发挥价值。这些算法在高维下一代网络问题中，能够显著提升搜索多样性、收敛速度和可扩展性，为经典计算范式与量子计算范式之间搭建了切实可行的桥梁。

• 量子强化学习通过利用量子编码和变分电路，可构建紧凑且富有表现力的控制模型，减少训练参数的数量并提升策略的适应性。这些优势对于动态且受限的无线环境至关重要。其优势不仅在于表达能力，还体现在样本效率以及对部分可观测性的鲁棒性。

• 便捷的量子-经典混合工作流概念，成为 NISQ时代最可行的方法。无论是用于初始化、采样还是策略近似，将量子子程序嵌入经典优化流程，都能在无需

部署完整量子技术栈 .

• 要有效实现量子增强随机优化，必须采用 QUBO、伊辛模型或参数化量子电路编码；然而，嵌入开销和有限的连接性要求通过降维或结构化分解来确保与硬件兼容。

•在评估量子优势时，不能仅看解的质量是否提升。现实的基准测试必须涵盖能效、实际运行延迟、不确定条件下的适应能力以及帕累托前沿覆盖范围。早期部署应利用量子模拟器、定制混合组件，并与大语言模型和/或数字孪生集成，以支持可解释的意图驱动网络自动化。

•鉴于量子处理器容易受到各种缺陷的影响，错误感知电路设计（例如低深度参数化量子电路、冗余编码，以及结合或不结合纠错的量子错误缓解）对于确保可靠性能至关重要，尤其是在实时波束成形或资源切片等反馈驱动型应用中。

这些见解表明，即使在当前的NISQ时代，量子计算也能切实提升下一代网络的随机优化，尤其是在采用针对无线领域约束量身定制的混合式、模块化和容错策略时。

VI. 设计指南、未来研究方向与结论

本节提出超密集部署、多层异构下一代网络的设计指南，这些网络覆盖从太空到水下通信的广阔范围。预计它们能够支持海量连接、极高的服务需求，以及感知、通信与计算功能的集成。随后，我们将介绍一系列潜在的研究方向，并得出切实的结论。

A. 通用设计指南

• **可扩展系统设计与问题表述**：有效的问题表述构成了下一代网络可扩展性的数学基础。这要求在连续域（例如波束成形 [8]）、离散域（例如用户关联 [95]）和混合域 [214]中定义变量。然而，为了应对超密集部署中的维数灾难，问题表述必须通过采用分解策略，将大规模问题划分为可并行化子任务 [215]，从而超越单体模型。此外，高效的问题表示至关重要；将多模态数据（例如，信道状态、视觉）映射到紧凑嵌入中，可确保问题具有可处理性。尤为关键的是，在计算上无法实现精确的全局最优性时，问题表述应优先考虑稳健的

可行性，通过风险感知方法（例如机会约束优化 [216]）在边缘硬件严格的能量预算内提供可靠性界限。

•**资源高效算法设计**：为下一代网络设计算法，必须在探索与开发之间取得平衡，同时满足严格的硬件和时延约束。

(i) 初始化与表示：随着问题规模扩大，朴素的随机采样可能导致过早收敛。设计必须利用领域特定启发式方法——例如使用模拟退火或粒子群优化生成稳健的初始种群 [217]，以快速引导优化过程进入可行域。

(ii) 硬件感知执行：鉴于超线性复杂度增长会给电池供电设备带来负担，算法必须融入**绿色人工智能原则**（例如模型压缩），以最大限度降低热应力和处理开销 [218]。大规模设计还应进一步采用去中心化多智能体协调与轻量级共识，以缓解中心瓶颈 [219]。

(iii) 自适应：通过局部搜索或梯度微调来开发候选项，同时利用自适应机制（例如贝叶斯优化）动态校准参数，以应对非平稳动态，无需进行穷尽式手动调参 [220]。

• **多维性能评估**：在超密集网络中评估随机优化，需要超越简单的和速率最大化，考察实际可扩展性。评估框架必须体现解的质量与计算成本之间的矛盾：*(i)* 最优性-时延权衡：在超可靠低时延通信场景中，评估算法时，应考察其能否快速收敛至稳健的近似最优工作点，而不是仅仅因未能找到难以企及的全局最优解而受到惩罚 [221], [222]。*(ii)* 计算效率：指标必须明确量化优化过程本身的运行时间、内存占用和能耗，确保开销不会抵消系统收益 [223]。*(iii)* 稳定性与鲁棒性：在随机扰动下保持一致，对于风险感知设计至关重要。最后，对于多目标任务，需要使用帕累托前沿可视化和专用指标（表 VIII），以分析算法在高维压力下应对相互冲突目标的能力。

• **性能评估**：选择评估框架对于评估下一代网络中随机优化的有效性至关重要。性能分析必须利用现实场景和能够反映解的质量、效率、稳定性与可扩展性的指标。主要评估维度包括：（*i*）解的质量，表示所得结果与最优解或参考解的接近程度，通常通过可达和速率、系统效用或能效等指标进行衡量；（*ii*）收敛速度，以达到近似最优解所需的迭代次数或总运行时间进行量化；（*iii*）稳定性与鲁棒性，用于评估在不同初始化、随机扰动或环境动态下结果的一致性；以及（*iv*）计算复杂度，反映算法在运行时间、内存和通信开销方面的可扩展性。由于随机优化本质上具有非确定性，因此应评估多次运行中的平均性能和方差。许多下一代网络优化任务涉及多个相互冲突的目标。在此类情境下评估算法性能，需要采用专门的指标，同时衡量算法向帕累托最优前沿的收敛程度以及解的多样性。表 VIII 列出了一些常见的多目标指标。此外，帕累托前沿的可视化还可以进一步帮助分析权衡，从而直观地比较不同优化优先级下的算法性能。

B. 未来研究方向

基于从上述各项开放问题中获得的见解，我们提炼出关键经验教训，并概述了旨在推动随机优化与下一代网络无缝融合的未来研究方向。

•**不确定性感知与遍历优化：** 一个根本性挑战在于，下一代网络固有的随机性会削弱确定性分配方案的可靠性。因此，未来研究应开发能够明确考虑不确定性的随机优化框架，可以采用机会约束或分布鲁棒优化等鲁棒风险感知表述，也可以在多个相干区间内进行遍历评估。通过结合概率模型与基于样本的方法，即使面对高度多变的恶劣环境，也能设计出可提供可靠性保证的资源分配方案。这一能力使随机优化成为大规模部署中实现鲁棒资源管理的关键推动力量。

• **面向随机环境的多目标设计：**第二个关键挑战源于同时优化频谱效率、能耗、时延和公平性等冲突目标的需求。在实践中，当信道动态和设备移动性随时间改变最优平衡时，实现有意义的权衡会更加困难，静态单目标解也会因此迅速退化。多目标随机优化提供了一个颇具前景的框架，但在这些非平稳条件下，识别鲁棒的帕累托最优解仍然十分困难。因此，未来研究应聚焦于开发能够跟踪不断演变的帕累托前沿、实时学习运营者偏好，并在多个时间尺度上调整优先级的算法。这些方法将有助于构建能够提供差异化服务保证的下一代网络，同时维持静态优化或单指标优化无法实现的效率与公平性。

• **无梯度与黑盒优化：**下一代网络中的另一项紧迫限制，是非凸、含噪且仅依赖仿真器的优化问题普遍存在；在这些问题中，梯度可能不存在，或并不可靠。调度、波束选择或硬件在环优化等资源分配任务，均直接属于这一类别。随机优化通过提供无梯度方法，为此类问题提供了自然的解决方案。这些方法依靠基于种群的搜索、概率采样或基于强化学习的探索，在无需解析可处理性的情况下发现近似最优策略。未来研究应进一步完善这些方法，以提高样本效率、降低计算开销并实现在线自适应。这样一来，黑盒随机优化将成为优化现实系统不可或缺的工具，尤其适用于不存在闭式模型的场景，使可部署算法能够直接在含噪、不完整且不可微的环境中运行。

•**可扩展性和实时可行性：** 随着网络向超密集场景演进，可扩展性逐渐成为算法和架构层面的瓶颈。优化问题的维数迅速增加，而实时约束要求在严格的能量预算下进行毫秒级决策。集中式求解器即使在理论上达到最优，在此类环境中也并不实用。未来研究

表 VIII：多目标性能指标

指标	描述 ption	特征
超体积 [97], [106], [155] 帕累托集支配的体积		表示收敛性和多样性
反向世代距离 [97], [100] 与参考帕累托前沿的平均距离	到获得的前沿	评估解的收敛性和覆盖度
世代距离 [87], [224] 获得的前沿到参考	前沿的平均距离	衡量与帕累托最优前沿的接近程度
间距指标 [225] 相邻解之间距离的标准差	相邻解	评估帕累托点的分布是否均匀
扩展度指标 [87] 极端解与中间解之间的多样性比率	解	量化解沿帕累托前沿的分布情况
埃普西隆指标 [226] 支配另一个前沿所需的最小偏移量		提供帕累托前沿之间的成对比较
标量化 [79], [103], [120] 目标的线性组合		通过单目标等价性简化比较

应重点关注基于分解的SO、去中心化多智能体协调以及自适应学习策略，这些方法能够将大规模问题分解为更小的组件，同时保持全局协调。此外，还需要轻量级通信协议和硬件感知算法设计，以确保即使在资源受限的设备上也具备可处理性。实现可扩展且高能效的随机优化，将使系统能够实时提供近似最优解，从而支持下一代网络进行城市规模的部署，同时不牺牲服务质量。

- **与分布式系统、生成式人工智能和自动化的集成：**向分布式、自动化和智能导向网络的范式转变，带来了复杂优化问题。一方面，分布式环境具有非独立同分布数据、部分可观测性以及边缘计算容量有限等特征。与此同时，生成式人工智能模型（例如大语言模型）和基于意图的自动化，为将高层次的面向服务的规范转换为可执行策略提供了新型接口。未来的研究应探索能够增强去中心化决策能力、同时保护隐私的联邦式和无模型随机优化方法，以及混合流程，其中生成式人工智能负责将模糊意图解析为广泛的优化

  约束。随机优化算法系列能够将这些输出进一步优化为可行解。与数字孪生和闭环自动化协同后，这些技术将推动网络实现自优化与自愈，使其能够在不确定环境中可靠运行。这种集成为实现零接触网络管理开辟了道路，在这种管理模式下，人工干预降至最低，效率达到最大，并且服务质量在异构环境中得以维持。

- **量子增强随机优化：** 最后，量子计算为下一代网络中的随机优化带来了变革性但迄今尚未充分探索的机遇。尽管含噪声中等规模量子硬件在量子比特数量和连通性方面仍有限制，量子启发算法已在多样性、收敛性和可扩展性方面展现出切实优势。与此同时，量子-经典混合工作流可将量子子程序嵌入经典处理流程，使随机优化能够利用强大的隧穿和叠加效应，而无须依赖完全容错的设备。未来研究应着重克服嵌入开销、降低电路深度，并整合量子误差缓解与纠错编码技术，同时建立切合实际的基准测试指标，将时延、能效和对不确定性的鲁棒性纳入考量。量子增强随机优化不仅有望加快对大型组合空间的探索，还将开辟经典方法难以企及的全新性能前沿，因此可将其视为下一代网络优化的长期战略方向。

C. 总结与结论

本教程与综述全面探讨了随机优化（SO）作为一种统一方法，在以下领域进行资源分配：

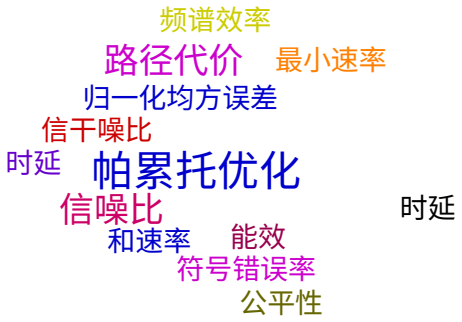

图 18：NG网络中的常见目标函数。



图 19：随机优化算法系列。

NG网络。我们重新审视了随机优化（SO）与经典确定性优化之间的根本模型和算法框架差异，强调了随机优化适用于高维、动态且易受不确定性影响的环境。在此基础上，我们考察了随机优化如何支持多种下一代系统中的单一目标和多目标权衡，涵盖大规模 MU-MIMO、可重构智能表面、太赫兹通信、卫星—空中—地面一体化以及移动边缘计算等关键技术。在第五节中，我们进一步阐述了随机优化与分布式网络架构的融合，使系统能够在信息不完整或延迟的情况下实现自适应、可扩展的决策。讨论还延伸至将随机优化与大语言模型和自动化等新兴工具相结合的混合设计，为应对非结构化且复杂的决策空间提供了新途径。最后，我们还探讨了量子计算（QC）作为随机优化自然延伸的作用，强调其在加速收敛、增强解的多样性以及处理原本难以解决的优化任务方面的潜力。综上，这些见解表明，随机优化不仅是一种便捷的数学框架，更是设计、部署和演化智能、弹性且可信的下一代网络的基础性赋能手段。

我们对图 18 中所示、在下一代无线网络随机优化中经常采用的整套目标函数进行了深入评估，而所考察的随机优化算法系列则展示于图 19。由此得出的

结论是，与随机优化算法的选择相比，目标函数的选择（例如和速率或极小极大目标函数）对整体系统性能的影响更大。然而，并非所有随机优化算法都适合用于便捷地求得目标函数的最优值。

参考文献

[1] J. Wang, C. Jiang, H. Zhang, Y. Ren, K.-C. Chen, and L. Hanzo, 《机器学习三十年：迈向帕累托最优无线网络》, IEEE通信调查与教程, 第22卷, 第3期, 第1472–1514页, 2020年。[2] K. B. Letaief, Y. Shi, J. Lu, and J. Lu, 《面向6G的边缘人工智能：愿景、赋能技术与应用》, IEEE通信选定领域期刊, 第40卷, 第1期, 第5–36页, 2021年。[3] W. Chen, X. Lin, J. Lee, A. Toskala, S. Sun, C. F. Chiasserini, and L. Liu, 《从第五代移动通信-Advanced迈向6G：过去、现在与未来》, IEEE通信选定领域期刊, 第41卷, 第6期, 第1592–1619页, 2023年。[4] M. M. Kiasaraei, K. Nikitopoulos, and R. Tafazolli, 《通过模拟处理实现超高能效、Tbps级无线系统：现有方法、挑战与未来方向》, IEEE通信调查与教程, 2023年。[5] Z. Zhang, Y. Xiao, Z. Ma, M. Xiao, Z. Ding, X. Lei, G. K. Karagiannidis, and P. Fan, 《6G无线网络：愿景、需求、架构与关键技术》, IEEE Veh. Tech. Mag., 第14卷, 第3期, 第28–41页, 2019年。[6] S. Chen, Y.-C. Liang, S. Sun, S. Kang, W. Cheng, and M. Peng, 《6G的愿景、需求与技术趋势：如何应对系统覆盖范围、容量、用户数据速率和移动速度方面的挑战》, IEEE Wirel. Commun., 第27卷, 第2期, 第218–228页, 2020年。[7] Q. Guo, F. Tang, T. K. Rodrigues, and N. Kato, 《支持数字孪生网络的6G五项颠覆性技术》, IEEE Wirel. Commun., 第31卷, 第1期, 第149–155页, 2023年。[8] T. Van Chien, B. T. Duc, H. V. D. Luong, H. T. T. Binh, H. Q. Ngo, and S. Chatzinotas, 《RIS辅助MIMO系统中用于符号错误率最小化的主动与被动波束成形设计》, IEEE Trans. Wirel. Commun., 2024年。[9] J. He, Y. Mao, Y. Zhou, T. Wang, and Y. Shi, 《利用可重构智能表面赋能的绿色无线网络中的用户接纳控制》, IEEE通信汇刊, 第71卷, 第7期, 第4062–4078页, 2023年。[10] L. T. Wedage, B. Butler, S. Balasubramaniam, Y. Koucheryavy, J. M. Jornet, and M. C. Vuran, 《通过太赫兹通信基础设施感知气候变化：6G网络的一项颠覆性应用》, IEEE网络, 第38卷, 第3期, 第261–268页, 2023年。[11] Y. Shi, L. Lian, Y. Shi, Z. Wang, Y. Zhou, L. Fu, L. Bai, J. Zhang, and W. Zhang, 《面向6G无线网络大规模优化的机器学习》, IEEE通信调查与教程, 第25卷, 第4期, 第2088–2132页, 2023年。[12] H. Jiang, Z. Xiao, Z. Li, J. Xu, F. Zeng, and D. Wang, 《异构小蜂窝网络中物联网的节能框架》, IEEE移动计算汇刊, 第21卷, 第1期, 第31–43页, 2020年。[13] M. Asim, Y. Wang, K. Wang, and P.-Q. Huang, 《云计算与边缘计算中的计算智能技术综述》, IEEE Trans. Emerg. Top. Comput. Intell., 第4卷, 第6期, 第742–763页, 2020年。[14] B. Ji, Y. Wang, K. Song, C. Li, H. Wen, V. G. Menon, and S. Mumtaz, 《6G计算智能综述：关键技术、应用与趋势》, IEEE Trans. Industr. Inform., 第17卷, 第10期, 第7145–7154页, 2021年。[15] Q.-V. Pham, D. C. Nguyen, S. Mirjalili, D. T. Hoang, D. N. Nguyen, P. N. Pathirana, and W.-J. Hwang, 《面向下一代网络的群体智能：最新进展与应用》, 《网络与计算机应用杂志》, 第191卷, 文章编号103141, 2021年。[16] S. Zeb, A. Mahmood, S. A. Hassan, M. J. Piran, M. Gidlund, and M. Guizani, 《工业数字孪生：NextG无线网络与计算智能交汇处的研究综述》, 《网络与计算机应用杂志》, 第200卷, 文章编号103309, 2022年。[17] H. Zhou, M. Erol-Kantarci, Y. Liu, and H. V. Poor, 《RIS辅助无线网络中基于模型、启发式和机器学习的优化方法综述》, IEEE通信调查与教程, 第26卷, 第2期, 第781–823页, 2023年。[18] A. K. Abasi, M. Aloqaily, B. Ouni, M. Guizani, M. Debbah, and F. Karray, 《基于优化技术的6G无线通信安全综述》, 载于IWCMC会议论文集。IEEE, 2023年, 第216–223页。[19] S. P. Singh, N. Kumar, G. Kumar, B. Balusamy, A. K. Bashir, and Y. D. Al-Otaibi, 《面向6G赋能的物联网（IoT）的混合多目标优化》, IEEE Trans. Consum. Electron., 2024年。[20] A. K. Abasi, M. Aloqaily, M. Guizani, and B. Ouni, 《6G无线通信的元启发式算法：最新进展与应用》, Ad Hoc Netw., 文章编号103474, 2024年。[21] M. O. Butt, N. Waheed, T. Q. Duong, and W. Ejaz, 《面向6G网络的量子启发式资源优化：综述》, IEEE通信调查与教程, 2024年。

[22] S. S. Hassan, L. U. Khan, Y. M. Park, M. Guizani, Z. Han, T. Ratnarajah, 以及 C. S. Hong, “面向 6G 太空-空中-地面的量子机器学习集成网络：综合教程与综述”, IEEE通信调查与教程, 2025年。[23] R. Sun、N. Cheng、C. Li、W. Quan、H. Zhou、Y. Wang、W. Zhang 和 X. Shen, “面向6G智能无线网络优化的知识驱动深度学习综合综述”, IEEE通信调查与教程, 2025年。[24] Y. Wang、C. Yang、T. Li、Y. Ouyang、X. Mi 和 Y. Song, “意图驱动的端到端6G移动通信系统综述”, IEEE通信调查与教程, 2025年。[25] W. U. Khan、A. Mahmood、M. A. Jamshed、E. Lagunas、M. Ahmed 和 S. Chatzinotas, “面向6G非地面网络的超越对角RIS：潜力与挑战”, IEEE网络, 2024年。[26] A. A. Khan 和 R. S. Adve, “无线网络中的百分位优化——第一部分：从最大最小速率到和速率最大化的功率控制（以及介于两者之间的一切）”, IEEE信号处理汇刊, 第72卷, 第1518–1532页, 2024年。[27] Y. Wang、C. Yang 和 M. Peng, “频率选择性信道下采用低分辨率移相器的太赫兹混合预编码：一种部分解耦方法”, IEEE广播汇刊, 2025年。[28] J. Zhang、H. Miao、P. Tang、L. Tian 和 G. Liu, “面向6G的新中频段：从信道传播特性角度的若干考量”, IEEE通信杂志, 第63卷, 第1期, 第175–180页, 2024年。[29] Y. Fan、C. Yang、R. Yuan 和 M. Peng, “太赫兹大规模MIMO-OTFS通信系统中的动态时延-多普勒-角度域信道跟踪”, IEEE无线通信汇刊, 2025年。[30] M. Biagi、A. Petroni、F. Campagnaro 和 M. Zorzi, “不可见光通信：利用紫外线实现鲁棒高速水下通信”, IEEE无线通信, 2025年。[31] S. Willhammar、H. Iimori、J. Vieira、L. Sundstr¨om、F. Tufvesson 和 E. G. Larsson, “借助中继辅助蜂窝大规模MIMO实现分布式MIMO性能”, IEEE通信杂志, 第63卷, 第3期, 第114–119页, 2025年。[32] L. X. Nguyen、S. S. Hassan、Y. K. Tun、K. Kim、Z. Han 和 C. S. Hong, “语义通信赋能的6G非地面网络框架：一种新型去噪与网关跳集成机制”, IEEE无线通信汇刊, 2025年。[33] S. Wang、J. Ye、C. Chen、G. Pan 和 J. An, “保障星间传输安全：来自隐蔽性的视角”, IEEE无线通信, 第32卷, 第1期, 第221–228页, 2025年。[34] M. Gu、Y. Liu、B. He、W. Huangfu 和 K. Long, “面向峰均功率比感知的无人机赋能的感知通信一体化的RIS辅助联合波形设计”, IEEE车辆技术汇刊, 第74卷, 第7期, 第10 480–10 494页, 2025年。[35] W. Jiang、Q. Zhou、J. He、M. A. Habibi、S. Melnyk、M. El-Absi、B. Han、M. Di Renzo、H. D. Schotten、F.-L. Luo 等, “面向6G及未来的太赫兹通信与感知：综合综述”, IEEE通信调查与教程, 第26卷, 第4期, 第2326–2381页, 2024年。[36] V. Petrov、H. Guerboukha、A. Singh 和 J. M. Jornet, “面向6G及未来近场太赫兹通信物理层安全的波前跳变”, IEEE通信汇刊, 第73卷, 第2996–3012页, 2025年。[37] A. Trucco, “预测由风力涡轮机贡献主导的水下噪声频谱”, IEEE海洋工程期刊, 第49卷, 第4期, 第1675–1694页, 2024年。[38] L. Mendes、J. Silva、N. Lourenc ̧o、J. C. Vaz、R. Martins 和 F. Pas-sos, “面向第五代移动通信/6G应用的全自动综合毫米波低噪声放大器”, IEEE微波理论与技术汇刊, 2025年。[39] Z. Xiao、X. Liu、Y. Zeng、J. A. Zhang、S. Jin 和 R. Zhang, “重新思考6G波形：利用时延-多普勒对齐调制”, IEEE通信杂志, 2024年。[40] S. Ju 和 T. S. Rappaport, “142 GHz室内工厂宽带亚太赫兹无线传播的统计信道模型：面向6G工业无线网络”, IEEE无线通信汇刊, 第23卷, 第11期, 第16 316–16 331页, 2024年。[41] A. M. Seid、A. Erbad、H. N. Abishu、A. Albaseer、M. Abdallah 和 M. Guizani, “无人机赋能的医疗物联网网络中的多智能体联邦强化学习资源分配”, IEEE物联网期刊, 第10卷, 第22期, 第19 695–19 711页, 2023年。[42] X. Ke 和 K. Ho, “利用多普勒导数和多普勒频移频率进行定位”, IEEE信号处理汇刊, 第72卷, 第2890–2904页, 2024年。[43] K. Zhang、Y. Zhang、C.-X. Wang、X. Wu 和 C. Du, “太赫兹非对称大规模MIMO系统的非互易信道模型”, IEEE无线通信汇刊, 第23卷, 第7期, 第7787–7801页, 2024年。[44] I. Ghareeb 和 O. Al-Shalali, “具有广义相关性的级联Nakagami-m衰落信道统计分析”, 通信与网络期刊, 第26卷, 第1期, 第1–18页, 2024年。[45] S. Chakraborty、T. K. Rana 和 S. Das, “丘陵热带地区Ka波段的对流层闪烁”, IEEE天线与无线传播快报, 第20卷, 第7期, 第1288–1291页, 2021年。

[46] R. He、X. Zhang、Q. Cui 和 X. Tao，“关于基于正交时频空（OTFS）的低轨卫星系统的多普勒干扰分析”，*IEEE*通信选定领域期刊，第43卷，第1期，第75–89页，2025年。[47] S. Kisseleff、V. M. Baeza、H. Al-Hraishawi、K. Ntontin、W. A. Martins 和 S. Chatzinotas，“面向大规模非地面网络的大规模射频星间链路”，IEEE通信杂志，第63卷，第48–53页，2025年。[48] X. Yi、Y. Li、X. Tao、A. M. Vegni 等，“具有综合衰减损耗的IRS辅助水下光无线通信统一信道模型”，IEEE通信选定领域期刊，第43卷，第5期，第1552–1567页，2025年。[49] Y. Zhang、Q. Hu、M. Peng、Y. Liu、G. Zhang 和 T. Jiang，“相互依存的无蜂窝网络与蜂窝网络：思考无蜂窝架构在6G中的作用”，IEEE网络，第38卷，第5期，第247–254页，2023年。[50] W. Mao、Y. Lu、C.-Y. Chi、B. Ai、Z. Zhong 和 Z. Ding，“无蜂窝大规模MIMO通感一体化系统的通信感知区域”，IEEE无线通信汇刊，第23卷，第12 396–12 411页，2024年。[51] A. R. Pawar、S. Kashyap 和 S. Chouhan，“信道老化和导频污染对上行大规模多输入多输出非正交多址系统译码与功率控制策略的影响”，IEEE通信汇刊，第73卷，第1期，第103–116页，2025年。[52] T. Van Chien、H. Q. Ngo、S. Chatzinotas、M. Di Renzo 和 B. Ottersten，“空间相关信道下可重构智能表面辅助的无蜂窝大规模MIMO系统”，IEEE无线通信汇刊，第21卷，第7期，第5106–5128页，2022年。[53] W. Deng、M. Li、M.-M. Zhao、M.-J. Zhao 和 O. Simeone，“从6 GHz以下频段到毫米波的信道状态信息传输：降低开销的多用户混合波束成形”，IEEE通信选定领域期刊，第43卷，第973–987页，2025年。[54] S. C. Prabhashana、D. Van Huynh、K. Singh、H.-J. Zepernick、O. A. Dobre、H. Shin 和 T. Q. Duong，“机器学习驱动的6G天地一体化网络辅助智能自主交通资源分配”，IEEE智能交通系统汇刊，2025年。[55] Y.-F. Liu、T.-H. Chang、M. Hong、Z. Wu、A. M.-C. So、E. A. Jorswieck 和 W. Yu，“无线通信优化方法最新进展综述”，IEEE通信选定领域期刊，第42卷，第11期，第2992–3031页，2024年。[56] W. Yu 和 J. Zhao，“具有异构虚拟现实与非虚拟现实360度视频的6G无线通信优化：一种差异化强化学习方法”，IEEE无线通信汇刊，2025年。[57] P. M. Pereira、T. A. de Bairros、R. A. de Souza 和 M. D. Yacoub，“移动性、路径损耗与复合衰落：采用鲁棒自编码器的传统系统与非传统系统性能”，IEEE车辆技术汇刊，第72卷，第12期，第16 725–16 730页，2023年。[58] A. Liu、V. K. Lau 和 B. Kananian，“非凸约束随机优化的随机逐次凸近似”，IEEE信号处理汇刊，第67卷，第16期，第4189–4203页，2019年。[59] T. Van Chien、E. Bj¨ornson 和 E. G. Larsson，“节能型无小区大规模多输入多输出网络的联合功率分配与负载均衡优化”，IEEE无线通信汇刊，第19卷，第10期，第6798–6812页，2020年。[60] Z. Tang、X. Zhu、H. Zhu 和 H. Xu，“基于可重构智能表面和速率分割多址的6G多小区通信系统节能优化算法”，IEEE物联网期刊，第11卷，第2期，第2097–2108页，2023年。[61] G. Eichfelder、O. Stein 和 L. Warnow，“一种多目标混合整数凸与非凸优化求解器”，优化理论与应用期刊，第203卷，第2期，第1736–1766页，2024年。[62] M. Ahmed、S. Raza、A. A. Soofi、F. Khan、W. U. Khan、S. Z. U. Abideen、F. Xu 和 Z. Han，“有源可重构智能表面：拓展无线通信前沿——综述”，IEEE通信调查与教程，第27卷，第2期，第839–869页，2024年。[63] D. Han、J. Park、S.-H. Park 和 N. Lee，“有限前传容量云无线接入网络的稀疏联合传输”，IEEE无线通信汇刊，第21卷，第5期，第3395–3408页，2021年。[64] Y. Xiu、Y. Zhao、S. Yang、Y. Zhang、D. Niyato、H. Du 和 N. Wei，“具有不完美信道状态信息误差的近场动态超表面天线-非正交多址毫米波通信鲁棒波束成形设计”，IEEE无线通信汇刊，第24卷，第2期，第1678–1692页，2025年。[65] A. Azarbahram、O. L. López 和 M. Latva-Aho，“采用动态超表面天线和非线性能量采集器的近场无线能量传输波形优化与波束聚焦”，IEEE无线通信汇刊，第24卷，第2期，第1031–1045页，2025年。[66] D. H. Nguyen、X. T. Nguyen、S.-G. Jeong、T. Van Chien、L. Hanzo 和 W. J. Hwang，“混合量子卷积神经网络辅助的无蜂窝大规模MIMO系统导频分配”，IEEE车辆技术汇刊，第1卷，第1期，第1–6页，2025年。[67] Z. Zhu、J. Li、J. Yang 和 B. Ai，“具有有界信道状态信息误差的STAR-RIS辅助安全无线信息与能量同传系统鲁棒波束成形设计”，IEEE绿色通信与网络汇刊，第8卷，第3期，第968–977页，2024年。[68] H. Byeon、J. V. N. Ramesh、S. Gupta、M. K. Sahu、S. K. Nallamala、R. Regulagadda 和 A. Vidyarthi，“下一代优化视频编-面向6G无线通信网络的……机制”，*IEEE*通信标准杂志，2025年。[69] Z. Jia、M. Sheng、J. Li、D. Niyato 和 Z. Han，“低地球轨道卫星辅助无人机：6G空中接入网络中远程物联网的联合轨迹与数据收集”，IEEE物联网期刊，第8卷，第12期，第9814–9826页，2021年。[70] F. Kavehmadavani、V.-D. Nguyen、T. X. Vu 和 S. Chatzinotas，“利用深度强化学习增强6G开放式无线接入网中的流量引导”，IEEE无线通信汇刊，第23卷，第10期，第12 782–12 798页，2024年。[71] B. Li、L.-L. Yang、R. G. Maunder、S. Sun 和 P. Xiao，“用于多载波分时双工无蜂窝大规模MIMO系统功率分配的异构图神经网络”，IEEE无线通信汇刊，第23卷，第2期，第962–977页，2023年。[72] D. Tagliaferri、M. Mizmizi、S. Mura、F. Linsalata、D. Scazzoli、D. Badini、M. Magarini 和 U. Spagnolini，“通过双域波形叠加实现通感一体化系统”，IEEE无线通信汇刊，第23卷，第5期，第4284–4299页，2024年。[73] V.-D. Nguyen、T. X. Vu、N. T. Nguyen、D. C. Nguyen、M. Juntti、N. C. Luong、D. T. Hoang、D. N. Nguyen 和 S. Chatzinotas，“6G开放式无线接入网中的网络辅助智能流量引导：多层优化框架”，IEEE通信选定领域期刊，2023年。[74] F. E. Curtis 和 K. Scheinberg，“自适应随机优化：随机优化算法分析框架”，IEEE信号处理杂志，第37卷，第5期，第32–42页，2020年。[75] P.-Q. Huang、Y. Zhou、K. Wang 和 B.-C. Wang，“多智能反射面辅助无线通信的部署优化：自适应差分进化算法”，IEEE无线通信快报，第11卷，第5期，第942–946页，2022年。[76] Y. Qiao、Y. Niu、Z. Han、L. Xiong、N. Wang、T. Q. Quek 和 B. Ai，“混合粒子群—遗传算法下无人机辅助高速铁路系统中通感一体化和高可靠低时延通信的资源分配”，IEEE物联网期刊，2024年。[77] X. Wang、S. Wang、X. Liang、D. Zhao、J. Huang、X. Xu、B. Dai 和 Q. Miao，“深度强化学习：综述”，IEEE神经网络与学习系统汇刊，第35卷，第4期，第5064–5078页，2022年。[78] T. V. Chien、B. T. Duc、M. Mohammadi、H. Ngo 和 M. Matthaiou，“网络辅助全双工无蜂窝大规模MIMO中不可行情形的差分进化”，载于GECCO论文集，2025年，第1497–1505页。[79] D. Zhu、J. Shen、J. Hu、Z. Ouyang、G. Hu、C. Zhou、J. Zhang 和 S. Cheng，“用于农村基站部署的群组合并粒子群优化算法”，IEEE新兴计算智能主题汇刊，2025年。[80] S. Goudarzi、S. A. Soleymani、W. Wang 和 P. Xiao，“采用协作演化计算进行资源分配的无人机赋能移动边缘计算”，IEEE航空航天与电子系统汇刊，第59卷，第5期，第5134–5147页，2023年。[81] W. Qi、N. Zhang、G. Zong、S.-F. Su、H. Yan 和 R.-H. Yeh，“具有信道衰落的网络化马尔可夫跳变系统的事件触发滑模控制及其应用：遗传算法”，IEEE控制论汇刊，第53卷，第10期，第6503–6515页，2023年。[82] H. Mei、K. Yang、Q. Liu 和 K. Wang，“利用深度强化学习进行可重构智能表面辅助无人机系统的三维轨迹与相移设计”，IEEE车辆技术汇刊，第71卷，第3期，第3020–3029页，2022年。[83] D. Liu 和 O. Simeone，“无线联邦朗之万蒙特卡罗：重新利用信道噪声实现贝叶斯采样与隐私保护”，IEEE无线通信汇刊，第22卷，第5期，第2946–2961页，2022年。[84] Y. He、J. Huang、W. Li、L. Zhang、S.-W. Wong 和 Z. N. Chen，“用于优化宽带贴片天线的人工神经网络与模拟退火算法混合方法”，IEEE天线与传播汇刊，第72卷，第1期，第944–949页，2023年。[85] Z. Yu、Z. Si、X. Li、D. Wang 和 H. Song，“一种用于无人机路径规划的新型混合粒子群优化算法”，IEEE物联网期刊，第9卷，第22期，第22 547–22 558页，2022年。[86] Q. Zhang、H. Wen、Y. Liu、S. Chang 和 Z. Han，“联邦强化学习支持的联网自动驾驶车辆网络通信、感知与计算资源联合分配”，IEEE物联网期刊，第9卷，第22期，第23 224–23 240页，2022年。[87] Y. Wang、J. Zhu、H. Huang 和 F. Xiao，“无人机辅助移动边缘计算系统中轨迹规划与任务卸载的双目标蚁群优化”，IEEE移动计算汇刊，第23卷，第12期，第12 360–12 377页，2024年。[88] J. Bi、H. Yuan、S. Duanmu、M. Zhou 和 A. Abusorrah，“利用基于遗传模拟退火的粒子群优化实现移动边缘计算中的能耗优化部分计算卸载”，IEEE物联网期刊，第8卷，第5期，第3774–3785页，2020年。[89] Y. Li、Q. Zhang、H. Yao、X. Xin、Y. Zhao 和 R. Gao，“非地面网络中成本高效的服务功能链路由优化：一种新型变换器蚁群优化框架”，IEEE车辆技术汇刊，2025年。[90] M. Dehghani、Z. Montazeri、E. Trojovská 和 P. Trojovskỳ，“蜜獾优化算法：一种用于求解优化问题的新型仿生元启发式算法”，KBS，第259卷，文章编号110011，2023年。

[91] M. Yıldırım，“基于联合并行禁忌搜索算法的查找表设计和基于深度学习的正交频分复用瞄准信号检测，”*IEEE* IEEE无线通信快报，第13卷，第2期，第575–579页，2023年。[92] J. Qi、H. Zhang、X. Qi 和 M. Peng，“用于宽带抗干扰无线通信的深度强化学习跳频策略”，IEEE车辆技术汇刊，第73卷，第3期，第3568–3579页，2023年。[93] M. Sohaib、S.-W. Jeon 和 W. Yu，“移动边缘计算系统中任务卸载的混合在线—离线学习”，IEEE无线通信汇刊，第23卷，第7期，第6873–6888页，2023年。[94] D. G. S. Pivoto、F. A. de Figueiredo、C. Cavdar、G. R. de Lima Tejerina 和 L. L. Mendes，“机器学习应用于无线通信资源分配的全面综述”，IEEE通信调查与教程，2025年。[95] H. Pan、Y. Liu、G. Sun、J. Fan、S. Liang 和 C. Yuen，“存在障碍物的无人机赋能无线能量传输通信网络中的功率与三维轨迹联合优化”，IEEE通信汇刊，第71卷，第4期，第2364–2380页，2023年。[96] H. Song、B. Gu、K. Son 和 W. Choi，“通过遗传算法实现无线边缘网络中边缘计算服务器部署与用户卸载关联的联合优化”，IEEE网络科学与工程汇刊，第9卷，第4期，第2535–2548页，2022年。[97] H.-A. Tran、C.-S. Duong、T.-D. Bui、V. Tong 和 H. T. T. Binh，“Gamr：利用动态遗传算法革新软件定义网络中的多目标路由”，IEEE新兴计算智能主题汇刊，2025年。[98] T. Van Chien、N. T. A. Thu、L. Nguyen、N. Binh 和 H. Binh，“整数编码遗传算法下天地通信中的用户关联性能”，载于遗传与演化计算大会论文集（GECCO），2024年，第1373–1380页。[99] M. N. Omidvar、X. Li 和 X. Yao，“大规模黑盒全局优化的基于种群的元启发式算法综述——第一部分”，IEEE演化计算汇刊，第26卷，第5期，第802–822页，2021年。[100] N. T. Tam、T. H. K. Ly、B. T. Duc、T. H. Hung 和 H. T. T. Binh，“虚拟网络功能部署与流量路由问题”，载于2024年IEEE演化计算大会（CEC）论文集。IEEE，2024年，第01–08页。[101] W. Zheng 和 B. Doerr，“非支配排序遗传算法II（NSGA-II）的近似保证”，IEEE演化计算汇刊，2024年。[102] W. Zheng、Y. Yang、T.-X. Feng 和 H. Li，“基于微波网络理论与NSGA-III的小型化频率选择表面的系统逆向设计”，IEEE微波理论与技术汇刊，2025年。[103] B. Bandyopadhyay、P. Kuila、M. Bey 和 M. C. Govil，“量子启发式差分进化用于数字孪生赋能车联网中的新鲜度感知缓存辅助卸载”，IEEE智能车辆汇刊，2024年。[104] T. Van Chien、C. V. Le、H. T. T. Binh、H. Q. Ngo 和 S. Chatzinotas，“采用改进差分进化的RIS辅助无蜂窝大规模MIMO相移设计”，IEEE无线通信快报，第12卷，第9期，第1499–1503页，2023年。[105] M. B. Taha、C. Talhi、H. Ould-Slimane、S. Alrabaee 和 K.-K. R. Choo，“一种基于差分进化与深度学习算法的车载自组织网络多目标方法”，IEEE车辆技术汇刊，第72卷，第3期，第3035–3050页，2022年。[106] B. T. Duc、T. V. Chien、H. Q. Ngo 和 H. T. T. Binh，“平衡多个相互冲突指标的多目标信号优化：用于RIS辅助MIMO系统”，载于GECCO论文集，2025年，第915–918页。[107] Z. Liao、X. Mi、Q. Pang 和 Y. Sun，“具有变邻域的历史档案辅助小生境差分进化算法，用于多峰优化”，群体与演化计算，第76卷，文章编号101206，2023年。[108] K. Zhang、C. Shen、G. G. Yen、Z. Xu 和 J. He，“用于多峰多目标优化的两阶段双小生境进化策略”，IEEE演化计算汇刊，第25卷，第4期，第754–768页，2021年。[109] Y. Qiao、Y. Niu、Z. Han、L. Xiong、N. Wang、T. Q. Quek 和 B. Ai，“混合粒子群—遗传算法下无人机辅助高速铁路系统中通感一体化和高可靠低时延通信的资源分配”，IEEE物联网期刊，2024年。[110] S. Yang、B. Wei、L. Deng、X. Jin、M. Jiang、Y. Huang 和 F. Wang，“采用降维策略的领导者自适应粒子群优化用于特征选择”，群体与演化计算，第91卷，文章编号101743，2024年。[111] G. Yuan、B. Wang、B. Xue 和 M. Zhang，“利用基于自编码器的编码策略高效演化深度卷积神经网络的粒子群优化”，IEEE演化计算汇刊，2023年。[112] T. Qian、X.-F. Liu 和 Y. Fang，“具有优先约束的多目标多机器人任务分配协作蚁群系统”，IEEE演化计算汇刊，2024年。[113] B. Wu、X. Zuo、M. Zhou、X. Wan、X. Zhao 和 S. Yang，“一种基于多目标蚁群系统的公交路线网络调整方法”，IEEE智能交通系统汇刊，第25卷，第7期，第7878–7892页，2024年。[114] F. Zhu、Z. Shuai、Y. Lu、H. Su、R. Yu、X. Li、Q. Zhao 和 J. Shuai，“oBABC：用于二进制优化的一维二进制人工蜂群算法”，群体与演化计算，第87卷，文章编号101567，2024年。[115] F. Zhao、Z. Xu、L. Wang、N. Zhu、T. Xu 和 J. Jonrinaldi，“一种基于种群的分布式装配无等待流水车间调度问题的迭代贪心算法车间调度问题，”IEEE工业信息学汇刊，第19卷，第5期，第6692–6705页，2022年。[116] P. V. T. Dat、L. Doan和H. T. T. Binh，“Hsevo：利用大语言模型，通过多样性驱动的和声搜索和遗传算法提升自动启发式设计水平”，载于AAAI会议论文集，第39卷，第25期，2025年，第26 931–26 938页。[117] S. A. EL-Meadawy、P. Zhu和H. S. Khallaf，“多层非规则RIS辅助无线通信系统的性能优化”，IEEE物联网期刊，2024年。[118] S.-G. Jeong、P. D. A. Duc、Q. V. Do、D.-I. Noh、N. X. Tung、T. Van Chien、Q.-V. Pham、M. Hasegawa、H. Sekiya和W.-J. Hwang，“基于量子退火的多无人机辅助无线网络和速率最大化”，IEEE物联网期刊，2025年。[119] H.-Y. Lu、S. P. Azizi和S.-C. Cheng，“DeepEigen-Tabu：深度特征值网络辅助的概率禁忌搜索，用于大规模MIMO检测”，IEEE车辆技术汇刊，第73卷，第9期，第13 292–13 308页，2024年。[120] A. S. Nandan、S. Singh、R. Kumar和N. Kumar，“一种基于可移动汇聚节点和可调感知范围、用于基于物联网的混合无线传感器网络簇头选举的优化遗传算法”，IEEE物联网期刊，第9卷，第7期，第5027–5039页，2021年。[121] F. J. Kaleibar、M. St-Hilaire和M. Barati，“一种面向SLA感知服务配置的定制遗传算法，适用于无基础设施车联网云网络”，IEEE服务计算汇刊，2025年。[122] Y. He、J. Huang、W. Li、L. Zhang、S.-W. Wong和Z. N. Chen，“用于宽带贴片天线优化的人工神经网络与模拟退火算法混合方法”，IEEE天线与传播汇刊，第72卷，第1期，第944–949页，2023年。[123] N. Naderializadeh、J. J. Sydir、M. Simsek和H. Nikopour，“通过多智能体深度强化学习实现无线网络资源管理”，IEEE无线通信汇刊，第20卷，2021年，第3523页，第6期，第3507页。[124] C. Wang、Z. Cao、Y. Wu、L. Teng和G. Wu，“用于求解带回程取货的车辆路径问题的深度强化学习”，IEEE神经网络与学习系统汇刊，第36卷，第3期，第4779–4793页，2024年。[125] Y. Long、S. Gong、S. Sun、G. C. Lee、L. Li和D. Niyato，“李雅普诺夫引导的深度强化学习，用于无人机辅助无线网络中的语义感知AoI最小化”，IEEE无线通信汇刊，2025年。[126] Y. Guo、J. Fan、R. Zhang、B. Chang、D. W. K. Ng、D. Niyato和D. I. Kim，“采用RSMA的IRS辅助VLC MISO网络保密能量效率最大化：一种DS-PPO方法”，IEEE无线通信汇刊，2025年。[127] S. Tripathi、O. J. Pandey和R. M. Hegde，“一种采用Q学习的RIS辅助物联网网络反射元件分组优化模型”，IEEE电路与系统汇刊第二辑：简报，第70卷，2023年，第3218页，第8期，第3214页。[128] N. Sharvari、D. Das、J. Bapat和D. Das，“用于无人机辅助通信的改进型基于Q学习的多跳路由”，IEEE网络与服务管理汇刊，2024年。[129] S. Wang、X.-L. Huang、F. Hu和S. Yu，“一种基于加速Q学习、快速收敛且具有诱导性的动态频谱接入方法，适用于认知无线电网络”，IEEE车辆技术汇刊，2025年。[130] W. Ahsan、W. Yi、Y. Liu和A. Nallanathan，“一种用于上行NOMA-URLLC网络资源分配的可靠强化学习方法”，IEEE无线通信汇刊，第21卷，第8期，第5989–6002页，2022年。[131] F. Khoramnejad和M. Erol-Kantarci，“关于联合卸载与资源分配：一种双重深度Q网络方法”，IEEE认知通信与网络汇刊，第7卷，第4期，第1126–1141页，2021年。[132] H. Zhao、W. Sun、Y. Ni、W. Xia、G. Gui和C. Zhu，“基于深度确定性策略梯度的RIS-UAV辅助车联网速率最大化”，IEEE智能交通系统汇刊，2024年。[133] I. Ahmad、R. Narmeen、H. Tabassum和Z. Becvar，“面向车联网中无人机搭载RIS的基于智能定位的深度确定性策略梯度”，IEEE车辆技术汇刊，2025年。[134] X. Han、Z. Li和Z. Xie，“面向第五代移动通信及以后系统的LEO卫星通信系统的两步随机接入优化：一种基于TD3的MsgA信道分配策略”，IEEE通信快报，第27卷，第6期，第1570–1574页，2023年。[135] A. A. Puspitasari和B. M. Lee，“基于TD3算法、采用UAV-RIS辅助的MIMO通信SWIPT”，IEEE车辆技术汇刊，2024年。[136] S. Shen、X. Hao、Z. Gao、G. Wu、Y. Shen、H. Zhang、Q. Cao和S. Yu，“SAC-PP：联合优化隐私保护与移动边缘计算中的计算卸载”，IEEE网络与服务管理汇刊，2024年。[137] F. D. Tilahun、A. T. Abebe和C. G. Kang，“面向无蜂窝大规模MIMO赋能的移动边缘计算网络中分布式资源分配的多智能体强化学习”，IEEE车辆技术汇刊，第72卷，第12期，第16 454–16 468页，2023年。[138] Z. Chen、W. Wang、W. Zhang、T. Wan和L. Liu，“毫米波多用户大规模MIMO的混合极化波束成形优化

通信系统”，*IEEE*车辆技术汇刊，第74卷，第7期，第11 055–11 065，2025年。

[139] W. Li和M. Assaad，“信息交换量较低的网络中的分布式随机优化”，IEEE信息论汇刊，第67卷，第5期，第2989–3008页，2021年。[140] A. Ghasemi和H. De Meer，“相互依存的电网与通信网络抵御级联故障的鲁棒性”，IEEE网络科学与工程汇刊，第10卷，第4期，第1919–1930页，2023年。[141] Y. Zhou、L. Lei、X. Zhao、L. You、Y. Sun和S. Chatzinotas，“基于分解与元深度强化学习的6G卫星系统异步联邦学习多目标优化”，IEEE通信选定领域期刊，第42卷，第5期，第1115–1129页，2024年。[142] T. Bozkus和U. Mitra，“利用数字表亲在大规模无线网络中实现集成Q学习”，IEEE信号处理汇刊，第72卷，第1114–1129页，2024年。[143] H. Q. Ali、A. B. Darabi和S. Coleri，“基于优化理论的深度强化学习，用于超可靠无线网络化控制系统中的资源分配”，IEEE通信汇刊，第72卷，第8期，第4774–4787页，2024年。[144] W. Wang和A. Leshem，“毫米波网络中用于能效功率分配与波束成形的非凸广义纳什博弈”，IEEE信号处理汇刊，第70卷，第3193–3205页，2022年。[145] M. Chen、A. Liu、N. N. Xiong、Y. Ren和H. H. Song，“ANNS：面向IRS辅助下一代移动通信网络的智能先进非凸非光滑方案”，IEEE移动计算汇刊，2025年。[146] J. B. Perazzone、S. Wang、M. Ji和K. Chan，“利用李雅普诺夫优化实现联邦学习的通信高效设备调度”，IEEE网络汇刊，2025年。[147] L. Lei、Y. Yuan、Y. Zhou、Y. Yang、Y. Luo、L. Pu和S. Chatzinotas，“无线边缘系统中高效联邦学习的能量优化与轻量化设计”，IEEE车辆技术汇刊，第73卷，第9期，第13 542–13 557页，2024年。[148] Y. Zhou、L. Feng、X. Jiang、W. Li和F. Zhou，“用于衔接混合时间敏感与实时服务的可预测无线网络化调度”，IEEE通信汇刊，第72卷，第6期，第3664–3680页，2024年。[149] Z. Zhang、H. Chen、F. Jiang、Y. Yang和Q. S. Cheng，“基于K均值的多群体差分进化优化框架，用于带去耦元件的MIMO天线设计”，IEEE天线与无线传播快报，第21卷，第10期，第1980–1984页，2022年。[150] X. Yuan、F. Tang、M. Zhao和N. Kato，“面向6G空天地一体化网络太赫兹/射频多频段通信的速率与覆盖联合优化”，IEEE无线通信汇刊，第23卷，第6期，第6669–6682页，2023年。[151] Y. Yin、M. Liu、G. Gui、H. Gacanin和H. Sari，“无人机辅助缓存网络中MIMO-NOMA资源分配的时延最小化”，IEEE车辆技术汇刊，第72卷，第4期，第4728–4732页，2023年。[152] S. Kurma、M. Katwe、K. Singh、T. Q. Duong和C.-P. Li，“RIS辅助FD-MIMO系统中的频谱能效资源分配”，IEEE无线通信汇刊，第23卷，第5期，第5125–5141页，2024年。[153] M.-H. T. Nguyen、T. T. Bui、L. D. Nguyen、E. Garcia-Palacios、H.-J. Zepernick、H. Shin和T. Q. Duong，“面向6G卫星-无人机-地面网络的实时优化聚类与缓存”，IEEE智能交通系统汇刊，第25卷，第3期，第3009–3019页，2023年。[154] R. Hou、J. Fu、M. Dong、K. Ota和D. Zeng，“水下声传感器网络中一种基于粒子群优化的非均匀聚类方法”，IEEE物联网期刊，第9卷，第24期，第25 027–25 036页，2022年。[155] Z. Li、W. Ge、J. Yin、L. Wei和Q. Liu，“一种基于定向接收TDMA协议的水下声学网络多目标优化算法”，IEEE传感器期刊，第24卷，2024年，第26 769页，第16期，第26 755页。[156] R. Tang、R. Zhang、Y. Xu、C. Liu、C. Huang和C. Yuen，“部分频谱共享条件下水下声传感器网络的资源分配：当优化遇上深度强化学习”，IEEE网络与服务管理汇刊，第22卷，第3期，第2715–2730页，2025年。[157] K. Zhi、C. Pan、H. Ren和K. Wang，“具有统计信道状态信息的RIS辅助大规模MIMO系统功率缩放定律分析与相移优化”，IEEE通信汇刊，第70卷，2022年，第3574页，第5期，第3558页。[158] I. Yildirim、A. Koc、E. Basar和T. Le-Ngoc，“毫米波大规模MIMO系统中RIS辅助的基于角度的混合波束成形设计”，载于GLOBECOM会议论文集，2022年。[159] T. V. Chien、N. H. Viet、S. Chatzinotas和L. Hanzo，“改进差分进化，以提升RIS辅助无蜂窝大规模MIMO的聚合信道估计性能”，IEEE车辆技术汇刊，第1–6页，2025年。[160] Z. Guo、F. Tang、X. Chen、L. Luo和M. Zhao，“基于深度强化学习的卫星-地面辅助空中通信内容缓存”，IEEE物联网期刊，第11卷，第12期，第22 779–22 789页，2024年。[161] Y. Song、J. Ou、P. N. Suganthan、W. Pedrycz、Q. Yang和L. Xing，“用于地球电磁卫星的自适应遗传算法学习调度”，*IEEE*航空航天与电子系统汇刊，第59卷，第6期，第9010–9025，2023年。

[162] X. Li、H. Zhang、H. Zhou、N. Wang、K. Long、S. Al-Rubaye 和 G. K. Karagiannidis，《面向天地一体化网络资源分配与缓存设计的多智能体深度强化学习》，IEEE无线通信汇刊，第22卷，第8期，5031–5042页，2023年。[163] Z. Zhang、Q. Chang、S. Yang 和 J. Xing，《基于强化学习的车载链路感知通信带宽分配》，IEEE Wireless Commun. Lett.，第12卷，第1期，11–15页，2023年。[164] C. Liu、M. Xia、J. Zhao、H. Li 和 Y. Gong，《物联网中一体化感知与通信的最优资源分配：一种深度强化学习方法》，IEEE车辆技术汇刊，第74卷，第2期，3028–3038页，2025年。[165] Y. Qiao、Y. Niu、Z. Han、L. Xiong、N. Wang、T. Q. S. Quek 和 B. Ai，《采用混合粒子群—遗传算法的无人机辅助高速铁路系统通感一体化与高可靠低时延通信资源分配》，IEEE物联网期刊，第12卷，第6期，6790–6804页，2025年。[166] P. Wang、K. Li、B. Xiao 和 K. Li，《移动边缘计算中任务卸载、功率分配与资源分配联合优化的多目标优化》，IEEE Internet Things J.，第9卷，2021年，第14期，11 737–11 748页。[167] S. Han、L. Li、X. Li、Z. Liu、L. Yan 和 T. Zhang，《面向时变能量采集驱动水下声传感器网络的联合中继选择与功率分配：一种分层强化学习方法》，IEEE传感器期刊，第22卷，第20期，20 063–20 072页，2022年。[168] F. Khoramnejad 和 E. Hossain，《生成式人工智能在下一代无线网络优化中的应用：基础、最先进水平与开放挑战》，IEEE通信调查与教程，第27卷，2025年，第6期，3483–3525页。[169] T.-H. Vu、S. Kumar Jagatheesaperumal、M.-D. Nguyen、N. Van Huynh、S. Kim 和 Q.-V. Pham，《生成式人工智能（GAI）在移动与无线网络中的应用：综述》，IEEE物联网期刊，第12卷，第2期，1266–1290页，2025年。[170] F. Hamidi-Sepehr、M. Sajadieh、S. Panteleev、T. Islam、I. Karls、D. Chatterjee 和 J. Ansari，《5G超可靠低时延通信：面向工业自动化的高性能无线网络演进》，IEEE Commun. Stand. Mag.，第5卷，第2期，132–140页，2021年。[171] S. Duan、D. Wang、J. Ren、F. Lyu、Y. Zhang、H. Wu 和 X. Shen，《端-边-云计算赋能的分布式人工智能：综述》，IEEE通信调查与教程，第25卷，第1期，591–624页，2022年。[172] X. Liu、S. Gao、B. Liu、X. Cheng 和 L. Yang，《LLM4WM：将大语言模型应用于无线多任务处理》，IEEE Trans. Mach. Learn. Commun. Netw.，第1–1页，2025年。[173] J. Wen、J. Kang、D. Niyato、Y. Zhang、J. Wang、B. Sikdar 和 P. Zhang，《生成式人工智能在无线网络数据增强中的应用：分析、应用与案例研究》，IEEE Wirel. Commun.，第1–10页，2025年。[174] H. Zhou、C. Hu、Y. Yuan、Y. Cui、Y. Jin、C. Chen、H. Wu、D. Yuan、L. Jiang、D. Wu 等，《电信领域的大语言模型（LLM）：原理、关键技术与机遇的全面综述》，IEEE通信调查与教程，第27卷，第3期，1955–2005页，2024年。[175] E. Coronado、R. Behravesh、T. Subramanya、A. Fernàndez-Fernàndez、M. S. Siddiqui、X. Costa-Pérez 和 R. Riggio，《零接触管理：第五代移动通信和6G网络自动化解决方案综述》，IEEE通信调查与教程，第24卷，第4期，2535–2578页，2022年。[176] J.-Y. Li、K.-J. Du、Z.-H. Zhan、H. Wang 和 J. Zhang，《采用自适应资源分配的分布式差分进化》，IEEE Trans. Cybern.，第53卷，第5期，2791–2804页，2023年。[177] H. Zhou、K. Jiang、S. He、G. Min 和 J. Wu，《面向车联网协作式边缘缓存的分布式深度多智能体强化学习》，IEEE无线通信汇刊，第22卷，2023年，第12期，9595–9609页。[178] O. Urmonov、H. Aliev 和 H. Kim，《用于提升车载网络分布式资源分配的多智能体深度强化学习》，IEEE Syst. J.，第17卷，第1期，491–502页，2023年。[179] Y. Xu、L. Zheng、X. Wu、Y. Tang、W. Liu 和 D. Sun，《基于均值场多智能体强化学习的无人机辅助车联网通信联合资源分配》，IEEE车辆技术汇刊，2024年。[180] Y. Zhu、H. Zhou、R. Su、P. Zhuang 和 L. Bai，《群体智能增强推理：一种面向基于大语言模型的多智能体优化的密度驱动框架》，2025年。 [在线]。可访问：https://arxiv.org/abs/2505 17115 。[181] C. Jimenez-Romero、A. Yegenoglu 和 C. Blum，《大语言模型赋能的多智能体系统：群体智能中的应用》，Front. Artif. Intell.，第8卷，1–23页，2025年。[182] X. Wu、S.-H. Wu、J. Wu、L. Feng 和 K. C. Tan，《大语言模型时代的进化计算：综述与路线图》，IEEE Trans. Evol. Comput.，第29卷，第2期，534–554页，2025年。[183] S. Liu、C. Chen、X. Qu、K. Tang 和 Y.-S. Ong，《作为进化优化器的大语言模型》，载于《2024年IEEE进化计算大会（CEC）论文集》，2024年，1–8页。[184] H. Tian、X. Han、G. Wu、A. Guo、Y. Zhou、J. Zhang、S. Li、J. Wei 和 T. Zhang，《一种由大语言模型赋能的自适应进化算法，用于

多组分深度学习系统”，载于*AAAI*会议论文集，第39卷，第19期，2025年4月，第20 894–20902页。

[185] F. Lotfi、H. Rajoli 和 F. Afghah，《用于动态开放式无线接入网网络切片的提示调优LLM增强型深度强化学习》，2025年。 [在线]。可访问：https://arxiv.org/abs/2506 00574 。

[186] Y. Chen、R. Li、X. Yu、Z. Zhao 和 H. Zhang，《边缘计算中无线大语言模型推理的自适应层拆分：一种基于模型的强化学习方法》，2024年。 [在线]。可访问：https://arxiv.org/abs/2406 02616 。

[187] N. Van Huynh、J. Wang、H. Du、D. T. Hoang、D. Niyato、D. N. Nguyen、D. I. Kim 和 K. B. Letaief，《生成式人工智能在物理层通信中的应用：综述》，IEEE Trans. Cogn. Commun. Netw.，第10卷，第3期，706–728页，2024年。

[188] Y. Liu、H. Du、D. Niyato、J. Kang、Z. Xiong、D. I. Kim 和 A. Jamalipour，《深度生成模型及其在高效无线网络管理中的应用：教程与案例研究》，IEEE Wirel. Commun.，第31卷，第4期，199–207页，2024年。

[189] S. Zhang、Y. Xue、Z. Tang、H. Wang、C. Shen、Q. Shi 和 T.-H. Chang，《基于深度生成模型与随机优化的鲁棒网络优化》，IEEE无线通信汇刊，第24卷，第7期，6069–6084页，2025年。

[190] T. Liu、N. Astorga、N. Seedat 和 M. van der Schaar，《利用大语言模型增强贝叶斯优化》，载于ICLR论文集，2024年。[在线]。可访问：https://openreview.net/forum?id=OOxotBmGol

[191] M. Conforth 和 Y. Meng，《利用群体智能对神经网络进行强化学习》，载于《2008年IEEE群体智能研讨会》，2008年，1–7页。

[192] M. Farzanullah、H. V. Vu 和 T. Le-Ngoc，《工厂自动化中用于联合用户关联与资源分配的深度强化学习》，载于《IEEE无线通信与网络会议2022论文集》，2022年，2059–2064页。

[193] S. Gong、M. Wang、B. Gu、W. Zhang、D. T. Hoang 和 D. Niyato，《贝叶斯优化增强的深度强化学习：用于多无人机网络中的轨迹规划与网络构建》，IEEE车辆技术汇刊，第72卷，第8期，10 933–10 948页，2023年。

[194] S. Liu、P.-Y. Chen、B. Kailkhura、G. Zhang、A. O. Hero III 和 P. K. Varshney，《信号处理与机器学习中的零阶优化入门：原理、近期进展与应用》IEEE Signal Process. Mag.，第37卷，第5期，43–54页，2020年。

[195] A. Mukherjee、P. Goswami、Z. Yan、L. Yang 和 J. J. P. C. Rodrigues，《面向无线传感器网络的ADAI与自适应粒子群优化资源分配》，IEEE Access，第7卷，131 163–131 171页，2019年。

[196] Y. Nie、J. Zhao、F. Gao 和 F. R. Yu，《无人机辅助移动边缘计算系统中的半分布式资源管理：一种多智能体联邦强化学习方法》，IEEE车辆技术汇刊，第70卷，第12期，13 162–13 173页，2021年。

[197] M. Coccia、S. Roshani 和 M. Mosleh，《量子计算的演进：对新兴量子产业的理论与创新管理启示》，IEEE Trans. Eng. Manag.，第71卷，2024年，2270–2280页。

[198] T. Q. Duong、L. D. Nguyen、B. Narottama、J. A. Ansere、D. V. Huynh 和 H. Shin，《面向6G网络的量子启发式实时优化：机遇、挑战与未来方向》，IEEE Open J. Commun. Soc.，第3卷，1347–1359页，2022年。

[199] K. Bharti、A. Cervera-Lierta、T. H. Kyaw、T. Haug、S. Alperin-Lea、A. Anand、M. Degroote、H. Heimonen、J. S. Kottmann、T. Menke、W.-K. Mok、S. Sim、L.-C. Kwek 和 A. Aspuru-Guzik，《含噪声中等规模量子算法》，Rev. Mod. Phys.，第94卷，015004页，2022年2月。

[200] Y. Fu、M. Ding 和 C. Zhou，《将相位角编码和量子行为粒子群优化应用于无人机三维路径规划》，IEEE Trans. Syst. Man Cybern. A Syst. Hum.，第42卷，第2期，511–526页，2012年。

[201] H. M. H. Saad、R. K. Chakrabortty、S. Elsayed 和 M. J. Ryan，《用于资源受限项目调度的量子启发式遗传算法》，IEEE Access，第9卷，38 488–38 502页，2021年。

[202] S.-G. Jeong、P. D. A. Duc、Q. V. Do、D.-I. Noh、N. X. Tung、T. V. Chien、Q.-V. Pham、M. Hasegawa、H. Sekiya 和 W.-J. Hwang，《基于量子退火的多无人机辅助无线网络和速率最大化》，IEEE物联网期刊，第12卷，2025年，第12期，21 225–21 239页。

[203] Silvirianti、B. Narottama 和 S. Y. Shin，《用于无人机轨迹与资源分配联合优化的逐层量子深度强化学习》，IEEE物联网期刊，第11卷，第1期，430–443页，2024年。

[204] W. J. Ryu、J.-M. Lee 和 D.-S. Kim，《用于基于非正交多址接入的不规则重复时隙ALOHA自适应传输的多智能体量子强化学习》，IEEE Open J. Commun. Soc.，第6卷，2025年，4405–4420页。

[205] X. Wei、X. Gao、K. Ye、C.-Z. Xu 和 Y. Wang，《移动边缘计算中联合资源分配与任务卸载的量子强化学习方法》，IEEE移动计算汇刊，第24卷，第4期，2580–2593页，2025年。

[206] A. Paul、K. Singh、A. Kaushik、C.-P. Li、O. A. Dobre、M. Di Renzo 和 T. Q. Duong，“面向通感一体化系统中到达方向估计与任务卸载的量子增强深度强化学习优化”，IEEE通信选定领域期刊，第43卷，第1期，第364–381页，2025年。

[207] J. A. Ansere、E. Gyamfi、V. Sharma、H. Shin、O. A. Dobre 和 T. Q. Duong，“基于移动边缘计算的物联网系统动态资源分配的量子深度强化学习”，IEEE无线通信汇刊，第23卷，第6期，第6221–6233页，2024年。

[208] G. S. Kim、J. Chung 和 S. Park，“实现计算受限的可重复使用火箭稳定着陆：一种量子强化学习方法”，IEEE车辆技术汇刊，第73卷，12 257，2024 8，12 252第。–期。

[209] G. Seon Kim、S. Lee、I.-S. Cho、S. Park 和 J. Kim，“用于轻量级低地球轨道卫星路由的量子强化学习”，IEEE物联网期刊，第12卷，第14期，第28 986–29 004页，2025年。

[210] T. Q. Dinh、S. H. Dau、E. Lagunas、S. Chatzinotas、D. N. Nguyen 和 D. T. Hoang，“卫星通信系统复杂优化的量子退火”，IEEE物联网期刊，第12卷，第4期，第3771–3784页，2025年。

[211] L. Fan 和 Z. Han，“面向未来网络优化的量子-经典混合计算”，IEEE网络，第36卷，第5期，第72–76页，2022年。

[212] S. Kanno、J. Soda 和 J. Tokuda，“引力子引起的噪声与退相干”，《物理评论D》，第103卷，第4期，044017页，2021年。

[213] A. Kandala、A. Mezzacapo、K. Temme、M. Takita、M. Brink、J. M. Chow 和 J. M. Gambetta，“用于小分子和量子磁体的硬件高效变分量子本征求解器”，《自然》，第549卷，第7671期，第242–246页，2017年9月。

[214] N. T. Nguyen、V.-D. Nguyen、H. Van Nguyen、Q. Wu、A. T¨olli、S. Chatzinotas 和 M. Juntti，“采用有源-无源混合可重构智能表面的无人机系统公平性增强”，IEEE无线通信汇刊，第23卷，第5期，第4379–4396页，2023年。

[215] Y. Liu、W. Huangfu、H. Zhou、H. Zhang、J. Liu 和 K. Long，“蜂窝网络中无人机部署问题的公平且节能的覆盖优化”，IEEE通信汇刊，第70卷，4235，2022 6，4222第。–期。

[216] W. Huang 和 W. B. Haskell，“风险感知马尔可夫决策过程的随机逼近”，IEEE自动控制汇刊，第66卷，第3期，第1314–1320页，2020年。

[217] U. Sadana、A. Chenreddy、E. Delage、A. Forel、E. Frejinger 和 T. Vidal，“不确定条件下决策的情境优化方法综述”，《欧洲运筹学杂志》，第320卷，第2期，第271–289页，2025年。

[218] S. Pasricha、R. Ayoub、M. Kishinevsky、S. K. Mandal 和 U. Y. Ogras，“移动设备和物联网设备能源管理综述”，IEEE设计与测试，第37卷，第5期，第7–24页，2020年。

[219] C. Tang、Y. Chen、G. Chen、L. Du 和 H. Liu，“基于多智能体深度强化学习的卫星-地面融合网络动态协作频谱共享策略”，IEEE车辆技术汇刊，第74卷，第5期，第7969–7984页，2025年。

[220] J. Sun、X. Liu、T. B¨ack 和 Z. Xu，“通过策略梯度从优化经验中学习自适应差分进化算法”，IEEE进化计算汇刊，第25卷，第4期，第666–680页，2021年。

[221] Z. Fei、B. Li、S. Yang、C. Xing、H. Chen 和 L. Hanzo，“无线传感器网络多目标优化综述：指标、算法与开放问题”，IEEE通信调查与教程，第19卷，第1期，第550–586页，2016年。

[222] Y. Teng、M. Liu、F. R. Yu、V. C. Leung、M. Song 和 Y. Zhang，“超密集网络资源分配：综述、若干研究问题与挑战”，IEEE通信调查与教程，第21卷，2168，2018 3，2134第。–期。

[223] M. M. H. Shuvo、S. K. Islam、J. Cheng 和 B. I. Morshed，“资源受限的边缘设备上深度学习推理的高效加速：综述”，《IEEE会刊》，第111卷，第1期，第42–91页，2023年。

[224] Y.-X. Xing、J.-S. Wang、S.-H. Zhang、S.-W. Zhang、Y.-H. Zhang 和 X.-F. Sui，“基于密度排序与柱面网格机制的无线传感器网络布局优化多目标转运算法”，《网络与计算机应用杂志》，104217页，2025年。

[225] R. Chaudhry 和 N. Kumar，“软件定义无线传感器网络绿色计算的多目标元启发式解法”，IEEE绿色通信与网络汇刊，第6卷，第2期，第1231–1241页，2021年。

[226] S. K. Goudos、P. D. Diamantoulakis 和 G. K. Karagiannidis，“大规模多输入多输出第五代移动通信无线网络中的多目标优化”，IEEE通信快报，第22卷，第11期，第2346–2349页，2018年。